



HAL
open science

**ANR HYEP ANR 14-CE22-0016-01 Hyperspectral
imagery for Environmental urban Planning Hyep
Programme Mobilité et systèmes urbains 2014**

Christiane Weber, Thomas Houet, Sebastien Gadai, Rahim Aguejdad,
Grzegorz Skupinski, Aziz Serradj, Yannick Deville, Jocelyn Chanussot, Mauro
Dalla Mura, Xavier Briottet, et al.

► **To cite this version:**

Christiane Weber, Thomas Houet, Sebastien Gadai, Rahim Aguejdad, Grzegorz Skupinski, et al..
ANR HYEP ANR 14-CE22-0016-01 Hyperspectral imagery for Environmental urban Planning Hyep
Programme Mobilité et systèmes urbains 2014. [Rapport de recherche] CNRS UMR TETIS, ESPACE,
LETG; ONERA; GIPSA-lab; IRAP; IGN. 2018. hal-01888126

HAL Id: hal-01888126

<https://hal.science/hal-01888126>

Submitted on 24 Oct 2018

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

ANR HYEP ANR 14-CE22-0016-01

Hyperspectral imagery for Environmental urban Planning

Hyep

Programme Mobilité et systèmes urbains 2014

A	IDENTIFICATION	2
B	RESUME CONSOLIDE PUBLIC	2
	B.1 Instructions pour les résumés consolidés publics	2
	B.2 Résumé consolidé public en français	3
	B.3 Résumé consolidé public en anglais.....	4
C	MEMOIRE SCIENTIFIQUE	5
	C.1 Résumé du mémoire	5
	C.2 Enjeux et problématique, état de l'art	5
	C.3 Approche scientifique et technique.....	8
	C.4 Résultats obtenus	11
	C.5 Exploitation des résultats.....	12
	C.6 Discussion	12
	C.7 Conclusions.....	14
	C.8 Références.....	15
D	LISTE DES LIVRABLES	16
E	IMPACT DU PROJET	16
	E.1 Indicateurs d'impact	16
	E.2 Liste des publications et communications.....	17
	E.3 Liste des éléments de valorisation.....	23
	E.4 Bilan et suivi des personnels recrutés en CDD (hors stagiaires)	24

Ce document est à remplir par le coordinateur en collaboration avec les partenaires du projet. L'ensemble des partenaires doit avoir une copie de la version transmise à l'ANR.

Ce modèle doit être utilisé uniquement pour le compte-rendu de fin de projet.

A IDENTIFICATION

Acronyme du projet	HYEP
Titre du projet	Hyperspectral imagery for Environmental urban Planning
Coordinateur du projet (société/organisme)	Christiane Weber
Période du projet (date de début – date de fin)	2014 (octobre) – 2018 (septembre)
Site web du projet, le cas échéant	http://hyep.cnrs.fr/

Rédacteur de ce rapport	
Civilité, prénom, nom	Mme Weber Christiane
Téléphone	
Adresse électronique	Christiane.weber@cnrs.fr
Date de rédaction	Juillet 2018

Si différent du rédacteur, indiquer un contact pour le projet	
Civilité, prénom, nom	
Téléphone	
Adresse électronique	

Liste des partenaires présents à la fin du projet (société/organisme et responsable scientifique)	UMR CNRS : LETG : Thomas HOUET ; ESPACE : Sébastien GADAL TETIS : Christiane Weber, Rahim Aguejdad LIVE : Grzegorz SKUPINSKI et Aziz SERRADJ IRAP Toulouse : Yannick Deville Gipsa-Lab Grenoble : Jocelyn CHANUSSOT, Mauro DALLA MURA ONERA : Xavier BRIOTTET IGN LASTIG: Clément MALLET, Arnaud Le BRIS
---	---

B RESUME CONSOLIDE PUBLIC

B.1 INSTRUCTIONS POUR LES RESUMES CONSOLIDES PUBLICS

Les deux premiers paragraphes sont précédés d'un titre spécifique au projet rédigé par vos soins.

Titre 1 : situe l'objectif général du projet et sa problématique (150 caractères max espaces compris)

Enjeux et Objectifs du projet 1513 char

Paragraphe 1 : (environ 1200 caractères espaces compris)

Le paragraphe 1 précise les enjeux et objectifs du projet : indiquez le contexte, l'objectif général, les problèmes traités, les solutions recherchées, les perspectives et les retombées au niveau technique ou/et sociétal

Titre 2 : précise les méthodes ou technologies utilisées (150 caractères max espaces compris)

Paragraphe 2 : (environ 1200 caractères espaces compris)

Le paragraphe 2 indique comment les résultats attendus sont obtenus grâce à certaines méthodes ou/et technologies. Les technologies utilisées ou/et les méthodes permettant de surmonter les verrous sont explicitées (il faut éviter le jargon scientifique, les acronymes ou les abréviations).

Résultats majeurs du projet (environ 600 caractères espaces compris)

Faits marquants diffusables en direction du grand public, expliciter les applications ou/et les usages rendus possibles, quelles sont les pistes de recherche ou/et de développement originales, éventuellement non prévues au départ.

Préciser aussi toute autre retombée= partenariats internationaux, nouveaux débouchés, nouveaux contrats, start-up, synergies de recherche, pôles de compétitivités, etc.

Production scientifique et brevets depuis le début du projet (environ 500 caractères espaces compris)

Ne pas mettre une simple liste mais faire quelques commentaires. Vous pouvez aussi indiquer les actions de normalisation

Illustration

Une illustration avec un schéma, graphique ou photo et une brève légende. L'illustration doit être clairement lisible à une taille d'environ 6cm de large et 5cm de hauteur. Prévoir une résolution suffisante pour l'impression. Envoyer seulement des illustrations dont vous détenez les droits.

B.2 RESUME CONSOLIDE PUBLIC EN FRANÇAIS

Titre : Hyperspectral imagery for Environmental urban Planning

Enjeux et objectifs

L'imagerie hyperspectrale (IH) est à l'heure actuelle encore trop peu considérée, pourtant ses spécificités en font un auxiliaire de poids pour le suivi des éléments du milieu urbain. Le projet HYPE a pour objectif de proposer un panel de méthodes et de **traitements** appliqués à l'imagerie hyperspectrale tout en comparant à celles d'autres capteurs existants. Si l'IH est complémentaire aux capteurs actuels car plus riche spectralement, elle permet d'identifier et de caractériser autrement les éléments naturels ou anthropiques. Pour ce faire les méthodes d'extraction d'information doivent être adaptées, voire créées. Le volet méthodologique du projet est ancré à la fois dans la solidification des approches actuelles et le test de méthodes ou adaptées ou nouvelles. Nos résultats ont été présentés tout au long du projet à la communauté scientifique et aux collectivités territoriales. Un des intérêts des travaux a été la comparaison des résultats à différentes résolutions spatiales pour préciser le gain d'un tel capteur hyperspectral par rapport à ceux existants ou à venir.

Données et Méthodes : Utilisation et adaptation de méthodes courantes en télédétection 1200

Les méthodes déployées ont été choisies parmi l'ensemble des méthodes existantes en les adaptant au type de signal, au nombre de bandes spectrales et aux caractéristiques du milieu. Ainsi les données étant issues de survol aérien les premiers développements ont été réalisés pour s'affranchir des effets de l'atmosphère (correction atmosphérique des images hyperspectrales– 3 méthodes testées) et une base de données de signatures morphospectrales pour divers éléments d'occupation du sol en ville (toits, routes, la végétation etc.) permettant de mieux cerner les valeurs spectrales des matériaux a été établie. Elle comprend des données de littérature, des mesures in situ et en laboratoire. Ses apports dans différents traitements de classification ont été testés. Des méthodes d'extraction, de fusion ou de classification ont été utilisées à différentes résolutions spatiales et spectrales afin de spécifier les gains par rapport à d'autres capteurs. Des méthodes de classifications et de démixage ont été adaptées. Des indices de forme facilitant la classification d'image en milieux urbain ont été testés et/ou développés.

Résultats majeurs et faits marquant

- 3 méthodes de correction atmosphériques développées et comparées en fonction de la résolution spatiale ;
- Adaptation de méthodes de fusion (pan ou multi sharpening) et de démixage.
- Transfert : Mise en place à Kaunas (Lituanie) du développement complet de l'approche.
- Algorithmes : Dépôt sur la plateforme ouverte : <http://openremotesensing.net/> et des outils de fusion PAN-hyperspectrale
- Un résultat particulièrement intéressant porte sur l'extraction et l'identification des panneaux solaires. Une validation a été réalisée par le calcul des surfaces des panneaux. Ce développement est une des réussites du projet HYPE.
- Ecole thématique CNRS en 2017.

Productions scientifiques

Présentation des travaux à ISPRS GeospatialWeek 2015, JURSE 2017, IGARSS 2017-2018, WHISPERS 2016-2018, GeoHyper (2015), aux ateliers TEMU, AFIGEO, dans des sessions de GDRs (Madics et ISIS) ou dans le cadre de la mission Hypxim. Elle a organisé des sessions de conférences nationales SFPT hyperspectral (2016) et 2 à l'international en 2018 IGARSS, WHISPERS. Elle a monté une école thématique CNRS (28 Août - 1 Septembre 2017- 25 participants). 10 publications et 38 communications avec actes, 3 chapitres de livre, 1 numéro spécial dans la revue « Remote Sensing - Hyperspectral Imagery for Urban Environment » ont été produites.

Coordination & contact: Christiane Weber; christiane.weber@cnrs.fr

Participants :

UMR TETIS/ LIVE: C Weber, R Aguejdad

A Serradj, G Skupinski

ONERA: X Briottet, S Fabre, V Achard

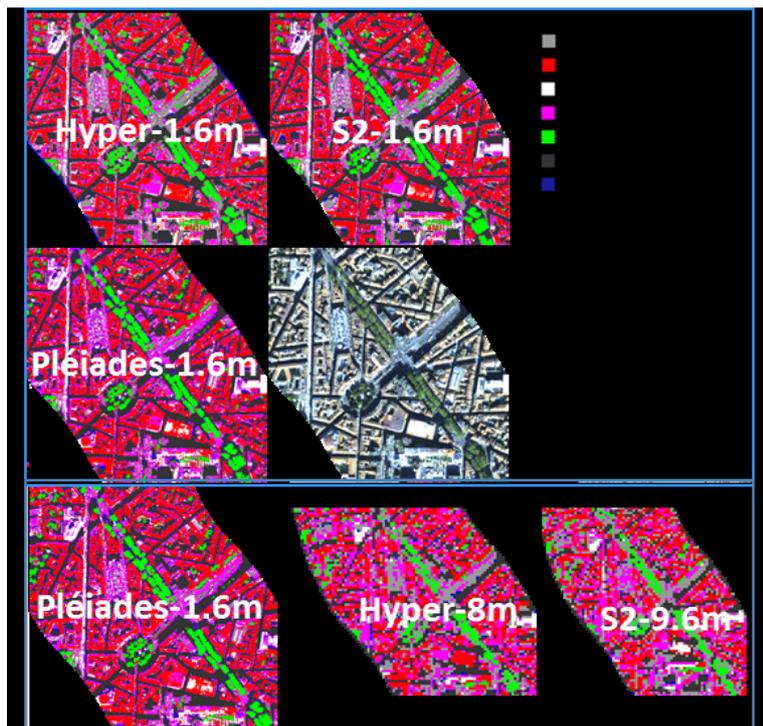
UMR LETG T Houet

IGN Lastig: C Mallet, A Le Bris, N Chehata

UMR ESPACE: S Gadal, W Ouerghemmi

UMR GIPSA : J Chanussot ; M Dalla Mura

UMR IRAP : Y Deville, M. S. Karoui, F Benhalouche



Comparaison des performances de classification supervisée (SVM) entre : HYPXIM Sentinel-2 et Pléiades (1) à la même résolution spatiale de 1,6 m afin de confirmer l'apport de la richesse spectrale, (2) à leur résolution respective avec leurs résolutions nominales, Pléiades (1,6 m) et HYPXIM (8 m) présentent des performances similaires.,. Pour Sentinel-2 (9.6 m) les performances de classification sont plus faibles.

Informations factuelles

L'ANR HYPE est un projet de recherche fondamental et exploratoire. La coordination a été assurée par C. Weber (UMR TETIS) avec l'appui de S. Gadal (UMR ESPACE), C. Mallet (IGN) et X. Briottet (ONERA) pour la coordination des WP. Le démarrage effectif a eu lieu début 2015. La durée du projet a été de 48 mois. Le soutien de l'ANR s'est élevé à 505 483,81 € HT pour un montant total de 2 382 998€.

B.3 RESUME CONSOLIDE PUBLIC EN ANGLAIS

Hyperspectral imagery for Environmental urban Planning

Objectives

The hyperspectral images (HI) is at the moment still too poorly considered; nevertheless its specificities make a weighty auxiliary for the monitoring of the elements of the urban area. The HYPE project has for objective to propose a panel of methods and processes designed for hyperspectral imaging. We take into account other existing sensors in order to compare the performances. If the IH is complementary to the sensors HRS and VHRS due to its better radiometric richness, it allows to identify and to characterize the natural or anthropogenic elements in a complementary perspective. To this end methods for the extraction of information had to be adapted, created even. The methodological part of the project articulated at the same time in the solidification of the current approaches and the design of new methods. Results have been presented along the project duration to scientific community and local authorities. One of the milestones of the works was the comparison of the results to various spatial resolutions to specify the contribution of such a hyperspectral sensor with regard to those existing or to come.

Data and data processing Methods: existing or adapted

The methods were chosen among all the existing methods by adapting them to the signal, among spectral ranges and to the characteristics of urban areas. Since data arose from airborne platforms, the first developments were realized to counter the effects of the atmosphere on the IH (atmospheric correction - 3 tested methods) and a database of spectral signatures for diverse elements of land use in town (roofs, roads, the vegetation etc.) was established. It allowed encircling better the spectral values of materials. It was set up based simultaneously on the literature, *in situ* and laboratory measurements. Its contributions in various classification processing were tested. Methods for information, extraction, pansharping or classification purposes were used for various spatial and spectral resolutions to highlight its interest towards other sensors and also its benefits for a spatial mission. Classification and unmixing methods have been adapted and spatial pattern indicators for urban areas defined.

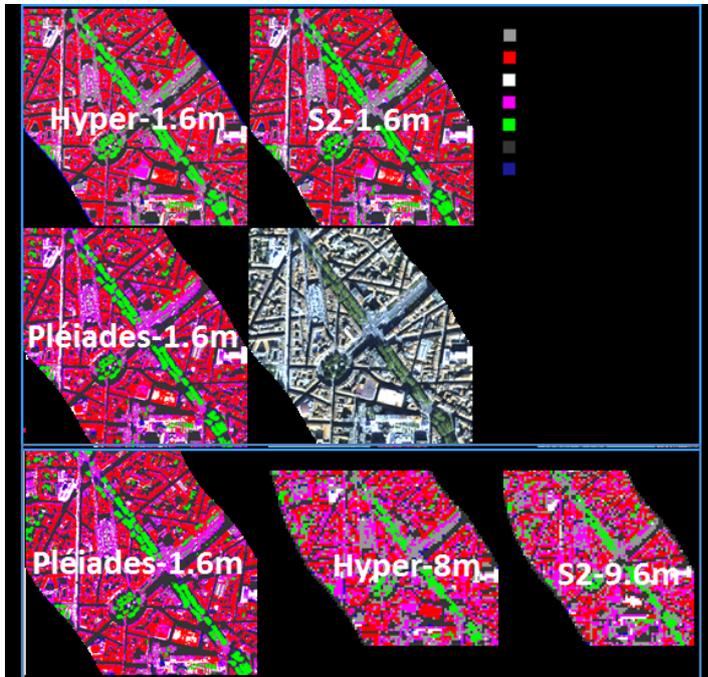
Outcomes

- 3 atmospheric correction methods have been tested; it leads to a specific code development by ONERA.
- Methods adaptation : pansharping and unmixing
- Transfer: a complete design of the study has been transferred to Kaunas (Lithuania) teams
- Algorithms: Depository on <http://openremotesensing.net/>
- One of the major results is the extraction and the identification of photovoltaic panel
- CNRS Summer school 2017

Scientific production

The team has presented at ISPRS Geospatial Week 2015, GeoHyper (2015), Jurse 2017, IGARSS 2016-2017, SFPT or workshops TEMU, AFIGEO and to GdR Session (MaDics and ISIS) or within the framework of the Hypxim mission. The team organized special conference sessions at the national level, SFPT hyperspectral (2016) and international level IGARSS 2018 and WHISPERS 2018. A thematic CNRS summer school (2017 August 28th - September 1st - 25 participants) has been set up. The project gave rise to 10 publications Rang A and 38 communications, 4 chapters and a special issue for the Remote Sensing journal.

Illustration



Comparison of the supervised classification (SVM) performances between: HYPXIM Sentinel-2 and Pleiades (1) at the same spatial resolution of 1.6 m in order to evaluate the contribution of the spectral richness, (2) to their respective resolution with their nominal resolutions, Pleiades (1.6 m) and HYPXIM (8 m) have similar performance. Sentinel-2 performances are less good.

Informations

THE ANR HYPEP is a fundamental and exploratory research project. The coordination was assured by C. Weber (UMR TETIS) with the support of S. Gadal (UMR ESPACES), C. MALLET (IGN-National Institute for Geographic and Forestry Information) and X. Briottet (ONERA). The starting up took place in 2015. The duration of the project was of 48 months. The support of the ANR rose in 505,483.81HT for a total amount of 2,382,998 €.

C MEMOIRE SCIENTIFIQUE (5 PAGES)

Mémoire scientifique confidentiel : non

C.1 RESUME DU MEMOIRE

Titre : Hyperspectral imagery for Environmental urban Planning

L'imagerie hyperspectrale (IH) est à l'heure actuelle encore trop peu considérée, pourtant ses spécificités en font un auxiliaire de poids pour le monitoring des éléments du milieu urbain. Le projet HYPEP a pour objectif de proposer un panel de méthodes et de traitements appliqués à l'imagerie hyperspectrale en tenant compte des autres capteurs existants afin d'en comparer les performances. Les images hyperspectrales sont complémentaires aux capteurs actuels car plus riche spectralement mais spatialement moins résolues. Elles permettent d'identifier et de caractériser autrement les éléments naturels ou anthropiques. Pour ce faire les méthodes d'extraction d'information doivent être adaptées, voire créées. Le volet méthodologique du projet est ancré à la fois dans la solidification des approches actuelles et le test de nouvelles méthodes. Nos résultats ont été présentés tout au long du projet à la communauté scientifique et aux collectivités territoriales. Un des intérêts des travaux a été la comparaison des résultats à différentes résolutions spatiales pour préciser le gain d'un tel capteur hyperspectral par rapport à ceux existants ou à venir.

C.2 ENJEUX ET PROBLEMATIQUE, ETAT DE L'ART

Enjeux

La population mondiale se regroupe de plus en plus dans les centres urbains modifiant aux niveaux locaux et régionaux les territoires avec l'émergence de vastes espaces urbanisés. Ces espaces sont caractérisés par des processus paradoxaux d'une part un étalement au détriment des écosystèmes naturels ou agricoles et d'autre

part une densification du tissu pouvant entraîner des effets contre intuitifs comme l'aggravation des îlots de chaleur. Ces deux processus combinés ont lourdement impacté les caractéristiques climatiques des échelles locales et régionales (Santamouris et al., 2007; Shafri et al., 2012), ainsi que les processus biotiques et abiotiques des milieux environnants (Voogt et Oke, 2003). Des besoins en information de plus en plus conséquents ont suivi cette évolution, renforcés par l'émergence de logiques de développement durable. Cette transition urbaine dans les décennies futures rassemblera près de 70% de la population mondiale ce qui va induire des effets considérables sur les ressources naturelles et agricoles. Une gestion durable de l'organisation des territoires urbains et la mobilisation d'information sur le milieu urbain sont cruciales. La ville est caractérisée par une forte dynamique interne, une très haute hétérogénéité spatiale des éléments, des formes géométriques (horizontales et verticales) et des volumes variés, une grande variété de matériaux et la présence d'ombre. Cette thématique requiert ainsi l'accès à des observables spécifiques comme les bâtiments et leur morphologie, les surfaces minérales, les friches et les surfaces en eau ou couvertes de végétation de différentes strates. La cartographie des surfaces anthropisées, l'étude de l'état de la végétation urbaine, le suivi du vieillissement des matériaux, des systèmes d'hydrologie de surface et de leur qualité, la caractérisation de la biodiversité végétale (Miller et Small, 2003) mais aussi des habitats recouvrent des champs d'investigation à enjeu(x) pour le milieu urbain.

Etat de l'art

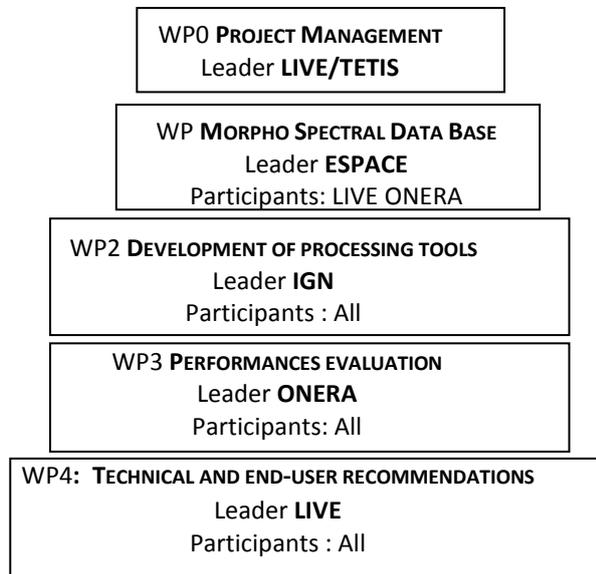
Plusieurs travaux ont montré montrant l'apport de l'imagerie hyperspectrale comparé à l'imagerie multispectrale. Platt et Goetz (2004) montrent que les performances de la classification des surfaces urbaines obtenues avec des images acquises par le spectro-imageur Aviris sont meilleures que celles obtenues avec des données multispectrales Landsat ETM+. Plus récemment, Tan et Wang (2007) évaluent le gain apporté par l'instrument hyperspectral CHRIS/PROBA sur la classification et l'utilisation des milieux urbains par rapport aux données ASTER (3 bandes VISNIR). Plusieurs auteurs (Lu, 2006 ; Bauer et al., 2003) illustrent les limitations de capteurs multi-spectraux pour la caractérisation des surfaces imperméables et évaluent l'intérêt de l'imagerie hyperspectrale. Des conclusions similaires sont déduites des travaux de Cavalli (2008) pour la classification. Les capacités hyperspectrales permettent l'identification d'observables émergents comme la pollution des sols, ou des matériaux nouveaux ou à enjeu (amiante) (Pascucci et al., 2010). Les projets de trames vertes et bleues, les corridors écologiques vont bénéficier des capacités de ces informations tant pour l'identification des espèces (indigènes ou invasives), que pour le relevé sanitaire (Gong et Howarth, 1992a ; Gong et al., 1992; Mc Kinney, 2002). La ville, par son fonctionnement et sa matrice construite, est un élément majeur de la perturbation des cycles biotiques et abiotiques de l'environnement, en ce sens le suivi de son développement est important pour l'étude des impacts anthropiques sur le milieu (Clapham, 2003 ; Arnold et Gibbons, 1996). La richesse et la complexité des matériaux et des formes des observables dans les centres urbains ou dans les périphéries requièrent des spécificités spectrales couvrant le visible jusqu'au SWIR (Short Wave Infra Red, <2,5 µm). Herold et al. (2003) a démontré que les spectromètres offrant une résolution spectrale élevée sur un domaine spectral continu permettaient de mieux identifier (par rapport aux capteurs habituels) et spatialiser des informations sur les sols, la végétation et les matériaux. La composition des matériaux (Lu, 2006 ; Pascucci et al., 2010) et de leur état (Herold et al., 2003) nécessitent des résolutions spectrales et radiométriques adaptées qu'il convient d'estimer. La taille moyenne des objets urbains se situe entre 10 et 20 m (Cutter et al., 2004 ; Small, 2001). Aussi, une résolution de 5 m ou mieux est considérée comme nécessaire pour une représentation d'objets urbains (bâtiments, routes) et de leur vieillissement (Herold et Roberts, 2005), de la végétation urbaine (Weng et Quattrochi, 2007 ; Jensen et al., 2012), ou pour la réalisation de support à la planification du territoire (Puissant et Weber, 2003, Puissant et Hirsch, 2004, Wania et Weber, 2007). Compte tenu des caractéristiques géométriques du milieu et des patrons morphologiques urbains (îlot), les capacités d'un instrument tel qu'HYPXIM¹ combinant haute résolution spectrale (imageur hyperspectral) et spatiale (imageur panchromatique) devraient permettre d'étudier des objets de taille inférieure à 5 m avec une capacité à couvrir le domaine spectral 0,4 à 2,5 µm.

Néanmoins, des verrous scientifiques devaient être levés pour (1) conforter l'intérêt de l'IH par rapport à d'autres capteurs existants ou à venir sur des thématiques d'intérêt en milieu urbain, (2) pour dépasser ce seuil de 5 m en utilisant le potentiel technologique disponible par la plateforme HYPXIM. Les travaux se sont portés sur l'influence des résolutions spatiales et spectrales de l'IH, l'évaluation des méthodes de fusion (avec de l'imagerie panchromatique (1.8 m), du (pan et multi) sharpening, de l'utilisation de la richesse spectrale afin de démanteler les pixels image constitués de plusieurs matériaux.

¹ Mission HYPXIM

Les thématiques comme l'aménagement urbain (types d'occupation du sol), la végétation (espèces, alignement etc.), la détection des panneaux solaire ou encore l'extraction de l'imperméabilisation des sols nous ont permis d'évaluer l'intérêt de l'IH.

Pour réaliser ce programme de travail, les tâches ont été distribuées entre cinq groupes de travail (WP = Working Package ; cf. diagramme ci-dessous).



Les relations entre les WP ont été soutenues. Les WP1 et 2 bien que décalés ont œuvré ensemble pour tester les résultats des bases de données ; l'évaluation des performances a conduit les WP2 et WP3 à travaillé ensemble.

Le WP4 a rassemblé l'ensemble des participants lors des réunions avec les collectivités.

Références

- Bauer, M. E., N. Heinert, and J. Doyle, 2003, Impervious Surface Mapping and Change Monitoring using Landsat Remote Sensing. Photogrammetric Engineering & Remote Sensing, January 2003
- Cavalli, R.M, Fusilli, L., Pascucci, S, Pignatti, S, Santini F. (2008) Hyperspectral sensor data capability for retrieving complex urban land cover in comparison with multispectral data: Venice City case study (Italy). Sensors 2008, 8, 3299–3320.
- Cutter M.A., Johns L.S., Lobb D.R., Williams T.L., Settle J.J., 2004, Flight experience of the Compact High Resolution Imaging Spectrometer (CHRIS), In Proc. Imaging Spectrometry, SPIE, Vol. 5159, pp. 392-405.
- Gong, P., and P. J. Howarth, 1992, Frequency-based contextual classification and grey-level vector reduction for land-use identification. Photogrammetric Engineering and Remote Sensing, 58(4):423-437.
- Gong, P., D. Marceau and P. J. Howarth, 1992, A comparison of spatial feature extraction algorithms for land-use classification with SPOT HRV data. Remote Sensing of Environment. 40:137-151
- Herold M., Liu X., Clarke K.C., 2003, Spatial metrics and image texture for mapping urban land use. Photogrammetric Engineering & Remote Sensing, 69(9), 991-1001
- Herold M., Roberts D., 2005, Spectral characteristics of asphalt road aging and deterioration: implications for remote-sensing applications, Applied Optics, 44:4327-4334.
- Lu, D.S.; Weng, Q.H., 2006, Use of impervious surface in urban land-use classification. Remote Sensing of Environment. 102, 146–160.
- Mc Kinney, 2002, Urbanization, Biodiversity, and Conservation BioScience Vol. 52 No. 10 Clapham Jr. B, W., 2003, Continuum-based classification of remotely sensed imagery to describe urban sprawl on watershed scale. Remote Sensing of Environment, 86, 322-340.
- Platt, R. V. and Goetz, A. F. H., 2004, A comparison of AVIRIS and Landsat for land use classification at the urban fringe. Photogrammetric Engineering & Remote Sensing 70, pp. 813–819
- Puissant A., Weber C., 2003, Les images à très haute résolution spatiale : une source d'information géographique en milieu urbain ? État des lieux et perspectives, L'Espace Géographique, 4:345-356, 2014,
- Puissant A., Hirsch J., 2004, Télédétection urbaine et résolution spatiale optimale : intérêt pour les utilisateurs et aide pour les classifications, Revue Internationale de Géomatique, 14(3-4):403-415
- Santmouris M., Adnot J., Alvarez S., Klitsikas N., Lopes C., Orphelin M., Sanchez F., 2007, Cooling the Cities - Rafrâchir les villes. Presses Internationales Polytechniques, Montréal, 264 pp.
- Shafri H.Z.M., Taherzadeh E., Mansor S., Ashurov R., 2012, Hyperspectral remote sensing of urban areas: an overview of techniques and applications, Research Journal of
- Small C., 2001, Spectral dimensionality and scale of urban radiance, In Proc. AVIRIS Workshop, Pasadena, CA, USA11
- Tan Q. & Wang J., 2007, Hyperspectral versus multispectral satellite data for urban land cover and land use mapping – Beijing an evolving city. ASPRS
- Voogt, J.A., Oke, T.R., 2003, Thermal remote sensing of urban climates. Remote Sensing of Environment 86, 370-384
- Wania A., Weber C., 2007, Hyperspectral imagery and urban green observation, in Proc. Urban Remote Sensing Joint Event, 11-13 April 2007, pp. 1-8.
- Weng Q., Quattrocchi D.A., 2007, Urban Remote Sensing, CRC Press, 432 pp. Jensen R.R., Hardin P.J., Hardin A.J., 2012, Classification of urban tree species using hyperspectral data, Geocarto International, 27:443-458.

Evolution de l'état de l'art pendant la durée du projet

Pendant la période du projet HYPEP, l'intérêt pour l'imagerie hyperspectrale ne s'est pas démenti et s'est même consolidé. La mission Hypxim est une étude préliminaire qui a débuté en 2009 conduite et financée par le CNES. Entre 2010 et 2015 trois scénarios de mission ont été conçus avec le soutien industriel d'Airbus Defense & Space et de Thalès Alenia Space. Une étude a été mise en place pour revisiter les besoins mission pour un satellite d'Observation de la Terre. (Lefevre-Fonollosa et al. 2018). Une proposition de mission a été faite à l'appel Earth Explorer de l'ESA. Cela a permis une bonne visibilité de la communauté scientifique internationale dans le domaine de l'urbain.

Parmi les méthodes en développement, celles sur la correction atmosphérique est toujours d'actualité et l'approche proposée par HYPEP a été reconnue (Roussel et al., 2017) ; les méthodes portant sur la fusion inter-capteurs et notamment la fusion hyper et panchromatique (revue faite par L. Loncan ; (Loncan et al., 2015)) restent d'actualité ; enfin les méthodes portant sur le démélange sont les plus explorées (Ghamisi et al. a et b, 2017; Guanter et al., 2018, Mookambiga et Gomathi, 2016, Masson et al. 2018). Les approches d'apprentissage se sont aussi fortement développées (Zhang et al., 2016 ; Monidipa et al., 2016 ; Xiaorui et al. 2016 ; Mou et al. 2017 ; Ienco et al., 2017) face à la montée des données massives.

La fusion entre des données Lidar aéroportés et des images multi/hyperspectrales fait toujours l'objet de recherche (A Le Bris et al. 2018 ; Dechesne Thèse en 2017 ; Deschene et al., 2017, Aval, 2018)

La fusion de données Sentinel2 et de données hyperspectrales est une perspective intéressante notamment dans des approches de simulation (Yokooya et al. 2018 ; Qunming et al., 2016 ; ; Chongyue et al., 2018)

Les méthodes de démélange et l'impact de la résolution spatiale sur ces méthodes (Guerrero et al., 2018 ; Rebeyrol et al., 2018 ; Bioucas-Dias et al., 2012 ; Revel Thèse 2016, Chia-Hsiang, 2018) sont toujours d'actualité. Applications thématiques : le milieu forestier et la végétation en général font l'objet de nombreux développements (Le Bris et al., 2018 ; Erudel Thèse 2018 ; Aval Thèse 2018) ; le milieu urbain et notamment la détection de formes ou de panneaux solaires connaissent des développements prometteurs (Gadal, 2018 ; Karoui, 2018)

Références

- M. Das, S. K. Ghosh. *Deep-STEP: A Deep Learning Approach for Spatiotemporal Prediction of Remote Sensing Data*. IEEE Geoscience and Remote Sensing Letter, vol. 13, no. 12, pp. 1984-1988, 2016.
- S. Gadal, W. Ouerghemmi, G. Mozgeris, R. Baarlatier. *Recognition of urban vegetation by hyperspectral airborne high-resolution VNIR imager (Kaunas Lithuania)*. SFPT groupe Hyperspectral 17&18 mai 2018.
- P. Ghamisi et al. *Advances in Hyperspectral Image and Signal Processing: A Comprehensive Overview of the State of the Art*. IEEE Geoscience and Remote Sensing Magazine, vol. 5, no. 4, pp. 37-78, Dec. 2017. doi:10.1109/MGRS.2017.2762087.
- P. Ghamisi, J. Plaza, Y. Chen, J. Li, A. J. Plaza. *Advanced Spectral Classifiers for Hyperspectral Images: A review*. IEEE Geoscience and Remote Sensing Magazine, vol. 5, no. 1, pp. 8-32, March 2017. doi: 10.1109/MGRS.2016.2616418.
- Luis Guanter, M. Brell, J. C.-W. Chan, C. Giardino, J. Gomez-Dans, C. Mielke, F. Morsdorf, K. Segl, N. Yokoya. *Synergies of Spaceborne Imaging Spectroscopy with Other Remote Sensing Approaches*. Surveys in Geophysics, 2018.
- A. Guerrero, Y. Deville, S. Hosseini. *Une méthode de démélange non supervisée basée sur la corrélation non linéaire des sorties pour des mélanges bilinéaires : application au milieu urbain*. SFPT groupe Hyperspectral 17&18 mai 2018.
- D. Ienco, R. Gaetano, C. Dupaquier, P. Maurel. *Land Cover Classification via Multitemporal Spatial Data by Deep Recurrent Neural Networks*. IEEE Geoscience Remote Sensing Letters 14(10): 1685-1689, 2017.
- A. Le Bris, C. Deschesne, C. Mallet, V. Gouet-Brunet. *Segmentation sémantique de peuplements forestiers à partir d'imagerie optique et de données Lidar aéroportées : comparaison de capteurs*. SFPT groupe Hyperspectral 17&18 mai 2018.
- C.-H. Lin, F. Ma, C.-Y. Chi, C.-H. Hsieh. *A Convex Optimization-Based Coupled Nonnegative Matrix Factorization Algorithm for Hyperspectral and Multispectral Data Fusion*. IEEE Transactions on Geoscience and Remote Sensing, vol. 56, no. 3, pp. 1652-1667, 2018.
- L. Loncan et al., "Hyperspectral Pansharpening: A Review," *IEEE Geoscience and Remote Sensing Magazine*, vol. 3, no. 3, pp. 27-46, Sept. 2015.
- X. Ma, H. Wang, J. Wang. *Semisupervised classification for hyperspectral image based on multi-decision labeling and deep feature learning*. ISPRS Journal of Photogrammetry and Remote Sensing, vol. 120, pp. 99, 2016.
- T. Masson, M. Dalla Mura, M. Dumont, J. Chanussot. *Fusion de données multispectrales multicapteurs*. SFPT groupe Hyperspectral » 17&18 mai 2018
- A. Mookambiga, V. Gomathi. *Comprehensive review on fusion techniques for spatial information enhancement in hyperspectral imagery*. Multidim Syst Sign Process 27:863–889 DOI 10.1007/s11045-016-0415-2, 2016.
- L. Mou, P. Ghamisi, X. Xiang Zhu. *Deep Recurrent Neural Networks for Hyperspectral Image Classification*". IEEE Transactions on Geoscience and Remote Sensing 55(7): 3639-3655, 2017.

S. Rebeyrol, Y. Deville, V. Achard, X. Briottet, S. May. *Impact de la résolution spatiale sur des méthodes de démixage hyperspectral*. SFPT groupe Hyperspectral 17&18 mai 2018.

N. Yokoya, C. Grohnfeldt, J. Chanussot. *Hyperspectral and Multispectral Data Fusion: A comparative review of the recent literature*. IEEE Geoscience and Remote Sensing Magazine, vol. 5, no. 2, pp. 29-56, June 2017. doi: 10.1109/MGRS.2016.2637824

L. Zhang, L. Zhang, B. Du. *Deep Learning for Remote Sensing Data: A Technical Tutorial on the State of the Art*. IEEE Geoscience and Remote Sensing Magazine, vol. 4, no. 2, pp. 22-40, June 2016. doi: 10.1109/MGRS.2016.2540798.

C. Zhao, X. Gao, W. J. Emery, Y. Wang, Jie Li. *An Integrated Spatio-Spectral–Temporal Sparse Representation Method for Fusing Remote-Sensing Images With Different Resolutions*. IEEE Transactions on Geoscience and Remote Sensing, vol. 56, no. 6, pp. 3358-3370, 2018.

J. Aval, S. Fabre, X. Briottet, D. Sheeren, M. Fauvel, E. Zenou. *Object-based fusion for urban tree species classification from hyperspectral, panchromatic and nDSM data*, International Journal of Remote Sensing. Accepted 14 Sept, to be published, TRES-PAP-2018-0200.R2

C.3 APPROCHE SCIENTIFIQUE ET TECHNIQUE

Le projet HYPE a eu pour objectif de proposer un panel de méthodes et de traitements appliqués à l'imagerie hyperspectrale (IH) en tenant compte des autres capteurs existants afin d'en comparer les performances. L'IH est complémentaire aux capteurs actuels car plus riche radiométriquement, en effet elle permet d'identifier et de caractériser autrement les éléments naturels ou anthropiques) (Weber et al. 2018 ; Aguejdad et al. 2017 ; Gadal et Ouerghemmi, 2016). Cependant il est encore nécessaire (1) de consolider les connaissances des caractéristiques spectrales des milieux et plus particulièrement du milieu urbain (hétérogène et dense) et (2) de fournir des « outils » (approches, méthodes, algorithmes) qui soient utilisables par la communauté et dont les résultats soient compréhensibles par les utilisateurs.

Données : (Tableaux 1, 2, 3) Les données hyperspectrales sont issues de missions aéroportées sur Toulouse (campagne UMBRA 2012 puis 2014 et 2015 sur la même trace avec les mêmes caractéristiques techniques) et Kaunas (campagnes 2015, 2016, 2017). Les images Sentinel2, Pléiades ont été simulées à partir du capteur HySpex.

Port	Spectral range (µm)	Number of bands	Full Width at Half Maximum (nm)	GSD (m)
VNIR	0.4-1.0	160	3.6	0.8
SWIR	1.0-2.5	256	6.0	1.6

Tableau 1 : Toulouse, spécificités du capteur HySpex (<http://www.hyspex.no/>).

Port	Spectral range	Number of bands	Full Width at Half Maximum (nm)	GSD (m)
VNIR	0.5-0.9	16		0.7
VNIR	0.5-0.9	64		0.5

Tableau 2 : Kaunas, spécificités du capteur Ricola LTD Finlande.

Name	Number of bands used for classification purposes	Spectral range	GSD (m)
PLEIADES_1.6m	4	VNIR	1.6
SENTINEL2_1.6m	9	VNIR-SWIR	1.6
Hyper_1.6m	245	VNIR-SWIR	1.6
Hyper_8m	245	VNIR-SWIR	8
Hypex_2m	408	VNIR-SWIR	2
Hypxim_4m	108	VNIR-SWIR	4
Hypxim_8m	245	VNIR-SWIR	8
SENTINEL2_10m	13	VNIR-SWIR	10

Tableau 3 : Description des images simulées.

Zones d'étude

Les lignes de passage des capteurs aéroportés sont représentées Figures 1 et 2. Les revisites ont été faites en général sur les mêmes zones.

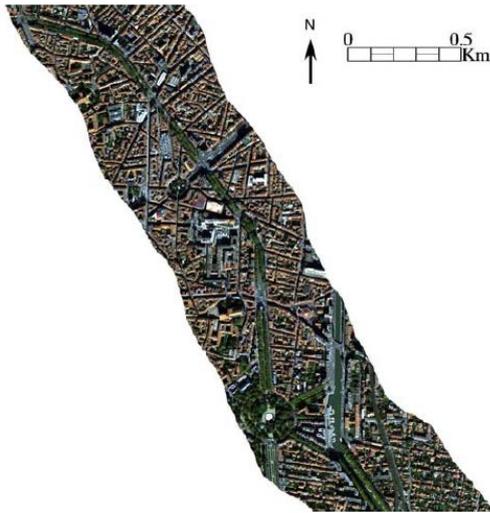


Figure 1 : Toulouse (France)

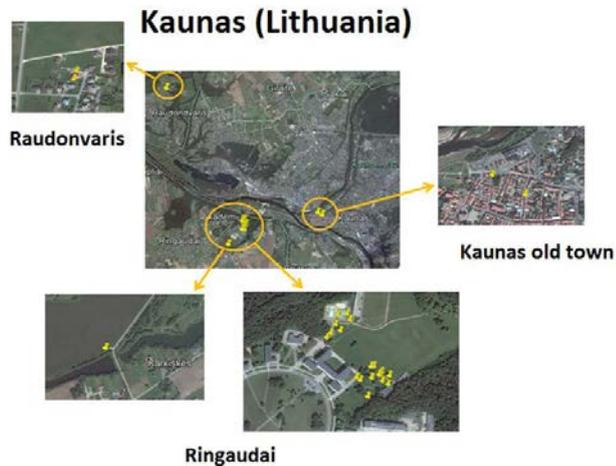


Figure 2 : Kaunas (Lituanie)

Sur le plan scientifique

Pour répondre à nos objectifs, les méthodes d'extraction d'information doivent être adaptées, voire créées. Le volet méthodologique du projet est ancré à la fois dans *la consolidation des approches actuelles* et le *test de nouvelles méthodes*.

Un approfondissement méthodologique a été nécessaire pour améliorer nos connaissances partielles à la fois sur les effets des résolutions spatiales et spectrales sur la détection et la caractérisation des observables, mais aussi sur les développements à adapter ou à faire pour l'amélioration de la résolution spatiale considérant la richesse spectrale, sur la sélection de bande ou la réduction de dimensions.

A partir des résultats obtenus par comparaisons opérées à différentes résolutions spatiales et spectrales nous avons précisé le gain d'un tel capteur hyperspectral par rapport à ceux existants ou à venir. Le problème inhérent au nombre de bandes spectrales a été apprécié et une réduction de dimension s'est avérée nécessaire dans la plupart des cas. Le verrou de la résolution spatiale notamment pour le capteur Hypxim (8m) a été partiellement levé par la mise au point de méthodes de fusion ou de sharpening permettant de considérer l'apport des résolutions spatiale et spectrale mais contraignant des développements supplémentaires sont nécessaires en présence de ville de forte densité (forte présence de pixels mixtes avec des zones d'ombre) notamment dans le cadre de cette mission.

Les développements thématiques ont fourni des éléments prometteurs dans le cas de la végétation arborée avec des avancées sur la discrimination d'espèces, la localisation des alignements d'arbres et la proposition de méthodes mieux adaptées (modèles « ensemble »). En ce qui concerne les panneaux solaires, il s'agit d'une première qui valorise particulièrement les travaux. Des développements sont évidemment à faire pour apprécier la robustesse de la méthode et sa transposabilité.

Sur le plan technique

Les résultats obtenus ont été rassemblés pour la synthèse technique de la mission Hypxim et compilés en WP4. Les données liées aux résolutions spatiales et spectrales, les observables identifiables selon les échelles, les méthodes les plus adaptées au contexte ont été synthétisés (WP4).

Parmi les recommandations faites pour une mission ayant une résolution à 8m :

- Intérêt du domaine 0.4-2.5 μm
- La résolution spatiale de 8 m est un bon compromis... au-delà les performances se dégradent fortement ; pour améliorer les résultats en fonction de la résolution il faut poursuivre les efforts sur la fusion
- Une correction atmosphérique tenant compte de l'ombre et du relief pour la classification à 8m est recommandée

➔ N'a pas été testé : la résolution spectrale et l'apport d'images multitemporelles

C.4 RESULTATS OBTENUS

Le projet a permis de conforter l'intérêt de l'IH dans l'appréhension du milieu urbain, notamment pour les thématiques liées à la végétation et aux panneaux solaires (PV, Weber et al. 2018 ; Gadal et Ouerghemmi, 2016).

Les développements apportés aux méthodes de correction atmosphérique ont permis de stabiliser les algorithmes et de définir leur domaine d'utilisation en fonction de la résolution spatiale. (Roussel et al. 2018 ; Roussel et al. 2016 ; WP1 livrable1).

Il a permis de mesurer la complémentarité entre les différents capteurs actuels : d'une part avec la confirmation d'une meilleure capacité spectrale grâce à l'apport du SWIR. (WP3 livrable1 p11-12 et WP3 livrable2), d'autre part par les traitements de fusion et de sharpening qui permettent de conserver la richesse spectrale et d'améliorer la précision géométrique (WP2 et WP3, Loncan et al., 2015 ; Hervieu et al. 2016 ; Ouerghemmi, 2016 ; WP et WP3).

Les approches de démixage ont été valorisées car elles permettent de conserver la richesse des mesures à travers des cartes d'abondance. (WP2 p 23 ; WP3 livrable3, Benhalouche et al., 2017 ; Benhalouche et al., 2016). Ces éléments sont retenus pour la caractérisation de la mission Hypxim. (W4 livrable1)

-/-

L'objectif n'était pas de développer de nouvelles méthodes mais bien d'appliquer celles reconnues dans le domaine et de les transposer au besoin au milieu urbain. Les méthodes déployées ont été choisies parmi l'ensemble des méthodes existantes (WP2-Etat de l'art livrable1) en les adaptant au type de signal, au nombre de bandes spectrales et aux caractéristiques du milieu. Ainsi les données étant issues de survols aériens les premiers développements ont été réalisés pour s'affranchir les effets de l'atmosphère sur l'IH (correction atmosphérique – 3 méthodes testée) (Roussel et al. 2018 ; WP1 livrable1). La réduction de dimension dans le cas des données IH s'avère nécessaire. Pour réduire le volume des données (nombre de bandes) des tests ont été fait sur l'extraction de caractéristiques et de sélection d'attributs. Dans le premier cas les méthodes classiques de réduction de l'information ont été utilisées (ACP, MNF etc. ; Le Bris et al., 2015b ; Brabant et al., 2018)

Une base de données de signatures spectrales (BDS) a été construite à partir d'éléments de la littérature, de données *in situ* (sur Toulouse et Kaunas) et de mesures de laboratoire. L'idée étant d'enrichir notre base de connaissances utilisable notamment pour créer une BD de références et appliquer les méthodes de classification supervisées (pour l'entraînement et la validation). Ainsi en cohérence avec divers éléments d'occupation du sol en ville (toits, routes, la végétation etc.) les valeurs spectrales des matériaux ont été enregistrées (WP1 livrable2) et de paramètres morpho spatiaux ont été définis (WP1). L'apport de ces BDS dans différents traitements de classification a ensuite été testé ; les résultats concernant l'apport de BDS sont mitigés. L'hétérogénéité des mesures et le déséquilibre des éléments sont sans doute en cause (WP3 livrable1 p6 et WP3 livrable2 p22). Les données d'apprentissage ont ensuite directement été extraites des images traitées. Là encore la variabilité des proportions d'échantillons dans les différentes classes a perturbé les résultats sans compter les effets liés à l'ombre, ou aux surplombs.

L'influence des configurations spectrales et spatiales a été abordée avec des comparaisons par rapport à des images simulées à 1.6m (Sentinel2, Pléiades, Hypxim). Ainsi à la même résolution spatiale : HPYXIM (0.4*-2.5 μ m) donne de meilleurs résultats que Pléiades et aux résolutions nominales, les performances sont équivalentes (WP3 tab1 p12). A noter qu'à performances égales l'IH fournit de meilleures discriminations de matériaux que le capteur Pléiades.

Ajouter des bandes issues du domaine SWIR améliore encore ces résultats, les meilleurs résultats étant atteints pour la configuration couvrant le domaine 400-2500nm (WP3 livrable1 p11-12 et WP3 livrable2). L'influence de la résolution spatiale pour une même configuration spectrale a été étudiée à la fois sur la structure générale du paysage urbain mais aussi sur la végétation plus précisément à diverses résolutions 2, 4, 8, 10m (WP3 livrable2 p47). Cette influence a été étudiée par rapport à différents classifieurs habituellement utilisés (WP2), le classifieur Support Vector Machine (SVM) est celui qui offre les meilleurs résultats, surtout s'il est précédé par une réduction de dimension (MNF). La résolution spectrale influence la capacité à distinguer des essences d'arbres dont les signatures spectrales sont similaires, d'où les résultats médiocres de Sentinel-2 comparativement aux images Hypxim à 4 et 8m. Cependant la résolution à 4m offre des résultats plus satisfaisants pour des finalités de reconnaissance de famille ou de genre d'arbre. L'échelle de l'espèce est dans

bien des cas plus difficile à conforter. Toutefois une démarche avec un ensemble de classifieurs a été développée et testée sur 5 espèces d'arbres (WP3 livrable2 p37). Cette méthode est intéressante car moins sensible aux changements d'échelle spatiale des bases d'apprentissage.

Des méthodes d'extraction, de fusion ou de classification ont été utilisées à différentes résolutions spatiales afin de qualifier les gains et la complémentarité de l'IH par rapport à d'autres capteurs. Des tests ont été élaborés sur diverses thématiques d'occupation du sol conformément aux souhaits formulés par les utilisateurs (aménagement, végétation, panneaux solaires et imperméabilisation). Des méthodes de classifications et de démixage ont été adaptées. Des améliorations notables peuvent être obtenues par fusion de classifications (Ouerghemmi, 2016). Le (pan ou multi) sharpening est aussi un moyen d'améliorer les rendus en conservant et la richesse spectrale et la précision géométrique ; cependant l'abondance de bandes, la présence du SWIR voire l'absence de bande panchromatique complique l'application de méthodes habituelles et nécessite d'autres types de fusion multicapteurs. Une boîte à outils des méthodes issues d'une revue de l'état de l'art (Loncan et al., 2015) a été déposée <http://openremotesensing.net>. Un développement particulier des méthodes de démixage a été réalisé (WP3 livrable3). Les méthodes de démixage tendent à la récupération des signatures spectrales « pures » des matériaux et leurs proportions relatives dans chaque pixel de l'image (WP2 p23). L'algorithme proposé est très attractif pour la détection et l'estimation des superficies des panneaux solaires en milieux urbains, par l'utilisation de l'imagerie hyperspectrale de télédétection spatiale, et beaucoup plus précis qu'une méthode classique de la littérature (WP3 livrable3 p64). Une autre méthode prenant en compte la variabilité des spectres à l'intérieur d'une même classe de matériaux a aussi été développée.

C.5 EXPLOITATION DES RESULTATS

Au sein du projet HYPEP, les résultats développés par un partenaire ont été utilisés par les autres. La démarche a été transférée aux collègues de Kaunas. L'école thématique organisée pendant le projet a fourni la possibilité de tester les approches avec des données drones. Les discussions internes ont permis de suivre l'évolution des développements méthodologiques, de les tester ensemble et de juger de leur validité. Certains développements ont été déposés sur <http://openremotesensing.net/>. Les thèses développées pendant le projet L. Loncan, F. Benhalouche, C. Revel, J. Aval sont ou seront accessibles sur les sites dédiés. Une discussion est en cours pour utiliser un « dataverse » permettant de mettre les résultats à disposition de la communauté.

C.6 DISCUSSION

Le projet a rassemblé les compétences interdisciplinaires complémentaires des partenaires permettant d'aborder la complexité des images hyperspectrales dans le domaine de l'urbain. Les travaux sont inscrits dans les avancées actuelles développées par la communauté scientifique internationale.

En ce qui concerne l'intérêt des images hyperspectrales pour l'étude du milieu urbain, l'apport du SWIR est sans conteste appréciable pour la détection et l'identification d'observables urbains. Les méthodes développées pour la correction atmosphérique ont permis de stabiliser les approches et de proposer une méthode opérationnelle (ICARE – Roussel et al., 2017).

Le verrou de la prise en compte de la dimension des images, a été évalué et les tests menés ont confirmé l'intérêt d'une réduction des dimensions avant d'entreprendre les traitements d'image (WP3).

Les difficultés rencontrées pour l'utilisation de bases de données de spectres dans des méthodes d'apprentissage ont permis de relever des limitations des méthodes liées aux différentes échelles entre les mesures. Les mesures de laboratoire à l'échelle du matériau inerte ou de la feuille ne sont pas cohérentes avec celles obtenues sur le terrain ou les signatures extraites des images. De fait l'hétérogénéité des observables, comme les arbres par exemple, ne peut pas être abordée du fait de la complexité des interactions au sein du houppier. De plus les mesures collectées sur le terrain s'avèrent délicates parce que non exhaustives et déséquilibrées en ce qui concerne les observables. Ceux-ci sont souvent surreprésentés dans une classe de matériau ou d'espèces, et la variété existante est difficile à cerner avec les mesures existantes.

Pour pallier le manque de mesures de terrain, l'idée de rassembler plusieurs bases de données spectrales (BDS) nous semblait intéressante. Cependant la disparité de ces BDS au niveau des mesures (réalisées avec différents capteurs), des localisations, des protocoles de mesures s'est avérée plutôt pénalisante lors des traitements (WP3).

Ce manque de références a des répercussions sur les classifications supervisées avec ou sans signatures spectrales de terrain. Ainsi des confusions entre matériaux urbains ont été relevées sans que l'on puisse suffisamment améliorer les résultats, en effet les toits en ardoise, l'asphalte, les pavés ou en graviers ne sont pas distinguables, de même les sols nus, les graviers de toits ou en ciment sont confondus. Ce point souligne

clairement le fait que des efforts restent à faire en ce qui concerne la mise en place de BDS utilisables pour l'entraînement des méthodes mais aussi pour la validation des résultats (WP3).

Les méthodes existantes sont en général à adapter du fait des dimensions des images, cependant les possibilités d'utilisation conjointe d'images de sources différentes offrent des opportunités pour gagner de la précision spatiale. Les développements pour le démélange, la fusion ou le sharpening sont des directions qui ont été poursuivies et qui restent à approfondir. D'autres approches ont été envisagées comme l'utilisation de sources multiples permettant d'améliorer les résultats. Ainsi l'utilisation d'un modèle numérique d'élévation issu de mesures Lidar, ou de sources multiples (image hyperspectrale, imagerie panchromatique, Lidar) au sein d'une même classification, s'est avérée une voie intéressante. Cette dernière a par ailleurs permis de préciser le rôle faible d'une voie panchromatique dans une classification (WP3).

L'opérationnalité envisagée pour la détection des panneaux solaires est un atout de ce projet, car elle peut pallier le manque d'information des collectivités sur des inventaires qu'elles ne peuvent réaliser de manière exhaustive (WP3). Ainsi l'approfondissement des méthodes de démélange avec une application précise peut s'avérer tout à fait pertinent. D'autres observables intéressants pour la gestion du territoire comme la détection de piscine ou la détermination plus précise des sols imperméables peuvent s'avérer utiles voire ouvrir des champs d'application opérationnels.

Précisons que les deux approches de traitement d'image ont été abordées –approche pixel et approche orientée objet- cette dernière semble plus efficace dans le cadre de la représentation des observables urbains à des échelles compatibles avec des supports de gestion et de planification (WP3).

Le partenariat de l'UMR Espace avec l'équipe de l'université Aleksandras Stulginski (ASU – Lituanie) et l'université technologique de Kaunas (KTU – Lituanie) a permis de valider la démarche sur des données différentes grâce à la mise à disposition par nos collègues de moyens conséquents (avion, capteurs, unité de traitement). De plus les développements réalisés dans le cadre d'une approche « low cost » notamment en utilisant des drones ont fourni lors de l'école thématique un support technique très appréciable. Ces approches en vogue à l'heure actuelle, ne peuvent pas être développées en France en milieu urbain pour cause d'interdiction de survol, aussi ces perspectives sont-elles intéressantes à étudier par comparaison pour les équipes françaises.

Des évolutions par rapport au projet initial ont été liées à :

- L'acquisition d'image et aux prétraitements : Les conditions d'obtention d'images aéroportées ont été limitées par la diminution des missions ONERA ; par contre les survols sur Kaunas se sont intensifiés une fois les problèmes de capteurs résolus. Les prétraitements notamment de corrections géométriques ont compliqué la remise des images en temps utiles. Les travaux ont essentiellement été appliqués sur des images acquises en 2012 et 2015 sur Toulouse.
- Le traitement de séries temporelles a été limité par le manque d'images aéroportées, il n'y a pas eu d'avancées dans ce domaine pendant le projet.
- L'apport de bases de données Spectrales : L'idée initiale d'utilisation de BD exogènes au projet afin de mobiliser le plus de spectres possibles pour couvrir la variété des matériaux, n'a pas été totalement concluante. En effet la mise en place a été achevée (structure, filtres morphologiques, texture ou attributaire selon la géométrie des objets). Mais son utilisation dans les traitements n'a pas été concluante du fait de la très grande hétérogénéité de chaque BD (type de capteur, design de la BD, types de matériaux, manque de métadonnées). Cependant cela nous a permis de tester la valeur ajoutée de l'utilisation d'une BD (acquisition, traitement) et d'en tirer des conclusions.
- L'adaptation nécessaires des méthodes : Les méthodes font partie de l'état de l'art en traitement d'image ; le nombre de bandes spectrales a nécessité des adaptations de traitement et des approfondissements.
- Aux contacts avec les autorités locales : La métropole Toulousaine n'a pas répondu à toutes nos attentes pour des raisons de réorganisation, heureusement celle de Montpellier a pris la suite même si les données ne concernaient pas la métropole montpelliéraine.
- Quelques difficultés administratives ont freiné le bon déroulement du projet suite à la mobilité d'un partenaire.

Le projet a ainsi été réalisé à 80% environ, en effet

- La finalisation de la BDS et sa mise à disposition au travers d'un support web n'ont pas pu être réalisés. L'hétérogénéité des BDS mobilisées nous a conduits à plus cerner les éléments d'amélioration qu'à poursuivre dans le développement d'un support technique.

- Les travaux des séries temporelles n'ont pas pu être réalisés sur Toulouse ; le manque de missions a restreint les évaluations potentielles sur plusieurs années. Néanmoins le choix des périodes adaptées à la phénologie de la végétation a pu être cerné en traitant d'autres images (Sentinel 2).

C.7 CONCLUSIONS

Le projet HYPE peut être considéré comme une réussite. Il a permis de mesurer la nécessité d'une approche globale sur un milieu très contraint à la fois par sa complexité et par les freins qu'il représente pour la définition de méthodes pertinentes de collecte, de traitement et de validation. Le projet était ambitieux, basé sur un territoire complexe en utilisant des données aéroportées à tester.

Il a conduit à l'amélioration de méthodes employées par les divers partenaires, à la levée d'un certain nombre de verrous scientifique et a favorisé le dialogue entre partenaires de différentes disciplines. Il s'agit d'un des aspects positifs du projet ; ceci a permis les discussions et la montée en compétences des divers partenaires sur l'une ou l'autre des méthodes et leur utilisation commune. Cela a facilité une réelle réflexion entre les membres du projet mais aussi avec d'autres collectifs.

Les verrous liés à l'amélioration des capacités spatiales des capteurs et aux changements d'échelle spatiale ont été en partie levés par les approches de fusion, de sharpening, qui se sont avérées concluantes.

Le projet a fourni des réponses aux verrous actuels qui résident dans la détermination de la largeur de bande efficace, de la résolution spectrale optimale et dans les méthodes retenues et/ou développées.

L'ensemble du travail a fourni un nombre remarquable de publications, chapitres d'ouvrage et présentations en conférences, organisation de sessions spéciales et d'une école thématique, participation à des événements de vulgarisation scientifique. La cohésion des partenaires se reflète dans les publications entre partenaires ou des participations croisées à des conférences, la participation commune à des conférences a permis de souder les relations et d'être disponibles aux travaux présentés dans leur ensemble.

Des transferts de connaissances ont été réalisés envers diverses populations : des collègues au niveau national et international, des étudiants et jeunes collègues (master, doctorat et post doctorat), des personnels de collectivités ou de services de l'Etat.

Parmi les ouvertures, la détection des panneaux solaires est une réussite qu'il convient de conforter sur des images plus grandes et variées. L'opérationnalité de ces travaux sera ensuite à évaluer avec des partenaires.

Le devenir des données créées dans le cadre de ce projet est à étudier dans le cadre d'une mise à disposition pour la communauté.

Les perspectives

Des perspectives techniques ont été envisagées par des partenaires comme la mise au point depuis 2017 d'une caméra superspectrale par l'équipe de l'IGN (avec l'ajout du SNIR) ou encore le design de caméras expérimentales capables d'être montés sur drones.

Des perspectives de recherche comme la création d'une plateforme collaborative en cours de réalisation ; elle devrait permettre de valider des résultats de classification par des remontées individuelles participatives. Cette réalisation répond à la difficulté en milieu urbain à collecter des éléments d'entraînement ou de validation de terrain. Il s'agirait de compléter les mesures *in situ* relevées avec des instruments avec des informations collectées grâce à une interface web.

Cette démarche s'inscrit dans la nécessité qu'il y a à stabiliser les méthodes grâce à de plus grands ensembles de référence (pour l'entraînement et la validation). Le projet a soulevé ce manque important que ne comble pas la mise en commun de bases de données spectrales collectées à divers endroits du globe. Parmi les perspectives, la possibilité d'avoir une approche globale permettant de prendre en compte les contraintes du milieu par une définition claire des méthodes de collecte et la mise en place de chaînes de prétraitement pertinentes nous semble une priorité pour continuer à développer l'utilisation de l'imagerie hyperspectrale (sachant qu'une telle réalisation, s'appliquerait de façon plus large à d'autres types d'imagerie).

Du point de vue méthodologique des questions se posent concernant le minimum d'information à collecter et les ressources nécessaires (Temps/Homme, puissance de calcul et moyens) ; il s'agit d'un questionnement de plus en plus actuel au sein de collectifs scientifiques.

La simulation physique d'observables par maquette de transfert radiatif (comme DART par exemple) pourrait être une solution et permettrait d'estimer les grandeurs biochimiques (et leur suivi) et de constituer des données de réflectance simulées utilisables pour traiter les images hyperspectrales adaptées à la résolution spatiale des instruments. Cette direction permettrait de réduire le manque de signatures spectrales ci-dessus et de faciliter l'extraction et l'identification des observables urbains.

Un autre volet important actuellement repose sur l'utilisation des capacités liées à l'existence de données massives et aux méthodes actuelles d'apprentissage (profond ou non). De la même manière se sont des méthodes gourmandes en données qu'il faut pouvoir caler pour l'apprentissage. Si les capteurs actuels de l'ESA Copernicus (Sentinel 1, 2 et autres capteurs multispectraux) fournissent des images ayant des temps de revisite très rapides, ce n'est pas le cas des données aéroportées. La question serait d'étudier la complémentarité entre capteurs hyperspectraux à faible revisite avec des capteurs ayant des temps de revisite soutenus. Dès lors l'utilisation des méthodes de deep learning par exemple serait justifiée et permettrait certainement de se pencher sur un aspect qui n'a pas été développé dans le projet HYEP, celui des séries temporelles. Pour les perspectives opérationnelles : l'extraction d'observables spécifiques comme les panneaux solaires, nous a conduit à identifier des points d'intérêt susceptibles d'être utiles pour la gestion d'un territoire ; les matériaux (à Kaunas, les toits en amiante sont particulièrement nombreux et nécessitent un suivi régulier) ; la détermination du degré d'imperméabilité serait un beau challenge auquel les collectivités pourraient s'intéresser ; enfin pour accompagner et renseigner les questionnements sur la biodiversité végétale ou l'implantation d'îlots de fraîcheur, le suivi temporel et sanitaire des espaces de végétation (arbres, arbustes, prairies, espaces verts) serait pertinent (WP4). La question de la temporalité nécessiterait très certainement de revoir certains choix méthodologiques pris dans le cadre de HYEP du fait de la variabilité des sources et des effets de saisonnalité. Ainsi dans le cas d'une approche de série temporelle par complémentarité de sources (capteurs) les aspects de fusion restent un frein méthodologique important notamment du fait de l'évaluation des effets d'ombres au cours d'une année par exemple.

C.8 REFERENCES

- K.R.M. Adeline, M. Chen, X. Briottet, S.K. Pang, N. Paparoditis. *Shadow detection in very high spatial resolution aerial images: A comparative study*. ISPRS Journal of Photogrammetry and Remote Sensing, 80:21 – 38, 2013.
- R. Aguejda, A. Serradj, C. Weber. *Mapping urban impervious surfaces from an airborne hyperspectral imagery using the object-oriented classification approach*, ASCMCES-17, Sharjah, 18-20 avril 2017.
- E. Ben-Dor, N. Levin, H. Saaroni. *A spectral based recognition of the urban environment using the visible and near-infrared spectral region (0.4-1.1 μm): a case study over Tel-Aviv, Israel*. International Journal of Remote Sensing, 22 (2001), 2193–2218.
- C. Carneiro, E. Morello, T. Voegtli, F. Golay. *Digital Urban Morphometrics: Automatic Extraction and Assessment of Morphological Properties of Buildings*. Transactions in GIS, 14(4), pp. 497-531, 2010.
- R.M. Cavalli, S. Pascucci, S. Pignatti. *Hyperspectral remote sensing data to map hazardous materials in a rural and industrial district: The Podgorica dwellings case studies*. In Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, 2009. WHISPERS '09. First Workshop on (pp.14), Grenoble, France, 2009.
- M. Chen, K.L.C. Seow, X. Briottet, S.K. Pang. *Efficient empirical reflectance retrieval in urban environments*. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 6(3):1596–1601, June 2013.
- S. Gadal, W. Ouerghemmi. *Morpho-Spectral Recognition of Dense Urban Objects by Hyperspectral Imagery*. The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, 40(3), 433, 2015.
- U. Heiden, S. Roessner, K. Segl, H. Kaufmann. *Analysis of spectral signatures of urban surfaces for their identification using hyperspectral HyMap data*. Remote Sensing and Data Fusion over Urban Areas, IEEE/ISPRS Joint Workshop 2001, 173–177.
- U. Heiden, K. Segl, S. Roessner, H. Kaufmann. *Determination of robust spectral features for identification of urban surface materials in hyperspectral remote sensing data*. Remote Sensing of Environment 111 (2007), 537–552.
- H. Heijmans. *Morphological image operators*. In: Hawkes, P. (ed.): 'Advances in electronics and electron physics', Academic Press, 1994.
- M. Herold. *Spectral characteristics of asphalt road surfaces*. In: Weng, Q. (Ed.), Remote Sensing of Impervious Surfaces. CRC Press, Boca Raton, Florida, 2007, 237–247.
- M. Herold, M.E. Gardner, D.A. Roberts. *Spectral resolution requirements for mapping urban areas*. IEEE Transactions on Geoscience and Remote Sensing, 41(9):1907–1919, Sept 2003.
- M. Herold, D.A. Roberts, M.E. Gardner, P.E. Dennison. *Spectrometry for urban area remote sensing – development and analysis of a spectral library from 350 to 2400 nm*. Remote Sensing of Environment 91 (2004), 304–319.
- S. Lachérade, C. Miesch, D. Boldo, X. Briottet, C. Valorge, H. Le Men. *Icare: A physically-based model to correct atmospheric and geometric effects from high spatial and spectral remote sensing images over 3d urban areas*. Meteorology and Atmospheric Physics, 102(3-4):209–222, 2008.
- L. Mackay, S. Barr. *Assessing the potential of hyperspectral angular imaging of urban built form surfaces for the inference of fine spatial scale urban land cover information*. Geoinformation for European-wide Integration, Benes (ed.), 2003.
- W. Ouerghemmi, A. Le Bris, N. Chehata, C. Mallet. *A two-step decision fusion strategy: application to hyperspectral and multispectral images for urban classification*. The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, XLII (1/W1):167-174, 2017.
- Q. Weng. *Remote sensing of impervious surfaces in the urban areas: Requirements, methods, and trends*. Remote Sensing of Environment 117 (2012), 34–49.

D LISTE DES LIVRABLES

Date de livraison	N°	Titre	Nature (rapport, logiciel, prototype, données, ...)	Partenaires (souligner le responsable)	Commentaires
2015	1	WP1 BD morphospectrale	Rapport	S Gadal	
2016 /2018	2	WP2 Outils méthodologiques	Rapport	C Mallet	
2017/2018	3	WP3 Evaluation des performances	Rapport	X Briottet	
2018	4	WP4 Recommandations	Rapport	C Weber	
2015/2016	5	Logiciels	ToolBox Fusion	ONERA GIPSA-Lab	
2015/2016	6	BD Spectrales	Plateforme Web	Réalisation stoppée	Voir texte
2015-2018	7	Thèses, master	Documents	ONERA IRAP GIPSA ESPACE LETG	

E IMPACT DU PROJET

Ce rapport rassemble des éléments nécessaires au bilan du projet et plus globalement permettant d'apprécier l'impact du programme à différents niveaux.

E.1 INDICATEURS D'IMPACT

Nombre de publications et de communications (à détailler en E.2)

*Comptabiliser séparément les actions monopartenaire, impliquant un seul partenaire, et les actions multipartenaires résultant d'un travail en commun. **Attention** : éviter une inflation artificielle des publications, mentionner uniquement celles qui résultent directement du projet (postérieures à son démarrage, et qui citent le soutien de l'ANR et la référence du projet).*

		Publications multipartenaires	Publications mono-partenaire
International	Revue à comité de lecture	6	4
	Ouvrages ou chapitres d'ouvrage	2	1
	Communications (conférence)	10	28
	Communication invitée	1	
	Sessions spéciales	4	
	Communications (conférence) sans actes	4	
France	Revue à comité de lecture		
	Ouvrages ou chapitres d'ouvrage	2	
	Communications (conférence)	10	
Actions de diffusion	Articles vulgarisation	1	
	Conférences vulgarisation	6	
	Autres		

Autres valorisations scientifiques (à détailler en E.3)

	Nombre, années et commentaires (valorisations avérées ou probables)
Brevets internationaux obtenus	

Brevet internationaux en cours d'obtention	
Brevets nationaux obtenus	
Brevet nationaux en cours d'obtention	
Licences d'exploitation (obtention / cession)	
Créations d'entreprises ou essaimage	
Nouveaux projets collaboratifs	
Colloques scientifiques	4 sessions de conférences Grenoble 2016, IGARSS 2018, Whispers 2018, JURSE 2019
Autres (préciser)	Ecole thématique 2017

E.2 LISTE DES PUBLICATIONS ET COMMUNICATIONS

Organisation de sessions spéciales

SFPT Groupe Hyperspectral Grenoble (F) 2016 (Christiane Weber, Xavier Briottet)
 IGARSS Valencia (E) 2018 (Christiane Weber, Xavier Briottet, Clément Mallet)
 WHISPERS, Amsterdam (NL) 2018 (Sébastien Gadal, Rahim Aguejdad)
 JURSE 2019 (Vannes, F) 2019 (Christiane Weber, Ellen Banzhaft)

Soumis

C. Brabant, E. Alvarez-Vanhard, G. Morin, K. Thanh Nguyen, A. Laribi, T. Houet, (submitted) Evaluation of dimensional reduction methods on urban vegetation classification performance using hyperspectral data, Remote Sensing
 Charlotte REVEL, Yannick DEVILLE, Véronique ACHARD and Xavier BRIOTTET, Christiane WEBER, Inertia-Constrained Pixel-by-Pixel Nonnegative Matrix Factorisation: a Hyperspectral Unmixing Method Dealing with Intra-class Variability. Submitted to Remote Sens., pages 1 – 26
 G. Mozgeris, V. Juodkienė, D. Jonikavičius, L. Straigtė, S. Gadal, W. Ouerghemmi, (submitted) Ultra-light aircraft based hyperspectral and colour-infrared imaging to identify deciduous tree species in urban environment, Remote Sensing

A paraître

J. Aval, S. Fabre, X. Briottet, D. Sheeren, M. Fauvel, E. Zenou. *Object-based fusion for urban tree species classification from hyperspectral, panchromatic and nDSM data*, International Journal of Remote Sensing. Accepted 14 Sept, to be published, TRES-PAP-2018-0200.R2

Publications

G. Vivone, P. Addesso, R. Restaino, M. Dalla Mura and J. Chanussot, Pansharpener Based on Deconvolution for Multiband Filter Estimation. IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING. 2018 *in press*
 C. Dechesne, C. Mallet, A. Le_Bris, V. Gouet-Brunet. Semantic segmentation of forest stands of pure species combining airborne lidar data and very high resolution multispectral imagery. ISPRS Journal of Photogrammetry and Remote Sensing, 126 (2017), pp.129–145, 2017.
 G. Roussel, C. Weber, X. Briottet and X. Ceamanos, "Comparison of two atmospheric correction methods for the classification of spaceborne urban hyperspectral data depending on the spatial resolution", International Journal of Remote Sensing, vol. 39(5), pp. 1593-1614, 2018.
 F. Z. Benhalouche, M. S. Karoui, Y. Deville, I. Boukerch, A. Ouamri, "Multi-sharpener hyperspectral remote sensing data by multiplicative joint-criterion linear-quadratic nonnegative matrix factorization", Proceedings of the 2017 IEEE International Workshop on Electronics, Control, Measurement, Signals and their application to Mechatronics (ECMSM 2017), May 24-26, 2017, Donostia - San Sebastian
 F. Z. Benhalouche, M. S. Karoui, Y. Deville, A. Ouamri, "Hyperspectral and multispectral data fusion based on linear-quadratic nonnegative matrix factorization", Journal of Applied Remote Sensing (SPIE Digital Library), vol. 11, no. 2, pp. 025008-1 to 025008-18, Apr-Jun 2017. DOI: 10.1117/1.JRS.11.025008
 M. S. Karoui, Y. Deville, F. Z. Benhalouche, I. Boukerch, "Hypersharpener by Joint-Criterion Nonnegative Matrix Factorization", IEEE Transactions on Geoscience and Remote Sensing, vol. 55, no. 3, pp. 1660-1670, March 2017

- W. Ouerghemmi, A. Le_Bris, N. Chehata, C. Mallet, A two-step decision fusion strategy: application to hyperspectral and multispectral images for urban classification, *ISPRS Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2017
- C. Revel, Y. Deville, V. Achard, X. Briottet, Inertia-Constrained Pixel-by-Pixel Nonnegative Matrix Factorisation: a Hyperspectral Unmixing Method Dealing with Intra-class Variability, 24 Feb 2017 arXiv:1702.07630v1 [stat.ME] 24 Feb 2017
- L. Loncan, L. B. Almeida, J. M. Bioucas-Dias, X. Briottet, J. Chanussot, N. Dobigeon, S. Fabre, W. Liao, G. Licciardi, M. Simoes, J-Y. Tourneret, M. Veganzones, G. Vivone, Q. Wei and N. Yokoya, "Hyperspectral pansharpener: a review," *IEEE Geoscience and Remote Sensing Magazine* vol. 3(3), 2015. arxiv.org/pdf/1504.04531.pdf

Ouvrages ou chapitres d'ouvrages

Y. Deville, C. Revel, V. Achard, X. Briottet, "Application and extension of PCA concepts to blind unmixing of hyperspectral data with intra-class variability", chapter in "Advances in Principal Component Analysis - Research and Development", pp 225-252, G. R. Naik (ed), Springer, Singapore, 2018. DOI : https://doi.org/10.1007/978-981-10-6704-4_9

BRIOTTET X. N. CHEHATA, A. LE BRIS, R.OLTRA CARRIO ET C WEBER, 2016, APPLICATION DE L'OPTIQUE A L'URBAIN in PARTIE 2 : Chapitre 4: Application de l'optique aux milieux urbains. Télédétection pour l'Observation des Surfaces Continentales Tome 4 Applications thématiques : Aménagement, Environnement et Risques *Coord. Nicolas Baghdadi et Mehrez Zribi. ed. ISTE*

Xavier BRIOTTET, Nesrine CHEHATA, Rosa OLTRA-CARRIO, Arnaud LE BRIS and Christiane WEBER, 2016, Optical Remote Sensing in Urban Environments. Télédétection pour l'Observation des Surfaces Continentales Tome 4 Applications thématiques : Aménagement, Environnement et Risques *Coord. Nicolas Baghdadi et Mehrez Zribi. ed. ISTE*

Conférences avec actes

2018

- F. Z. Benhalouche, M. S. Karoui, Y. Deville, "Linear-quadratic NMF-based urban hyperspectral data unmixing with some known endmembers", *Proceedings of the 9th Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS 2018)*, Sept. 23-26, 2018, Amsterdam, The Netherlands
- W. Ouerghemmi, S. Gadal, G. Mozgeris, Urban vegetation mapping by airborne hyperspectral imagery: Feasibility and limitations, *Proceedings of the 9th Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS 2018)*, Sept. 23-26, 2018, Amsterdam, The Netherlands
- C. Brabant, Alvarez-Vanhard E., Morin G., Thanh Nguyen K., Laribi A., Houet T. (2018) Evaluation of dimensional reduction methods on urban vegetation classification performance using hyperspectral data, *IGARSS 2018, Valencia, (E)*, 2018.
- C. Weber, R. Aguejdad, X Briottet, J. Aval, S. Fabre, J. Demuyndck, E. Zenou ; Y. Deville, M. S. Karoui, F.Z. Benhalouche; S. Gadal, W. Ourghemmi; C. Mallet, A. Le Bris, N Chehata, Hyperspectral Imagery for Environmental Planning, in *Proc. of the IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Valencia (E), 2018
- C. Dechesne, C. Mallet, A. Le_Bris, V. Gouet-Brunet. Forest stand extraction: which optimal remote sensing data source(s) in *Proc. of the IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, July 2018, Valencia, (E),
- M. Karoui, F. Benhalouche, Y. Deville, K. Djerriri, X. Briottet, A. Le Bris. Detection and area estimation for photovoltaic panels in urban hyperspectral remote sensing data by an original NMF-based unmixing method. in *Proc. of the IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2018)*, 20-27 July 2018, Valencia, (E)
- W. Ouerghemmi, S. Gadal, G. Mozgeris, Urban Vegetation Mapping using Hyperspectral Imagery and Spectral Library. in *Proc. of the IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2018)*, 20-27 July 2018, Valencia, (E).

2017

- C. Revel, Y. Deville, V. Achard, X. Briottet, Inertia-Constrained Pixel-by-Pixel Nonnegative Matrix Factorisation: a Hyperspectral Unmixing Method Dealing with Intra-class Variability, 24 Feb 2017 Methodology (stat.ME); Computer Vision and Pattern Recognition (cs.CV); Data Analysis, Statistics and Probability (physics.data-an); Machine Learning (stat.ML) Cite as: arXiv:1702.07630 [stat.ME]
- F. Z. Benhalouche, M. S. Karoui, Y. Deville, "Linear-quadratic NMF-based urban hyperspectral data unmixing with some known endmembers", to appear in the Proceedings of the 9th *Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing* (WHISPERS 2018), Amsterdam, The Netherlands, Sept. 23-26, 2018.
- A. Le Bris, N. Chehata, X. Briottet, N. Papanikolaou, Hierarchically exploring the width of spectral bands for urban material classification, *JURSE 2017*, March 2017, Dubai, UAE.
- W. Ouerghemmi, S. Gadai, G. Mozgeris, D. Jonikavičius, W. Christiane. Urban objects classification by spectral library: feasibility and applications. Devis Tuia; Vincent Mallet; IEEE. *JURSE 2017*, Mar 2017, Dubai, United Arab Emirates. p23-27.
- C. Revel, Y. Deville, V. Achard, X. Briottet, "Impact of the initialisation of a blind unmixing method dealing with intra-class variability" (**invited paper in special oral session on "Environmental signal processing: new trends and applications"**), *Proceedings of the 25th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning* (ESANN 2017), pp. 227-232, 26-28 April 2017, Bruges, Belgium
- C. Revel, Y. Deville, V. Achard, X. Briottet, Inertia-Constrained Pixel-by-Pixel Nonnegative Matrix Factorisation: a Hyperspectral Unmixing Method Dealing with Intra-class Variability, 24 Feb 2017 arXiv:1702.07630v1 [stat.ME] 24 Feb 2017
- R. Aguejdad, A. Serradj, C. Weber, Mapping urban impervious surfaces from an airborne hyperspectral imagery using the object-oriented classification approach, *ASCMCES-17*, Sharjah, 18-20 avril 2017
- W. Ouerghemmi, A. Le Bris, N. Chehata, and C. Mallet, "A two-step decision fusion strategy: application to hyperspectral and multispectral images for urban classification", *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII (1/W1):167-174, 2017.
- F. Z. Benhalouche, M. S. Karoui, Y. Deville, I. Boukerch, and A. Ouamri, "Multi-sharpening hyper-spectral remote sensing data by Multiplicative Joint-Criterion Linear-Quadratic Nonnegative Matrix Factorization," in *Proc. IEEE ECMSM*, pp. 1-6, San Sebastian, Spain, 2017
- M. S. Karoui, F. Z. Benhalouche, Y. Deville, K. Djerriri, X. Briottet, A. Le Bris, "Detection and area estimation for photovoltaic panels in urban hyperspectral remote sensing data by an original NMF-based unmixing method", *Proceedings of IGARSS 2018*.
- M. S. Karoui, F. Z. Benhalouche, Y. Deville, K. Djerriri, X. Briottet, T. Houet, A. Le Bris, "An NMF-based unmixing method with known spectra of photovoltaic panels for their detection and area estimation from urban hyperspectral remote sensing data", SFPT-GH 2018 conference, Montpellier, France, May 17-18, 2018.
- 2016**
- F. Z. Benhalouche, Y. Deville, M. S. Karoui, A. Ouamri, Hyperspectral endmember spectra extraction based on constrained linear-quadratic matrix factorization using a projected gradient method, 2016 *IEEE International Workshop on Machine Learning for Signal Processing* (MLSP 2016), 13-16 Sept. 2016, Salerno, Italy
- S. Gadai, W. Ouerghemmi. Morpho-spectral objects classification by hyperspectral airborne imagery. University of California Los Angeles. 8th Workshop in Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, Aug 2016, Los Angeles, United States. pp.349-353.
- G. Mozgeris, S. Gadai, D. Jonikavičius, L. Straigyte, W. Ouerghemmi, et al.. Hyperspectral and color-infrared imaging from ultra-light aircraft: Potential to recognize tree species in urban environments. University of California Los Angeles. 8th Workshop in Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, Aug 2016, Los Angeles, United States. pp.542-546.
- S. Gadai et W. Ouerghemmi, Morpho-spectral objects classification by hyperspectral airborne imagery, WHISPERS - 8th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing 21 - 24 August 2016, Los Angeles, United States
- G. Roussel, C. Weber, X. Ceamanos and X. Briottet, 2016, A sun/shadow approach for the classification of hyperspectral data, WHISPERS - 8th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, 21 - 24 August 2016, Los Angeles, United States
- C. Revel, Y. Deville, V. Achard, X. Briottet, "A linear-quadratic unsupervised hyperspectral unmixing method dealing with intra-class variability", Proceedings of the 8th Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS 2016), Los Angeles, USA, August 21-24, 2016.

- G. Roussel, C. Weber, X. Ceamanos and X. Briottet, "A sun/shadow approach for the classification of hyperspectral data", *Proceedings of the 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2016)*), pp. 6565-6568, 10-15 July 2016, Beijing, China BEIJING, Chine, 2016.
- F. Z. Benhalouche, Y. Deville, M. S. Karoui, A. Ouamri, Bilinear matrix factorization using a gradient method for hyperspectral endmember spectra extraction, *Proceedings of the 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2016)*, pp. 6565-6568, 10-15 July 2016, Beijing, China
- A. Le Bris, N. Chehata, X. Briottet, N. Paparoditis, Spectral band selection for urban material classification using hyperspectral libraries. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 3 (7), pp. 33-40, ISPRS Congress, Juillet 2016, Prague, Czech Republic
- C. Dechesne, C. Mallet, A. Le Bris, V. Gouet, Forest stand segmentation combining airborne lidar data and very high resolution multispectral imagery. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLI-B3, 2016 XXIII ISPRS Congress, 12–19 July 2016, Prague, Czech Republic
- A. Hervieu, A. Le Bris and C. Mallet, 2016, Fusion of multispectral and hyperspectral aerial image classifications in urban areas, *ISPRS Annals of Photogrammetry, Remote Sensing and the Spatial Information Sciences*, Vol. III-3: 457-464, July 2016, Prague, Czech Republic.
- S. Gadai, W. Ouerghemmi, 2016, Urban objects recognition feasibilities by airborne hyperspectral and multispectral remote sensing. Actes Avignon Series - ISBN: 978-2-9105-4510-5, pp.101-108, 2016, *Spatial uncertainty in knowledge-based systems, Spatial Accuracy 2016*, July 2016, Montpellier, France

2015

- L. Loncan, J. Chanussot, S. Fabre and X. Briottet, "Hyperspectral Pansharpening based on unmixing techniques", in *Proc. 7th Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing WHISPERS 2015*.
- A. Le Bris, N. Chehata, X. Briottet, N. Paparoditis, Extraction of optimal spectral bands using hierarchical band merging out of hyperspectral data. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 15 (3/W3), pp. 459-465, Octobre 2015
- S. Gadai, W. Ouerghemmi, 2015, Morpho-spectral recognition of dense urban objects by hyperspectral imagery, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XL-3/W3, 2015, ISPRS Geospatial Week 2015, 28 Sep. – 03 Oct. 2015, La Grande Motte, France
- F. Z. Benhalouche, M. S. Karoui, Y. Deville and A. Ouamri, Local hyperspectral data multi-sharpening based on linear/linear-quadratic nonnegative matrix factorization by integrating lidar data, *Proceedings of Image and Signal Processing for Remote Sensing XXI SPIE conference*, vol. 9643, pp. 96430Y-1 to 96430Y-9, 21 Sept. 2015, Toulouse, France
- Y. Deville, "Matrix factorization for bilinear blind source separation: methods, separability and conditioning", *Proceedings of the 23rd European Signal Processing Conference (EUSIPCO 2015)*, pp. 1945-1949, Aug. 31 - Sept. 4, 2015, Nice, France
- A. Le Bris, N. Chehata, X. Briottet, N. Paparoditis, A Random Forest class memberships based wrapper band selection criterion: application to hyperspectral. *Proc. of the IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Juillet 2015, Milan, Italie
- F. Z. Benhalouche, M. S. Karoui, Y. Deville, A. Ouamri, "Hyperspectral data multi-sharpening based on linear-quadratic nonnegative matrix factorization", *Proceedings of the 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2015)*, pp. 3290-3293, July 26-31, 2015, Milan, Italy
- C. Revel, Y. Deville, V. Achard, X. Briottet, "A method based on nonnegative matrix factorization dealing with intra-class variability for hyperspectral unmixing", *Proceedings of the 7th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS 2015)*, June 2-5, 2015, Tokyo, Japan
- L. Loncan, L. B. Almeida, J. Bioucas Dias, X. Briottet, J. Chanussot, N. Dobigeon, S. Fabre, W. Liao, G. Licciardi, M. Simoes, J. Y. Tourneret, M. A. Veganzones, G. Vivone, Q. Wei, N. Yokoya, "Comparison of nine Hyperspectral Pansharpening methods", in *Proc. Proceedings of the 2015 IEEE International Geoscience and Remote Sensing Symposium IGARSS, 2015*
- A. Le Bris, N. Chehata, X. Briottet, N. Paparoditis, Extraction of optimal spectral bands using hierarchical band merging out of hyperspectral data. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 15 (3/W3), pp. 459-465, Octobre 2015
- C. Weber C. et al., 2015, Imagerie Hyperspectrale pour la planification urbaine environnementale. ISPRS Geospatial Week 2015. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XL(3/W3) pp 653-66.,

COMMUNICATIONS DANS DES COLLOQUES ET VULGARISATION (SANS ACTES)

- J. Aval, S. Fabre, D. Sheeren, E. Zenouo, X. Briottet, oral : Individual street tree detection from airborne data and contextual information, GEOBIA 2018, 18-22 June, Montpellier, France
- M. S. Karoui, F. Z. Benhalouche, Y. Deville, K. Djerriri, X. Briottet, T. Houet, A. Le Bris, "An NMF-based unmixing method with known spectra of photovoltaic panels for their detection and area estimation from urban hyperspectral remote sensing data", SFPT-GH 2018 conference, Montpellier, France, May 17-18, 2018
- S. Gadal, W. Ouerghemmi, G. Mozgeris, R. Barlatier, Recognition of urban vegetation by hyperspectral airborne high-resolution VNIR imager (Kaunas, Lithuania), 6ème édition : colloque groupe hyperspectral SFTP-GH, pp.47, May 2018, Montpellier, France
- Ouerghemmi W., A. Le Bris, N.Chehata, C. Mallet, oral : Fusion de classifications pour l'utilisation conjointe d'images multispectrales à très haute résolution spatiale et de données hyperspectrales. Colloque du Groupe Hyperspectral de la Société Française de Photogrammétrie et Télédétection, 2017, Brest, France
- Aval J., S. Fabre, D. Sheeren, E. Zenouo, X. Briottet, oral : Urban tree species classification with airborne hyperspectral VNIR and SWIR, PAN and DSM data, EARSeL SIG Imaging Spectroscopy Workshop, 19 - 21 April 2017, Zurich, Switzerland
- Mozgeris G., Gadal S., Jonikavičius D., Straigyte L., Ouerghemmi W., Juodkienė V. (2016). HYPERSPECTRAL AND COLOR-INFRARED IMAGING FROM ULTRA-LIGHT AIRCRAFT: POTENTIAL TO RECOGNIZE TREE SPECIES IN URBAN ENVIRONMENT, Whisper, 21-24 August 2016, UCLA, USA.
- Gadal S., Ouerghemmi W. (2016). Morpho-spectral objects classification by hyperspectral airborne imagery, Whisper, 21-24 August 2016, UCLA, USA
- Weber C., X Briottet, C. Mallet, S Gadal, Hyperspectral Imagery for Environmental urban Planning: HYEP, 2016, Colloque du Groupe Hyperspectral de la Société Française de Photogrammétrie et Télédétection, 2016, Grenoble, France
- Roussel G., et al., 2016, Comparaison de deux méthodes de correction atmosphérique à différentes résolutions pour des applications de classification d'images hyperspectrales Colloque du Groupe Hyperspectral de la Société Française de Photogrammétrie et Télédétection, 2016, Grenoble, France
- Ouerghemmi W., S. Gadal, G. Mozgeris, V. Juodkiene, D. Jonikavicius, G. Skupinski, C. Weber, Generation of urban objects spectral database using laboratory hyperspectral imager in Kaunas city (Lithuania) Colloque du Groupe Hyperspectral de la Société Française de Photogrammétrie et Télédétection, 2016, Grenoble, France
- Gadal S., W. Ouerghemmi Identification of urban objects using spectral library combined with airborne hyperspectral imaging Colloque du Groupe Hyperspectral de la Société Française de Photogrammétrie et Télédétection, 2016, Grenoble, France
- Y. Deville, F. Z. Benhalouche, M. S. Karoui, A. Ouamri, "Bilinear matrix factorization methods and application to unsupervised unmixing of urban hyperspectral images", Colloque du Groupe Hyperspectral de la Société Française de Photogrammétrie et Télédétection, 2016, Grenoble, France
- Zinko S., Lampert T, P Gançarski et C Weber, 2016, HYEP: des bases de données spectrales à l'usage de la communauté. Colloque du Groupe Hyperspectral de la Société Française de Photogrammétrie et Télédétection, 2016, Grenoble, France
- C. Weber, A Serradj, R Aguejdad, T Houet, X Briottet, S Gadal, N Paparoditis, C Maller, A Lebris, J Chanussot, Y Deville, Apport de l'Imagerie Hyperspectrale pour l'étude de l'écosystème urbain. Colloque du Groupe Hyperspectral de la Société Française de Photogrammétrie et Télédétection. 2014 Porquerolles, France

Vulgarisation

Article

X Briottet, Imagerie hyperspectrale visible et infrarouge thermique : principes et application. « Techniques pour l'ingénieur » (P960). 50p.

Conférence - workshop

- S. Gadal, W. Ouerghemmi, Cartographie de la végétation urbaine par imagerie aéroportée hyperspectrale sur la ville de Kaunas (Lituanie), TEMU 2018 : Atelier Télédétection pour l'Etude des Milieux Urbains, Mar 2018, Strasbourg, France
- Aval J., S. Fabre, D. Sheeren, E. Zenouo, X. Briottet, oral : Classification des espèces d'arbres en milieu urbain par fusion de données aéroportées hyperspectrales, panchromatiques et d'un MNS, TEMU, 16 - 17 Janv. 2017, Toulouse, France

- G. Mozgeris, S. Gadal, D. Jonikavičius, L. Straigyte, W. Ouerghemmi, et al.. The Potential of Imaging from Ultra-Light Aircraft for Urban Tree Inventories: Case Study in Kaunas, Lithuania. IUFRO - 125th Anniversary Congress 2017, Sep 2017, Freiburg, Germany. IUFRO, pp.430, 2017, Interconnecting Forest, Science, and People.
- A. Le Bris, N.Chehata, X. Briottet, N. Paparoditis, oral : Optimisation spectrale pour la classification de matériaux urbains, Atelier Télédétection pour l'Étude des Milieux Urbains, 2017, Toulouse, France
- Le Bris A., N.Chehata, X. Briottet, N. Paparoditis, oral : Occupation du sol fine en milieu urbain, Réunion "Imagerie hyperspectrale : quelles données ? Quels traitements ? Quelles applications ?" du GdR ISIS, 2016, Toulouse, France
- Le Bris A., oral : Imagerie et classification de l'occupation du sol pour l'analyse des milieux urbains. Salon Pollutec, 2016, Lyon, France
- Le Bris A., oral : Contribution de l'imagerie hyperspectrale à l'analyse des milieux urbains. Journées de la Recherche de l'IGN, 2016, Marne-la-Vallée, France

Posters

- Weber C., X. Briottet, C. Mallet, S. Gadal, Y. Deville, J. Chanussot, T. Houet, et al., HYEP - Hyperspectral Imagery for Environmental Urban Planning, Journées ADEME / ANR - La recherche au service de la transition énergétique. 4 - 5 juin 2018, Palais des Congrès d'Issy-les-Moulineaux, Paris, France (poster)
- Aval J., S. Fabre, D. Sheeren, E. Zenouo, X. Briottet, Urban tree species classification with airborne hyperspectral VNIR and SWIR, PAN and DSM data by fusion at the object level, IAC, 25 - 29 Sept. 2017, Adelaide, Australia
- Le Bris A., N. Chehata, X. Briottet, N. Paparoditis : Optimisation de la configuration d'un instrument superspectral aéroporté pour la classification en milieu urbain. Colloque du Groupe Hyperspectral de la Société Française de Photogrammétrie et Télédétection, 2016, Grenoble, France
- Weber C., S Zinko, T Lampert et P Gancarski, HYEP: des bases de données spectrales à l'usage de la communauté. Colloque du Groupe Hyperspectral de la Société Française de Photogrammétrie et Télédétection, 2016, Grenoble, France
- Weber C., Briottet X, Mallet C. et Gadal S., 2016, Hyperspectral Imagery for Environmental Urban Planning. SAGEO 2016, NICE

Thèses et Master

Master

- BRABANT Charlotte, 2018 – Evaluation de multiples techniques visant l'amélioration de la performance de classification de la végétation urbaine à partir de données hyperspectrales. Mémoire de Master 2 TELENVI, Université Rennes 2, 50 p.
- BARLATIER Romain, 2018, Analyse critique de l'utilisation d'images aéroportées de type hyperspectrale pour l'étude de l'environnement urbain. Mémoire de Master 2 de Géographie, spécialité Structures et dynamiques spatiales, Aix-Marseille Université, 127 p.
- LARIBI Achour, 2017, Evaluation de la capacité de l'imagerie hyperspectrale en milieu urbain : application à la végétation urbaine. Mémoire de Master 2 TELENVI, Université Rennes 2, 34 p.
- KHELFA Mériem, 2017, Evaluation des données aéroportées hyper spectrales pour l'aménagement et l'urbanisme dans la ville de Kaunas en Lituanie. Mémoire de Master 1 de Géographie, Aix-Marseille Université, 76 p.
- BARLATIER Romain, 2017, Analyse critique de l'utilisation d'images de télédétection haute résolution et hyperspectrale à l'environnement urbain, Mémoire de Master 1 de Géographie, Aix-Marseille Université, 85 p.

Thèses

- LONCAN Laetitia, 2016, Fusion d'images panchromatiques et hyperspectrales à très haute résolution spatiale. Dir. J Chanussot, X. Briottet et S Fabre. GIPSA-Lab

REVEL, 2016, Apport de la prise en compte de la variabilité intra-classe dans les méthodes de démixtion hyperspectral pour l'imagerie urbaine. Dir. X Briottet et Y Deville. Institut de Recherche en Astrophysique et Planétologie (IRAP) et ONERA

AVAL Josselin, 2018, Vers une cartographie automatique du patrimoine arboré en milieu urbain. Dir. Briottet Xavier, Zenou Emmanuel. ONERA

Fatima Zohra BENHALOUCHE, Méthodes de démixtion et de fusion des images multispectrales et hyperspectrales de télédétection spatiale. Y Deville IRAP

E.3 LISTE DES ELEMENTS DE VALORISATION

La liste des éléments de valorisation inventorie les retombées (autres que les publications) décomptées dans le deuxième tableau de la section On détaillera notamment :

- *Logiciels : ToolBox pan/hyperspectrale ONERA/GIPSA-Lab*
- *Ouverture internationale : travail avec l'équipe de Lituanie, KAUNAS*
- *Co-directions de thèses/ Revel et Loncan*
- *Participation à des conférences de vulgarisation : TEMU, GDRs (MAGIS, ISIS, MacDISC)*
- *Articles dans la revue « Techniques pour l'ingénieur » (P960) Imagerie hyperpéctrale visible et infrarouge thermique : principes et application. 50p.*

E.4 BILAN ET SUIVI DES PERSONNELS RECRUTES EN CDD (HORS STAGIAIRES)

Les données recueillies pourront faire l'objet d'une demande de mise à jour par l'ANR jusqu'à 5 ans après la fin du projet.

Identification				Avant le recrutement sur le projet			Recrutement sur le projet				Après le projet				
Nom et prénom	Sexe H/F	Adresse email (1)	Date des dernières nouvelles	Dernier diplôme obtenu au moment du recrutement	Lieu d'études (France, UE, hors UE)	Expérience prof. Antérieure, y compris post-docs (ans)	Partenaire ayant embauché la personne	Poste dans le projet (2)	Durée missions (mois) (3)	Date de fin de mission sur le projet	Devenir professionnel (4)	Type d'employeur (5)	Type d'emploi (6)	Lien au projet ANR (7)	Valorisation expérience (8)
BARLATIE R Romain	H			Master 2	Aix-Marseille Université	6	UMR ESPACE LIVE	Stagiaire	6	01/03/2018 - 30/09/2018	Géomaticien			WP-3	
BARLATIE R Romain	H			Master 1	Aix-Marseille Université	4	UMR ESPACE	Stagiaire	4	01/03/2017 - 31/07/2017	Master 2 en Géomatique et Analyse spatiale			WP-1	
KHELFA Mériem	F			Master 1	Aix-Marseille Université	4	UMR ESPACE	Stagiaire	4	01/03/2017 - 31/07/2017	Master 2 en Géomatique et Analyse spatiale			WP-1	
OUERGHE MMI Walid	H			Doctorat en géosciences	SupAgro Montpellier	3	UMR ESPACE	Chercheur CNRS (post-doctorant)	12	01/06/2015 - 31/05/2016	Chercheur contractuel (IGN, puis CNRS)	IGN, CNRS		WP-1	
RAGUET Hugo	H	hugo.raguet@gmail.com		Doctorat en mathématique,	Paris Dauphine	3	UMR LIVE	Chercheur contractuel	3	01/05/2018 - 31/08/2018	PAST ? (AMU)			WP-3	
HERVIEU Alexandre	H		Juin 2018	Doctorat	France	Post-doc 3 ans	IGN	Post-doctorant	5,5 mois	Décembre 2015	Chercheur DGA	Public	Chercheur	WP2	Oui
OUERGHE MMI Walid	H		Juin 2018	Doctorat	France	Post-doc 1 an	IGN	Post-doctorant	6,5 mois	Décembre 2016	Post-doc Université Aix Marseille	Public	Chercheur	WP2	Oui
BRABANT Charlotte	F			Master 1	Université Rennes	0	UMR LETG	Stagiaire	6	01/02/2018 - 31/07/2018				WP3	
BRABANT Charlotte	F			Master 2	Université Rennes	0	UMR LETG	CDD IE	1	20/08/2018 au 14/09/2018	Thèse			WP3	
LARIBI Achour	H			Master 1	Université Rennes	0	UMR LETG	Stagiaire	6	01/02/2017 - 31/07/2017	Master 2			WP3	

Aide pour le remplissage

- (1) **Adresse email** : indiquer une adresse email la plus pérenne possible
- (2) **Poste dans le projet** : post-doc, doctorant, ingénieur ou niveau ingénieur, technicien, vacataire, autre (préciser)
- (3) **Durée missions** : indiquer en mois la durée totale des missions (y compris celles non financées par l'ANR) effectuées sur le projet
- (4) **Devenir professionnel** : CDI, CDD, chef d'entreprise, encore sur le projet, post-doc France, post-doc étranger, étudiant, recherche d'emploi, sans nouvelles
- (5) **Type d'employeur** : enseignement et recherche publique, EPIC de recherche, grande entreprise, PME/TPE, création d'entreprise, autre public, autre privé, libéral, autre (préciser)
- (6) **Type d'emploi** : ingénieur, chercheur, enseignant-chercheur, cadre, technicien, autre (préciser)
- (7) **Lien au projet ANR** : préciser si l'employeur est ou non un partenaire du projet
- (8) **Valorisation expérience** : préciser si le poste occupé valorise l'expérience acquise pendant le projet.

Les informations personnelles recueillies feront l'objet d'un traitement de données informatisées pour les seuls besoins de l'étude anonymisée sur le devenir professionnel des personnes recrutées sur les projets ANR. Elles ne feront l'objet d'aucune cession et seront conservées par l'ANR pendant une durée maximale de 5 ans après la fin du projet concerné. Conformément à la loi n° 78-17 du 6 janvier 1978 modifiée, relative à l'Informatique, aux Fichiers et aux Libertés, les personnes concernées disposent d'un droit d'accès, de rectification et de suppression des données personnelles les concernant. Les personnes concernées seront informées directement de ce droit lorsque leurs coordonnées sont renseignées. Elles peuvent exercer ce droit en s'adressant l'ANR (<http://www.agence-nationale-recherche.fr/Contact>).

F ANNEXES

F.1 RAPPORTS

WPI

WP2

WP3

WP4

F.2 ECOLE THEMATIQUE



Ecole thématique HYEP 2017 Imagerie Hyperspectrale –

Lieu : Aspet Le Village-Club « Le Bois Perché »
<http://www.vnt31.net/nos-etablisements/aspet-le-niemont-ovreneen/>

Localisation : proximité de Toulouse
A 500 m d'altitude dans le piémont pyrénéen,
au pied du massif du Cagire (2000 m) et à 35
km à peine de l'Espagne

Dates : 28 août au 1er septembre 2017
Durée : 5 (jours), arrivée : lundi 28 août matin

Site d'inscription :
<https://hyep2017.sciencesconf.org/> (

Intervenants (ressentis) :

Mauro Dalla Mura (GIPSA lab, Grenoble)
Yannick Deville (IRAP)
Pierre Gancarski (ICUBE Université de
Strasbourg)
Dino Ienco (TETIS, Irstea)
Gintautas Mozgeris (University, Faculty of
Forestry and Ecology)
Arnaud Lebris (IGN)
Rodolphe Marion (CEA)
Xavier Briottet (ONERA)
J. Baptiste Feret (TETIS Irstea)
Camille Lelong (TETIS, CIRAD)
Christiane Weber (TETIS, CNRS)



Hyperspectral Imagery for Environmental urban Planning
Projet ANR: 14-CE22-0016-01
<http://hyep.cnrs.fr/>

Contexte

L'imagerie hyperspectrale ne diffère pas des grandes lignes de traitement en télédétection. Il faut en effet traiter les mesures acquises afin d'accéder aux quantités spectrales d'intérêt pour ensuite identifier les paramètres chimiques ou biophysiques de la surface, intéressants pour les applications développées. Etalonnage, corrections radiométrique et géométrique sont donc de mise. Cependant, une étape cruciale de réduction du jeu de données est essentielle.

La correction atmosphérique reste une étape nécessaire mais délicate afin de s'affranchir des phénomènes de diffusion, d'absorption et/ou d'émission atmosphériques qui ont chacun un impact radiatif spectralement différent et dont l'importance dépend de l'état de l'atmosphère. La réflectance, l'émissivité spectrale ou la température de surface sont disponibles en sortie de correction.

Ensuite, selon l'application, des traitements de plus haut niveau sont réalisés : classifications supervisées ou non, utilisation de données multisources permettant de traiter conjointement les apports spectraux et spatiaux, etc. Enfin, l'imagerie hyperspectrale permet d'identifier des pixels purs (pôles de mélange ou *endmembers*) pour ensuite identifier la composition interne d'un pixel en termes de pôles de mélange et de leur abondance (démélange ou *unmixing*).

Pour les thématiciens, l'intérêt de l'image hyperspectrale est bien entendu de pouvoir remonter aux propriétés biophysiques des milieux et caractériser l'état de l'environnement.

Les axes du programme se définissent donc autour de l'architecture présentée ci-dessus en proposant (1) des approfondissements sur certaines étapes comme les corrections radiométriques, les traitements de démélange et de classification.

(2) Les méthodes de fusion avec les données panchromatiques ou des données d'autres sources comme le LIDAR seront aussi présentées.

(3) Des questionnements sur les applications et les produits utilisables par les acteurs de terrain. Une étude de cas sera proposée avec la préparation d'un survol et sa réalisation avec un drone, complétée par des relevés terrain (description et signatures spectrales) et la mise en forme de méta-données, puis des traitements et des discussions sur les résultats obtenus. Ceci permettra aux participants et notamment aux jeunes collègues d'envisager le déroulement complet d'une mission.

L'école bénéficie des avancées réalisées dans le cadre de l'ANR HYEP (HYperspectral imagery for Environmental urban Planning)

Hyperspectral Imagery for Environmental urban Planning

Projet ANR 14-CE22-0016-01

<http://hyep.cnrs.fr/>

WP leader : ESPACE

Livrable : WP1.1 Atmospheric corrections

WP leader : S GADAL

Livrable WP1.1

Mois Décembre

Année

2015

Auteurs :

Guillaume Roussel (LIVE)

Xavier Briottet (Onera)

Dissémination : public

Interne au consortium

Rappel :

Dans vos communications, il faut mentionner le financement ANR. Pour cela je propose la phrase suivante : **"Cette recherche a bénéficié du financement de l'Agence Nationale de la Recherche dans le cadre du projet ANR 14-CE22-0016-01 »**

Enregistrer le fichier sous le nom dans le site web

Jalon	Version en cours	HYEP_01_GR_XB.doc
	Version finale (validée)	HYEP_01_VF.doc
Livrable	Version en cours	HYEP_Roussel
	Version finale (validée)	HYEP_W1.1 .doc.
	Version : Vfin... J1, livrable WP 1.1	Auteur : Initiales (GR G Roussel et aC Weber

Document Information

ANR 14-CE22-0016-01

Acronym HYEP

Titre Hyperspectral Imagery for Environmental urban Planning

URL <http://hyep.cnrs.fr/>

Suivi ANR

Deliverable Number WP1

WP 1.1 **Titre** Corrections atmosphériques :

WP 1.2 Bases de données morphospectrales

Date : Contractuel T+6 date 20/01/2016 Intermédiaire
Statut x Final
Nature du deliverable : x Report Prototype Autre
Dissémination: Confidentialité x Public

Emploi

CDD x durée 18 mois

Nom Roussel Prénom Guillaume

Responsable X. Briottet et C. Weber

Lieu(x) ONERA Toulouse

OBJECTIFS WP1 Bases de données Morphospectrales

WP1.1 Corrections atmosphériques : comparaison (ONERA LIVE) Rapports 10/ 2015 02/2016 (final)

Validation 06/2016 ESPACE : S Gadal

WP1.2 Hyperspectral database design (LIVE)

Rapports 06/2015 02/2016 (final)

Validation 06/2016 ESPACE : S Gadal

WP1.3 Campagne sur KAUNAS (ESPACE)

Rapport 01/2016 05/2016 (final)

Validation : 06/2016 ESPACE : S Gadal

Les objectifs sont de fournir une représentation des surfaces en milieux urbain qui correspondent à l'hétérogénéité des formes et des matériaux. Ce WP se détermine en trois sous tâches : les prétraitements nécessaires à l'application des méthodes par soustraction des perturbations atmosphériques, mais aussi des ombres.

1.1 Pré-traitements

Les travaux se déroulent en conformité avec le plan de travail initialement prévu. D'une part un effort conséquent a été réalisé sur les pré-traitements d'images aéroportées (post doc. G Roussel) en effet les corrections atmosphériques nécessaires à un traitement de qualité nous a conduit à tester plusieurs méthodes, à comparer les résultats et à fournir des images à diverses résolutions (de 2 à 30m) (1m sur les données de Kaunas) permettent aux équipes de travailler.

1.1 Bases de données morphospectrales

1.2.1 Bibliothèques de signatures spectrales (spectral libraries)

L'existence de bases de signatures spectrales (BSS) collectées par divers auteurs, équipes ou institutions avec plus ou moins de références correctes a nécessité une analyse approfondie de la littérature afin de les identifier mais aussi de les localiser. Cette étape a été nécessaire à l'identification des éléments pertinents relevés par les collègues à partir de divers instruments, dans différentes conditions de prise de vue, in situ ou au laboratoire. Si la littérature fournit un état des lieux plus ou moins détaillée, les accès aux BSS ne sont pas toujours aisés (restriction ou disparition), les descriptions ne sont pas toujours de qualité suffisante (métadonnées incomplètes). Un état des lieux des sites et BSS intéressantes a été réalisé. il a fallu associer ce qui était pertinent dans notre domaine (ontologie urbaine d'occupation du sol / utilisation) avec ce qui se discrimine sur les images que nous avons obtenues. Un rapprochement a été réalisé entre les éléments urbains, leurs caractéristiques (couleur, texture, matériaux) et les valeurs des BSS relevées sur le terrain ou dans la littérature.

1.2.2 Détermination des éléments morpho-spectraux

Les missions de Kaunas ont permis d'établir à partir de survols, de relevés terrain et de mesures en laboratoire, des caractéristiques précises des matériaux urbains servant à la description des bâtiments. Des Indices de formes ont été appliqués en sus afin d'améliorer la caractérisation et l'identification des surfaces urbaines, et également afin d'enrichir les bases de données de type spectrale, en intégrant la morphologie des objets urbains. Une librairie morpho-spectrale pourra donc être générée et exploitée pour classer les objets urbains.

1.2.3 Standardisation de la base de données morphospectrales

Les valeurs spectrales et les indices de formes vont être rassemblés au sein d'une BD permettant aux membres du consortium de les utiliser pour des traitements ultérieurs.

1. Introduction

L'environnement urbain est un écosystème dynamique et complexe caractérisé par une forte hétérogénéité en termes de forme et de taille d'objet, une structure en trois dimensions impliquant l'omniprésence potentielle de zones d'ombre ainsi qu'une grande variété de matériaux. De nombreux articles tendent à prouver que l'imagerie hyperspectrale, de par la précision de sa résolution spectrale, constitue un outil prometteur pour la discrimination de ces derniers. Herold et al. [1] ont montré que les capteurs hyperspectraux étaient bien plus efficaces pour la caractérisation des sols, des minéraux et des végétaux que l'imagerie multispectrale. Platt et al. [2] et Tan et al. [3] soulignent quant à eux les bénéfices induits par l'utilisation de telles données dans le cadre d'applications de classification des surfaces urbaines. Enfin, plusieurs auteurs dont Chen [4] insistent sur l'apport de l'imagerie hyperspectrale concernant la caractérisation des surfaces imperméables.

Il convient toutefois de préciser que le signal de luminance obtenu au niveau d'un capteur aéroporté est altéré par divers mécanismes relatifs à son passage au travers de l'atmosphère (diffusion, absorption, effets de couplage) ainsi qu'à la topographie de l'environnement (réflexions, ombres). Or de nombreuses applications de traitement d'image gagneraient à s'affranchir de ces effets afin de travailler sur des données ne dépendant que du ou des types de matériau présents sur le terrain. Cette mesure appelée réflectance s'obtient par l'intermédiaire d'un processus de transfert radiatif inverse, dont plusieurs occurrences existent dans la littérature. ATREM [5] et ACORN [6] fonctionnent sur la base d'une hypothèse lambertienne avec un sol plat et homogène. S'appuyant sur le code MODTRAN [7], FLAASH [8] et Cochise [9] considèrent pour leur part un arrière-plan hétérogène. Ces quatre méthodes ne tiennent cependant aucun compte du relief, ce qui est incompatible avec un environnement urbain généralement caractérisé par une forte rugosité. ATCOR4 [10] et SIERRA [11] contournent ce problème via l'utilisation d'un modèle numérique d'élévation (MNE) tout en demeurant incapables de modéliser avec précision les effets de transfert radiatif dans les zones d'ombre. La méthode ICARE [12] utilise quant à elle un modèle traitant de manière différenciée les surfaces situées à l'ombre et au soleil, associé à un modèle vectoriel 3D de la zone couverte et à un algorithme DDV [13] (Dark Dense Vegetation), lesquels permettent une estimation précise des termes radiatifs liés à l'environnement. Ces corrections se font malheureusement au prix d'une complexité temporelle élevée, sans compter le besoin d'avoir accès à un MNE pour la zone à traiter. Considérant ces deux défauts, Chen et al. [14] ont introduit une méthode empirique visant à calculer rapidement une mesure de réflectance uniquement à partir d'une image en luminance et des conditions atmosphériques et d'illumination.

L'objectif de ce travail est d'analyser et de comparer trois méthodes de correction atmosphérique développées à l'Onera – Cochise, ICARE ainsi que l'approche empirique de Chen et al. – et de mesurer les performances de chacune sur des images de résolution spatiale variable.

2. Modèle de transfert inverse

L'objectif d'un tel modèle est, à partir d'une donnée capteur en luminance et d'informations sur l'éclairage de la scène, de calculer une mesure de réflectance propre aux matériaux avec lesquels interagit le signal lumineux. Paramètre sans unité et dépendant de la longueur d'onde, la réflectance est un rapport entre la proportion de luminance réfléchi par une surface et la proportion d'éclairage reçue par cette même surface. En partant d'une hypothèse lambertienne et pour des conditions d'illumination données, la valeur de réflectance d'un pixel i de coordonnées (x, y) peut être formulée comme suit :

$$\rho(i) = \frac{\pi \times L_{dir}(i)}{E_{tot}(i) \times T_{dir}^{\uparrow}} \quad (1)$$

avec :

$$L_{dir}(i) = L_{tot}(i) - L_{env}(i) - L_{atm} \quad (2)$$

$$E_{tot}(i) = E_{dir}(i) + E_{dif}(i) + E_{coup}(i) + E_{refl}(i) \quad (3)$$

où L_{tot} est la luminance totale mesurée au niveau du capteur, L_{env} la part de L_{tot} provenant du voisinage de la cible et L_{atm} la part diffusée par l'atmosphère sans interaction avec le sol. E_{tot} , l'éclairement total associé au pixel cible, est divisé en quatre parties :

- E_{dir} : éclairement direct associé aux photons atteignant directement la cible depuis l'espace, sans interaction avec l'atmosphère.
- E_{dif} : éclairement diffus associé aux photons diffusés au moins une fois par l'atmosphère avant d'atteindre la cible.
- E_{coup} : éclairement de couplage associé aux photons effectuant au moins un aller-retour entre le sol et l'atmosphère avant de percuter la cible.
- E_{refl} : éclairement réfléchi associé aux photons percutant dans un premier temps la structure 3D voisine de la cible au moins une fois.

Enfin, T_{dir}^{\uparrow} correspond à la transmission ascendante directe. La plupart de ces termes sont illustrés dans la figure ci-dessous :

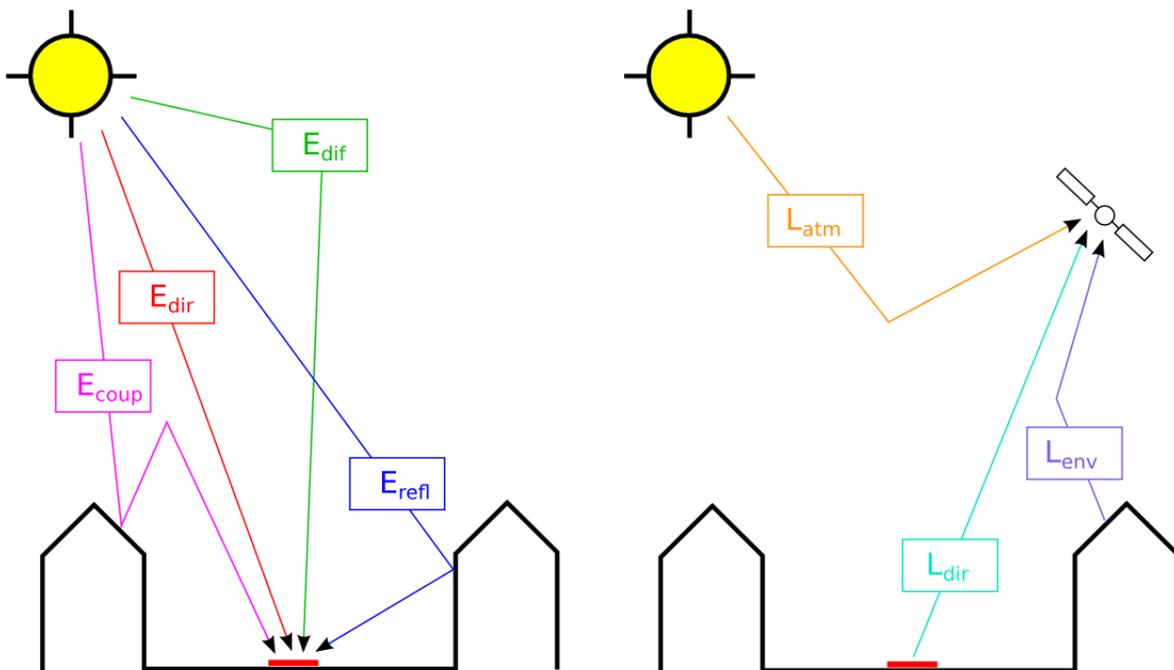


Figure 1 : Termes radiatifs dans un canyon urbain

3. Méthodes de correction atmosphérique

Trois algorithmes développés à l'Onera sont analysés dans cette étude. Le premier, Cochise, fonctionne sur la base d'une hypothèse « sol plat ». Le second, décrit dans Chen et al. [14], fait la distinction entre zones d'ombre et ensoleillées via une estimation parfois approximative (mais rapide) de certains termes radiatifs. Le troisième, ICARE, utilise pour sa part un modèle tridimensionnel construit à partir d'un modèle numérique de surface pour estimer de la façon la plus précise possible l'ensemble des termes du modèle radiatif.

3.1. Cochise

Pour calculer une valeur de réflectance, Cochise considère un sol plat et hétérogène. Le terme E_{refl} est par conséquent ignoré, tandis que les composantes directe et diffuse de l'éclairement sont considérées constantes dans l'ensemble de la scène. Partant de l'équation (2) nous avons :

$$L_{tot}(i) = L_{atm} + L_{dir}(i) + L_{env}(i) \quad (4)$$

avec :

$$L_{dir}(i) = T_{dir}^{\uparrow} \frac{\rho(i)}{\pi} \cdot \frac{E_{dir} + E_{dif}}{1 - \rho_c(i) \cdot S} \quad (5)$$

$$L_{env}(i) = T_{dif}^{\uparrow} \iint_{(u,v) \in V(x,y)} \frac{\rho(u,v)}{\pi} \cdot \frac{E_{dir} + E_{dif}}{1 - \rho_c(u,v) \cdot S} \cdot F(u,v) \cdot du \cdot dv \quad (6)$$

T_{dir}^{\uparrow} et T_{dif}^{\uparrow} sont respectivement les composantes directe et diffuse de la transmission ascendante. $V(x,y)$ correspond au voisinage du pixel cible i de coordonnées (x,y) , S est l'albedo sphérique de l'atmosphère et :

$$\rho_c(i) = \iint_{(u,v) \in V(x,y)} \rho(u,v) \cdot G(u-x, v-y) \cdot du \cdot dv \quad (7)$$

est la valeur de réflectance moyenne associée à l'effet de couplage sol/atmosphère. L'effet de couplage n'est ainsi pas modélisé par un terme unique E_{coup} mais sous la forme d'une pondération de la somme des éclaircements direct et diffus. Les fonctions d'environnement G et F représentent la probabilité qu'un rayon lumineux associé à cet effet interagisse avec le voisin (u,v) . Ces fonctions sont calculées par l'intermédiaire d'un algorithme Monte Carlo [15]. Les paramètres atmosphériques apparaissant dans (4)-(6), à savoir L_{atm} , T_{dir}^{\uparrow} , T_{dif}^{\uparrow} , E_{dir} , E_{dif} et S sont estimés à l'aide du code de transfert radiatif MODTRAN, connaissant un certain nombre d'autres paramètres

tels que le type et l'abondance des aérosols, le profil atmosphérique, les contenus en vapeur d'eau et enfin les conditions d'illumination.

Le processus d'inversion permettant d'aboutir à la réflectance ρ est basé sur une approche itérative. Au départ, la réflectance associée à l'environnement de la cible est considérée égale à celle de cette dernière :

$$\rho_1(i) = \frac{\pi(L_{tot}(i) - L_{atm})}{(T_{dir}^{\uparrow} + T_{dif}^{\uparrow}) \cdot (E_{dir} + E_{dif}) - \pi S(L_{tot}(i) - L_{atm})} \quad (8)$$

La valeur de réflectance suivante est ensuite calculée ainsi :

$$\rho_{n+1}(i) = \frac{\pi \left(L_{tot}(i) - L_{atm} - T_{dif}^{\uparrow} E_{dif}^{(n)}(i) \right)}{T_{dir}^{\uparrow} \frac{E_{dir} + E_{dif}}{1 - \rho_c^{(n)}(i) \cdot S}} \quad (9)$$

où :

$$\left\{ \begin{array}{l} \rho_c^{(n)}(i) = \iint_{(u,v) \in V(x,y)} \rho^{(n)}(u,v) \cdot G(u-x, v-y) \cdot du \cdot dv \\ E_{dif}^{(n)}(i) = \iint_{(u,v) \in V(x,y)} \frac{\rho^{(n)}(u,v)}{\pi} \cdot \frac{E_{dir} + E_{dif}}{1 - \rho_c^{(n)}(u,v)} F(u,v) \cdot du \cdot dv \end{array} \right. \quad (10)$$

Généralement, seules deux occurrences sont suffisantes pour atteindre la convergence.

3.2. ICARE

L'algorithme précédent fonctionne sur la base d'une hypothèse « sol plat », c'est-à-dire qu'il ne tient aucun compte des effets induits par le relief d'une scène urbaine (réflexions, ombres), lesquels peuvent être déterminants dans le cas où les bâtiments en présence sont hauts, et d'autant plus lorsque l'image est réalisée alors que le soleil est bas. La méthode ICARE s'appuie pour sa part sur un modèle vectoriel 3D qui lui permet d'une part d'identifier automatiquement les zones situées à l'ombre, et d'autre part d'intégrer au calcul de transfert radiatif la part d'éclairement réfléchi due à la structure tridimensionnelle environnant chaque pixel.

3.2.1 Modélisation des termes radiatifs

L'expression analytique de la réflectance utilisée est celle de l'équation (1), à partir de laquelle chaque terme est modélisé de façon individuelle. L'éclairement direct E_{dir} , dominant pour les pixels ensoleillés, dépend entre autres des angles zénithaux et azimutaux solaires θ_s et φ_s , de la pente au sol et de l'éclairement solaire au sommet de l'atmosphère E_{TOA} :

$$E_{dir}(i) = E_{TOA} \cdot T_g^\downarrow(i, \theta_s) \cdot \langle \vec{N}(i) \cdot \vec{n}_s \rangle \cdot e^{-\frac{\tau^\downarrow(i)}{\cos(\theta_s)}} \cdot bool(i, \theta_s, \varphi_s) \quad (11)$$

T_g^\downarrow est la transmission gazeuse descendante et τ^\downarrow l'épaisseur optique total au-dessus de la cible. \vec{N} est un vecteur unitaire orthogonal à la surface élémentaire centrée sur le pixel cible, \vec{n}_s un vecteur unitaire pointant vers le soleil et $\langle \cdot \rangle$ correspond au produit scalaire. Enfin la fonction $bool(\cdot)$ permet, en fonction des positions du soleil et du pixel cible, de déterminer si ce dernier est à l'ombre ou au soleil (la fonction sera égale à 0 dans le premier cas et 1 dans le second).

L'éclairement diffus est quant à lui obtenu en intégrant les luminances ciel descendantes L_{ciel}^d sur l'angle de vue du ciel α_{ciel} associé à chaque pixel :

$$E_{dif}(i) = T_g^\downarrow(i, \theta_s) \times \iint_{\alpha_{ciel}(i)} L_{ciel}^d(\theta, \varphi) \cos \theta \sin \theta d\theta d\varphi \quad (12)$$

Troisième composante descendante, l'éclairement réfléchi E_{refl} est issu des réflexions des composantes directes et diffuse sur les surfaces avoisinantes. On a ainsi :

$$E_{refl/dir}(i) = \iint_{\alpha_{ciel}(i)} E_{dir}(P_{d\omega}) \frac{\rho(P_{d\omega})}{\pi} \times \langle \vec{N}(i) \cdot \vec{n}_{iP_{d\omega}} \rangle T_g(P_{d\omega}, i) \times e^{-\tau(P_{d\omega}, i)} \sin \theta d\theta d\varphi \quad (13)$$

$$E_{refl/dif}(i) = \iint_{\alpha_{ciel}(i)} E_{dif}(P_{d\omega}) \frac{\rho(P_{d\omega})}{\pi} \times \langle \vec{N}(i) \cdot \vec{n}_{iP_{d\omega}} \rangle T_g(P_{d\omega}, i) \times e^{-\tau(P_{d\omega}, i)} \sin \theta d\theta d\varphi \quad (14)$$

$P_{d\omega}$ est la surface élémentaire centrée sur le pixel P visée par l'angle solide $d\omega$ provenant de la cible, $\rho(P_{d\omega})$ est la valeur de réflectance associée au pixel P , $\vec{n}_{iP_{d\omega}}$ est la normale dont la direction est défini par la cible et le pixel P , $T_g(P_{d\omega}, i)$ est la transmission gazeuse sur le chemin délimité par la cible et le pixel P , et $\tau(P_{d\omega}, i)$ est l'épaisseur optique totale associée à ce chemin. Enfin $\overline{\alpha_{ciel}}$ est le complémentaire de l'angle de vue du ciel de la cible ($\overline{\alpha_{ciel}} = 2\pi - \alpha_{ciel}$). A noter que le modèle gère les réflexions à la fois simples et doubles (E_{refl^2}).

Enfin l'éclairement de couplage est tout d'abord calculé au-dessus du relief, dans un plan fictif, avant d'être pondéré en fonction du relief associé à chaque pixel :

$$E_{coup}(i) = \frac{\bar{I}\rho \cdot S}{1 - \rho_e S} \iint_{\alpha_{ciel}(i)} \frac{\cos \theta d\omega}{\pi} \quad (15)$$

avec :

$$\bar{I}\rho = \frac{\iint_R \rho(i) \left(E_{dir}(i) + E_{dif}(i) + E_{refl}(i) + E_{refl^2}(i) \right) \alpha_{ciel}(i) dU}{\iint_R \alpha_{ciel}(i) dU} \quad (16)$$

et :

$$\rho_e = \frac{\iint_R \rho(i) \alpha_{ciel}(i) dU}{\iint_R \alpha_{ciel}(i) dU} \quad (17)$$

où R représente la scène observée.

Toutes les composantes d'éclairement ont été détaillées. Les deux derniers termes à estimer sont les luminances atmosphériques et d'environnement. Le terme de luminance atmosphérique dépend à la fois de la distance sol/capteur et du champ de vision de ce dernier. Dans ICARE, il est calculer pour une altitude moyenne par l'intermédiaire de 6S [16], un code de transfert radiatif direct, ce dernier étant également utilisé pour calculer les transmissions ascendantes directe (T_{dir}^\uparrow) et diffuse (T_{dif}^\uparrow), l'éclairement au sommet de l'atmosphère E_{TOA} , les luminances ciel L_{ciel}^d , les épaisseurs optiques τ^\downarrow et l'albédo sphérique S .

Enfin, la luminance d'environnement est estimée avec la méthode *Dark Dense Vegetation* (DDV) proposée par Kaufman et al. [16], laquelle s'appuie sur les informations contenues dans les pixels sombres de l'image.

$$L_{env}(i) = L_{tot}(i) - L_{atm} - \left(E_{dir}(i) + E_{dif}(i) + E_{coup}(i) + E_{refl}(i) \right) \frac{\rho_{dark}}{\pi} T_{dir}^\uparrow \quad (18)$$

où ρ_{dark} est la valeur de réflectance correspondant à un pixel sombre de la scène. Un des avantages de cette méthode est d'utiliser le principe de conservation de l'énergie puisque la luminance d'environnement est calculée à partir de l'ensemble des autres termes.

3.2.2 Déroulement de l'algorithme d'inversion

Trois termes radiatifs peuvent être directement calculés à partir des données d'entrée (une image en luminance, un modèle vectoriel de surface et un ensemble de données relatives aux conditions atmosphériques et de prise de vue), ce sont les éclairnements direct et diffus au niveau du sol et la luminance atmosphérique au niveau du capteur. Ces termes resteront constants tout au long du processus d'inversion. Les éclairements de couplage et de réflexion ainsi que la luminance

d'environnement dépendent en revanche des valeurs de réflectance de l'environnement, valeurs dont nous n'avons pas connaissance a priori puisque c'est justement ce que l'algorithme d'inversion cherche à estimer. Ce problème est résolu par une approche itérative.

L'initialisation de cette dernière s'appuie sur une hypothèse « sol plat et homogène » impliquant de négliger certains effets environnementaux tels que l'éclairement réfléchi. C'est une hypothèse réductrice mais qui permet néanmoins d'obtenir un premier ordre de grandeur des réflectances présentes sur la scène. Une valeur de réflectance moyenne associée à l'ensemble de la scène est tout d'abord calculée :

$$\bar{\rho} = \frac{\overline{L_{tot}} - L_{atm}}{S(\overline{L_{tot}} - L_{atm}) + \frac{1}{\pi}(E_{dir} + E_{dif}) \times (T_{dir}^{\uparrow} + T_{dif}^{\uparrow})} \quad (19)$$

Cette réflectance moyenne est utilisée notamment pour initialiser le terme d'éclairement de couplage :

$$E_{coup_plat} = \frac{\bar{\rho}S}{1 - \bar{\rho}S} \cdot (E_{dir} + E_{dif}) \quad (20)$$

Le terme de luminance d'environnement est pour sa part initialisé de la sorte :

$$L_{env_plat} = \frac{E_{dir} + E_{dif}}{1 - \bar{\rho}S} \cdot \frac{\bar{\rho}}{\pi} \cdot T_{dif}^{\uparrow} \quad (21)$$

Enfin, il convient également d'attribuer une réflectance par défaut aux surfaces du modèle vectoriel qui ne sont pas couvertes par l'image (occultations, parois verticales) en prévention des calculs d'éclairement réfléchis de l'itération suivante. La solution proposée par ICARE consiste à leur attribuer un spectre de réflectance moyen créé à partir d'un ensemble de spectres associés à des matériaux typiquement urbains (granite, pavés, asphalte, briques, etc...).

A ce niveau de l'algorithme, une première valeur de réflectance est calculée pour chaque pixel de la scène. Le processus itératif peut alors commencer. Dès la première itération, l'hypothèse « sol plat et homogène » au profit d'une hypothèse plus réaliste, impliquant un sol à la fois hétérogène et accidenté. L'éclairement de couplage est ainsi réestimé en utilisant l'équation (15) tandis que l'éclairement réfléchi est estimé une première fois, dans les deux cas à partir de la première carte de réflectance. En ce qui concerne la luminance d'environnement en revanche, la valeur calculée lors de l'initialisation est conservée. En effet la méthode DDV est particulièrement sensible aux erreurs de réflectance. Au terme de l'initialisation, les valeurs de réflectance sont trop imprécises pour pouvoir utiliser cette méthode en toute confiance. Ce n'est donc qu'à partir de la seconde itération qu'elle est mise en place.

La méthode DDV implique de choisir un pixel sombre dans l'image. L'idéal est de choisir un pixel à l'ombre avec la réflectance la plus faible possible. Toutefois, une étude de sensibilité réalisée dans la thèse de Sophie Lachéradé [17] montre que le bilan d'erreur lié au processus d'inversion est beaucoup plus favorable au soleil qu'à l'ombre. La réflectance d'un pixel ensoleillé est en effet

estimée bien plus précisément que celle d'un pixel ombragé. Afin d'améliorer la méthode DDV, au lieu d'un unique pixel sombre, nous avons sélectionné un couple de pixels situés de part et d'autre de la frontière entre une zone d'ombre et une zone ensoleillée (appelons O le pixel à l'ombre et L le pixel au soleil). En raison de leur proximité spatiale, les propriétés optiques de ces deux pixels sont considérées similaires, ce qui nous permet d'attribuer la réflectance du pixel L au pixel O lors du calcul de la luminance d'environnement :

$$L_{env}(O) = L_{tot}(O) - L_{atm} - (E_{dif}(O) + E_{coup}(O) + E_{refl}(O)) \frac{\rho(L)}{\pi} T_{dir}^{\uparrow} \quad (22)$$

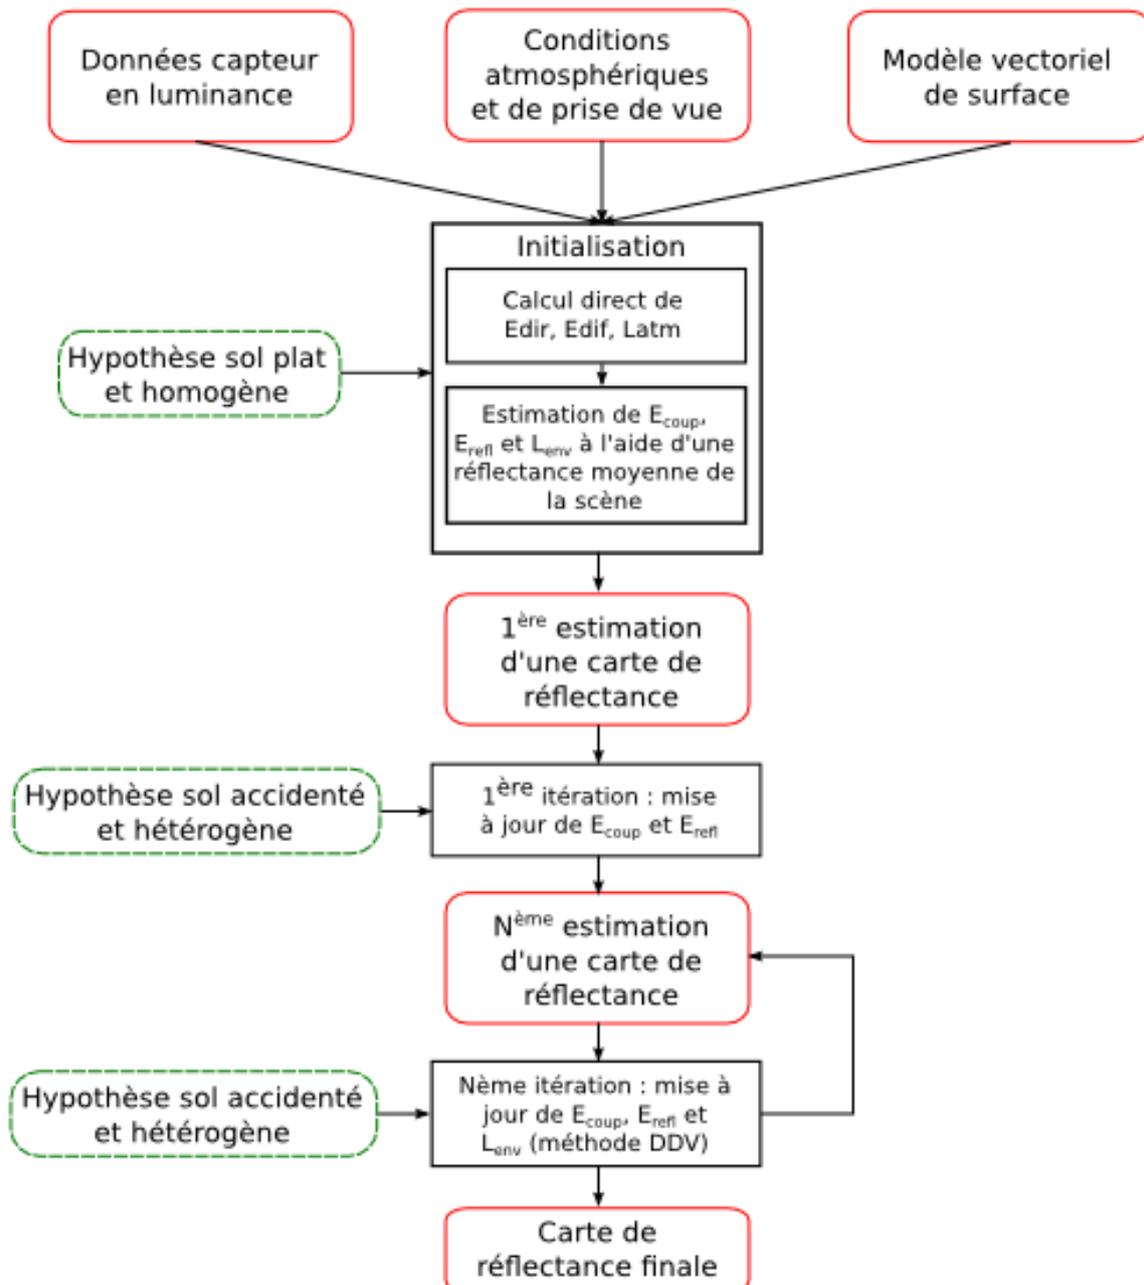


Figure 2 : Fonctionnement global de la méthode ICARE

Suite à cette seconde itération, le processus est répété jusqu'à convergence du système. La méthode globale est résumée par la figure 2.

3.3. Méthode empirique

Les proportions des termes radiatifs de l'équation (3) dépendent fortement du caractère ombragé ou non de la cible. Par conséquent, Chen et al. [14] ont décidé d'estimer différemment l'éclairement associé à une cible selon que celle-ci soit située à l'ombre ou au soleil. L'algorithme original a été modifié de sorte à ce que les termes radiatifs ne soient plus calculés par 6S [15] mais par MODTRAN [7], plus adapté à l'imagerie hyperspectrale en raison de sa meilleure résolution spectrale. Le schéma ci-dessous illustre le fonctionnement global de la méthode :

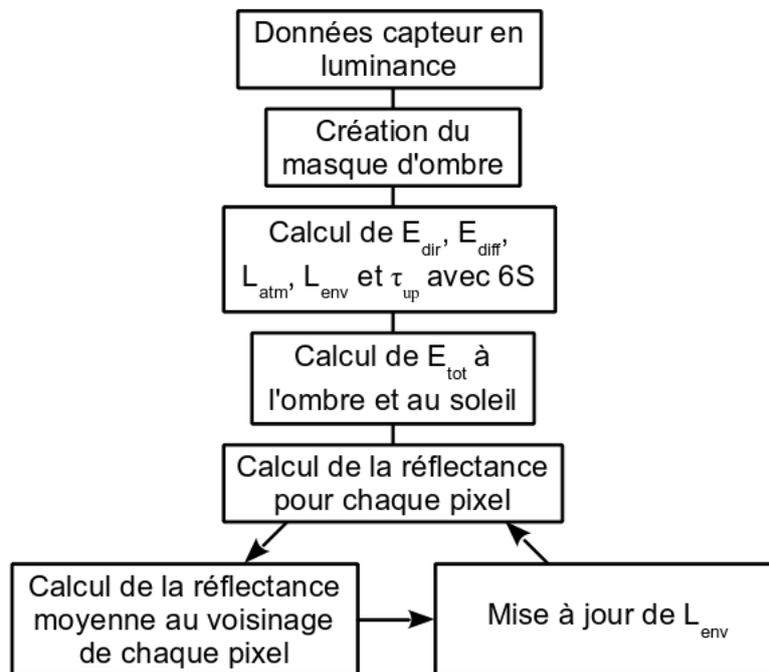


Figure 2 : Fonctionnement global de la méthode empirique

3.3.1 Masque d'ombre

Avant toute chose, il convient d'identifier l'ensemble des pixels de l'image situés à l'ombre. Pour ce faire, nous utilisons l'algorithme de de détection d'ombre automatique proposé par Nagao et al. [18] afin d'associer un masque d'ombre à l'image traitée (cf. figure 3). Adeline et al. [19] ont en effet montré que cet algorithme présentait un excellent compromis entre performances et autonomie.



(a)

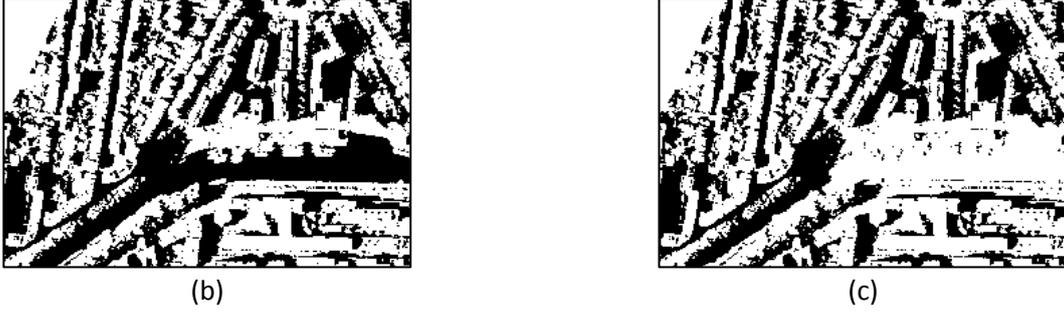


Figure 3 : (a) Composition RVB, (b) masque d'ombre obtenu avec l'algorithme de Nagao original, (c) masque d'ombre obtenu avec l'algorithme de Nagao modifié.

Le masque est obtenu par l'intermédiaire d'un processus de seuillage d'histogramme automatique réalisé sur la combinaison de bandes suivante :

$$L_{comb}(i) = \frac{2L_r(i) + L_v(i) + L_b(i) + 2L_{pir}(i)}{6} \quad (23)$$

où L_r , L_v , L_b et L_{pir} correspondent respectivement aux valeurs de luminances associées aux bandes rouge, verte, bleu et proche infrarouge. Comme précisé dans [19], l'algorithme de Nagao peut être mis en défaut si des pixels d'eau sont présents dans l'image. Ces derniers seront en effet considérés comme étant des pixels ombragés. Pour résoudre ce problème, une étape supplémentaire est requise. Un second seuillage d'histogramme est appliqué sur l'ensemble des pixels à l'ombre identifié par le premier, en ne considérant cette fois que la bande verte, laquelle a montré la meilleure capacité à différencier une zone aqueuse ensoleillée d'une zone d'ombre. Le masque d'ombre en sortie du processus est une matrice mono-bande M de même dimension que l'image traitée, telle que $M(i) = 0$ pour un pixel au soleil et $M(i) = 1$ pour un pixel à l'ombre.

3.3.2 Caractérisation de l'éclairement

Dans les zones ensoleillées, les termes d'éclairement direct et diffus représentent 95% [14] de l'éclairement total, ce qui implique que E_{tot} peut être raisonnablement approximé par ces deux termes. Dans les zones ombragées, l'éclairement direct est nul et l'éclairement total composé principalement des composantes diffuse (potentiellement atténué par les structures tridimensionnelles proches) et réfléchi. Généralement faible, le terme de couplage est négligé dans les deux cas, ce qui nous conduit à l'expression approximée suivante :

$$\begin{cases} E'_{tot}(i) \approx E_{dir} + E_{dif} & \text{si } M(i) = 0 \\ E'_{tot}(i) \approx \alpha_{sky} \times E_{dif} + E_{refl} & \text{si } M(i) = 1 \end{cases} \quad (24)$$

où

$$E_{refl} = \kappa \times (E_{dir} + E_{dif}) \times \bar{\rho} \quad (25)$$

$\alpha_{sky} \in [0,1]$ est un facteur mesurant la portion de ciel vue depuis le sol. Un pixel situé dans une zone parfaitement plate sera associé à un facteur de vue du ciel égal à 1. Ce dernier peut être calculé en utilisant soit un modèle numérique de surface, soit des photographies fish-eye [20]. Toutefois, l'un des objectifs de la méthode empirique est d'effectuer ses corrections sans utiliser de données d'élévation. Par conséquent un facteur moyen égal à 0.75 est utilisé pour tous les pixels dans l'ombre, ce choix s'appuyant sur l'étude faite par Gal et al. [20], laquelle affirme que la majorité des pixels situés au fond des canyons urbains présentent un facteur de vue du ciel compris dans l'intervalle [0.7,0.87].

L'éclairement réfléchi dépend de la structure 3D ainsi que des diverses valeurs de réflectances situées dans le voisinage de la cible. Délicat à estimer de façon précise sans MNS, ce terme peut être négligé dans les zones ensoleillées, où il ne représente qu'un faible pourcentage de l'éclairement total, mais pas dans les zones d'ombre. Ici, E_{refl} correspond à la somme des éclairagements direct et diffus pondérée par un facteur κ associé aux effets de la structure 3D et à la réflectance moyenne $\bar{\rho}$ du voisinage de la cible. Dans [14], κ est fixé à 0.2 pour le centre ville et 0 pour les zones suburbaines plus ouvertes. $\bar{\rho}$ dépend pour sa part de valeurs de réflectance dont on ne dispose pas, puisque ce sont justement celles que l'on recherche. Une valeur moyenne de spectres associés à divers matériaux urbains (béton, tuile, acier) est donc utilisée.

3.3.3 Calcul de la luminance d'environnement

L_{env} correspond à la portion de luminance émise par le voisinage de la cible et diffusé par l'atmosphère vers le capteur associé. De même que l'éclairement réfléchi, L_{env} dépend de la réflectance du voisinage de la cible, laquelle est inconnue au départ, et contrairement à $6S$, ce n'est pas une sortie directe du logiciel MODTRAN. L_{env} doit donc être calculée itérativement de la façon suivante :

$$L_{env,t}(i) = \frac{\tau_{dif}^{\uparrow} \cdot E_{tot} \cdot \check{\rho}_t(i)}{1 - \check{\rho}_t(i) \cdot S} \quad (26)$$

où :

$$\check{\rho}_t(i) = \iint_{(u,v) \in V(x,y)} \rho_{t-1}(u,v) \cdot du \cdot dv \quad (27)$$

et :

$$\rho_t(i) = \frac{\pi(L_{tot}(i) - L_{env,t}(i) - L_{atm})}{E'_{tot}(i) \times \tau^{\uparrow}} \quad (28)$$

$\check{\rho}_t$ est le spectre de réflectance moyenne associé au voisinage de la cible pour l'itération t , avec $\check{\rho}_0 = \bar{\rho}$. Généralement, deux itérations de ce processus suffisent pour atteindre la convergence [14]. L_{atm} , $\tau^{\uparrow} = \tau_{dir}^{\uparrow} + \tau_{dif}^{\uparrow}$, E_{dir} , E_{dif} et S sont calculés via MODTRAN, comme dans Cochise.

4. Comparaison des méthodes

Pour le moment, seules deux des trois méthodes détaillées précédemment sont opérationnelles : Cochise et l'approche empirique de Chen et al. [14]. Nous nous concentrerons par conséquent sur ces dernières. Les nombreuses approximations de l'approche empirique la rendant inutilisable pour des applications telles que l'identification de spectres, l'étude se bornera à évaluer les performances des deux méthodes dans le seul cadre de la classification. L'algorithme de classification pour cette évaluation est détaillé dans la section suivante.

4.1. Description des données

Les données à partir desquelles les algorithmes seront comparés ont été acquises sur une zone couvrant à la fois le centre-ville et la proche banlieue de Toulouse (voir figure 4). Deux capteurs de la gamme Hypspx ont été utilisés de simultanément de sorte à couvrir un intervalle de longueurs d'onde allant de 400 à 2500 nm . Le premier est un capteur VNIR-1600 couvrant l'intervalle 400 – 1000 nm avec une résolution spectrale de 3.7 nm pour un total de 160 bandes spectrales. Le second est un capteur SWIR-320m-e et couvre l'intervalle 1000 – 2500 nm avec une résolution spectrale de 6 nm pour un total de 256 bandes spectrales. A terme, trois jeux de données seront accessibles sur cette zone, lesquels ont été acquis en octobre 2012, septembre 2014 et septembre 2015. Pour le moment cependant seul le premier, obtenu dans le cadre de la campagne UMBRA organisée par l'Onera, est disponible. Durant ce vol, les capteurs étaient situés à 2392 m d'altitude, ce qui équivaut pour le capteur VNIR à une résolution spatiale de 84 cm et 170 cm pour le capteur SWIR. Il convient de préciser qu'un souci d'arrimage du capteur VNIR à l'appareil a causé un décalage de l'ensemble des bandes de quelques nanomètres. La présence d'un hublot a également résulté sur un biais de transmission qui a été corrigé par la suite. Enfin l'IGN s'est chargé d'effectuer la registration entre les données issues des deux capteurs.

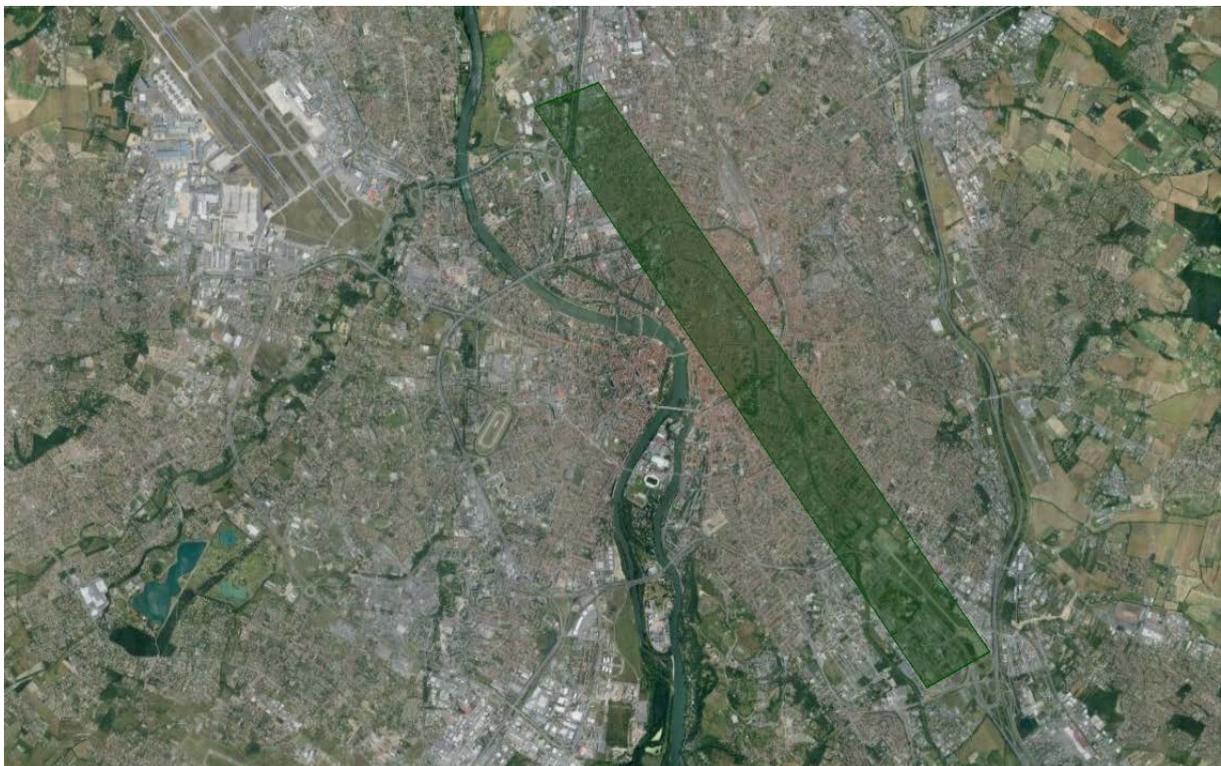


Figure 4 : zone d'intérêt

Dans un premier temps, nous travaillerons sur une sous-partie du tronçon présenté par la figure 4, sous-partie située dans le centre-ville (voir figure 5).



Figure 5 : zone de test

4.2. Correction atmosphérique

La première étape de la méthode Cochise consiste à estimer le contenu en vapeur d'eau de chacun des pixels de l'image à corriger (voir figure 6). Cette étape est basée sur le calcul d'un rapport de régression linéaire (LIRR) décrit dans [21]. L'algorithme utilise les indices spectraux situés de part et d'autre et à l'intérieur d'une bande d'absorption de vapeur d'eau (typiquement 940 ou 1130 nm) :

$$\text{LIRR}(\rho) = \frac{\overline{\tilde{L}_{\text{int}}}}{\text{LIR}(\lambda_{\text{pic}}, \tilde{L}_{\text{bord}}^{(1)}, \dots, \tilde{L}_{\text{bord}}^{(n)})} \quad (29)$$

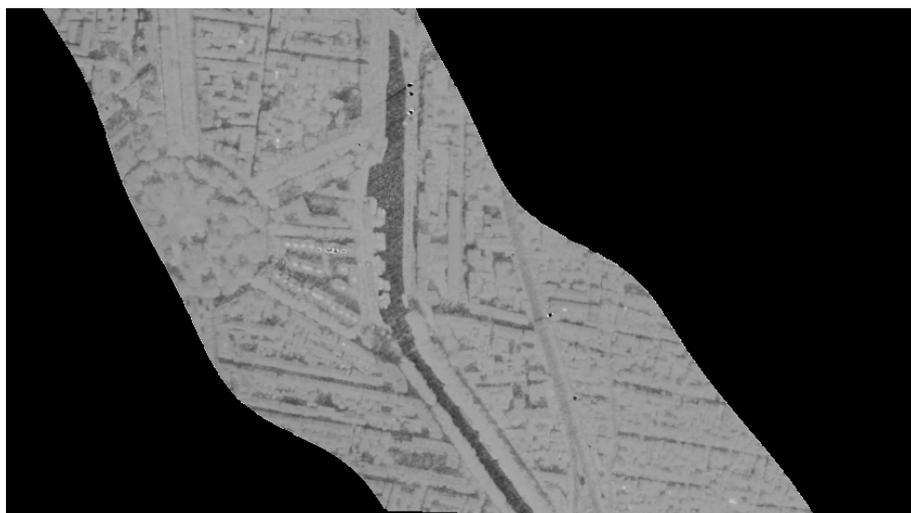


Figure 6 : Carte de contenu en vapeur d'eau

où $\overline{L_{int}}$ correspond à la luminance moyenne des indices spectraux situées au niveau du pic d'absorption tandis que le dénominateur est la luminance obtenue au centre de la bande d'absorption (associé à la longueur d'onde λ_{pic}) par régression linéaire sur les indices spectraux situés sur les bords de la bande (voir figure 6). Cette méthode se base sur l'hypothèse que le LIRR ne dépend pas de la réflectance de surface et est par conséquent directement dépendant du contenu en vapeur d'eau. La bande d'absorption de vapeur d'eau utilisée dans le cadre de ce travail est celle centrée sur 1130 nm, de sorte à utiliser pour le calcul du LIRR des indices spectraux appartenant tous au même capteur. La carte ainsi obtenue témoigne de valeurs assez homogènes sur les zones ensoleillées avec de brusques chutes du contenu en vapeur d'eau dans les zones d'ombre. Or de telles variations n'ont a priori pas lieu d'être. Le contenu en vapeur d'eau évolue généralement de façon assez mesurée et ne devrait pas être impacté par le fait qu'un pixel soit situé à l'ombre ou au soleil. Nous avons donc relancé Cochise en utilisant une valeur de contenu en vapeur d'eau moyenne, en l'occurrence la valeur moyenne de la carte de contenu en vapeur d'eau précédemment obtenue (1.2 g/cm² avec un profil atmosphérique *mid-latitude summer*).

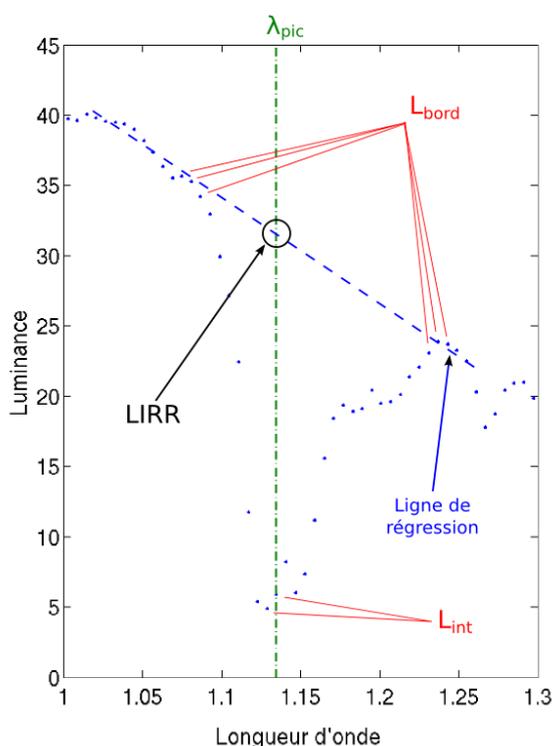


Figure 6 : Illustration de la méthode LIRR, pour la détermination des contenus en vapeur d'eau (longueurs d'onde en µm et luminances en W/m²/sr⁻¹).

Afin de comparer les deux méthodes de correction atmosphérique, nous avons sélectionné deux pixels associés au même matériau (en l'occurrence de la végétation), le premier étant situé au soleil et le second à l'ombre. La figure 7 présente les spectres de réflectance de ces deux pixels obtenus avec Cochise d'une part et la méthode empirique d'autre part. Sur ce graphique, on remarque que l'ombre a un effet radical sur le spectre de réflectance obtenu par l'intermédiaire de Cochise, lequel est complètement aplati. Cet effet est beaucoup moins marqué sur le spectre obtenu avec la méthode empirique, notamment au niveau du *red edge*. Remarquons toutefois qu'au-delà d'un certain seuil (représenté en vert sur la figure et situé aux alentours de 880 nm) le niveau de réflectance du spectre ombragé s'éloigne sensiblement de celui du spectre illuminé. Cela s'explique

par le fait qu'au-delà de ce seuil, le signal à l'ombre est trop faible pour que la valeur de réflectance calculée soit pertinente, ce qui implique que la correction atmosphérique dans les ombres n'est possible que pour des longueurs d'onde inférieures à 880 nm. Précisons enfin qu'au soleil, Cochise effectue une bien meilleure correction que la méthode empirique, notamment au niveau des deux premières bandes d'absorption de la vapeur d'eau (940 et 1130 nm). Cela est dû au caractère très approximatif du calcul de certains termes radiatifs effectué par la méthode empirique, ce qui limite son utilisation à de la classification d'image, là où une application de détection d'image nécessiterait des spectres de réflectance plus réalistes.

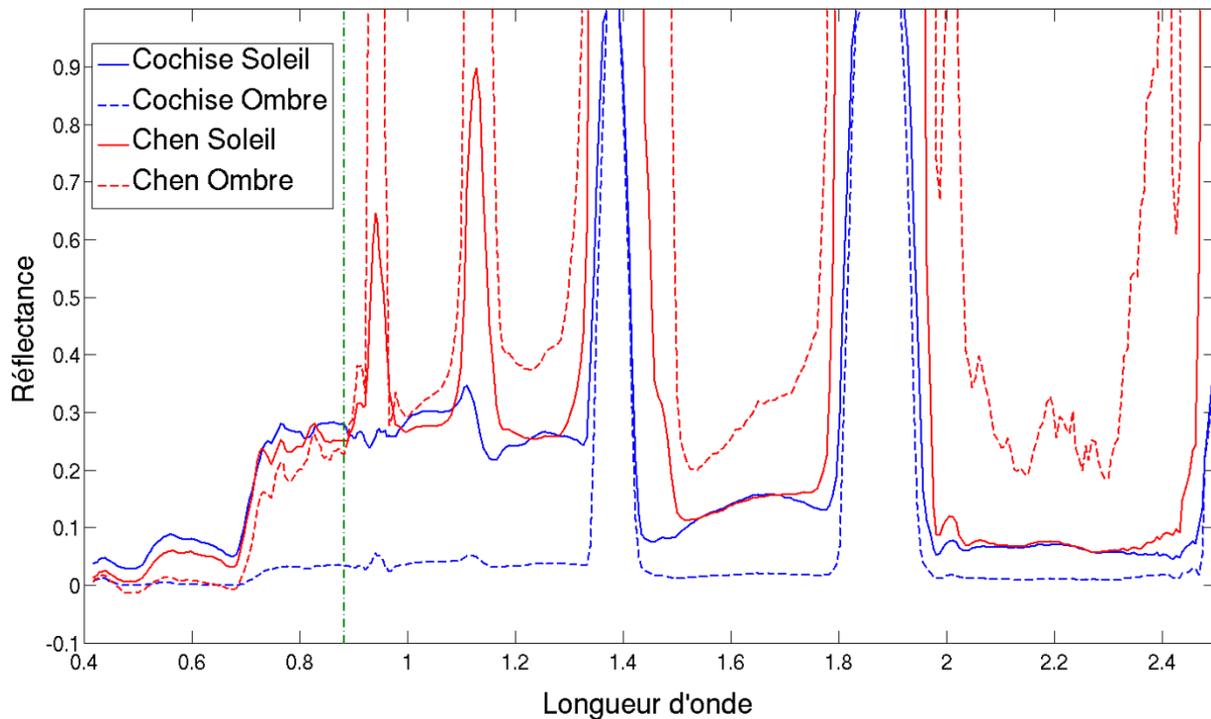


Figure 7 : Comparaison de deux spectres de réflectance obtenus avec Cochise et la méthode empirique (Chen), l'un situé à l'ombre, l'autre au soleil

4.3. Classification ombre/soleil

Pour la plupart des algorithmes de classification et notamment les algorithmes non supervisés, les zones d'ombre représentent un problème majeur car elles impliquent souvent la présence d'une classe parasite rassemblant de nombreux pixels associés pourtant à des matériaux dissemblables. La solution que nous proposons est un processus séquentiel consistant à classer successivement les zones ensoleillées et les zones d'ombre :

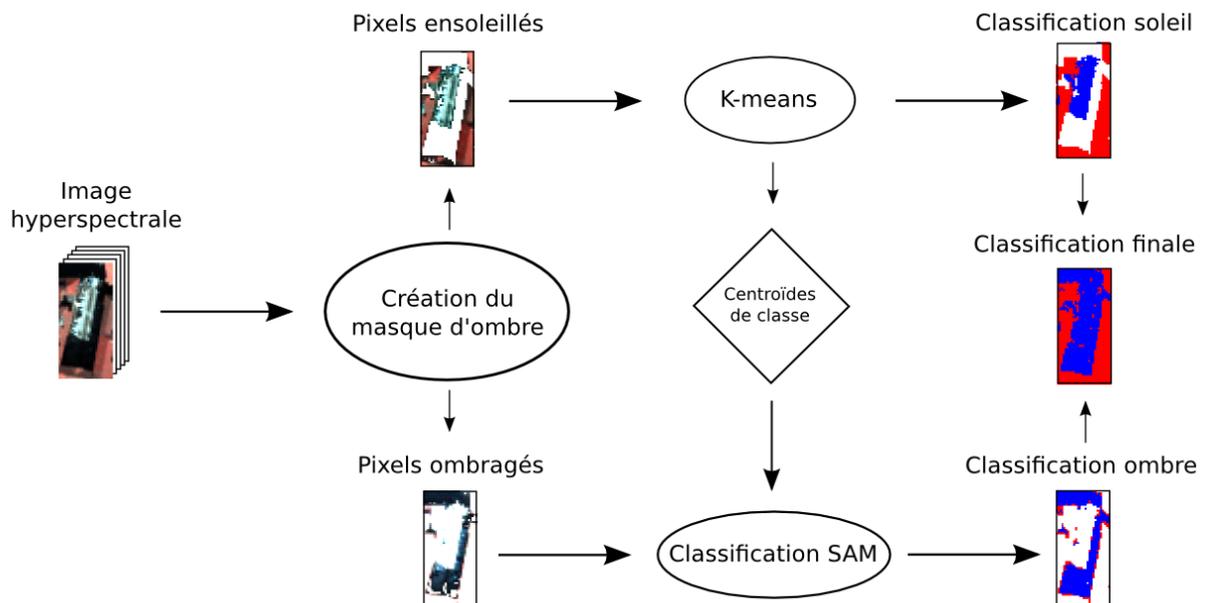


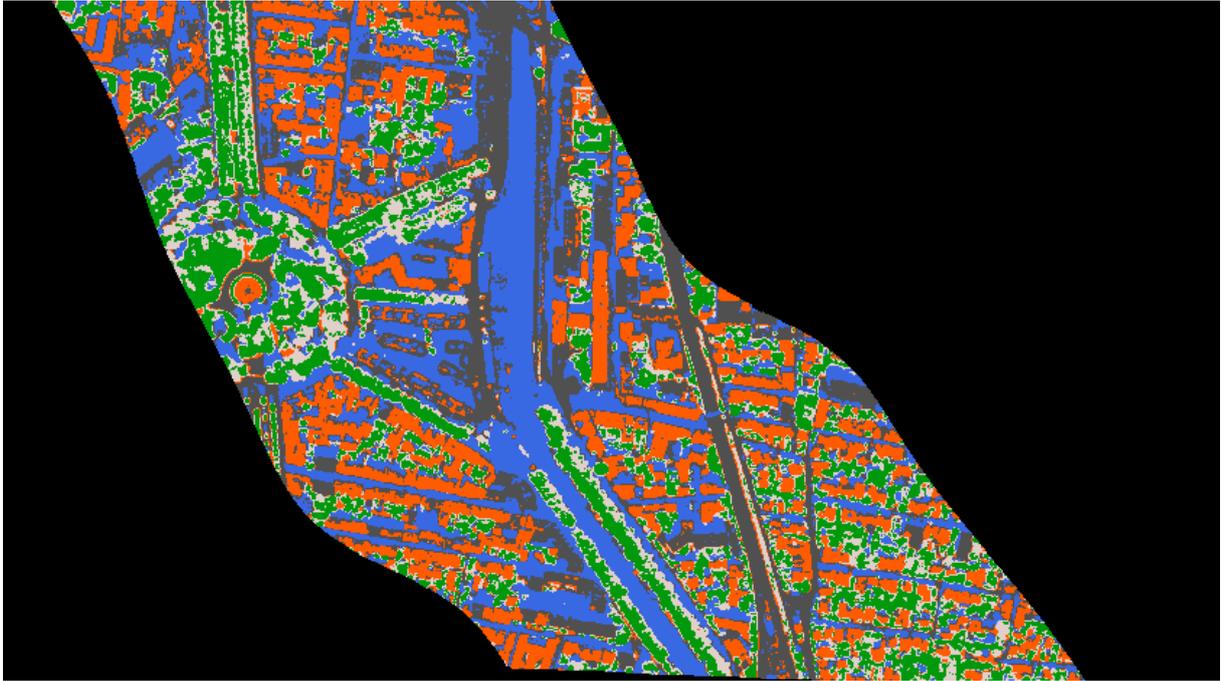
Figure 7 : fonctionnement global de l'algorithme de classification ombre/soleil

A l'aide du masque d'ombre décrit dans la section 3.3.1, les pixels ensoleillés sont isolés et classifiés par l'intermédiaire d'un K-means, avec un nombre de classes C fixé par l'utilisateur. Les centroïdes de chaque classe sont préservés puis utilisés en tant qu'entrées de la classification des pixels ombragés. Dans ce cas, une classification SAM (Spectral Angle Mapper) a été choisie pour sa faculté à se concentrer sur la forme des spectres, laquelle reste globalement similaire pour un couple de pixels associés au même matériau, même quand l'un est situé à l'ombre et l'autre au soleil. Pour chaque pixel p et chaque centroïde $\mu_i, i \in [1, C]$, le SAM est calculé de la façon suivante :

$$SAM(p, \mu_i) = \cos^{-1} \left(\frac{\sum_{b=1}^B p(b) \mu_i(b)}{\sqrt{\sum_{b=1}^B p(b)^2} \sqrt{\sum_{b=1}^B \mu_i(b)^2}} \right) \quad (30)$$

où B est le nombre de bande de l'image. La classe choisie pour chaque pixel p est celle minimisant le SAM entre le centroïde représentatif de cette classe et p . Remarquons que pour que cet algorithme soit efficace, il faut que l'ensemble des classes soient présentes à la fois à l'ombre et au soleil.

La figure 8 présente les résultats de classification obtenus sur des données en luminance d'une part (a), et en réflectance d'autre part – Cochise (b) et méthode empirique (c). Dans le contexte non supervisé de cet algorithme, nous avons choisi de nous limiter à cinq classes afin de discriminer globalement la végétation, l'eau, les toitures de tuile, l'asphalte et le béton. La carte de classification des données en luminance identifie plutôt bien les toitures de tuile (en orange) mais souffre du problème évoqué plus haut impliquant la présence d'une unique classe rassemblant tous les pixels à l'ombre (en bleu) et les associant dans le cas présent aux pixels d'eau, également très sombre. De plus, le classifieur ne parvient pas du tout à discriminer le béton de l'asphalte et préfère diviser l'ensemble des pixels de végétation en deux classes (verte et grise).



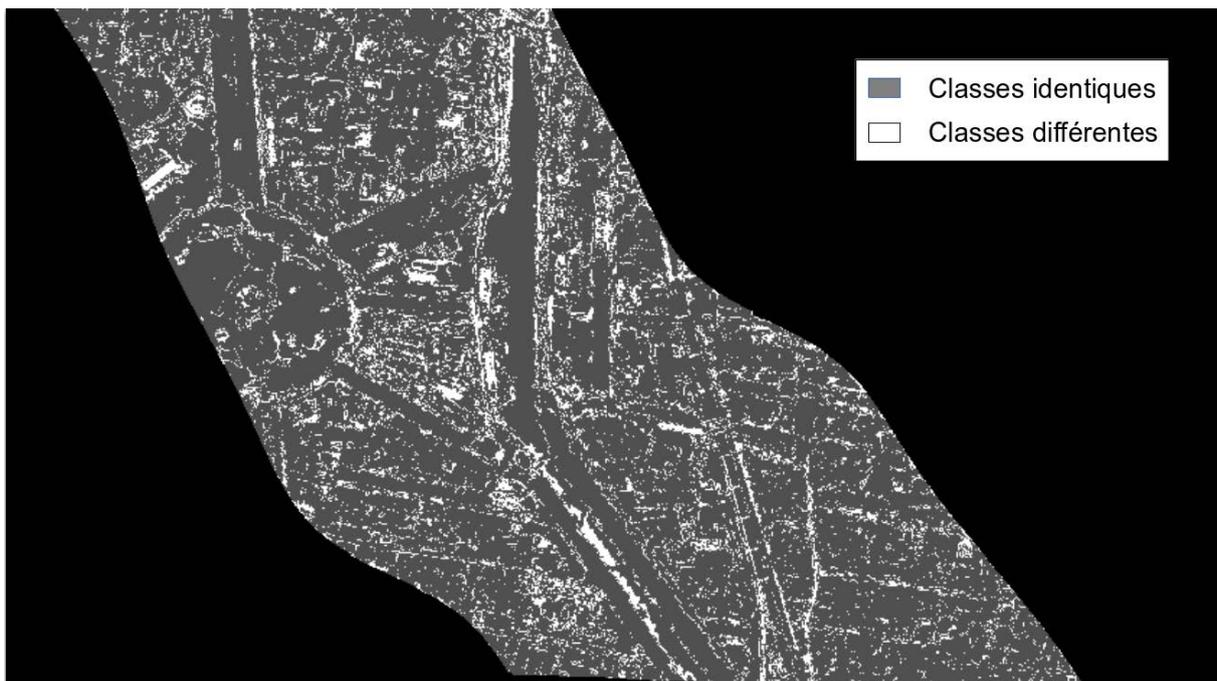
(a)



(b)



(c)



(d)

Figure 8 : Résultats de classification obtenus avec la méthode ombre/soleil, appliquée sur (a) les données en luminance, (b) les données en réflectance (Cochise), (c) les données en réflectance (méthode empirique) et (d) la carte des différences entre les deux cartes de réflectance (avec en gris foncé les pixels rangés dans la même classe et en blanc les pixels rangés dans des classes différentes).

Les deux cartes de classification obtenues à partir des données de réflectance parviennent d'une part à discriminer l'eau de l'ombre, mais également à distinguer plusieurs classes (végétation, eau) à l'intérieur des zones d'ombre (voir figure 9). Remarquons toutefois que la méthode empirique identifie plus efficacement les pixels d'eau situés à l'ombre. Certains arbres situés à l'ombre de hauts bâtiments sont également plus aisément identifiables. Enfin la confusion entre les classes d'asphalte et de gravier/béton est également moins marquée.

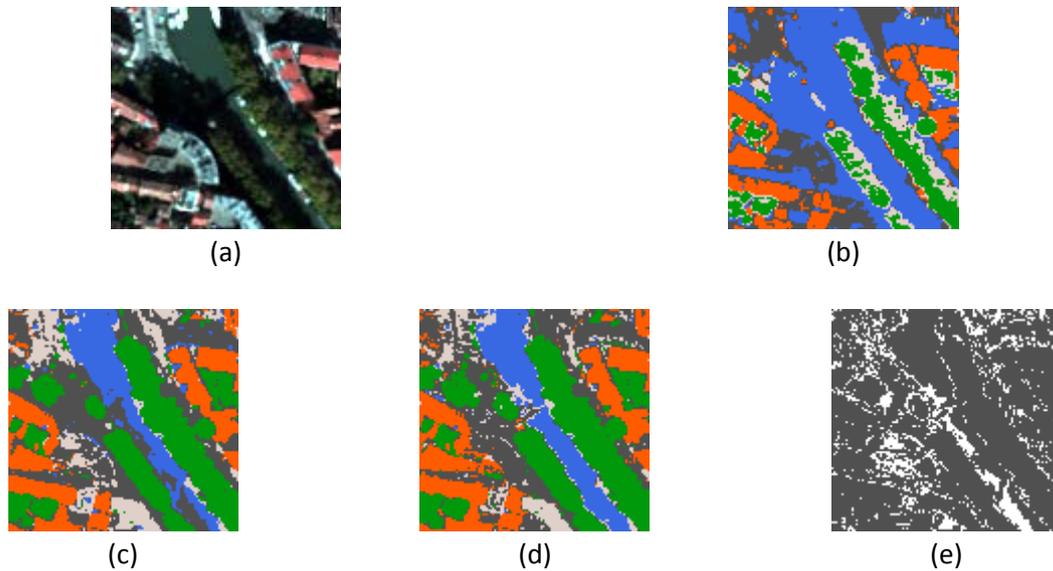


Figure 9 : Zoom sur les données avec (a) les données en luminance, et les résultats de classification obtenus sur (b) les données en luminance, (c) les données en réflectance (Cochise), (d) les données en réflectance (méthode empirique) et (e) la carte des différences entre les deux cartes de réflectance.

5. Perspectives

Par la suite, plusieurs axes seront poursuivis dans cette étude. Concernant l'algorithme de classification ombre/soleil, il conviendrait de remplacer le K-means de l'étape d'étiquetage des pixels illuminés par un algorithme supervisé (par exemple SVM) afin de pouvoir évaluer de façon plus solide la précision des résultats. Icare, le troisième algorithme de correction atmosphérique, sera également ajouté au processus de comparaison. Enfin une étude de sensibilité de ces trois algorithmes sera menée sur des images de résolution spatiale différentes (de 2 à 30 mètres) afin de définir les avantages et inconvénient de chacun en fonction de ce paramètre.

6. Bibliographie

[1] M. Herold, M.E. Gardner, and D.A. Roberts. *Spectral resolution requirements for mapping urban areas*. Geoscience and Remote Sensing, IEEE Transactions on, 41(9):1907–1919, Sept 2003.

- [2] Rutherford V Platt and Alexander F.H. Goetz. *A comparison of aviris and landsat for land use classification at the urban fringe*. Photogrammetric Engineering & Remote Sensing, (7):813–819, July 2004.
- [3] Q. Tan and J. Wang. *Hyperspectral versus multispectral satellite data for urban land cover and land use mapping - beijing, an evolving city*. American Society for Photogrammetry and Remote Sensing Conference, 2007.
- [4] C. M. Chen and G. Hepner. *Investigation of imaging spectroscopy for discriminating urban land covers and surface materials*. 2001.
- [5] Alexander F. H. Goetz, Joseph W. Boardman, Bruce C. Kindel, and Kathleen B. Heidebrecht. *Atmospheric corrections: on deriving surface reflectance from hyperspectral imagers*. Proc. SPIE, 3118:14–22, 1997.
- [6] Craig J. Miller. *Performance assessment of acorn atmospheric correction algorithm*. Proc. SPIE, 4725:438–449, 2002.
- [7] A. Berk, L. S. Bernstein, and D. C. Robertson. *Modtran : A moderate resolution model for lowtran 7*. Air Force Geophysics Laboratory Technical Report, 1989.
- [8] T. Cooley, G.P. Anderson, G.W. Felde, M.L. Hoke, A.J. Ratkowski, J.H. Chetwynd, J.A. Gardner, S.M. Adler-Golden, M.W. Matthew, A. Berk, L.S. Bernstein, P.K. Acharya, D. Miller and P. Lewis. *Flaash, a modtran4-based atmospheric correction algorithm, its application and validation*. Geoscience and Remote Sensing Symposium, 2002. IGARSS '02. 2002 IEEE International, 3:1414–1418, 2002.
- [9] C. Miesch, L. Poutier, V. Achard, X. Briottet, X. Lenot, and Y. Boucher. *Direct and inverse radiative transfer solutions for visible and near-infrared hyperspectral imagery*. Geoscience and Remote Sensing, IEEE Transactions on, 43(7):1552–1562, July 2005.
- [10] R. Richter and D. Schlapfer. *Geo-atmospheric processing of airborne imaging spectrometry data. part 2: Atmospheric/topographic correction*. International Journal of Remote Sensing, 23(13):2631–2649, 2002.
- [11] X. Lenot, V. Achard, and L. Poutier. *Irradiance calculation over mountainous areas in the reflective spectral domain: comparison with an accurate radiative transfer code*. Geoscience and Remote Sensing Symposium, 2003. IGARSS '03. Proceedings. 2003 IEEE International, 7:4298–4300 vol.7, July 2003.
- [12] S. Lacherade, C. Miesch, D. Boldo, X. Briottet, C. Valorge, and H. Le Men. *Icare: A physically-based model to correct atmospheric and geometric effects from high spatial and spectral remote sensing images over 3d urban areas*. Meteorology and Atmospheric Physics, 102(3-4):209–222, 2008.
- [13] Y. J. Kaufman and C. Sendra. *Algorithm for automatic atmospheric corrections to visible and near infrared satellite imagery*. Int. J. Remote Sensing 9 : 1357-81, 1988.

- [14] M. Chen, K.L.C. Seow, X. Briottet, and Sze Kim Pang. *Efficient empirical reflectance retrieval in urban environments*. Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of, 6(3):1596–1601, June 2013.
- [15] C. Miesch, X. Briottet, Y. H. Kerr, and F. Cabot. *Radiative transfer solution for rugged and heterogeneous scene observations*. Appl. Opt., 39(36):6830–6846, December 2000.
- [16] E.F. Vermote, D. Tanré, J.L. Deuzé, M. Herman and J.-J. Morcrette. *Second Simulation of the Satellite Signal in the Solar Spectrum, 6S: An Overview*, IEEE Transactions on Geoscience and Remote Sensing, Vol. 35, No. 3, p. 675-686., 1997.
- [17] Lachérade S. *Caractérisation des matériaux urbains à partir d’images de télédétection à très hautes résolutions spatiale et spectrale*. Thèse, 2006.
- [18] M. Nagao, T. Matsuyama, and Y. Ikeda. *Region extraction and shape analysis in aerial photographs*. Computer Graphics and Image Processing, 10(3):195–223, 1979.
- [19] K.R.M. Adeline, M. Chen, X. Briottet, S.K. Pang, and N. Paparoditis. *Shadow detection in very high spatial resolution aerial images: A comparative study*. {ISPRS} Journal of Photogrammetry and Remote Sensing, 80:21 – 38, 2013.
- [20] . Gal, M. Rzepa, B. Gromek, and J. Unger. *Comparison between sky view factor values computed by two different methods in an urban environment*. Acta. Climatol. Chorolog. , vol. 40, no. 41, pp. 17–26, 2007.
- [21] D. Schlöpfer and K. Itten. *Imaging spectrometry of tropospheric ozone and water vapor*. EARSeL Int. J. Advanced in Remote Sensing, 1995.

Date : Contractuelle	T6	Actuelle T11
Status	<input type="checkbox"/> Final	X Intermédiaire
Nature du deliverable:	X Report	<input type="checkbox"/> Prototype <input type="checkbox"/> Autre
Dissemination: Confidentialité	X	Public <input type="checkbox"/>

Valorisation
Articles
1.
2.
n.

Colloque/conférence
1. GADAL et al., Morpho-Spectral Recognition of Dense Urban Objects by Hyperspectral Imagery. GEOHYPER 2015
2.
n.

Vulgarisation
1. Mémoire de master 2 Zinko Sergii, 2015, <i>titre</i>
2.

Métadonnées	
Réalisation finalisation X	en cours <input type="checkbox"/>
Lien	
Responsable ZINKO	

WP1.2

1. Hyperspectral Spectral database: spectra design

Hyperspectral data provide the characteristics to investigate the spectral complexity and unique spectral characteristics of the urban environments, and give continuous information in the spectral region with spatial resolution that can be applied to the urban ecosystems (from 3 to 30 m). This work describes how the hyperspectral remote sensing open up new opportunities in identification and characterization of urban areas through spectral and spatial resolutions and comprehensive spectral libraries. This study proposes a processed bibliographic list where the latest developments on comprehensive field and image spectral libraries are introduced. The first steps of creation of a morpho-spectral data base are presented together with the list of particular spectral features in the context of the project *HYEP: Using Hyperspectral imaging for urban environmental planning* by the *National Research Agency (ANR)*. The results indicate that hyperspectral imaging is a powerful tool for solving urban remote sensing problems.

1.1. State of the art

The first objective of this project is to find necessary information according to the supplied questions and tasks. A state of the art has been done in order to collect the characteristics of urban surface materials required to localize, describe, identify and extract them. All information has been selected throughout scientific publications after a comprehensive examination of the literature. The articles and reviews are the main sources of needed information. One large file “database of read articles and reviews” (Figure 1; Add 1) has been created. The presented references consist of the author’s names, main words or key words and a short article description (sensor type, spatial and spectral information). The review of the information about urban hyperspectral image has been set up from 1976 till 2015. 36 studies concerning hyperspectral remote sensing of urban areas were found. Among them were some fundamental works about spectral data bases, methods of their determination, classification and extraction have been extracted and considered (Ben-Dor et al 2001, Heiden et al 2004, Herold et al 2001, 2007, Balbridge et al 2009, Clark et al 2007). Through this literature database, information on existing spectral database, specific radiometric values, sensors types and usual objectives, has been better identify.

	Bibliographic list	Abstract 1	Abstract 2	
1	1976 Rosen et al., 1976, L.C. Rosen, F.H. Wentzel, A.J. Gault, F.C. Willetting, J.R. Stewart Discontinuation of rock types and detection of hydrothermally altered areas in south-central Nevada by the use of computer-enhanced EXRT images.	This article is explaining a technique which combines digital computer processing and color compositing, and has been devised for enhancing visible spectral reflectivity differences. Another words this report presents the geologic interpretations and evaluation of the resulting processed images. Short descriptions are given of the EXRT-1 scanner profile and imaging subsystems, the general nature of the visible and near-infrared spectral reflectivity of rocks, and the techniques used.	EXRT-1 altitude 6000m, spatial resolution 10m, lines at the most common (vertical) metal ion, has absorption bands centered between 1.0 and 0.8 µm (Sant and Halburig, 1975) • Basic information about Contrast Stretching: • Atmospheric effects • Filtering	The result of this study shows that the most of the major rock units and altered areas in the study area can be separated on the basis of visible and near-infrared spectral reflectivity differences recorded from satellite altitudes. Although adequate spectrophotometric measurements are not available for defining the relationships between the mineralogical composition and spectral reflectivity of the surface materials.
2	1977 Abrams et al., 1977 M.J. Abrams, R. Ashley, L.C. Rosen, A.J. Gault, A.P. Kubit Mapping of hydrothermal alteration in the Capitan mining district, Nevada, using aerial multispectral images for the spectral region 0.46 to 2.36 µm	This report briefly described evaluation of multispectral images obtained from the Capitan Nevada mining using the airborne Spectra 24-channel (MSI) scanner	Field spectra (P, FFD, Portable Field Reflectance Spectrometer) provide scanner altitude, location, spatial resolution 10m, The place of indicators: Capitan Nevada Detailed notes: Tuff sequences in flat and absence of strong absorption features Altered rocks: Silicified material (near 1.7µm and a weak absorption feature at 2.2 µm.) Oxidized rocks (hydroxyl-bearing materials - (ring off beyond 1.7 µm and a deep 2.2 µm absorption band produced by aluminosilicates) Agricultural rocks (Strong absorption at 0.85 µm, high rise from 100 to 500, moderately strong absorption 2.2 µm.)	Limonite altered rocks, having high albedo, can successfully detected and mapped using color aerial photographs and Landsat images. But for limonite poor altered rock with low albedo should be utilized additional spectral information between 1.1 and 2.3 µm. Images at 2.2 µm rich by pronounced absorption features.
3	1987 C. S. Woodcock and A. R. Strahler The factor scale in remote sensing	A new method has been presented that measures the spatial structure of images as a function of spatial resolution	Thematic Mapper, SPOT, and AVIRIS A graph showing how the local variance of a digital image for a scene changes as the resolution cell size changes can help in selecting an appropriate image scale. Such graphs are obtained by imaging the scene at fine resolutions and then enlarging the image to successively coarser resolutions while subsampling a measure of local variance	1. The local variance in images is related to the relationship between the size of the objects in the scene and the spatial resolution of the sensor. 2. The spatial resolutions of high local variance change as a function of environments. 3. Multiple scales of variations in an environment will produce multiple images of spatial resolution with high local variance.
4	1990 G. F. Heynen, B. Woodford, I. Sullivan, and N. Bryant, Photogrammetric Engineering, Vol. 56, No. 5, pp. 493-505, 1990 Investigation of the integration of AVIRIS and SPAN for urban analysis	Urban centers are the focus of this study is the acquisition of the 3D geometry of the urban area, and the assessment of a comprehensive land cover classification for the study area.	AVIRIS - spatial resolution 3 m SPAN, altitude 11,000 m Center frequency - 0.558489 m Bandwidth 400 MHz Nadir swath separation - 2.5 m Ground resolution - 542.3 m 1. The classification of features and land cover is performed using statistical approaches for supervised and unsupervised classification and pattern recognition. 2. The second approach employs the collection of a library of field spectra which are matched against spectral signatures in the AVIRIS dataset.	1. Very significant measurement problems in urban areas involve the shadowing of features by other features. This problem is magnified in the imagery by direct reflections signals from a building or area being shadowed by another. 2. The integration of SPAN and AVIRIS provides information regarding the vertical size and the spatial extent for the thermal topographic and geomorphic structures in an urban area. Three-dimensional measurements merged with the radiometric and topographic classification of the extended scene has the capacity to provide a powerful regional information base. In addition, the extended image provides.
5	2001 Automated Differentiation of Urban Surfaces Based on Airborne Hyperspectral Imagery	Classification, automatic, supervised, unsupervised, spectral, urban, environment	In this paper, a new approach is presented that combines advantages of classification with linear spectral unmixing SAR - (1.21) (1.20 nm) 7% channel digital airborne imaging spectrometer (DAIS) The flight altitude of 7000 to near 7 m. The best SAR bands is [207 nm], 13 [207 nm], 13 [209 nm], 13 [210 nm], and [214 nm], 16 [215 nm], 16 [216 nm], 16 [217 nm], 16 [218 nm], 16 [219 nm], 16 [220 nm], 16 [221 nm], 16 [222 nm], 16 [223 nm], 16 [224 nm], 16 [225 nm], 16 [226 nm], 16 [227 nm], 16 [228 nm], 16 [229 nm], 16 [230 nm], 16 [231 nm], 16 [232 nm], 16 [233 nm], 16 [234 nm], 16 [235 nm], 16 [236 nm], 16 [237 nm], 16 [238 nm], 16 [239 nm], 16 [240 nm], 16 [241 nm], 16 [242 nm], 16 [243 nm], 16 [244 nm], 16 [245 nm], 16 [246 nm], 16 [247 nm], 16 [248 nm], 16 [249 nm], 16 [250 nm], 16 [251 nm], 16 [252 nm], 16 [253 nm], 16 [254 nm], 16 [255 nm], 16 [256 nm], 16 [257 nm], 16 [258 nm], 16 [259 nm], 16 [260 nm], 16 [261 nm], 16 [262 nm], 16 [263 nm], 16 [264 nm], 16 [265 nm], 16 [266 nm], 16 [267 nm], 16 [268 nm], 16 [269 nm], 16 [270 nm], 16 [271 nm], 16 [272 nm], 16 [273 nm], 16 [274 nm], 16 [275 nm], 16 [276 nm], 16 [277 nm], 16 [278 nm], 16 [279 nm], 16 [280 nm], 16 [281 nm], 16 [282 nm], 16 [283 nm], 16 [284 nm], 16 [285 nm], 16 [286 nm], 16 [287 nm], 16 [288 nm], 16 [289 nm], 16 [290 nm], 16 [291 nm], 16 [292 nm], 16 [293 nm], 16 [294 nm], 16 [295 nm], 16 [296 nm], 16 [297 nm], 16 [298 nm], 16 [299 nm], 16 [300 nm], 16 [301 nm], 16 [302 nm], 16 [303 nm], 16 [304 nm], 16 [305 nm], 16 [306 nm], 16 [307 nm], 16 [308 nm], 16 [309 nm], 16 [310 nm], 16 [311 nm], 16 [312 nm], 16 [313 nm], 16 [314 nm], 16 [315 nm], 16 [316 nm], 16 [317 nm], 16 [318 nm], 16 [319 nm], 16 [320 nm], 16 [321 nm], 16 [322 nm], 16 [323 nm], 16 [324 nm], 16 [325 nm], 16 [326 nm], 16 [327 nm], 16 [328 nm], 16 [329 nm], 16 [330 nm], 16 [331 nm], 16 [332 nm], 16 [333 nm], 16 [334 nm], 16 [335 nm], 16 [336 nm], 16 [337 nm], 16 [338 nm], 16 [339 nm], 16 [340 nm], 16 [341 nm], 16 [342 nm], 16 [343 nm], 16 [344 nm], 16 [345 nm], 16 [346 nm], 16 [347 nm], 16 [348 nm], 16 [349 nm], 16 [350 nm], 16 [351 nm], 16 [352 nm], 16 [353 nm], 16 [354 nm], 16 [355 nm], 16 [356 nm], 16 [357 nm], 16 [358 nm], 16 [359 nm], 16 [360 nm], 16 [361 nm], 16 [362 nm], 16 [363 nm], 16 [364 nm], 16 [365 nm], 16 [366 nm], 16 [367 nm], 16 [368 nm], 16 [369 nm], 16 [370 nm], 16 [371 nm], 16 [372 nm], 16 [373 nm], 16 [374 nm], 16 [375 nm], 16 [376 nm], 16 [377 nm], 16 [378 nm], 16 [379 nm], 16 [380 nm], 16 [381 nm], 16 [382 nm], 16 [383 nm], 16 [384 nm], 16 [385 nm], 16 [386 nm], 16 [387 nm], 16 [388 nm], 16 [389 nm], 16 [390 nm], 16 [391 nm], 16 [392 nm], 16 [393 nm], 16 [394 nm], 16 [395 nm], 16 [396 nm], 16 [397 nm], 16 [398 nm], 16 [399 nm], 16 [400 nm], 16 [401 nm], 16 [402 nm], 16 [403 nm], 16 [404 nm], 16 [405 nm], 16 [406 nm], 16 [407 nm], 16 [408 nm], 16 [409 nm], 16 [410 nm], 16 [411 nm], 16 [412 nm], 16 [413 nm], 16 [414 nm], 16 [415 nm], 16 [416 nm], 16 [417 nm], 16 [418 nm], 16 [419 nm], 16 [420 nm], 16 [421 nm], 16 [422 nm], 16 [423 nm], 16 [424 nm], 16 [425 nm], 16 [426 nm], 16 [427 nm], 16 [428 nm], 16 [429 nm], 16 [430 nm], 16 [431 nm], 16 [432 nm], 16 [433 nm], 16 [434 nm], 16 [435 nm], 16 [436 nm], 16 [437 nm], 16 [438 nm], 16 [439 nm], 16 [440 nm], 16 [441 nm], 16 [442 nm], 16 [443 nm], 16 [444 nm], 16 [445 nm], 16 [446 nm], 16 [447 nm], 16 [448 nm], 16 [449 nm], 16 [450 nm], 16 [451 nm], 16 [452 nm], 16 [453 nm], 16 [454 nm], 16 [455 nm], 16 [456 nm], 16 [457 nm], 16 [458 nm], 16 [459 nm], 16 [460 nm], 16 [461 nm], 16 [462 nm], 16 [463 nm], 16 [464 nm], 16 [465 nm], 16 [466 nm], 16 [467 nm], 16 [468 nm], 16 [469 nm], 16 [470 nm], 16 [471 nm], 16 [472 nm], 16 [473 nm], 16 [474 nm], 16 [475 nm], 16 [476 nm], 16 [477 nm], 16 [478 nm], 16 [479 nm], 16 [480 nm], 16 [481 nm], 16 [482 nm], 16 [483 nm], 16 [484 nm], 16 [485 nm], 16 [486 nm], 16 [487 nm], 16 [488 nm], 16 [489 nm], 16 [490 nm], 16 [491 nm], 16 [492 nm], 16 [493 nm], 16 [494 nm], 16 [495 nm], 16 [496 nm], 16 [497 nm], 16 [498 nm], 16 [499 nm], 16 [500 nm], 16 [501 nm], 16 [502 nm], 16 [503 nm], 16 [504 nm], 16 [505 nm], 16 [506 nm], 16 [507 nm], 16 [508 nm], 16 [509 nm], 16 [510 nm], 16 [511 nm], 16 [512 nm], 16 [513 nm], 16 [514 nm], 16 [515 nm], 16 [516 nm], 16 [517 nm], 16 [518 nm], 16 [519 nm], 16 [520 nm], 16 [521 nm], 16 [522 nm], 16 [523 nm], 16 [524 nm], 16 [525 nm], 16 [526 nm], 16 [527 nm], 16 [528 nm], 16 [529 nm], 16 [530 nm], 16 [531 nm], 16 [532 nm], 16 [533 nm], 16 [534 nm], 16 [535 nm], 16 [536 nm], 16 [537 nm], 16 [538 nm], 16 [539 nm], 16 [540 nm], 16 [541 nm], 16 [542 nm], 16 [543 nm], 16 [544 nm], 16 [545 nm], 16 [546 nm], 16 [547 nm], 16 [548 nm], 16 [549 nm], 16 [550 nm], 16 [551 nm], 16 [552 nm], 16 [553 nm], 16 [554 nm], 16 [555 nm], 16 [556 nm], 16 [557 nm], 16 [558 nm], 16 [559 nm], 16 [560 nm], 16 [561 nm], 16 [562 nm], 16 [563 nm], 16 [564 nm], 16 [565 nm], 16 [566 nm], 16 [567 nm], 16 [568 nm], 16 [569 nm], 16 [570 nm], 16 [571 nm], 16 [572 nm], 16 [573 nm], 16 [574 nm], 16 [575 nm], 16 [576 nm], 16 [577 nm], 16 [578 nm], 16 [579 nm], 16 [580 nm], 16 [581 nm], 16 [582 nm], 16 [583 nm], 16 [584 nm], 16 [585 nm], 16 [586 nm], 16 [587 nm], 16 [588 nm], 16 [589 nm], 16 [590 nm], 16 [591 nm], 16 [592 nm], 16 [593 nm], 16 [594 nm], 16 [595 nm], 16 [596 nm], 16 [597 nm], 16 [598 nm], 16 [599 nm], 16 [600 nm], 16 [601 nm], 16 [602 nm], 16 [603 nm], 16 [604 nm], 16 [605 nm], 16 [606 nm], 16 [607 nm], 16 [608 nm], 16 [609 nm], 16 [610 nm], 16 [611 nm], 16 [612 nm], 16 [613 nm], 16 [614 nm], 16 [615 nm], 16 [616 nm], 16 [617 nm], 16 [618 nm], 16 [619 nm], 16 [620 nm], 16 [621 nm], 16 [622 nm], 16 [623 nm], 16 [624 nm], 16 [625 nm], 16 [626 nm], 16 [627 nm], 16 [628 nm], 16 [629 nm], 16 [630 nm], 16 [631 nm], 16 [632 nm], 16 [633 nm], 16 [634 nm], 16 [635 nm], 16 [636 nm], 16 [637 nm], 16 [638 nm], 16 [639 nm], 16 [640 nm], 16 [641 nm], 16 [642 nm], 16 [643 nm], 16 [644 nm], 16 [645 nm], 16 [646 nm], 16 [647 nm], 16 [648 nm], 16 [649 nm], 16 [650 nm], 16 [651 nm], 16 [652 nm], 16 [653 nm], 16 [654 nm], 16 [655 nm], 16 [656 nm], 16 [657 nm], 16 [658 nm], 16 [659 nm], 16 [660 nm], 16 [661 nm], 16 [662 nm], 16 [663 nm], 16 [664 nm], 16 [665 nm], 16 [666 nm], 16 [667 nm], 16 [668 nm], 16 [669 nm], 16 [670 nm], 16 [671 nm], 16 [672 nm], 16 [673 nm], 16 [674 nm], 16 [675 nm], 16 [676 nm], 16 [677 nm], 16 [678 nm], 16 [679 nm], 16 [680 nm], 16 [681 nm], 16 [682 nm], 16 [683 nm], 16 [684 nm], 16 [685 nm], 16 [686 nm], 16 [687 nm], 16 [688 nm], 16 [689 nm], 16 [690 nm], 16 [691 nm], 16 [692 nm], 16 [693 nm], 16 [694 nm], 16 [695 nm], 16 [696 nm], 16 [697 nm], 16 [698 nm], 16 [699 nm], 16 [700 nm], 16 [701 nm], 16 [702 nm], 16 [703 nm], 16 [704 nm], 16 [705 nm], 16 [706 nm], 16 [707 nm], 16 [708 nm], 16 [709 nm], 16 [710 nm], 16 [711 nm], 16 [712 nm], 16 [713 nm], 16 [714 nm], 16 [715 nm], 16 [716 nm], 16 [717 nm], 16 [718 nm], 16 [719 nm], 16 [720 nm], 16 [721 nm], 16 [722 nm], 16 [723 nm], 16 [724 nm], 16 [725 nm], 16 [726 nm], 16 [727 nm], 16 [728 nm], 16 [729 nm], 16 [730 nm], 16 [731 nm], 16 [732 nm], 16 [733 nm], 16 [734 nm], 16 [735 nm], 16 [736 nm], 16 [737 nm], 16 [738 nm], 16 [739 nm], 16 [740 nm], 16 [741 nm], 16 [742 nm], 16 [743 nm], 16 [744 nm], 16 [745 nm], 16 [746 nm], 16 [747 nm], 16 [748 nm], 16 [749 nm], 16 [750 nm], 16 [751 nm], 16 [752 nm], 16 [753 nm], 16 [754 nm], 16 [755 nm], 16 [756 nm], 16 [757 nm], 16 [758 nm], 16 [759 nm], 16 [760 nm], 16 [761 nm], 16 [762 nm], 16 [763 nm], 16 [764 nm], 16 [765 nm], 16 [766 nm], 16 [767 nm], 16 [768 nm], 16 [769 nm], 16 [770 nm], 16 [771 nm], 16 [772 nm], 16 [773 nm], 16 [774 nm], 16 [775 nm], 16 [776 nm], 16 [777 nm], 16 [778 nm], 16 [779 nm], 16 [780 nm], 16 [781 nm], 16 [782 nm], 16 [783 nm], 16 [784 nm], 16 [785 nm], 16 [786 nm], 16 [787 nm], 16 [788 nm], 16 [789 nm], 16 [790 nm], 16 [791 nm], 16 [792 nm], 16 [793 nm], 16 [794 nm], 16 [795 nm], 16 [796 nm], 16 [797 nm], 16 [798 nm], 16 [799 nm], 16 [800 nm], 16 [801 nm], 16 [802 nm], 16 [803 nm], 16 [804 nm], 16 [805 nm], 16 [806 nm], 16 [807 nm], 16 [808 nm], 16 [809 nm], 16 [810 nm], 16 [811 nm], 16 [812 nm], 16 [813 nm], 16 [814 nm], 16 [815 nm], 16 [816 nm], 16 [817 nm], 16 [818 nm], 16 [819 nm], 16 [820 nm], 16 [821 nm], 16 [822 nm], 16 [823 nm], 16 [824 nm], 16 [825 nm], 16 [826 nm], 16 [827 nm], 16 [828 nm], 16 [829 nm], 16 [830 nm], 16 [831 nm], 16 [832 nm], 16 [833 nm], 16 [834 nm], 16 [835 nm], 16 [836 nm], 16 [837 nm], 16 [838 nm], 16 [839 nm], 16 [840 nm], 16 [841 nm], 16 [842 nm], 16 [843 nm], 16 [844 nm], 16 [845 nm], 16 [846 nm], 16 [847 nm], 16 [848 nm], 16 [849 nm], 16 [850 nm], 16 [851 nm], 16 [852 nm], 16 [853 nm], 16 [854 nm], 16 [855 nm], 16 [856 nm], 16 [857 nm], 16 [858 nm], 16 [859 nm], 16 [860 nm], 16 [861 nm], 16 [862 nm], 16 [863 nm], 16 [864 nm], 16 [865 nm], 16 [866 nm], 16 [867 nm], 16 [868 nm], 16 [869 nm], 16 [870 nm], 16 [871 nm], 16 [872 nm], 16 [873 nm], 16 [874 nm], 16 [875 nm], 16 [876 nm], 16 [877 nm], 16 [878 nm], 16 [879 nm], 16 [880 nm], 16 [881 nm], 16 [882 nm], 16 [883 nm], 16 [884 nm], 16 [885 nm], 16 [886 nm], 16 [887 nm], 16 [888 nm], 16 [889 nm], 16 [890 nm], 16 [891 nm], 16 [892 nm], 16 [893 nm], 16 [894 nm], 16 [895 nm], 16 [896 nm], 16 [897 nm], 16 [898 nm], 16 [899 nm], 16 [900 nm], 16 [901 nm], 16 [902 nm], 16 [903 nm], 16 [904 nm], 16 [905 nm], 16 [906 nm], 16 [907 nm], 16 [908 nm], 16 [909 nm], 16 [910 nm], 16 [911 nm], 16 [912 nm], 16 [913 nm], 16 [914 nm], 16 [915 nm], 16 [916 nm], 16 [917 nm], 16 [918 nm], 16 [919 nm], 16 [920 nm], 16 [921 nm], 16 [922 nm], 16 [923 nm], 16 [924 nm], 16 [925 nm], 16 [926 nm], 16 [927 nm], 16 [928 nm], 16 [929 nm], 16 [930 nm], 16 [931 nm], 16 [932 nm], 16 [933 nm], 16 [934 nm], 16 [935 nm], 16 [936 nm], 16 [937 nm], 16 [938 nm], 16 [939 nm], 16 [940 nm], 16 [941 nm], 16 [942 nm], 16 [943 nm], 16 [944 nm], 16 [945 nm], 16 [946 nm], 16 [947 nm], 16 [948 nm], 16 [949 nm], 16 [950 nm], 16 [951 nm], 16 [952 nm], 16 [953 nm], 16 [954 nm], 16 [955 nm], 16 [956 nm], 16 [957 nm], 16 [958 nm], 16 [959 nm], 16 [960 nm], 16 [961 nm], 16 [962 nm], 16 [963 nm], 16 [964 nm], 16 [965 nm], 16 [966 nm], 16 [967 nm], 16 [968 nm], 16 [969 nm], 16 [970 nm], 16 [971 nm], 16 [972 nm], 16 [973 nm], 16 [974 nm], 16 [975 nm], 16 [976 nm], 16 [977 nm], 16 [978 nm], 16 [979 nm], 16 [980 nm], 16 [981 nm], 16 [982 nm], 16 [983 nm], 16 [984 nm], 16 [985 nm], 16 [986 nm], 16 [987 nm], 16 [988 nm], 16 [989 nm], 16 [990 nm], 16 [991 nm], 16 [992 nm], 16 [993 nm], 16 [994 nm], 16 [995 nm], 16 [996 nm], 16 [997 nm], 16 [998 nm], 16 [999 nm], 16 [1000 nm], 16 [1001 nm], 16 [1002 nm], 16 [1003 nm], 16 [1004 nm], 16 [1005 nm], 16 [1006 nm], 16 [1007 nm], 16 [1008 nm], 16 [1009 nm], 16 [1010 nm], 16 [1011 nm], 16 [1012 nm], 16 [1013 nm], 16 [1014 nm], 16 [1015 nm], 16 [1016 nm], 16 [1017 nm], 16 [1018 nm], 16 [1019 nm], 16 [1020 nm], 16 [1021 nm], 16 [1022 nm], 16 [1023 nm], 16 [1024 nm], 16 [1025 nm], 16 [1026 nm], 16 [1027 nm], 16 [1028 nm], 16 [1029 nm], 16 [1030 nm], 16 [1031 nm], 16 [1032 nm], 16 [1033 nm], 16 [1034 nm], 16 [1035 nm], 16 [1036 nm], 16 [1037 nm], 16 [1038 nm], 16 [1039 nm], 16 [1040 nm], 16 [1041 nm], 16 [1042 nm], 16 [1043 nm], 16 [1044 nm], 16 [1045 nm], 16 [1046 nm], 16 [1047 nm], 16 [1048 nm], 16 [1049 nm], 16 [1050 nm], 16 [1051 nm], 16 [1052 nm], 16 [1053 nm], 16 [1054 nm], 16 [1055 nm], 16 [1056 nm], 16 [1057 nm], 16 [1058 nm], 16 [1059 nm], 16 [1060 nm], 16 [1061 nm], 16 [1062 nm], 16 [1063 nm], 16 [1064 nm], 16 [1065 nm], 16 [1066 nm], 16 [1067 nm], 16 [1068 nm], 16 [1069 nm], 16 [1070 nm], 16 [1071 nm], 16 [1072 nm], 16 [1073 nm], 16 [1074 nm], 16 [1075 nm], 16 [1076 nm], 16 [1077 nm], 16 [1078 nm], 16 [1079 nm], 16 [1080 nm], 16 [1081 nm], 16 [1082 nm], 16 [1083 nm], 16 [1084 nm], 16 [1085 nm], 16 [1086 nm], 16 [1087 nm], 16 [1088 nm], 16 [1089 nm], 16 [1090 nm], 16 [1091 nm], 16 [1092 nm], 16 [1093 nm], 16 [1094 nm], 16 [1095 nm], 16 [1096 nm], 16 [1097 nm], 16 [1098 nm], 16 [1099 nm], 16 [1100 nm], 16 [1101 nm], 16 [1102 nm], 16 [1103 nm], 16 [1104 nm], 16 [1105 nm], 16 [1106 nm], 16 [1107 nm], 16 [1108 nm], 16 [1109 nm], 16 [1110 nm], 16 [1111 nm], 16 [1112 nm], 16 [1113 nm], 16 [1114 nm], 16 [1115 nm], 16 [1116 nm], 16 [1117 nm], 16 [1118 nm], 16 [1119 nm], 16 [1120 nm], 16 [1121 nm], 16 [1122 nm], 16 [1123 nm], 16 [1124 nm], 16 [1125 nm], 16 [1126 nm], 16 [1127 nm], 16 [1128 nm], 16 [1129 nm], 16 [1130 nm], 16 [1131 nm], 16 [1132 nm], 16 [1133 nm], 16 [1134 nm], 16 [1135 nm], 16 [1136 nm], 16 [1137 nm], 16 [1138 nm], 16 [1139 nm], 16 [1140 nm], 16 [1141 nm], 16 [1142 nm], 16 [1143 nm], 16 [1144 nm], 16 [1145 nm], 16 [1146 nm], 16 [1147 nm], 16 [1148 nm], 16 [1149 nm], 16 [1150 nm], 16 [1151 nm], 16 [1152 nm], 16 [1153 nm], 16 [1154 nm], 16 [1155 nm], 16 [1156 nm], 16 [1157 nm], 16 [1158 nm], 16 [1159 nm], 16 [1160 nm], 16 [1161 nm], 16 [1162 nm], 16 [1163 nm], 16 [1164 nm], 16 [1165 nm], 16 [1166 nm], 16 [1167 nm], 16 [1168 nm], 16 [1169 nm], 16 [1170 nm], 16 [1171 nm], 16 [1172 nm], 16 [1173 nm], 16 [1174 nm], 16 [1175 nm], 16 [1176 nm], 16 [1177 nm], 16 [1178 nm], 16 [1179 nm], 16 [1180 nm], 16 [1181 nm], 16 [1182 nm], 16 [1183 nm], 16 [1184 nm], 16 [1185 nm], 16 [1186 nm], 16 [1187 nm], 16 [1188 nm], 16 [1189 nm], 16 [1190 nm], 16 [1191 nm], 16 [1192 nm], 16 [1193 nm], 16 [1194 nm], 16 [1195 nm], 16 [1196 nm], 16 [1197 nm], 16 [1198 nm], 16 [1199 nm], 16 [1200 nm], 16 [1201 nm], 16 [1202 nm], 16 [1203 nm], 16 [1204 nm], 16 [1205 nm], 16 [1206 nm], 16 [1207 nm], 16 [1208 nm], 16 [1209 nm], 16 [1210 nm], 16 [1211 nm], 16 [1212 nm], 16 [1213 nm], 16 [1214 nm], 16 [1215 nm], 16 [1216 nm], 16 [1217 nm], 16 [1218 nm], 16 [1219 nm], 16 [1220 nm], 16 [1221 nm], 16 [1222 nm], 16 [1223 nm], 16 [1224 nm], 16 [1225 nm], 16 [1226 nm], 16 [1227 nm], 16 [1228 nm], 16 [1229 nm], 16 [1230 nm], 16 [1231 nm], 16 [1232 nm], 16 [1233 nm], 16 [1234 nm], 16 [1235 nm], 16 [1236 nm], 16 [1237 nm], 16 [1238 nm], 16 [1239 nm], 16 [1240 nm], 16 [1241 nm], 16 [1242 nm], 16 [1243 nm], 16 [1244 nm], 16 [1245 nm], 16 [1246 nm], 16 [1247 nm], 16 [1248 nm], 16 [1249 nm], 16 [1250 nm], 16 [1251 nm], 16 [1252 nm], 16 [1253 nm], 16 [1254 nm], 16 [1255 nm], 16 [1256 nm], 16 [1257 nm], 16 [1258 nm], 16 [1259 nm], 16 [1260 nm], 16 [1261 nm], 16 [1262 nm], 16 [1263 nm], 16 [1264 nm], 16 [1265 nm], 16 [1266 nm], 16 [1267 nm], 16 [1268 nm], 16 [1269 nm], 16 [1270 nm], 16 [1271 nm], 16 [1272 nm], 16 [1273 nm], 16 [1274 nm], 16 [1275 nm], 16 [1276 nm], 16 [1277 nm], 16 [1278 nm], 16 [1279 nm], 16 [1280 nm], 16 [1281 nm], 16 [1282 nm], 16 [1283 nm], 16 [1284 nm], 16 [1285 nm], 16 [1286 nm], 16 [1287 nm], 16 [1288 nm], 16 [1289 nm], 16 [1290 nm], 16 [1291 nm], 16 [1292 nm], 16 [1293 nm], 16 [1294 nm], 16 [1295 nm], 16 [1296 nm], 16 [1297 nm], 16 [1298 nm], 16 [1299 nm], 16 [1300 nm], 16 [1301 nm], 16 [1302 nm], 16 [1303 nm], 16 [1304 nm], 16 [1305 nm], 16 [1306 nm], 16 [1307 nm], 16 [1308 nm], 16 [1309 nm], 16 [1310 nm], 16 [1311 nm], 16 [1312 nm], 16 [1313 nm], 16 [1314 nm], 16 [1315 nm], 16 [1316 nm], 16 [1317 nm], 16 [1318 nm], 16 [1319 nm], 16 [1320 nm], 16 [1321 nm], 16 [1322 nm], 16 [1323 nm], 16 [1324 nm], 16 [1325 nm], 16 [1326 nm], 16 [1327 nm], 16 [1328 nm], 16 [1329 nm], 16 [1330 nm], 16 [1331 nm], 16 [1332 nm], 16 [1333 nm], 16 [1334 nm], 16 [1335 nm], 16 [1336 nm], 16 [1337 nm], 16 [1338 nm], 16 [1339 nm], 16 [1340 nm], 16 [1341 nm], 16 [1342 nm], 16 [1343 nm], 16 [1344 nm], 16 [1345 nm], 16 [1346 nm], 16 [1347 nm], 16 [1348 nm], 16 [1349 nm], 16 [1350 nm], 16 [1351 nm], 16 [1352 nm], 16 [1353 nm], 16 [1354 nm], 16 [1355 nm], 16 [1356 nm], 16 [1357 nm], 16 [1358 nm], 16 [1359 nm], 16 [1360 nm], 16 [1361 nm], 16 [1362 nm], 16 [1363 nm], 16 [1364 nm], 16 [1365 nm], 16 [1366 nm], 16 [1367 nm], 16 [1368 nm],	

materials on a picture-element basis and can be completed by a proper sampling of the absorption features in the reflectance spectrum (Goetz et al., 1985). It was the beginning of understanding the great heterogeneity of surface reflectance signatures. Nowadays we have a large number of instruments allows to develop skills and techniques to extract information.

- ✓ Spatial resolution

One of the principal characteristics of hyperspectral image and also remotely-sensed images is the spatial resolution. Important progress was done with very high spatial resolution satellites, such as IKONOS (1999), QuickBird (2001), and OrbView (2003) in the various urban applications areas (Cablk & Minor, 2003; Goetz et al., 2003; Hu & Weng, 2011; Lu & Weng, 2009; Wu, 2009). The finer resolution gives a possibility to extract much more detailed thematic information (surface use and characterization), mapping features (structures and pavements), and stereo-image information (altitude and object volume). This information is very useful to estimate and map the impervious surface or obtain a reduced proportion of mixed pixels in the imaging scene. However, many new problems that are closely related to the shadows (topography), high buildings, vegetation, and high spectral variation of the same surfaces (Q. Weng, 2012) have to be cope with.

- ✓ Spectral variety of the urban materials

Hyperspectral data in the urban area provide some interesting information for urban mapping, despite the fact that there are some limitations in separation of some urban materials and other land cover surfaces (M Herold et al. 2004). Detailed investigations for mapping impervious surfaces could be explored using corresponding sensor characteristics. Looking back, the fundamental results have certainly been provided in hyperspectral remote sensing of urban materials (Clark et al., 2001) and in the assessing the effects of spectral sensor resolution for urban land cover accuracy (Herold et al., 2003).

1.3. Materials and methods

The study area is the métropole de Toulouse (Figure 2). This hyperspectral image was acquired on the 23-25th of October 2012 during the **UMBRA** mission (**Urban Material** characterization in the sun and shade of **Built-up** structures and trees and their **Retrieval** from **Airborne** image acquisition over two French cities). The UMBRA mission was started and realized in the context of collaboration between IGN (National Institute of Geographic

and Forest Information) and ONERA (The French Aerospace Laboratory) (Adeline K., et al. 2013).

HySpex configuration during UMBRA experiment (Table 1)

Channel	Spectral range (μm)	Number of bands	Full Width at Half Maximum (μm)	Spatial resolution (m)
VNIR	0.4-1.0	160	3.6	0.8
SWIR	1.0-2.5	256	6.0	1.6

(K. Adeline et al. 2013)

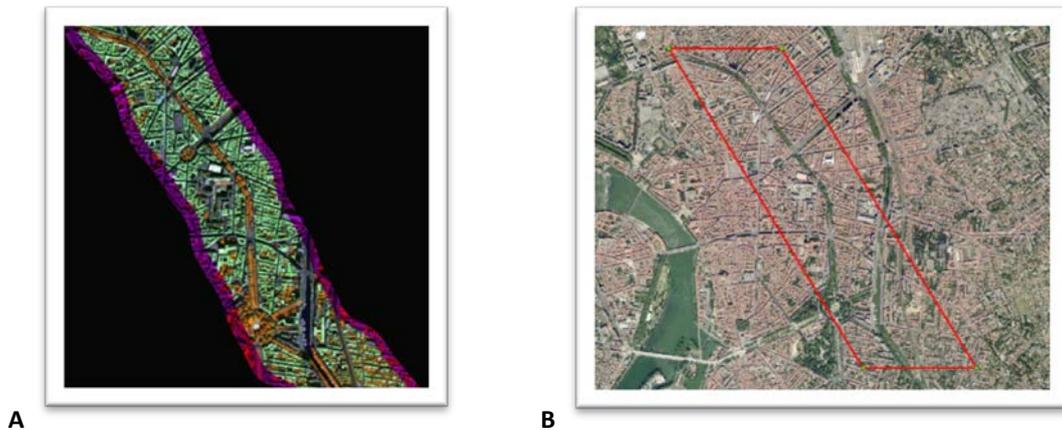


Figure 2. The images of Toulouse center in the hyperspectral data set (R=830 nm; G=1650 nm; B=660 nm) (A) and in natural colors (B); sources IGN and ONERA.

The Figure 2 presents the studied zone, a high built density area in the Toulouse city center (highlighted by red polygon on the Figure 2 B). Hyperspectral image of the area (Figure 2 A) was obtained from using the HySpex sensor (Table 1). This zone was selected because of its great variability of the urban roof materials, pavements, vegetation and water objects.

1.4. Morpho-spectral database

In the present project the morpho-spectral base is presented as “an assembly of object information both spectral and morphologic” extracted from urban objects. Thus, several features have been extracted from the UMBRA image for each type of materials (Figure 4). They are: increase and decrease of reflectance, the reflectance peak and constant features (Heiden et al 2007). These features are also attached to the description of the

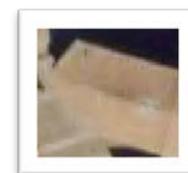
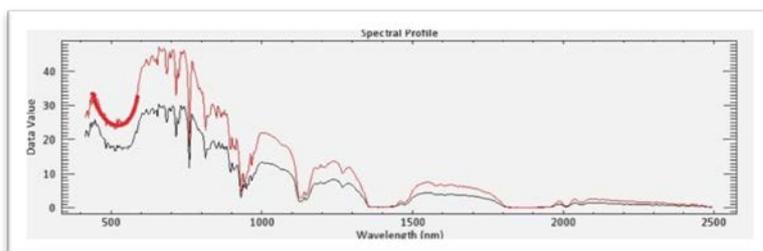
material, the values of spectra defined in the state of the art literature previously described and the spectral database that are already existing. Additional verification of these measurements in situ is also required to improve this observations.

Some factors may affect the object reflection like solar lightning angle, sensor angle or scattered light. Several spectral measurements have been set up to take this variability into account.

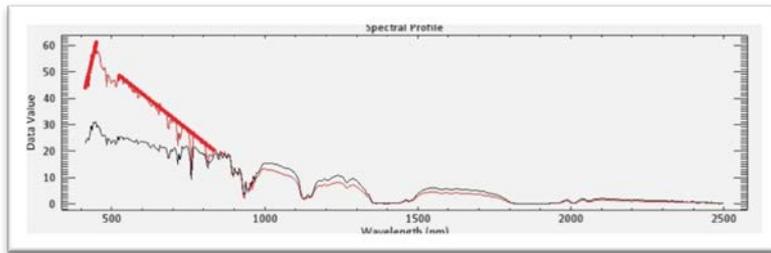
Morphospectral database				Address 1		Address 2		Spectral profile		Database organization	Object type
Image Action	Image Orthographic	Image Simple	Image 3D Map	Address	Date acquisition	Date processing	Spectral database	Spectral profile	Database organization	Object type	
[Image]	[Image]	[Image]	[Image]	15 Boulevard Pasteur, 13000 Marseille	06/10/2010	06/10/2010	13000 Marseille	[Spectral Profile]	13000 Marseille	Single	Building facade
[Image]	[Image]	[Image]	[Image]	15 Boulevard Pasteur, 13000 Marseille	06/10/2010	06/10/2010	13000 Marseille	[Spectral Profile]	13000 Marseille	Single	Building facade (shaded)
[Image]	[Image]	[Image]	[Image]	15 Boulevard Pasteur, 13000 Marseille	06/10/2010	06/10/2010	13000 Marseille	[Spectral Profile]	13000 Marseille	Single	Building facade
[Image]	[Image]	[Image]	[Image]	15 Boulevard Pasteur, 13000 Marseille	06/10/2010	06/10/2010	13000 Marseille	[Spectral Profile]	13000 Marseille	Single	Building facade
[Image]	[Image]	[Image]	[Image]	15 Boulevard Pasteur, 13000 Marseille	06/10/2010	06/10/2010	13000 Marseille	[Spectral Profile]	13000 Marseille	Single	Building facade
[Image]	[Image]	[Image]	[Image]	15 Boulevard Pasteur, 13000 Marseille	06/10/2010	06/10/2010	13000 Marseille	[Spectral Profile]	13000 Marseille	Single	Building facade
[Image]	[Image]	[Image]	[Image]	15 Boulevard Pasteur, 13000 Marseille	06/10/2010	06/10/2010	13000 Marseille	[Spectral Profile]	13000 Marseille	Single	Building facade

Figure 3. Morphospectral database characteristics

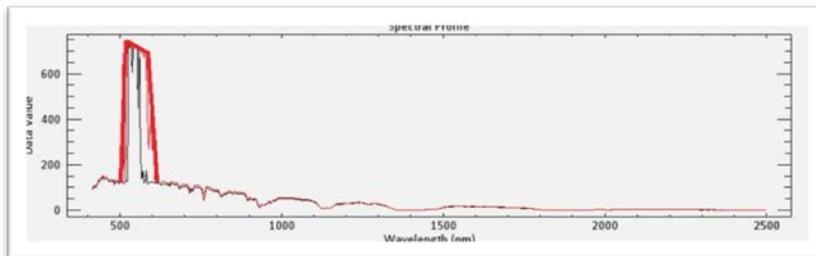
HySpex hyperspectral image spectra presented in comparison with two types of luminosity: illuminated (red line a; b; c; d) and shaded (black line a; b; c)



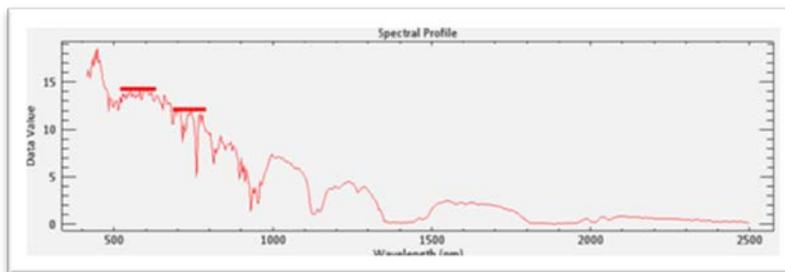
a) Clay roof



b) Gravel roof



c) Synthetic material roof



d) Gravel VS rails

Figure 4. Examples of different spectral curves for the feature description: a) zone of light absorption; b) increase and decrease of reflectance; c) reflectance peak, d) constant features.

1.5. Spectral features database

The goal of the work was to find, compare, and formulate a block of spectral information with an emphasis on the urban spectral features in order to set up the database.

To comfort the link between literature findings and urban materials has been set up and defined regarding land use/cover classification (Heiden et al.2001) (Figure 5).

		List of Particular Spectral Features			Addition 4		
Level 1	Level 2: Land cover types	Level 3: Material types	Level 4: Surface materials	Spectras	Article	Position	
Man-made/Artificial surfaces	Buildings/Roads	Mineral materials	Asbestos	Amiante	580, 800, 2323, (2320, 9,44)	[20]	Labor.
			Bitumen roof sheeting	Toit bitume	1700, 2350, 11300		
			Clay tiles (red)	Tuiles en argile rouge	A 520, 670, 870, (iron oxide absorption)		
			Concrete tiles	Tuiles en béton	A 2300-2370 (calcite and dolomite), A 2170 (content clay), 1413 and 2323 (portlandite, muscovite)	[20]	Labor.
			Gravel	Gravier	A silicates at 2200, hydro-carbonates above 2200, iron oxides near 520, 670,870	[9]	Santa Barb.
		Plate window glass	Plaque de verre à vitre	R 372, 400 A 2280	[23]	Labor.	
		Slate	Slate (ardoise)	R 791, A 940, 2200, 2260, 2340	[23]	Labor.	
		Metallic materials	Aluminum	Aluminium	A 840	[19], [3]	
			Copper	Cuivre	R 540-650, A 2240, 2340	[23]	Labor.
			Zinc	Zinc	A (strong) 550	[4]	
	Man-made/Artificial surfaces	Man-made/Artificial surfaces	Polyvinylchloride (PVC)	Polychlorure de vinyle	Deep absorption at 1200, 1700, 2170, 2300	[1], [2], [3], [4]	London
			PV	Mono crystalline silicon (Si)	732, 1100	[21]	Labor.
				Gallium arsenide (GaAs), Gallium indium phosphite (GaInP)	381, 887	[21]	Labor.
				PV	732-1067 (The optimal PV window is between)	[22]	Labor.
			Tar black paper	Ruberoïde	R 1660, A 2160, 2360, 2440	[22]	Labor.
		Biomass materials	Green roof	Toit végétal	R 550, 750, A 450, 680, 980, 1200,1400, 1900	[9]	Santa Barb.
			Tatched roof	Toit de chaume	Lingo- cellulose vibration A 2100, 2300	[9]	Santa Barb.
			Wood shingles	Tuile de bois	Lingo- cellulose vibration A 2100, 2300,	[9]	Santa Barb.
			Asphalt	Asphalte	Minor absorption 1850, 2315, 2350	[9]	Santa Barb.
			Cement brick	Brique de ciment	1700, 2350, 11300	[1], [2], [3], [4]	London
			R 600-700, iron oxides A1410, A1940-1970, gray cement m	[5], [6], [7], [8], [9]	London		

Figure 5. The list of the particular spectral features

Spectral information has been extracted. A first block (Figure 5) where the spectral information corresponds to the central wavelength of the sensor band with two types of the spectral features for the object's surface characterization: absorption and reflection.

Absorption of light is a physical process of transformation of one type of energy to another when the photons interact with the electrons of the materials.

Reflection is the change in direction of the light beam at the interface between two different media, it is a process when the incident light hits an object and bounces off.

In the second block particular information about spectral features is added in the morphospectral database (Figure 3). This kind of spectral information concerns objects selected from HySpex image of Toulouse on the full reflected spectral range from 0.4 μm to 2.5 μm . Spatial information have been gathered from some open cartographic sources (IGN Geoportal, IGN Orthophoto images) to check the urban related object and its location. This helps to describe the form, the height, the slope orientation and the color characterization of the surface material and urban object of reference.

1.6. Spectral Identificational card

The last part of the work was to determine and perform a method of gathering information for each spectrum group. A Spectral Identification Card (Figure 6) has been designed where two types of variability are presented: a physical variability appropriated to the spatial variations of the object surfaces and a contextual variability affected by the material use.

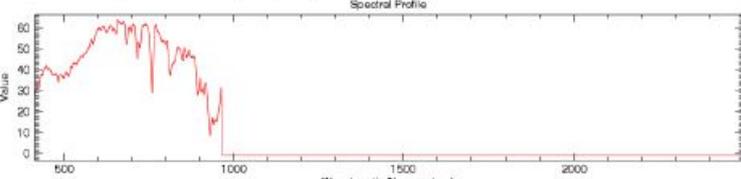
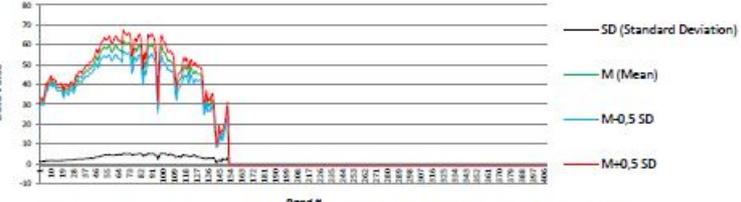
Each Spectral Identification Card contains general metadata (object surface description, graphical information with displayed research objects: HySpex image, IGN Geoportal image, IGN Ortophoto image) and the spectral variability of the sample. The surface spectral variability includes the information about spectral deviation, the average spectral properties to display surface homogeneity and spectral data with the similar type of surface. Thus the material using homogeneous parameters such as a type of material, color characterization and sun exposure were detected and described. The frequent urban surface materials such as asphalt, concrete, brick, clay, vegetation, water and found their corresponding spectra from the existent spectral libraries were structured and added. However their spectra are not fully identical and present some differences due to different measurement conditions. All spectral cards and their additional information can be found on the website <http://hyep.cnrs.fr/> in downloads. The open cartographic sources (IGN airborne photos, IGN geoportal <http://www.geoportail.gouv.fr/>) were also used to determine the object location. It helps to describe remotely the form, height, slope orientation and color characterization of the surface material. It has to be mentioned that additional verification of these measurements in situ is sometimes required to improve these observations.

1.7. Conclusions

The aim of the work was to establish an informational framework for characterizing and identifying the urban system components through hyperspectral data.

The first part of the WP1, was focused on finding the specific signatures associated linking remote sensed hyperspectral data with a surface of natural and man-made materials. By comparing the different sources of hyperspectral images (space borne and airborne platforms), it was found that:

- The hyperspectral remote sensing data open new facilities for analyzing the urban materials.
- The methods of automated acquisition of data from urban surface materials have been developed using airborne and satellites images.
- The high spatial and spectral resolution of hyperspectral sensors gave an opportunity to detect a wide range of object information.

Toulouse_Urban area			
Spectral Identificational Card – sample 1.1.1			
Client reference:	HYEP_ANR_TLSE_ID_sample_1.1.1		Sensor type: HySpex
Name:	Red clay tiles (Tuiles rouge)		
Type:	Manmade materials		
Class:	General Construction Materials		
Subclass:	Tile		
Owner:	ANR-HYEP (The French National Research Agency-CNRS)		
Coordinates :	Geographic (m)	Pixel location (img)	Address: 31 Boulevard d'Arcole, 31000 Toulouse
	N 374039,512	Sample 84	
	E 4829870,782	Line 65	Link: http://geoportail.fr/uri/7F7iiR
Data acquisition:			
October 2012		2013	2010
Pixel location on HySpex Image	Pixel's sample location (variability)	IGN Orthophotograph	IGN Geoportal
			
Data type:			
Simulation from HySpex airborne sensor		Airborne photograph	Airborne photograph
Spectral Domain :			
VIS, NIR, SWIR 1-2, 0.4µm-2.5µm		VIS, (0.4-0.7 µm)	VIS, (0.4-0.7 µm)
Plot #1: Reflected spectra from targeted pixel (Radiance data)			
			
Plot #2: Spectral variability of sample (4 pixels except targeted pixel) (Radiance data)			
			
Link of Acquired Spectral Data (ASCII):	HySpex (1 Pixel) : 1.1.1.txt / (4 Pixels) : 1.1.1_4.txt		
	SLI Plot (ENVI Format): DB_TOULOUSE_SL1.1.1.sli		
Link of Sample Report Statistics:	HySpex: BD_STANDARD_DEVIATION.1.1.1.1.1.txt		
	ASTER: Terra cotta Tiles		
Link of Spectral Data Reference (ASCII)	AVIRIS*: Brown Gray Tile Roof ; Red Tile Roof / ReadMe.txt		
	SANTA-BARBARA*: Red Tile Roof / ReadMe.txt		

*Please read first "Readme.txt" to utilize this Spectral Library. It provides explanations about diversity of urban materials used in following Spectral Library.

Figure 6. Spectral Identification Card

The second part of the WP1, focused on the identification of interactions between urban materials spectra and their morphological qualities. From the available information (Bibliographic list Add. 1) the spectral base was set up. It contains the particular spectral features of urban materials. An example of material classification was taken from the work of Heiden et al.(2001) (a hierarchical thematic classification of urban land cover types and materials). Additionally, the spectral data base was created (Add. 2), with some urban object information extracted from hyperspectral image of Toulouse.

1.8. Perspectives

There are a huge number of questions in the domain of hyperspectral remote sensing that should be considered:

- Lack of the new methods for the hyperspectral data analysis.
- Profound knowledge about the spectral characteristics of the urban and natural materials through a high spectral variability of the objects is required.
- Determination of the best source of additional data (object temperature, altimetry, spectra etc.) for resolving environmental problems.
- Popularization and commercialization of hyperspectral imaging for the scientific investments.

References:

A

Abrams M.J., R. Ashley, L.C. Rowan, A.F.H. Goetz, A.B. Kahle. *Mapping of hydrothermal alteration in the Cuprite mining district, Nevada, using aircraft scanner imagery for the 0.46–2.36 μm spectral region*. *Geology*, 5 (1977), 713–718
ASTER Library <http://speclib.jpl.nasa.gov/search-1>

B

Baldrige A.M., S.J. Hook, C.I. Grove, G. Rivera. *The ASTER spectral library version 2.0*. *Remote Sensing of Environment*, 113 (2009), 711–715.
Ben-Dor, E., Levin, N., Saaroni, H. *A spectral based recognition of the urban environment using the visible and near-infrared spectral region (0.4-1.1 μm): a case study over Tel-Aviv, Israel*. *Int. J. Remote Sens.*, 22 (2001), 2193–2218.
Bowen, B.B., Martini, B.A., Chan, M.A., Parry, W.T. *Reflectance spectroscopic mapping of diagenetic heterogeneities and fluid-flow pathways in the Jurassic Navajo Sandstone*. *Am. Assoc. Pet. Geol. Bull.* 91 (2007), 173–190.

C

Christensen, P.R., Bandfield, J.L., Hamilton, V.E., Howard, D.A., Lane, M.D., Piatek, J.L., Ruff, S.W., Stefanov, W.L. *A thermal emission spectral library of rockforming minerals*. *J. Geophys. Res.* 105 (2000), 9735.
Clark, R.N. *Spectroscopy of rocks and minerals, and principles of spectroscopy*. In: Rencz, A.N. (Ed.), *Manual of Remote Sensing, Remote Sensing for the Earth Sciences*. John Wiley and Sons, New York, 1999, 3–58.
Cloutis, E.A. *Spectral reflectance properties of hydrocarbons: remote-sensing implications*. *Science* 245 (1989), 165–168.
Colburn, Linda P., John M. Irvine, John C. Leachtenauer, William A. Malila, and Nanette L. Salvaggio. *The General Image Quality Equation (GIQE)*. ASPRS/ACSM Annual Convention & Exposition Technical Papers. Bethesda: ASPRS/ACSM, 1996.
Cowen, D.J., J.R. Jensen, G. Bresnahan, D. Ehler, D. Traves, X. Huang, C. Weisner, and H.E. Mackey. *The Design and Implementation of an Integrated GIS for Environmental Applications*. *Photogrammetric Engineering & Remote Sensing*, 61 (1995), 1393–1404.
Curtis E. Woodcock and Alan H. Strahler. *The factor of Scale in Remote Sensing*, 1987.

D

Deaton, B.C., Balsam, W.L. *Visible spectroscopy – a rapid method for determining hematite and goethite concentration in geological materials*. *J. Sediment. Pet.* 61 (1991), 628–632.
Deer, W.A., Howie, R.A., Zussman, J. *An Introduction to the Rock-Forming Minerals, second ed.* Longman Scientific & Technical, 1992, 528.

F

Felipe Crisostomo , Robert A. Taylor , Desiree Surjadi , Ahmad Mojiri , Gary Rosengarten Evatt R. Hawkes, *Spectral slitting strategy and optical model for the development of a concentrating hybrid PV/T collector*, 2014 *Applied energy* 141 (2015), 238–246.

G

Gaffey, S.J. *Reflectance spectroscopy in the visible and near-infrared (0.35-2.55 μm): applications in carbonate petrology*. *Geology* 13 (1985), 270–273.

Goetz, A.F.H., Vane, G., Solomon, J.E., and Rock, B.N. *Imaging spectrometry for earth remote sensing. Science*, 228 (1985), 1147-1153.

Graham R. Hunt. *Spectral signatures of particulate minerals in the visible and near infrared. Geophysics*, 42 (1977), 501–513.

H

Heiden, U., Roessner, S., Segl, K., Kaufmann, H. *Analysis of spectral signatures of urban surfaces for their identification using hyperspectral HyMap data. Remote Sensing and Data Fusion over Urban Areas, IEEE/ISPRS Joint Workshop 2001*, 173–177.

Heiden, U., Segl, K., Roessner, S., Kaufmann, H. *Determination of robust spectral features for identification of urban surface materials in hyperspectral remote sensing data. Remote Sens. Environ.* 111 (2007), 537–552.

Herold, M. *Spectral characteristics of asphalt road surfaces. In: Weng, Q. (Ed.), Remote Sensing of Impervious Surfaces. CRC Press, Boca Raton, Florida, 2007*, 237–247.

Herold, M., Roberts, D.A., Gardner, M.E., Dennison, P.E. *Spectrometry for urban area remote sensing – development and analysis of a spectral library from 350 to 2400 nm. Remote Sens. Environ.* 91 (2004), 304–319.

Hothem, David, John M. Irvine, Ellen Mohr, and Kristina B. Buckley. *Quantifying Image Interpretability for Civil Users. ASPRS/ACSM Annual Convention & Exposition Technical Papers. Bethesda: ASPRS/ACSM, 1996*, 292-298.

Hunt, G.R. *Spectral signatures of particulate minerals in the visible and near infrared. Geophysics* 42 (1977), 501–513.

Hunt, G.R., Salisbury, J.W. *Visible and near infrared spectra of minerals and rocks II. Carbonates. Mod. Geol.* 2 (1971), 23–30.

Hunt, J.M., Wisherd, M.P., Bonham, L.C. *Infrared absorption spectra of minerals and other inorganic compounds. Anal. Chem.* 22 (1950), 1478–1497.

I

Irvine, John M., and Jon C. Leachtenauer. *A Methodology for Developing Image Interpretability Rating Scales. ASPRS/ACSM Annual Convention & Exposition Technical Papers. Bethesda: ASPRS/ACSM, 1996*, 273-281.

K

King, T.V.V., Clark, R.N. *Reflectance spectroscopy (0.2 to 20 μ m) as an analytical method for the detection of organics. In: Soils: Proceedings First International Symposium: Field Screening Methods for Hazardous Waste Site Investigations, EPA, 1989*, 485–488.

L

Leachtenauer, Jon C. *National Imagery Interpretability Rating Scales Overview and Product Description. ASPRS/ACSM Annual Convention & Exposition Technical Papers. Bethesda: ASPRS/ACSM, 1996*, 262-272.

Leachtenauer, Jon C., and Nanette L. Salvaggio. *NIIRS Prediction: Use of the Briggs Target. ASPRS/ACSM Annual Convention & Exposition Technical Papers. Bethesda: ASPRS/ACSM, 1996*, 282-291.

M

Mackay L. & Barr S. *Assessing the potential of hyperspectral angular imaging of urban built form surfaces for the inference of fine spatial scale urban land cover information. Geoinformation for European-wide Integration, Benes (ed.), 2003.*

Meyer, R.F., de Witt, W. *Definition and world resources of natural bitumens. U.S. Geol. Surv. Bull.* 1944 (1990), 1–14.

Mohr, Ellen, Dave Hothem, John M. Irvine, and Carey Erdman. *The Multispectral Imagery Interpretability Rating Scale (MS IIRS)*. ASPRS/ACSM Annual Convention & Exposition Technical Papers. Bethesda: ASPRS/ACSM, 1996, 300-310.

P

Powell N., B.K. Hwang, A. Norris, Barry Ketola, G. Beaucarne, Keith McIntosh, *Improved Spectral Response of silicone Encapsulated Photovoltaic Modules*, 2010 IEEE PVSC Conference Australia

Price, John C. *Spectral band selection for visible-near infrared remote sensing: spectral-spatial resolution tradeoffs*. Agric. Res. Service, USDA, Beltsville, MD, USA, 1997.

Q

Qihao Weng. *Remote sensing of impervious surfaces in the urban areas: Requirements, methods, and trends*. Remote Sensing of Environment 117 (2012), 34–49.

R

Rivard, B., Arvidson, R.E., Duncan, I.J., Sultan, M., Elkaliouby, B. *Varnish, sediment, and rock controls on spectral reflectance of outcrops in arid regions*, 1992.

Rowan L.C., P.H. Wetlaufer, A.F.H. Goetz, F.C. Billingsley, J.H. Stewart. *Discrimination of rock types and detection of hydrothermally altered areas in South-Central Nevada by the use of computer-enhanced ERTS images*. USGS Professional Paper 883, 1974.

S

Sientop, S., & Fina, S. *Monitoring urban sprawl in Germany. Towards a GIS-based measurements and assessment approach*. Journal of land use science, 5 (2010), 73-104.

T

Testa, S.M. *Chemical aspects of cold-mix asphalt incorporating contaminated soil*. J. Soil Contam. 1995.

U

Ungar S.G., J.S. Pearlman, J.A. Mendenhall, D. Reuter. *Overview of the Earth Observing One (EO-1) mission*. IEEE Transactions on Geoscience and Remote Sensing, 41 (2003), 1149–1153. USGS Library <http://speclab.cr.usgs.gov/spectral-lib.html>.

V

Vane G., R.O. Green, T.G. Chrien, H.T. Enmark, E.G. Hansen, W.M. Porter. *The Airborne Visible/Infrared Imaging Spectrometer (AVIRIS)*. Remote Sensing of Environment, 44 (1993), 117–126.

W

Wan, Z., D., Dozier, J. *Spectral emissivity measurements of land surface materials and related radioactive transfer simulations*. Adv. Sp. Res. 14 (1994), 91-94.



Hyperspectral Imagery for Environmental urban Planning

Projet ANR 14-CE22-0016-01

<http://hyep.cnrs.fr/>

WP leader : ESPACE

Livable : WP1.3 Morpho spectral database design

Document Information ANR 14-CE22-0016-01 Acronym HYEP Titre Hyperspectral Imagery for Environmental urban Planning URL http://hyep.cnrs.fr/ Suivi ANR	WP leader : S GADAL Livable WP1.3
--	--

Deliverable Number WP1 WP 1.1 Titre Corrections atmosphériques : WP 1.2 Bases de données Hyperspectrales WP 1.3 Bases de données morphos-pectrales
--

Date : Contractuel	T+6	date 20/01/2016	Intermédiaire
Statut	x Final		
Nature du livrable :	x Report	<input type="checkbox"/> Prototype	<input type="checkbox"/> Autre
Dissémination:	<input type="checkbox"/> Confidentialité		x Public

Emploi	
CDD x	durée 18 mois
Nom Ouerghemmi	Prénom Walid
Responsable S GADAL et C. Weber	
Lieu(x) UMR ESPACE 7300	

Sébastien Gadal Walid Ouerghemmi
Grzegorz Skupinski

Aix-Marseille Université, CNRS ESPACE UMR 7300 CNRS ESPACE
UMR 7300
LIVE (Strasbourg)
LIVE (Strasbourg)

Préface

Il existe actuellement plusieurs librairies spectrales en ligne, avec une disponibilité totale ou partielle des données, nous pourrions citer la librairie spectrale digitale USGS (Clark et al, 2007) ou bien la librairie spectrale ASTER (Baldrige et al, 2009), néanmoins, ces librairies ne sont pas forcément ciblées sur les matériaux urbains, et la recherche de matériaux urbains spécifiques n'aboutit souvent pas. Depuis quelques années, des librairies spectrales exclusivement urbaines voient le jour, les plus connues sont :

- La SLUM (Spectral Library of impervious Urban Materials) (Kotthaus et al, 2014), c'est une librairie spectrale acquise sur la ville de Londres (Grande-Bretagne) de matériaux urbains, et contenant 74 spectres de réflectance de type visible - proche infrarouge (300 nm - 2500 nm) et infrarouge lointain (8 - 14 μ m).
- La Santa Barbara Urban Spectral Library (Herold et al, 2004) avec quelques signatures téléchargeables, de type visible - proche infrarouge (300 nm - 2500 nm), acquise sur la ville de Santa Barbara (États-Unis).

Nous pouvons mentionner d'autres études intéressantes qui concernent les librairies spectrales urbaines, sans toutefois, que les données spectrales soient téléchargeables (Heiden et al, 2007 ; Nasarudin & Sharfi, 2011), la collecte a été respectivement réalisée en Allemagne et en Malaisie, avec des signatures de type visible - proche infrarouge.

Le but de ce Work package n°1 de l'ANR HYEP, est 1) d'enrichir les librairies spectrales existantes, en proposant une multitude de matériaux, représentatifs du paysage urbain, et 2) de proposer une base de donnée morpho-spectrale, qui permettra de classer les objets urbains en prenant en compte, leurs attributs spectraux et leur attributs morphologiques.

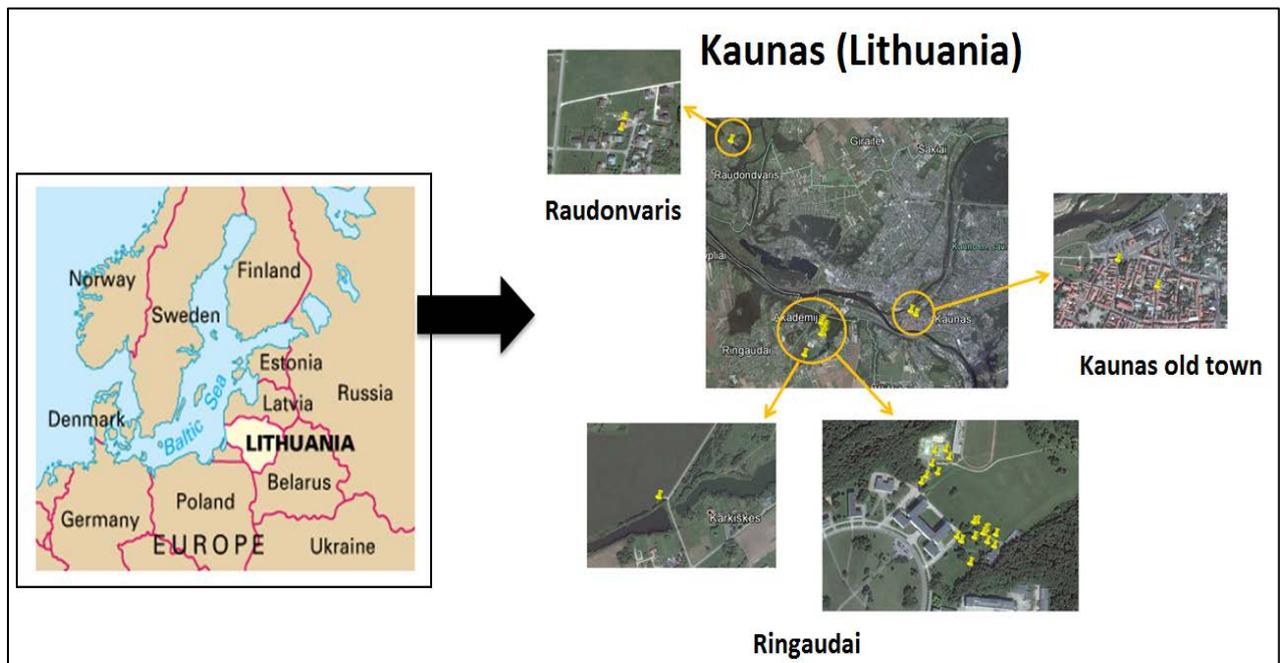
La librairie spectrale a été acquise sur la ville de Kaunas (Lituanie), en collaboration avec une équipe de chercheurs Litvaniens de l'université des sciences agronomiques de Kaunas (Aleksandras Stulginskis University, institut de gestion des forêts et des sciences du bois). Cette campagne d'acquisition vient consolider un jeu de données hyperspectral acquis sur la même ville en Juillet 2015.

1. Librairie spectrale

1.1.Zone d'étude

Les campagnes d'acquisition et de mesures ont été menées en Juillet 2015 comme suit; la première étape concerne la collecte d'objets urbains dans la ville de Kaunas (Fig 1), la deuxième étape concerne le remplissage des fiches d'acquisition (date et heure d'acquisition, coordonnées GPS, prise de vue, état de l'objet au moment de l'acquisition), la dernière étape concerne les mesures spectrales effectuées en laboratoire. La collecte d'objets ainsi que les mesures spectrales ont débutés le 21 Juillet 2015, et se sont poursuivis jusqu'au 27 juillet 2015. La température moyenne à Kaunas enregistrée est de 17.5° C, l'humidité moyenne enregistrée est de 67%. La collecte des matériaux s'est déroulée dans 3 quartiers de la ville de

Kaunas; centre-ville historique, Raudonvaris et Ringaudai. Les matériaux collectés couvrent une variété représentative du paysage urbain de Kaunas; végétation (arbres et gazon), toitures, routes et terre. En plus de la collecte de Juillet de 2015, des collègues de l'Université Technologique de Kaunas (KTU, département des matériaux), nous ont fourni généreusement des échantillons de toitures utilisés à Kaunas, ces échantillons complèteront ceux déjà acquis, les mesures spectrales ont été réalisées en laboratoire en Avril 2016.



Sébastien Gadal et Walid Ouerghemmi, Juillet 2015.

Figure 1. Zones d'échantillonnage dans la ville de Kaunas (Lituanie).

1.2. Mesures spectrales

1.2.1. Matériel

Les mesures spectrales ont été effectuées dans une salle aménagée (i.e. chambre noire, voir Fig 2.b), en utilisant la caméra superspectrale Themis Vision VNIR400H. Il s'agit d'une caméra développée par la société américaine Themis Vision systems LLC. Elle permet de mesurer la radiance électromagnétique de 400 nm à 1000 nm, en utilisant 955 bandes contiguës avec une résolution spectrale est de 0.6 nm. Le capteur CCD possède une taille des pixels de 6.45 μm , une fréquence d'horloge de pixels égale à 20 MHz, et un intervalle dynamique de 12 bits. La résolution des images est de 1392 \times 1000 pixels. L'objectif est orienté à 30°.

La salle utilisée pour effectuer les mesures spectrales est isolée de la lumière, les murs sont couverts d'un matériau noir, cela afin de minimiser les interférences lumineuses qui peuvent affecter le capteur lors de l'acquisition. La source de lumière est générée à l'aide de 2 lampes halogènes de 100 Watts chacune, orientées à 45° vers l'intérieur (Fig 2), et donnant une

lumière uniformément répartie sur la table d'acquisition. Lors de l'acquisition, les échantillons sont placés sur un porte-échantillon métallique de couleur noir mat, ayant la particularité de faire diverger toute lumière étrangère susceptible d'interférer avec l'échantillon. L'image est captée par le capteur CCD ligne par ligne, le résultat final est un cube superspectral de 955 images empilées les unes sur les autres. Chaque pixel appartenant au cube, traduit l'intensité de la radiation électromagnétique à une longueur d'onde donnée.

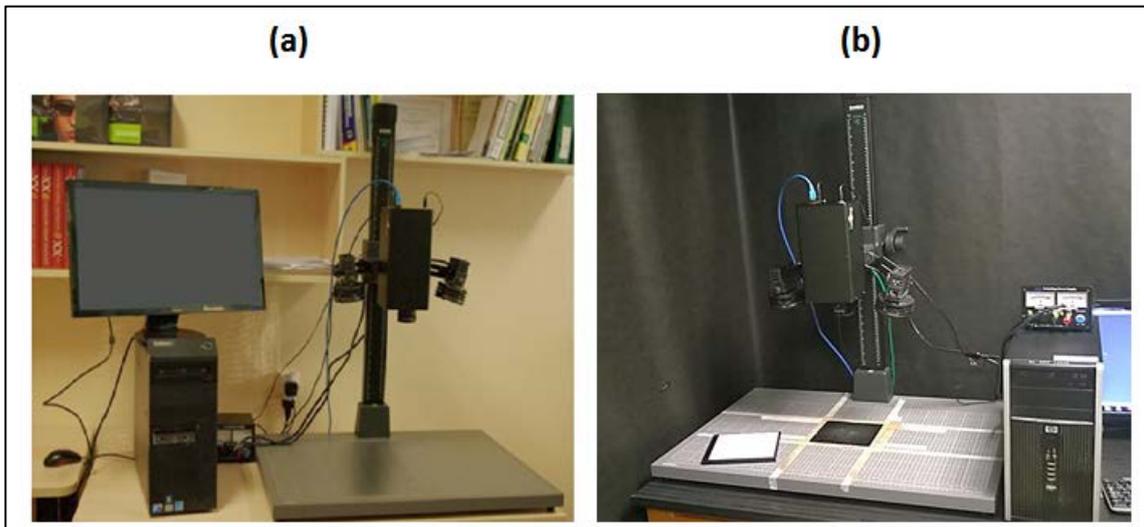


Figure 2.a. Gediminas Masaitis, 2013, Figure 2.b. Gintautas Mozgeris, 2016.

Figure 2. Mesures spectrales effectuées avec la camera superspectrale Themis-Vision VNIR400H, avec a) la caméra avec ses 2 lampes, son alimentation externe et son support et b) la même caméra pendant une session de mesure en chambre noire.

1.2.2. Post-traitements

a. Conversion en réflectance

Le cube superspectral, contient les valeurs en radiance de chaque pixel, une conversion en réflectance est donc effectuée après chaque acquisition; cela est effectué à l'aide d'une référence blanche standard (référence blanche à 99% de Avian Technologies LLC), cette référence permet de réfléchir 99% de la source incidente. La réflectance estimée est égale au rapport entre les valeurs en radiance de l'image « échantillon » acquise à une longueur d'onde λ , et les valeurs en radiance de l'image « référence blanche » acquise à la même longueur d'onde, multiplié par 99% (Eq. 1).

$$\rho_{\lambda} = \frac{NV_{sample}}{NV_{white\ reference}} \cdot 99\% \quad \text{Eq 1}$$

Avec:

ρ_{λ} : Réflectance estimée, calculée à la longueur d'onde λ .

NV_{sample} : Valeurs en radiance de l'image « échantillon » acquises à une longueur d'onde λ

$NV_{white\ reference}$: Valeurs en radiance de l'image « référence blanche » acquises à une longueur d'onde λ

b. Débruitage du signal

Le débruitage des parasites électroniques issus du capteur, est une étape importante dans une chaîne conventionnelle de traitement du signal. Les composants électroniques embarqués dans la caméra, génèrent un bruit affectant les valeurs numériques du cube hyperspectral. Ce bruit est éliminé en comparant l'image « échantillon », par rapport à une image « noire », acquise en couvrant l'objectif de la caméra, ensuite chaque pixel est purifié en appliquant un filtre de type Savitsky Golay (Savitsky & Golay, 1964), avec un kernel de (5×5) pixels (i.e. fenêtre de déplacement), et un polynôme d'ordre 2. Pour chaque nouvelle session de mesure, les mêmes post-traitements sont appliqués, en utilisant le logiciel fourni avec la caméra (Themis HyperVisual).

1.3. Kaunas Urban Spectral Library (KUSL)

1.3.1. Matériaux collectés

La campagne de mesures a été effectuée en 2 temps; une campagne principale en Juillet 2015 (collecte et mesures) et une seconde campagne complémentaire en Avril 2016 (mesures complémentaires). Concernant la première campagne, les objets collectés peuvent être classés en 4 classes (Fig 3); routes, terre, végétation et toitures.

-Concernant les routes, nous disposons de l'asphalte (nouveau et vieux), de pavés en béton (nouveau et vieux), et de pavés en pierres.

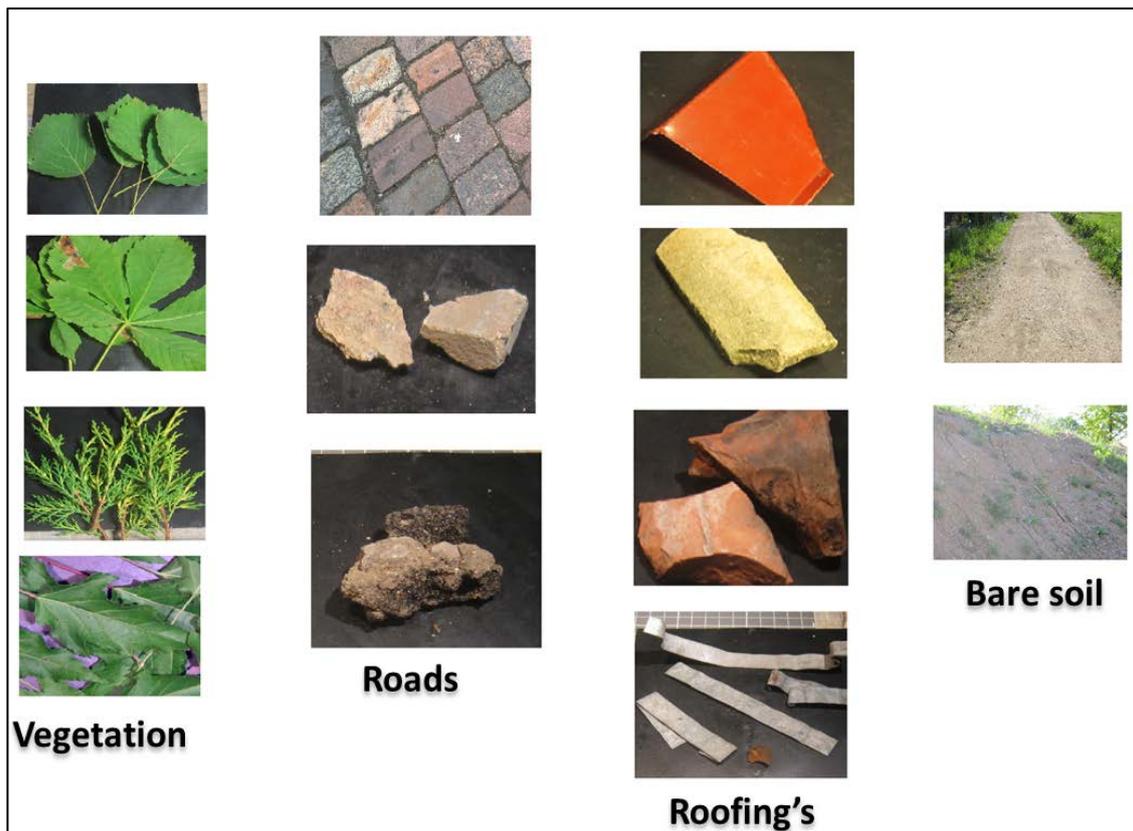
-Concernant la terre, nous disposons d'une terre argileuse, et d'une terre noire.

-Concernant la végétation, nous disposons de quinze espèces répertoriées comme suit : gazon (2 types), thuyas, tremble, *Corylus avellana*, *Juniperus horizontalis* 'Lime Glow', tilleul, sorbier, châtaigne, sapin (2 types), chênes, érable, pins et trèfle rouge.

-Concernant les toitures, nous disposons de 5 types de toitures : bitume, acier (peinture rouge), amiante, acier vieux (type soviétique), tuile.

-Concernant les divers, nous disposons des matériaux suivants : dalles et ciment.

Entre Octobre 2015 et Avril 2016, il y a eu une campagne de validation de terrain et de collecte de nouveaux matériaux.



Sébastien Gadal, Walid Ouerghemmi, Gintautas Mozgeris, Donatas Jonikavicius, et Vytaute Juodkiene, Juillet 2015.

Figure 3. Exemples de matériaux mesurés lors de la première campagne de mesure (Juillet 2015).

Concernant la 2^{ème} campagne d'avril 2016, les objets collectés concernent les toitures urbaines, nous disposons au total d'une vingtaine de matériaux (Fig 4):

- Toitures en amiante: toiture en bon état, toiture vieille avec lichen en surface, toiture vieille sans lichen.
- Toitures en acier : nous disposons de 2 types de toitures en acier peint de couleur marron issues de 2 manufacturiers différents. Nous disposons également d'un échantillon de toiture en acier non peint.
- Toitures en ciment ondulé : nous disposons de 7 échantillons de toitures en ciment ondulé de couleurs différentes (i.e. bleu, rouge, marron, gris foncé, gris clair, orangé, vert et marron).
- Toitures en tuiles : nous disposons d'un échantillon de tuile non peinte de type céramique.
- Toitures en aluminium : nous disposons d'un échantillon de toiture en aluminium.
- Toitures en bitume : nous disposons de 4 échantillons de toitures en bitume de couleurs et de textures différentes (noir, verdâtre, gris).

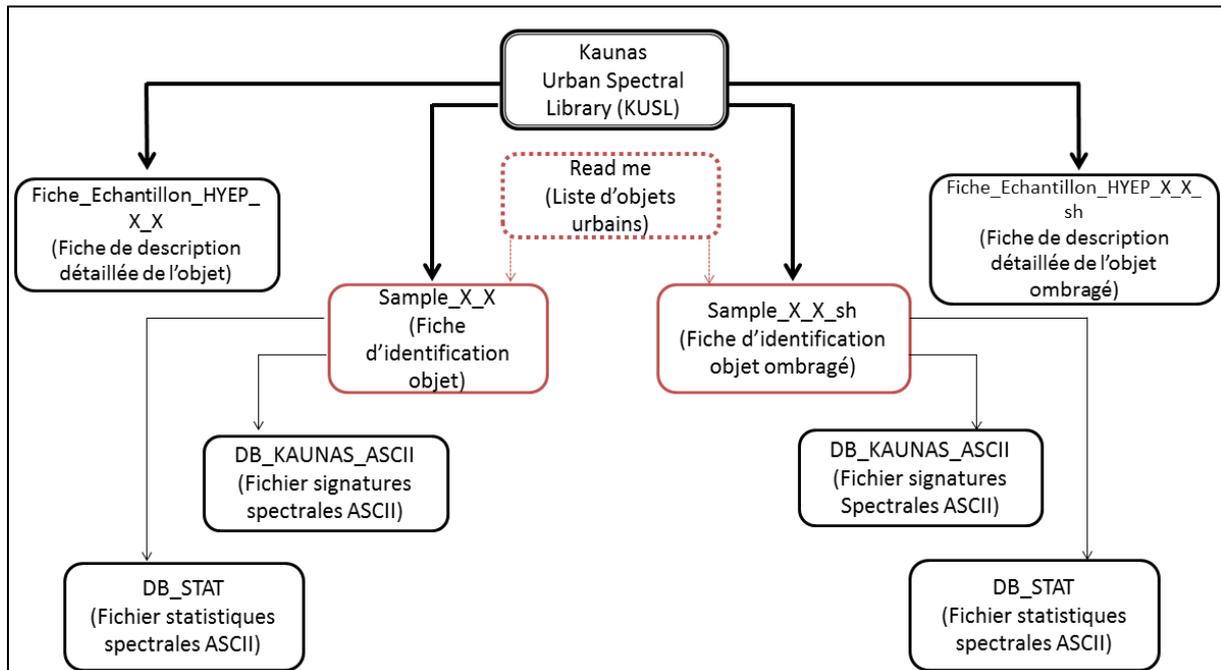


Sébastien Gadal, Walid Ouerghemmi, Gintautas Mozgeris, Algirdas Augonis et Danutė Vaiciukynienė, Avril 2016.

Figure 4. Exemples de matériaux mesurés lors de la deuxième campagne de mesure (Avril 2016).

1.3.2. Architecture de la librairie

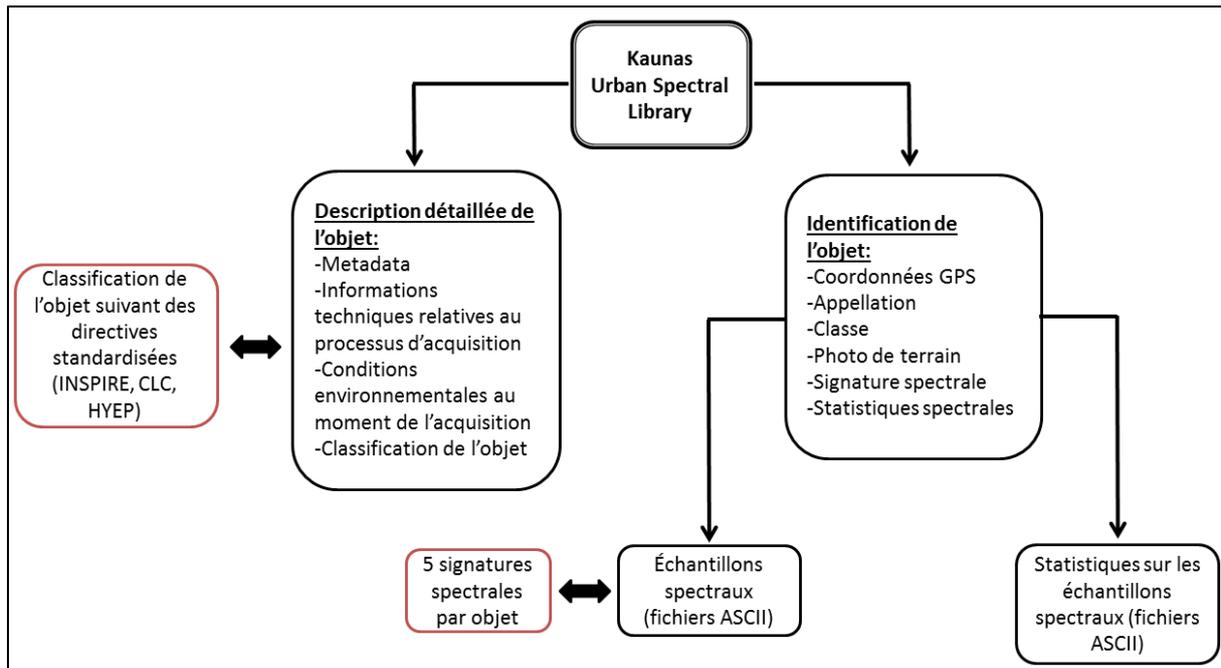
Chaque objet appartenant à la librairie spectrale “KUSL”, est caractérisé par deux fiches ; une fiche d’identification de l’objet, et une fiche de description détaillée du même objet. La fiche d’identification (Fig 5, *Sample_XX*, contour rouge), inclut des informations générales à propos de l’objet mesuré: type, nom, coordonnées GPS, coordonnées Google maps, prise de vue de terrain, signature spectrale, et statistiques spectrales (Fig 6). La fiche de description détaillée (Fig 5, *Fiche_echantillon_HYEP_XX*, contour rouge), inclut des informations plus détaillées à propos des objets mesurés: Metadata, description détaillée à propos des outils de mesures et d’acquisition, informations détaillées à propos des objets collectés et du contexte environnemental au moment de la collecte/acquisition, les contacts et auteurs de la librairie spectrale, et finalement une classification des objets urbains selon les standards universels de classification d’objets (INSPIRE, CLC), également selon le standard HYEP, lui-même s’inspirant des autres standards existants (Fig 6).



Walid Ouerghemmi, Sébastien Gadal, Sergiy Zinko et Grzegorz Skupinski, Janvier 2016.

Figure 5. Architecture globale de la bibliothèque spectrale “KUSL”.

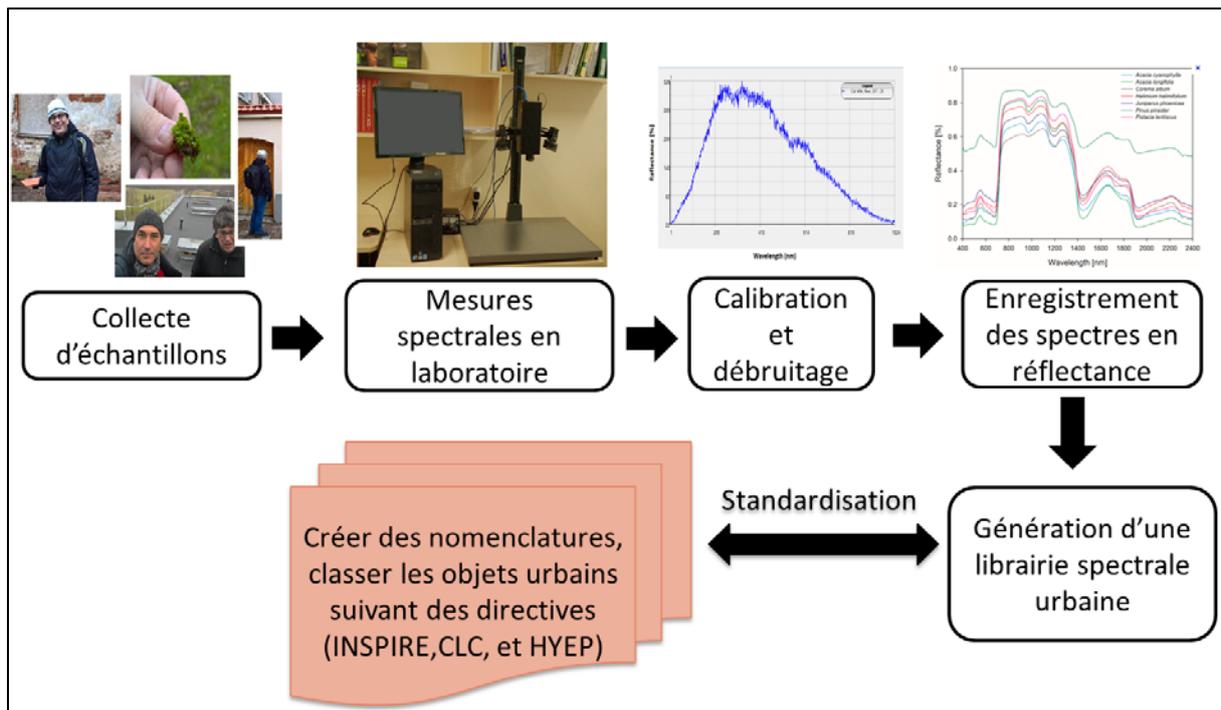
Chaque objet urbain est défini par un indice unique, les indices sont disponibles dans le fichier *Readme* (Fig 5, contour en pointillés rouges), ce fichier donne un aperçu général des objets appartenant à la bibliothèque spectrale, chaque objet est localisé avec Google maps (i.e. l'impression écran y figure), et propose un lien hypertexte vers les fiches d'identification des objets. Les fiches d'identification (Fig 5, *Sample_XX*, contour rouge), contiennent des liens vers les mesures spectrales ASCII de l'objet, qui sont au nombre de 5, et vers les statistiques spectrales en ASCII (écart type, moyenne, moyenne \pm écart type) (Figs 5 et 6). Chaque objet urbain est donc caractérisé par 5 mesures spectrales enregistrées dans des fichiers ASCII et stockées par indice dans le dossier (*DB_KAUNAS_ASCII*) (Fig 5), et par des statistiques de variabilité spectrale, enregistrées dans des fichiers ASCII et stockées par indice dans le dossier (*DB_STAT*) (Fig 5).



Walid Ouerghemmi, Sébastien Gadat, Sergiy Zinko et Grzegorz Skupinski, Janvier 2016.

Figure 6. Architecture détaillée de la librairie spectrale "KUSL".

La figure 7 donne un aperçu des étapes nécessaires à la génération de la librairie spectrale urbaine "KUSL", la première étape concerne la collecte d'échantillons urbains (i.e. soit par acquisition de terrain, soit par requêtes auprès d'organismes ou de laboratoires spécialisés). La deuxième étape concerne les mesures spectrales en laboratoire effectuées avec la caméra superspectrale Themis Vision (i.e. mesures en chambre noire, lampes halogènes dédiées et support adapté aux mesures en laboratoire). La 3ème étape concerne les post-traitements appliqués aux images en radiance (débruitage, génération d'images en réflectance et lissage par filtre digital), la quatrième étape concerne l'extraction et la sauvegarde de n signatures spectrales pour chaque objet urbain mesuré. La dernière étape concerne la génération d'une librairie spectrale standardisée. Le processus de standardisation de la librairie spectrale inclut la création d'une nomenclature spécifique aux objets collectés, et la classification de ces mêmes objets suivant les directives européennes d'aménagement du territoire (INSPIRE, CLC), et suivant la directive HYEP créée spécialement pour les objets urbains. La nomenclature standardisée comporte une fiche d'identification de l'objet, une fiche détaillée du même objet, et des fichiers ASCII contenant les mesures spectrales ainsi que les statistiques de variabilité spectrale.



Walid ouerghemmi et Sébastien Gadal, Mai 2016.

Figure 7. Génération de la librairie spectrale “KUSL”.

2. Classification des objets urbains à l’aide d’une base de données morpho-spectrale

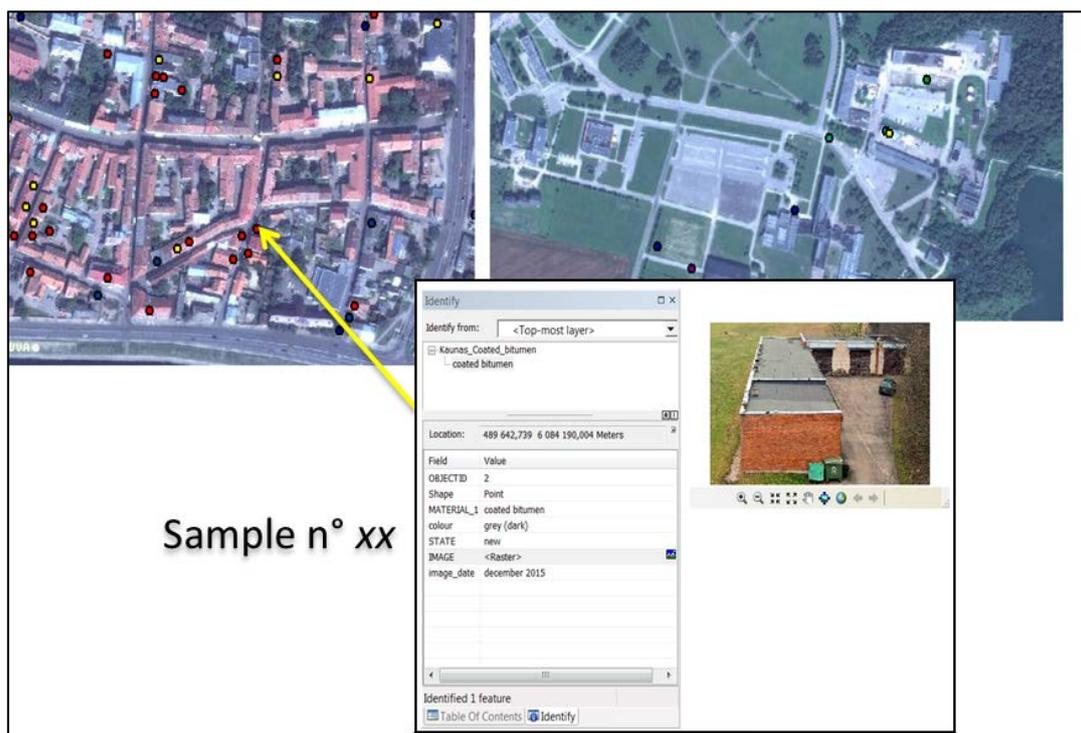
La première étape de ce work package n° 1 concerne la construction d’une librairie spectrale standardisée, cela étant présenté dans la section n° 1 de ce document. La deuxième étape présentée dans cette section n° 2, concerne la présentation de méthodologies de classification des objets urbains par base de données morpho-spectrale.

Le but étant d’exploiter à la fois, l’aspect spectral et morphologique des données hyperspectrales. La librairie spectrale servira à fournir une première classification des objets grâce à leur signature spectrale. Ensuite, une base de données morphologique caractérisant la forme des objets urbains sera générée, elle servira à fournir une classification de deuxième niveau, exploitant la forme des objets classés auparavant. Cette deuxième classification pourra fournir des statistiques quantitatives sur les objets urbains, elle pourra également fournir une classification socio-économique de ces mêmes objets. Pour l’étude morpho-spectrale nous allons nous intéresser seulement aux objets bâtis (i.e. les différents matériaux de toitures), le but étant d’étudier le degré de reconnaissance du bâti par imagerie hyperspectrale Vis-NIR, et de déterminer les matériaux les mieux détectables dans cette gamme spectrale.

Cette section est organisée en 3 sous-sections ; construction d’un GIS de validation, classification des objets urbains par librairie spectrale, classification morpho-spectrale des objets urbains.

2.1. Construction d'un Système d'Information Géographique (SIG)

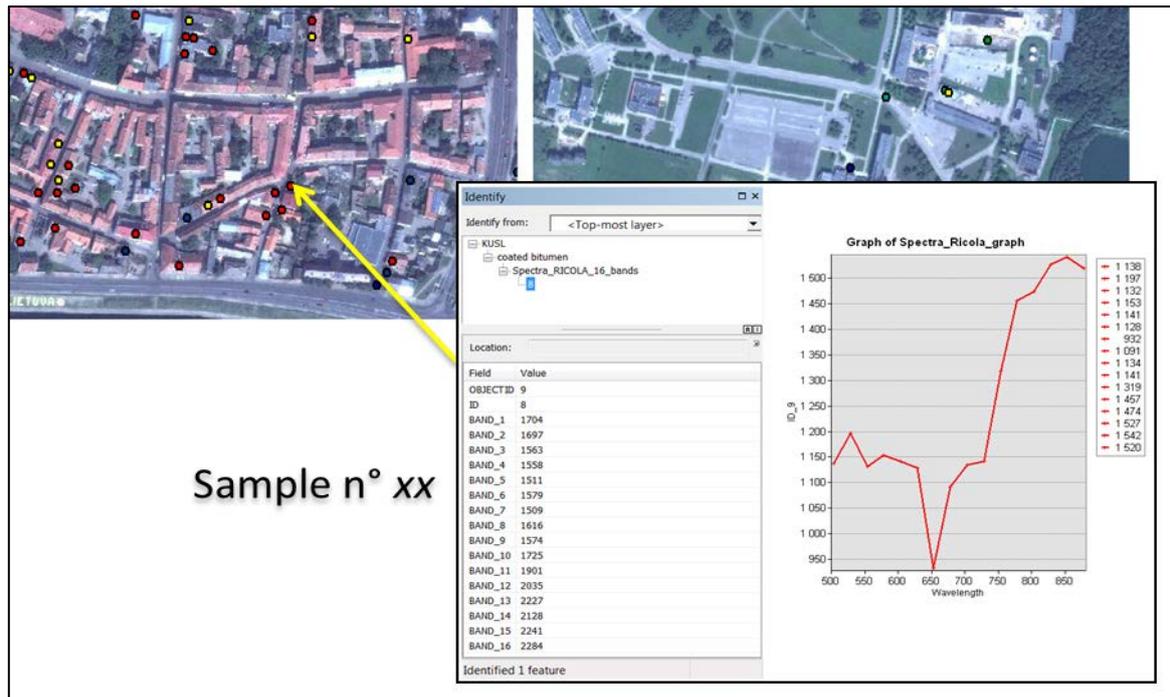
Cette partie concerne la construction d'un SIG sur la ville de Kaunas, qui servira plus tard, pour: 1) valider les résultats de classification, et 2) choisir des échantillons d'entraînement pour le classifieur -au besoin-. Le SIG contient 170 points de validation sur le centre-ville de Kaunas, ces points sont répartis essentiellement sur le centre-ville historique de la ville, cela correspond à la zone test qui nous intéresse. Les points SIG étaient caractérisés entre Décembre et Mars 2016. Pour chaque point, sont disponibles les informations suivantes; appellation matériau, couleur, prise de vue datée du matériau, état du matériau au moment de la prise de vue (Fig 8).



Sébastien Gadal et Walid Ouerghemmi, Octobre 2015-Mars 2016.

Figure 8. SIG créée sur la ville de Kaunas (Exemple d'identification d'un matériau appartenant au SIG nommé Sample n° XX).

Les points correspondant aux matériaux de la librairie 'KUSL' sont également disponibles dans le SIG, ces points sont plus au sud par rapport au centre-ville dans le quartier Ringaudai. les points SIG sont groupés par couleur suivant le type de matériau (Fig 8). En plus de l'identification spatiale d'un matériau, nous avons inclus une identification spectrale (Fig 9), chaque matériau est identifié par une ou deux signatures spectrales, une première signature spectrale de 16 bandes, extraite de l'image Hyperspectrale acquise avec la caméra Ricola (i.e. cela est possible seulement lorsque le point d'intérêt est couvert par l'image Ricola), et une 2^{ème} signature spectrale de type laboratoire, acquise à partir de la librairie spectrale de Kaunas, cette 2^{ème} signature est plus précise et offre 955 bandes spectrales (i.e. cela est possible seulement lorsqu'il existe une mesure spectrale de laboratoire correspondant au point d'intérêt).



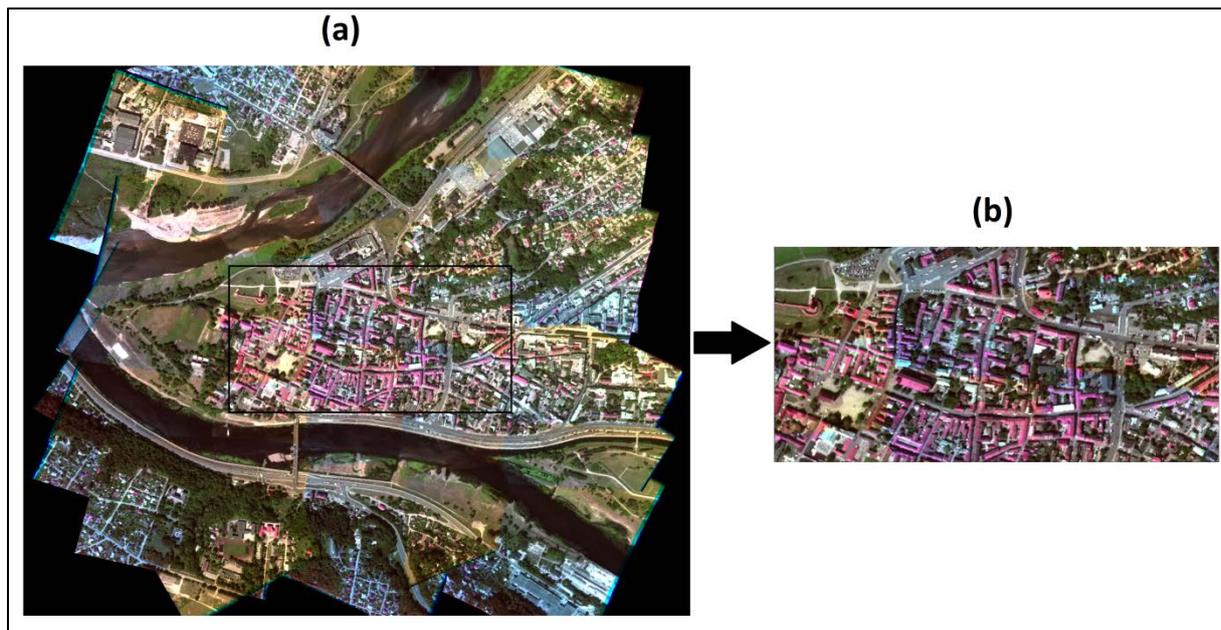
Sébastien Gadal et Walid Ouerghemmi, Octobre 2015-Mars 2016.

Figure 9. SIG créée sur la ville de Kaunas (Exemple d'identification spectrale d'un matériau appartenant au SIG nommé Sample n° XX).

2.2. Classification des objets urbains par librairie spectrale

2.2.1. Image hyperspectrale de 16 bandes

Pour cette étude, nous disposons d'une image hyperspectrale aéroportée du centre-ville de Kaunas (Lituanie) (Fig 10.a), acquise en Juillet 2015 avec la caméra hyperspectrale Vis-NIR RICOLA (RICOLA LTD). La caméra est de conception finnoise, elle possède une gamme spectrale de 500-900nm, et une résolution spatiale est de 0.7m, elle a été configurée pour produire 16 bandes dans le Vis-NIR simultanément; ce choix s'est décidé en étudiant plusieurs paramètres liés à la faisabilité de l'acquisition avec le matériel à disposition tel que; la vitesse d'obturation du capteur, la vitesse d'enregistrement de chaque imagerie sur un support amovible, la vitesse de l'avion, et l'altitude de l'avion. Il a donc fallu trouver un compromis pour configurer le nombre de bandes optimal au moment de l'acquisition. L'image en radiance produite par la caméra, a été convertie en réflectance en utilisant le modèle de transfert radiatif MODTRAN 4 (Matthew et al, 2000), avec un modèle atmosphérique « été latitudes moyennes », détection de l'eau à 820nm, les paramètres prédéfinies liées à la détection d'aérosols n'ont pas été utilisées, le taux d'aérosols dans l'air a été estimé par visibilité et a été configuré à 40Km. Pour cette étude une portion test de 0.8Km² a été extraite de l'image d'origine (Fig 10.b), pour laquelle nous disposons de connaissances de terrain et d'un ensemble de points de validation.



Sébastien Gadal, Walid Ouerghemmi, Gintautas Mozgeris, et Donatas Jonikavicius, Juillet-Aout 2015.

Figure 10. Zone d'étude, centrée sur la ville de Kaunas, a) Image aéroportée originale (Vraie couleur) acquise avec la caméra Ricola, b) zone test extraite de l'image originale pour l'étude.

2.2.2. Classification des objets urbains par librairie spectrale et SIG

L'espace urbain est caractérisé par une hétérogénéité spatiale et spectrale importante entre les objets composant cet espace. L'utilisation d'une librairie spectrale externe permet de détecter des objets spécifiques grâce à leur signature spectrale, en plus de la librairie spectrale, un SIG a été utilisé comme outil de décision, lorsqu'une sélection d'échantillons d'entraînement à partir de l'image est nécessaire (i.e. lorsqu'un objet est inexistant dans la librairie spectrale). L'objectif est de détecter efficacement les objets urbains dans un contexte géographique complexe. La classification des objets est effectuée avec le classifieur Spectral Angle Mapper (SAM) (Kruse et al 2003). Nous avons réalisé deux tests de classification d'objets urbains au cours de ce work package, le premier test visant à détecter les objets urbains les plus couramment rencontrés dans le paysage urbain à savoir: bâti (i.e. tuiles et acier), pavés et végétation (i.e. arbres et gazon). Au fur et à mesure de la construction du SIG et de l'avancement des travaux, nous nous sommes concentrés sur le bâti, et le 2^{ème} test vient consolider cela, en effet, nous avons étendu les matériaux de toitures à détecter, en incluant les tuiles peintes, 1 coloris supplémentaire au niveau des toitures en acier, et les toitures en amiante et en bitume.

a. Classification des objets urbains

Cette étude concerne la détection des objets urbains au centre-ville de Kaunas (Lituanie), les matériaux concernés sont: les toitures en tuiles (i.e. non-peintes), les toitures en acier (i.e. 3 coloris), les pavés, les arbres caducs, les arbres conifères et le gazon.

Les spectres d'entraînement sont importés depuis la librairie spectrale 'KUSL' (voir section 2.3), et rééchantillonnés à 16 bandes afin de correspondre à la résolution spectrale de notre image test (i.e. matériaux concernés : toitures en tuiles non peintes, acier rouge, pavés, arbres et gazon). En plus des spectres d'entraînement acquis par librairie spectrale externe, nous avons utilisé des spectres d'entraînement acquis à partir de l'image et localisés grâce au SIG (voir section 2.1) (i.e. matériaux concernés : toitures en acier clair et acier foncé), afin de caractériser les objets manquants (i.e. qui ne sont pas inclus dans la librairie spectrale).

Les résultats de classification (Figure 11.b) montrent une bonne identification des toitures en tuiles ainsi que des toitures en acier (i.e. acier rouge et acier clair), la détection des toitures en acier foncé est moins bonne, à savoir que ces dernières peuvent avoir des corrélations avec les routes et les toitures en bitume. Sur la zone test, la plupart des arbres sont de type conifères, avec quelques arbres de type caducs et du gazon. La détection des arbres conifères est plutôt satisfaisante, concernant les arbres caducs nous n'avons actuellement pas assez de points de validation pour évaluer leur détectabilité, les parcelles de gazon sont détectés mais pouvant être associées à des arbres. Les pavés sont bien détectés, néanmoins ils sont souvent corrélé avec l'asphalte, donc des sur-classifications sont à noter pour ce matériau.



Sébastien Gadal et Walid Ouerghemmi, Novembre 2015.

Figure 11. a) Zone test_1 Kaunas Centre (Vraie couleur), b) Classification des objets urbains par librairie spectrale externe et SIG.

Afin d'évaluer la performance de classification, nous avons calculé le coefficient Kappa ainsi que le coefficient de précision globale, les points de validation ont été extraits du SIG sur Kaunas (voir section 2.1). Le coefficient kappa obtenu est égal à 0.58 avec une précision globale de 65%, cela paraît acceptable, en prenant en compte le manque de points de validation pour certains matériaux moins représentatifs de la zone test, tels que: les toitures en acier foncé, ainsi que les ratées de classification, observées pour les matériaux suivants: toitures en acier rouge, associées aux toitures en tuiles. Parcelles de gazon, associées à des arbres. Pavés, associés à l'asphalte.

b. Classification du bâti

Cette étude concerne la détection du bâti en zone urbaine, les matériaux concernés sont les toitures en tuiles (i.e. peintes et non-peintes), les toitures en acier (i.e. quatre coloris), les toitures en amiante, et les toitures en bitume (i.e. à savoir que les résultats présentés dans cette section n'incluent pas ce matériau, car la détection de ce dernier n'est pas suffisamment fiable).

Les spectres d'entraînement sont importés depuis la librairie spectrale 'KUSL' (voir section 2.3), et rééchantillonnés à 16 bandes afin de correspondre à la résolution spectrale de notre image test (i.e. matériaux concernés : toitures en tuiles, acier rouge, bitume et amiante). En plus des spectres d'entraînement acquis par librairie spectrale externe, nous avons utilisé des spectres d'entraînement acquis à partir de l'image et localisés grâce au SIG (voir section 2.1) (i.e. matériaux concernés : toitures en acier clair, acier foncé, acier marron et tuiles peintes), afin de caractériser les objets manquants (i.e. qui ne sont pas inclus dans la librairie spectrale).

Les résultats de classification (Figure 12.b) montrent une bonne identification des toitures en tuiles ainsi que des toitures en acier, à savoir que ces dernières peuvent avoir différents coloris (i.e. les plus utilisés dans la ville de Kaunas sont : rouge, orange, rouge bordeaux, gris et vert). Les toitures en tuiles se trouvant dans la zone test, sont pour la plupart non peintes, mais suivant le degré de détérioration la couleur peut varier du rougeâtre au marron, de ce fait, nous pouvons noter que les vieilles toitures en tuiles (i.e. couleur plutôt marron) sont parfois non-détectées ou difficilement détectables, car ayant une couleur légèrement différente de nos échantillons de référence (i.e. appartenant à la librairie spectrale). Les toitures en acier foncé et acier couleur marron, sont moins bien détectées que les 2 autres toitures en acier. Les toitures en amiante et en bitume sont difficilement détectables avec notre image Vis-NIR, car spectralement corrélées avec les routes. Les toitures en amiante peuvent néanmoins, être détectées en prenant des spectres d'entraînement représentatifs. Les toitures en bitume sont pour le moment non détectables, donc non présentés dans les résultats. Afin d'évaluer les résultats de classification, nous avons calculé le coefficient Kappa ainsi que le coefficient de précision globale, les points de validation ont été extraits du SIG sur Kaunas (voir section 2.1). Le coefficient kappa obtenu est égal à 0.6 avec une précision globale de 69.17%, cela paraît acceptable, en prenant en compte la résolution spatiale de l'image, ainsi que le manque de points de validation pour certains matériaux moins représentatifs de la zone test, tels que: toitures en tuiles peintes, et toitures en acier foncé. Ce résultat s'explique également par les

ratées de classification, observée pour les toitures en acier rouge, qui sont souvent associées aux toitures en tuiles (i.e. similarité spectrale importante entre les 2 matériaux en Vis-NIR).

Afin de préparer l'étape suivante, qui concerne la classification morpho-spectrale, et une fois la classification des objets urbains terminée, nous avons sauvegardé les classes individuellement dans des raster images.



Sébastien Gadal et Walid Ouerghemmi, Mai 2016.

Figure 12. a) Zone test_2 Kaunas Centre (Vraie couleur), b) Classification de la zone test par librairie spectrale externe et SIG.

2.3. Classification morpho-spectrale des objets urbains

La classification morpho-spectrale présentée dans cette section, concerne seulement les résultats obtenus et présentés en section 2.2.2.b, à savoir les résultats de classification spectrale du bâti.

2.3.1. Méthodologie

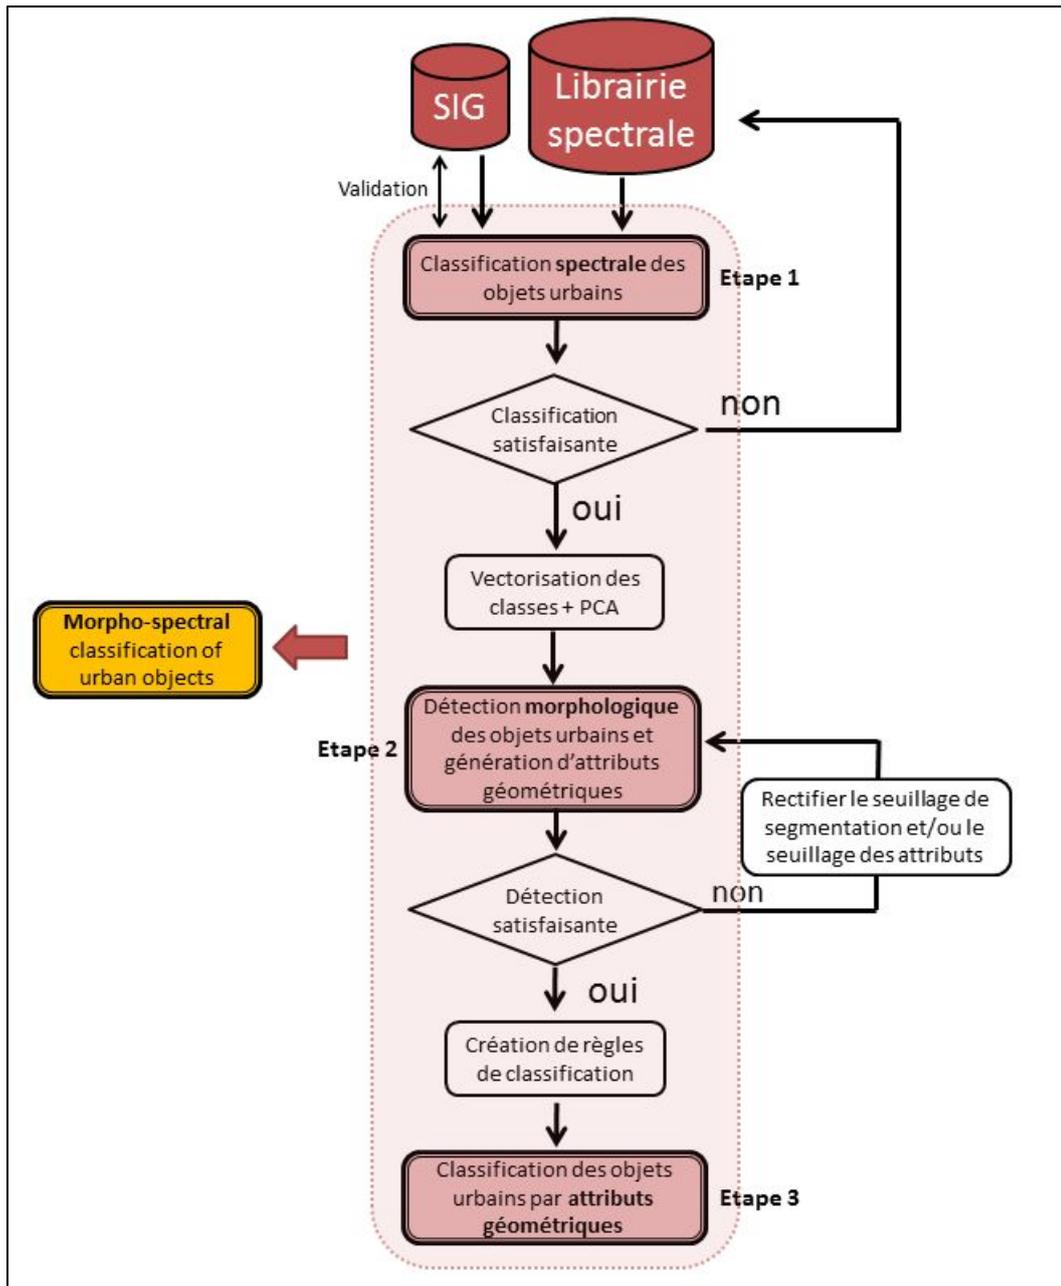
La classification morphe-spectrale a pour but de prendre avantage de l'aspect spectral ainsi que de l'aspect morphologique des objets issus de l'imagerie hyperspectrale. La méthodologie comprend 3 étapes principales: 1) classification spectrale des objets urbains (i.e. section 2.2.), 2) détection morphologique des objets urbains et 3) classification morphologique des objets urbains. La première étape de cette méthodologie concerne la classification spectrale par librairie externe et SIG décrite en section 2.2, les spectres d'entraînement sont acquis à partir de la librairie spectrale, les matériaux manquants sont caractérisés avec des spectres acquis à partir de l'image, en s'aidant du SIG pour le choix des zones d'intérêt (Fig 13, étape 1). L'opération peut être répétée si le résultat de classification n'est pas satisfaisant, la librairie spectrale et le SIG seront alors sollicités pour consolider les échantillons d'entraînement. Une fois la classification spectrale terminée, chaque classe est vectorisée individuellement dans un raster multi-bande.

Une fois la classification spectrale exécutée, les données sont préparées pour la classification morphologique ; à savoir qu'une seule bande est nécessaire pour l'exécution de cette seconde classification. Afin d'exploiter l'ensemble des bandes disponibles, nous avons appliqué une Principal Component Analysis (PCA), pour chaque raster multi-bande (i.e. correspondant à une classe *c*) issu de la classification spectrale, et nous avons gardé la première bande PCA, expliquant plus de 90% de la variance totale.

La classification morphologique (Fig 13, étape 2), traite les données en exploitant la dimension spatiale de l'image, dans le but de dissocier l'image en un ensemble d'objets. Chaque raster mono-bande, crée après l'exécution de la PCA, est donc traité par un algorithme de segmentation par seuillage (Otsu, 1979 ; Tizhoosh, 1997). Afin d'améliorer et de fiabiliser la détection des objets, une fonction de contraste morphologique et un filtre médian sont appliqués (Heijmans, 1994; Kim & Suh, 2007), ensuite la segmentation est configurée puis appliquée à l'image, les différents objets composant l'image sont alors détectés. En parallèle, différents attributs géométriques sont générés pour chaque objet (e.g. superficie, circularité, compacité, convexité, élongation, ect). La détection des objets par segmentation est rectifiée, en modifiant le seuillage de l'algorithme, et/ou en filtrant des objets de type –artefacts– ou –ratées de classification– (e.g. objets très petits, portions de routes identifiées comme éléments urbains, ombrages).

Une fois la reconnaissance d'objets effectuée avec succès, les attributs géométriques générés avec l'étape 2, sont combinés en règles afin de détecter des objets spécifiques, ou bien un groupe d'objet ayant des caractéristiques morphologiques semblables en termes de: surface, forme, élongation, ect (Fig 13, étape 3). Les règles sont créés suivant une connaissance basée sur les attributs géométriques, ces derniers sont d'abord étudiés (étude statistique, histogrammes), ensuite les entités d'intérêt (i.e. groupe d'objets) sont définies en utilisant un ou plusieurs attributs. Les entités sont définies, suivant la structure du territoire urbain disponible (i.e. maison individuelles, immeubles, bâtiments religieux, bâtiments administratifs, stades, centres commerciaux, ect), les caractéristiques propres aux entités et les statistiques générées sur les objets.

La première étape (i.e. classification spectrale et vectorisation des classes) a été implémentée avec IDL et le logiciel ENVI® (Exelis Visual Information Solutions), les étapes 2 et 3 (i.e. segmentation, mesure d'attributs et classification morphologique) ont été implémentées avec le logiciel de traitement morphologique Aphelion® (ADCIS, AAI INC).



Sébastien Gadal et Walid Ouerghemmi, Mai 2016.

Figure 13. Méthode de classification morpho-spectrale des objets urbains.

2.3.2. Détection morphologique des objets urbains

a. Génération des attributs géométriques

La première étape de tout traitement morphologique concerne la segmentation de l'image, pour notre cas, nous disposons de plusieurs raster images (générés après l'étape de classification spectrale, section 2.2.2.b), correspondant à des classes urbaines, une segmentation par seuillage est donc appliquée pour chaque raster image, afin de diviser le raster en un ensemble d'objets, ensuite un nombre d'attributs est généré pour chaque objet

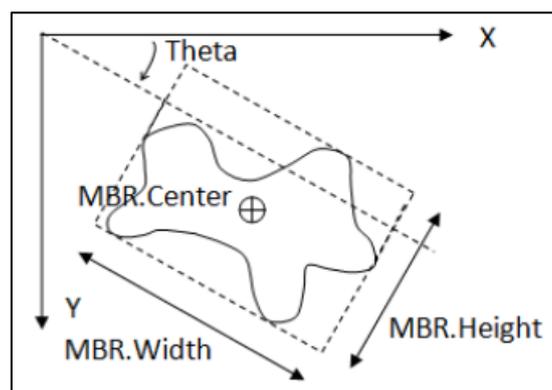
déecté. Le logiciel Aphelion donne la possibilité de générer jusqu'à 70 attributs, en revanche, il est à noter qu'un attribut peut être corrélé avec un ou plusieurs autres attributs, il est donc préférable de restreindre le nombre d'attributs, afin de limiter les répétitions. Ci-dessous nous allons présenter les attributs les plus utiles pour la classification des objets urbains:

-L'attribut "Area" : exprime la surface réelle d'un objet par nombre de pixels. Supposant un objet de 10 pixels, la valeur de "Area" correspondante sera égale à 10, pour une résolution spatiale de 1m², cela correspondrait à une surface totale de 10m². L'attribut "Area" est corrélée à plusieurs attributs de surface tel que "Perimeter" qui correspond au périmètre d'un objet, cette mesure est déterminée à l'aide 4 pixels de connectivité pris sur les bords de l'objet, et est exprimé en unité standardisée, et "Height", qui est la différence entre la coordonnée Y la plus élevée d'un objet et sa coordonnée Y la plus basse, additionnée de 1, et est exprimé en unité standardisée.

- L'attribut "Elongation" est égal à la différence entre les inerties des axes majeur et mineur, divisée par la somme de ces inerties (i.e. l'attribut est nul pour un cercle, il est égal à 1 pour une ellipse longue et étroite).

-L'attribut "MBR.FillRatio" correspond au ratio entre la surface d'un objet et la surface du rectangle de délimitation minimal (i.e. Minimum Bounding Rectangle ou MBR) (Fig 14), cet attribut est utile pour différencier entre les objets [cubiques ou convexes] et les objets [longs ou non-convexes].

-Plusieurs attributs sont associés au MBR : "MBR.Area" qui est la surface du MBR, "MBR.Height" qui est la longueur du plus petit côté du MBR, "MBR.Width" qui est la longueur du côté le plus petit du MBR, avec unité standardisée, "MBR.Theta" qui est l'angle du côté le plus large du MBR (i.e. nommé MBR.Width dans Figure 14) exprimé en radian et allant de $-\left(\frac{\pi}{2}\right)$ à $+\left(\frac{\pi}{2}\right)$.



Gauthier, G., 1999.

Figure 14. Minimum Bounding Rectangle (MBR) illustration.

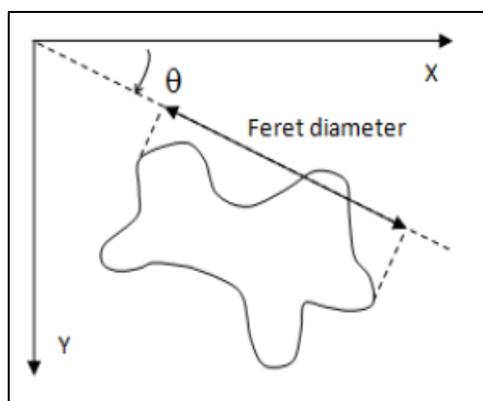
-L'attribut "Circularity" est égal à $(4 \cdot \pi \cdot \text{Area}) / (\text{Crofton Perimeter}^2)$ (i.e. l'attribut est égal à 1 pour un cercle, il est proche de zéro pour un objet long et peu épais).

-L'attribut "Number of Blobs", le nombre d'éléments composants un objet, la mesure est basée sur 4 connectivités. Cette mesure est utile pour différencier entre des objets simple ayant peu de composants (maisons individuelles plutôt carrée ou rectangulaire) et des objets plus complexes multi-composants; 2 immeubles imbriqués en V, auront un "Number of Blobs" égal à 2. Plus l'élément urbain est complexe (i.e. composée de plusieurs éléments), plus la valeur de l'attribut est élevée.

-L'attribut "Convexity" est égal à la surface d'un objet divisée par la surface de son enveloppe convexe, c'est un attribut utile pour discriminer des objets ayant une forme complexe.

-L'attribut "Compactness" : égal à $16 \times \text{Area} / \text{Perimeter}^2$. Cet attribut est égal à 1 pour un objet carré orienté sur un axe X-Y, il est proche de 0 pour un objet irrégulier ou long et peu épais, c'est un attribut efficace pour détecter des petit objets de forme régulières et qui sont plutôt carrées.

-L'attribut "Ferret.diameters": correspond à un ensemble de segments de projections (i.e. feret.diameter), dérivés à partir d'un objet, où l'angle de chaque projection est égal à $n \cdot \Delta\theta$, avec n un réel variant de 0 à 89 et $\Delta\theta$ égal à $\frac{\pi}{90}$, les diamètres de Feret sont exprimés dans une unité standardisée (i.e. un diamètre de Feret est un segment formée par les projections orthogonales des pixels limite de l'objet sur une ligne possédant un angle spécifique, voir figure 15). Afin de pouvoir exploiter cet attribut, il faut utiliser les attributs suivants: "Ferret.elongation", "Ferret.Max", "Ferret.Min", "Ferret.Mean", qui donneront des statistiques sur l'ensemble des diamètres de Feret calculés avec l'attribut "Ferret.diameters".



Gauthier, G., 1999.

Figure 15. Feret diameter illustration.

- L'attribut "HolesArea" : vecteur contenant le nombre de trous contenus dans un objet ainsi que leur surface pixellaire.

- L'attribut "HolesTotalArea" : donne la surface pixellaire totale de l'ensemble des trous contenus dans un objet.

b. Rectification des résultats de classification spectrale par attributs géométriques

La rectification d'une classification par attributs géométriques, permet de corriger les pixels mal classés et d'homogénéiser le rendu final. La figure 16 montre une classification d'objets urbains, avec rectification par attributs géométriques (Fig 13, étape 2). Le but étant de pouvoir supprimer les objets mal classés à l'étape 1, ainsi que les artéfacts de classification. Les artéfacts sont éliminés en appliquant un seuillage sur l'attribut "Area", les ratées de classification (i.e. ombrages et routes détectés comme zones de bâtis) sont éliminés en appliquant un seuillage sur l'attribut "Elongation", et donc d'agir sur les objets longs et peu épais. Cette rectification morphologique peut s'avérer utile afin de compenser les aléas de classification; ratées de classification entre classes dues à une corrélation spectrale importante entre les objets (i.e., routes et toitures, ombrages et toitures, et inter-toitures), et permet de proposer une solution intéressante d'analyse et de traitement des objets urbains par attributs géométriques. Cette étape permet de fiabiliser les résultats obtenus par classification spectrale, en fournissant des classes plus pertinentes quant à la vérité de terrain, et en éliminant les objets erronés.



Sébastien Gadal et Walid Ouerghemmi, Mai 2016.

Figure 16. Rectification de la classification spectrale par l'utilisation des attributs géométriques.

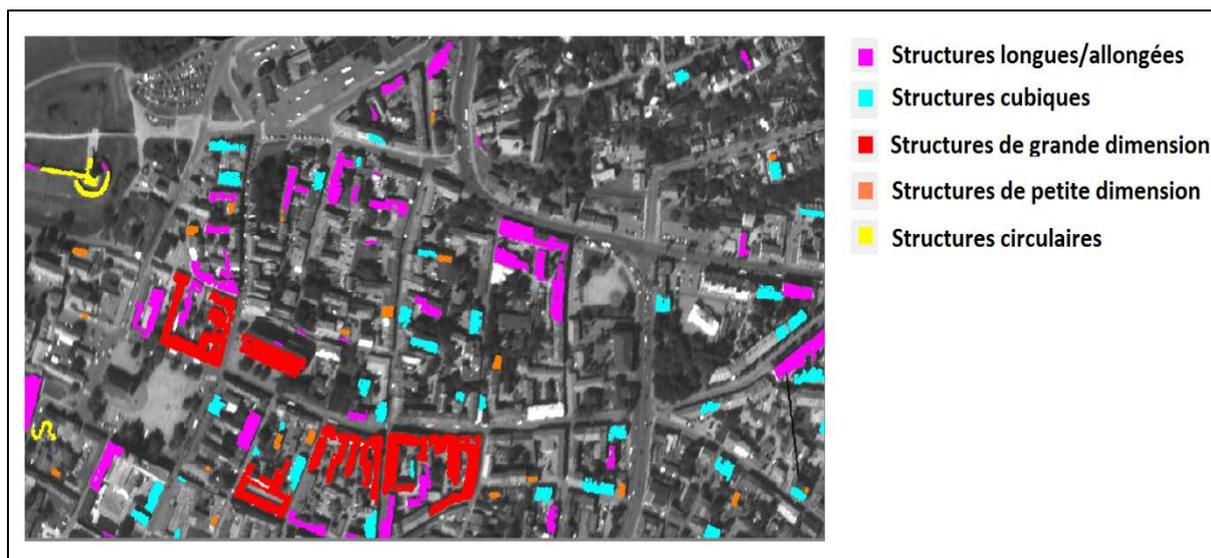
c. Classification des objets urbains par attributs géométriques

La classification par attributs géométriques (i.e. Fig 13, étape 3), est un outil complémentaire à la classification spectrale (i.e. Fig 13, étape 1), elle permet de fournir un 2^{ème} niveau de classification aux matériaux urbains détectés par classification spectrale, en segmentant les pixels d'une classe urbaine en objets distincts et en générant un ensemble d'attributs géométriques relatifs à ces objets (i.e. Fig 13, étape 2). Les applications associées à une telle classification sont diverses: fournir des statistiques sur les objets urbains suivant leur morphologie, fournir une classification socio-économique des objets urbains (e.g. Gadal, 2012 ; Gadal, 2015), fournir une caractérisation urbaine du bâti (Carneiro et al, 2010).

Pour cette étude nous allons tenter de fournir une classification socio-économique des objets urbains en “tuile”. Une classification des objets par attributs géométriques est donc appliquée au “raster” images séparément. Dans l'exemple de la figure 17, nous avons divisé le matériau “tuile”, en 5 classes en utilisant différents attributs géométriques ou en combinant un groupe d'attributs; structures de grande dimension (e.g. bâtiments culturels, sites industriels, centres commerciaux, ect), structures de petite dimension (e.g. maisons individuelles, petits commerces, ect), structures longues/allongées (e.g. immeubles administratifs, immeubles résidentiels, ect), structures circulaires/quasi-circulaires, rectangulaires/quasi-circulaires (grandes maisons, bâtiments culturels/religieux, bâtiments administratifs).

Les structures de grande et de petite dimension sont détectées avec l'attribut “Area”, qui correspond à la surface de l'objet, c'est une classification simple ne prenant en compte que le périmètre des objets, pour des besoins plus spécifiques d'autres attributs devront y être associés. Les structures longues sont détectées avec les attributs “Elongation” et “MBR.FillRatio”, le premier attribut servant à détecter la longueur des objets et le deuxième servant à détecter le degré de cubisme de ces même objets. Les structures cubiques sont détectées avec l'attribut “MBR.FillRatio”, qui est un attribut efficace pour détecter les objets cubiques/non-cubiques ou convexes/non-convexes. Les structures circulaires sont détectées avec les attributs “Circularity” et “Convexity”, le premier attribut servant à détecter le degré de circularité et le deuxième servant à détecter leur degré de convexité.

D'autres classifications peuvent être définis, cela dépend de la spécificité morphologique des objets appartenant à la zone d'étude et au besoin de l'étude de caractérisation (Gadal & Ouerghemmi, 2015).



Sébastien Gadal et Walid Ouerghemmi, Mai 2016.

Figure 17. Classification morphologique du matériau « Tuile ».

3. Conclusion

L'objectif de cet étude relative au WP1 de l'ANR HYEP, est de construire des bases de données morfo-spectral dans le but de caractériser, détecter, et reconnaître les objets urbains issus de l'imagerie hyperspectrale. L'idée étant d'exploiter la richesse spatiale et spectrale offerte par les données de type hyperspectrale, il a fallu donc construire une méthodologie et créer une stratégie d'implémentation, afin de mettre en place une tel base de donnée, et de pouvoir la tester sur un jeu de données hyperspectrale. La première étape de la méthodologie concerne la construction d'une librairie spectrale sur un terrain d'étude spécifique, le choix s'est porté sur la ville de Kaunas en Lituanie, pour 2 raisons :

- 1) Disponibilité d'une caméra superspectrale Vis-NIR, appartenant aux collègues lituaniens de l'ASU, qui va nous permettre d'effectuer les mesures d'échantillons en laboratoire.
- 2) Acquisition récente d'une image hyperspectrale Vis-NIR sur le centre-ville de Kaunas.

Ces 2 éléments font qu'il est possible de construire une librairie spectrale urbaine sur un terrain d'étude T et de pouvoir exploiter cette librairie sur une image hyperspectre I acquise sur le même terrain d'étude. Nous avons donc construit une librairie spectrale de matériaux urbains et évalué le degré de détectabilité d'un nombre de matériaux urbains dans le Vis-NIR en exploitant la librairie déjà construite.

Plusieurs études ont déjà montrés l'efficacité des attributs spectraux dans la caractérisation des matériaux issues de l'imagerie multibande (e.g. Bassani et 2007; Cavalli et al 2009; Kotthaus et al, 2014). Nous avons donc, dans un premier temps, appliqué une classification spectrale basée sur l'utilisation d'une librairie spectrale couplée à un SIG. Les résultats les plus marquants sont:

-Les toitures en tuiles ainsi que les toitures en acier peint sont détectables par classification spectrale, le degré de détectabilité va dépendre de la représentativité des échantillons

d'entraînement qui vont servir à initialiser les classifieurs, plus ces échantillons sont représentatifs du matériau à détecter, meilleur est le résultat de classification. Les toitures en amiante se sont révélées difficiles à détecter car présentant une corrélation importante avec les routes, néanmoins en jouant sur les réglages du classifieur (e.g. poids affecté à une classe pour SAM) et en choisissant des échantillons représentatifs et non affectés par l'ombre, on arrivait à localiser les zones de bâti avec toitures en amiante, en ayant quelques sur-classifications liées aux routes et à l'ombre. Les toitures en bitume se sont révélées non détectables par imagerie Vis-NIR, car très corrélées avec les routes, et même en rectifiant la configuration du classifieur, et les échantillons d'entraînement, la détection obtenue n'est pas assez fiable.

-les arbres de type conifères, ainsi que les parcelles de gazon sont correctement détectés, ces dernières peuvent toutefois être associées à des arbres. D'autres espèces d'arbres (i.e. caducs), sont également détectées, la validation n'a pas pu être faite pour ces arbres, faute de points de validation associés.

-Les pavés sont correctement détectés via l'utilisation de la librairie spectrale, néanmoins, des corrélations avec l'asphalte sont à prévoir.

-La détection des ombrages en Vis-NIR s'est révélée assez fiable, il suffit de sélectionner des spectres d'entraînement correspondant aux zones les plus ombrées (i.e. une dizaine) et de considérer l'ombre comme une classe à part, pour qu'il n'y ait pas de confusions avec les autres classes.

-On a vu que malgré les résultats encourageants obtenues avec la classification spectrale, des limites sont rencontrées, ces dernières sont dues essentiellement aux corrélations spectrales parfois importantes entre les matériaux urbains et à la gamme spectrale limitée (i.e. Vis-NIR). Ces limites vont occasionner des artefacts de classifications, et créer des sur-classifications. Afin de traiter ces éléments indésirables et fiabiliser les résultats de classification, nous avons appliqué une deuxième classification basée sur l'utilisation des attributs géométriques. Les classes obtenues par classification spectrale, sont segmentées par seuillage, et divisées en objets urbains, chaque objet est caractérisé par un ensemble d'attributs géométriques, ces derniers vont permettre d'appliquer une re-classification des éléments urbains en exploitant leur morphologie, les attributs les plus intéressants pour la reconnaissance et la caractérisation des objets urbains sont:

- “elongation” : différencier les objets urbains par leur longueur et leur finesse (e.g. immeuble allongés, ect).
- “area” : différencier les objets urbains par leur surface réelle pixellaire (e.g. grandes structures/petites structures).
- “convexity” : différencier entre les objets complexes/convexes et les objets non-complexes-non-convexes.
- “circularity” : différencier les objets circulaires (e.g. structures).
- “MBR.FillRatio/compactness” : détecter le degré de cubisme d'un objet (e.g. maisons individuelles).
- “Number of blobs” : c'est un attribut pouvant différencier les objets composés des objets non composés (e.g. détection des structures complexes, immeubles multi-éléments, structures culturelles ou administratives, ect).

Remerciements

Nous remercions vivement nos collègues d'Aleksandras Stulginskis University (ASU, Lituanie) : M. Gintautas Mozgeris, M. Donatas Jonikavicius, et Mme. Vytaute Juodkiene, d'avoir mis à disposition leur infrastructure (Avion, capteurs, traitement, ect), et de nous avoir permis de faire les mesures spectrales en laboratoire avec la caméra Themis-Vision, et du support logistique et matériel fourni.

Nous remercions également nos collègues de l'Université Technologique de Kaunas (KTU, Lituanie) : M. Algirdas Augonis et Mme Danuté Vaiciukynienė, de nous avoir fournis généreusement des matériaux de toitures urbaines afin que nous puissions effectuer les mesures spectrales de ces matériaux en laboratoire.

Annexe A (utilisation de la librairie spectrale-access public)

-Ouvrir le fichier “Readme.doc”, chaque matériau est défini par un identifiant unique, se trouvant dans la colonne n°1 du tableau. En appuyant sur l’identifiant, vous serez dirigé vers la fiche matériau “SAMPLE_X,X”, cette fiche contient les informations suivantes ; identification du matériau (i.e. nom, type, classe, sous-classe), coordonnées GPS, liens vers le maps, image Google maps de l’emplacement du matériau, image prise sur le terrain au moment de l’acquisition, signature spectrale d’un échantillon parmi les 5 disponibles, variabilité spectrale des échantillons spectrales (i.e. moyenne, écart type, $M-[0.5 \times SD]$, $M+[0.5 \times SD]$), en bas de la fiche vous aurez la possibilité d’accéder aux données ASCII contenant les signatures spectrales : “X,X.txt”, contient 5 signatures spectrales du même objet, le fichier STAT.txt, contient les statistiques de variabilité spectrales des 5 signatures spectrales relatives à l’objet urbain.

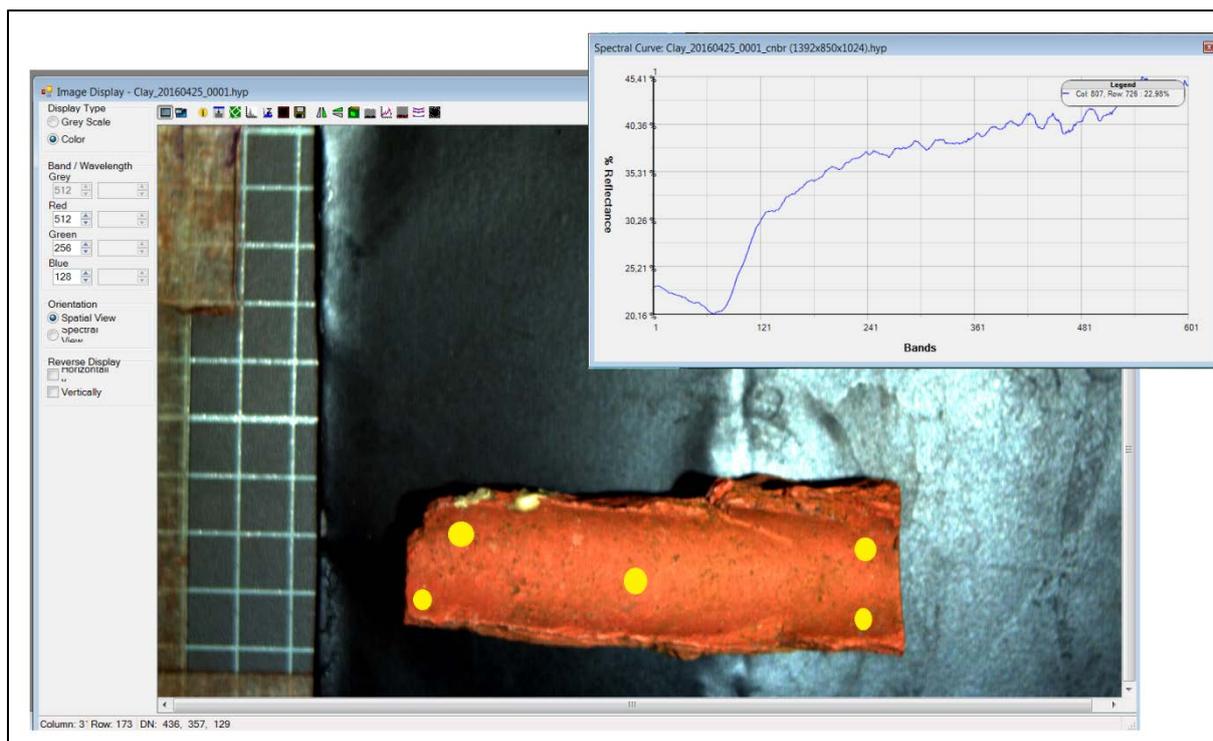
-En parallèle de la fiche matériau, il existe une fiche détaillée pour chaque objet, se trouvant dans le dossier suivant : “fichier source/SAMPLES_CARDS/Fiche_echantillons_HYEP_En_v1.01_SAMPLE_X,X.xls”, cette fiche contient des données plus détaillées sur l’objet: les auteurs de la librairie spectrale, les conditions d’acquisition, et le matériel utilisé: Metadata (i.e. désignation de l’objet, coordonnées des auteurs et détenteurs de la librairie spectrale), sample source description (i.e. informations détaillées sur les conditions d’acquisition et les caractéristiques de la caméra utilisée), sample description (i.e. informations détaillées sur l’objet mesuré), object description (i.e. classification du matériau selon les directives suivantes ; INSPIRE, CLC et HYEP), data package distribution (i.e. informations sur la distribution des données).

Annexe B (utilisation de la librairie spectrale-accès administrateur)

La librairie spectrale actuelle inclut 5 signatures spectrales en réflectance par matériau (Figure 18), en plus de ces spectres, seront fournies les images en radiance de chaque matériau, les images des références blanches et noires utilisées pour générer les images en réflectance, et les images calibrées en réflectance. Les post-traitements appliqués aux images en radiance, sont effectués avec le logiciel Hyper Visual (Themis Vision Systems), et sont décrits ci-dessous:

- 1) Localiser les dossiers où sont stockés les images en radiance des matériaux, les dossiers sont organisés par session de mesure, chaque session de mesure possède une date spécifique, à l'intérieur du dossier se trouve les images en radiance en 2 format, format "HYP" généré par défaut par le logiciel et format "HDR" qui est plus conventionnel et lisible par plusieurs logiciels de traitement d'images tels que ENVI (EXELIS). Dans le dossier "session", il existe un autre dossier nommé "/calibration" et contenant les images des références blanche et noire, qui sont remesurées pour chaque session d'acquisition spectrale.
- 2) La 1^{ère} opération consiste à calibrer l'image en radiance, cette étape comprend la correction du bruit électronique en utilisant une référence noire (i.e. en couvrant l'obturateur), et la génération d'une image en réflectance, en utilisant une référence blanche. L'opération nécessite le chargement des 2 références: blanche et noire, mesurées au début de la session d'acquisition, le résultat est donc une image en réflectance calibrée.
- 3) La 2^{ème} opération consiste à appliquer un lissage spectral sur l'image en réflectance afin d'éliminer les résidus et le bruit issues de l'étape précédente, cela est effectué en appliquant un filtre de Savitsky Golay, avec une fenêtre (5x5) et des moments d'ordre 2.
- 4) La caméra est conçue pour produire des images multibandes allant de 400nm-1000nm, les données qui sont en dehors de cet intervalle sont supprimés car bruités et non fiables.

Afin d'extraire d'avantages de spectres pour un matériau donné, il suffit d'ouvrir un fichier de session, ouvrir une mesure en réflectance de type "HDR" et extraire les spectres d'intérêt, sur certaines images il est possible d'extraire des spectres ombragés.



Sébastien Gadal, Walid Ouerghemmi, Gintautas Mozgeris, Donatas Jonikavicius, et Vytaute Juodkiene, Juillet 2015.

Figure 18. Cinq signatures spectrales extraites pour chaque objet urbain.

Références bibliographiques

ADCIS (<http://www.adcis.net/>), USER GUIDE, p. 177, 2014.

Anderson, G. W. Felde, M. P. Hoke, A. Ratkowski, H.-H. Burke, R. D. Kaiser, and D. P. Miller. *Status of Atmospheric Correction Using a MODTRAN4-based Algorithm*. SPIE Proceedings, Algorithms for Multispectral, Hyperspectral, and Ultraspectral Imagery VI. Vol. 4049, pp. 199-207, 2000.

Baldrige, A. M., S.J. Hook, C.I. Grove and G. Rivera, 2009. The ASTER Spectral Library Version 2.0. *Remote Sensing of Environment*, vol 113, pp. 711-715.

Bassani, C., Cavalli, R. M., Cavalcante, F., Cuomo, V., Palombo, A., Pascucci, S. and Pignatti, S., Aug. 2007.

Deterioration status of asbestos-cement roofing sheets assessed by analyzing hyperspectral data. *Remote Sensing of Environment*, 109(3), pp. 361–378.

Carneiro, C., Morello, E., Voegtle, T., and Golay, F. 2010. Digital Urban Morphometrics: Automatic Extraction and Assessment of Morphological Properties of Buildings. *Transactions in GIS*, 14(4), pp. 497-531.

Cavalli, R.M., Pascucci, S., and Pignatti, S., Aug. 2009. Hyperspectral remote sensing data to map hazardous materials in a rural and industrial district: The Podgorica dwellings case studies. In *Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, 2009. WHISPERS '09. First Workshop on* (pp.1,4), Grenoble, France.

Clark, R.N., Swayze, G.A., Wise, R., Livo, E., Hoefen, T., Kokaly, R., Sutley, S.J., 2007, USGS digital spectral library splib06a: U.S. Geological Survey, Digital Data Series 231.

CORINE: Land Cover Technical Guide, publ. 1994 EU, ISBN 92-826-2578-8.

Directive 2007/2/EC of the European Parliament and of the Council of 14 March 2007, establishing an infrastructure for spatial information in the European Community (INSPIRE), Brussels, 25.4.2007, Official Journal of the European Union (L108/1), <http://inspire.jrc.it/home.html>.

Heiden, U., Segl, K., Roessner, S., and Kaufmann, H., Dec. 2007. Determination of robust spectral features for identification of urban surface materials in hyperspectral remote sensing data. *Remote Sensing of Environment*, 111(4), pp. 537–552.

Heijmans, H., 1994. “Morphological image operators”, in: Hawkes, P. (ed.): ‘Advances in electronics and electron physics’ (Academic Press, 1994).

Herold, M., Roberts, D.A., Gardner, M.E., Dennison, P.E, 2004. Spectrometry for urban area remote sensing – development and analysis of a spectral library from 350 to 2400 nm *Remote Sens. Environ.*, 91, pp. 304–319.

Gadal, S., Oct.2012. Generation of an urban object oriented morphometry database by the remote sensing of SPOT 5 panchromatic images. *Proceeding of ESA-EUSC-JRC 8th Conference on Image Information Mining*, Oberpfaffenhofen, Germany.

Gadal, S., and Ouerghemmi, W., 2015. “Morpho-Spectral Recognition of Dense Urban Objects by Hyperspectral Imagery”. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 40(3), 433.

- Gauthier, G., 1999. Une approche alternative en traitement d'image: la représentation par objet, *ADCIS report*.
- Kim, S.I., and Suh, T.S. *World Congress of Medical Physics and Biomedical Engineering 2006: August 27 - September 1, 2006 COEX Seoul, Korea*. Springer Berlin Heidelberg, 2007.
- Kotthaus, S, TEL Smith, MJ Wooster, and CSB Grimmond 2014: Derivation of an urban materials spectral library through emittance and reflectance spectroscopy, *ISPRS Journal of Photogrammetry and Remote Sensing*, 94, 194-212.
- Kruse, F. A., A. B. Lefkoff, J. B. Boardman, K. B. Heidebrecht, A. T. Shapiro, P. J. Barloon, and A. F. H. Goetz, "The Spectral Image Processing System (SIPS) – Interactive Visualization and Analysis of Imaging spectrometer Data." *Remote Sensing of Environment*, v. 44, p. 145 – 163, 1993.
- Nasarudin, N.E.M., Shafri, H.Z.M., 2011. Development and Utilization of Urban Spectral Library for Remote Sensing of Urban Environment. *J. Urban. Env. Eng.* 5(1), 44–56.
- Matthew, M. W., S. M. Adler-Golden, A. Berk, S. C. Richtsmeier, R. Y. Levine, L. S. Bernstein, P. K. Acharya, G. P.
- Otsu, N., 1979. "A Threshold Selection Method From Gray-Level Histograms", *IEEE Trans. Syst. Man Cybernet.*, Vol. 9 (1).
- Savitzky, A., & Golay, M.J.E. (1964). Smoothing and differentiation of data by simplified least squares procedures. *Analytical Chemistry*, 36 (8), 1627–1639.
- Tizhoosh, H.R.. *Fuzzy Image Processing: Introduction in Theory and Applications*. Springer-Verlag, 1997.

ANNEXES

DATA Livraison

ONERA

CONTENTS

1. DATA DESCRIPTION	2
1.1. Study area.....	2
1.2. Airborne data.....	3
2. METHODOLOGY	3
2.1. Data Preprocessing.....	4
2.2. Instruments simulation.....	4
2.2.1. PLEIADES.....	4
2.2.2. SENTINEL 2.....	5
2.2.3. HYPXIM.....	5
3. REFERENCES	6

1. DATA DESCRIPTION

Between the 23rd and the 25th of October 2012 the UMBRA campaign was carried out over the city of Toulouse (France) [1]. Different ground and airborne data were acquired during the campaign. In this study we used the airborne imagery to obtain the classification maps.

1.1. Study area

Toulouse (43°36'19"N 1°26'34"E) is a city in the South-West of France. Different housing density areas are found in the city. We have selected two different zones. First, a high housing density area in the city centre (hereafter City centre), see Figure 1 left. In this image, stand out a tree-lined avenue and the *Canal du Midi* with the port. Second, a low density housing area, placed in the Montaudran site (hereafter Montaudran), see Figure 1 right. An ancient landing strip outlines in the south-half of the image. In this area, a urban development project is planned, so the classification of the present materials would be useful to detect future land cover changes.

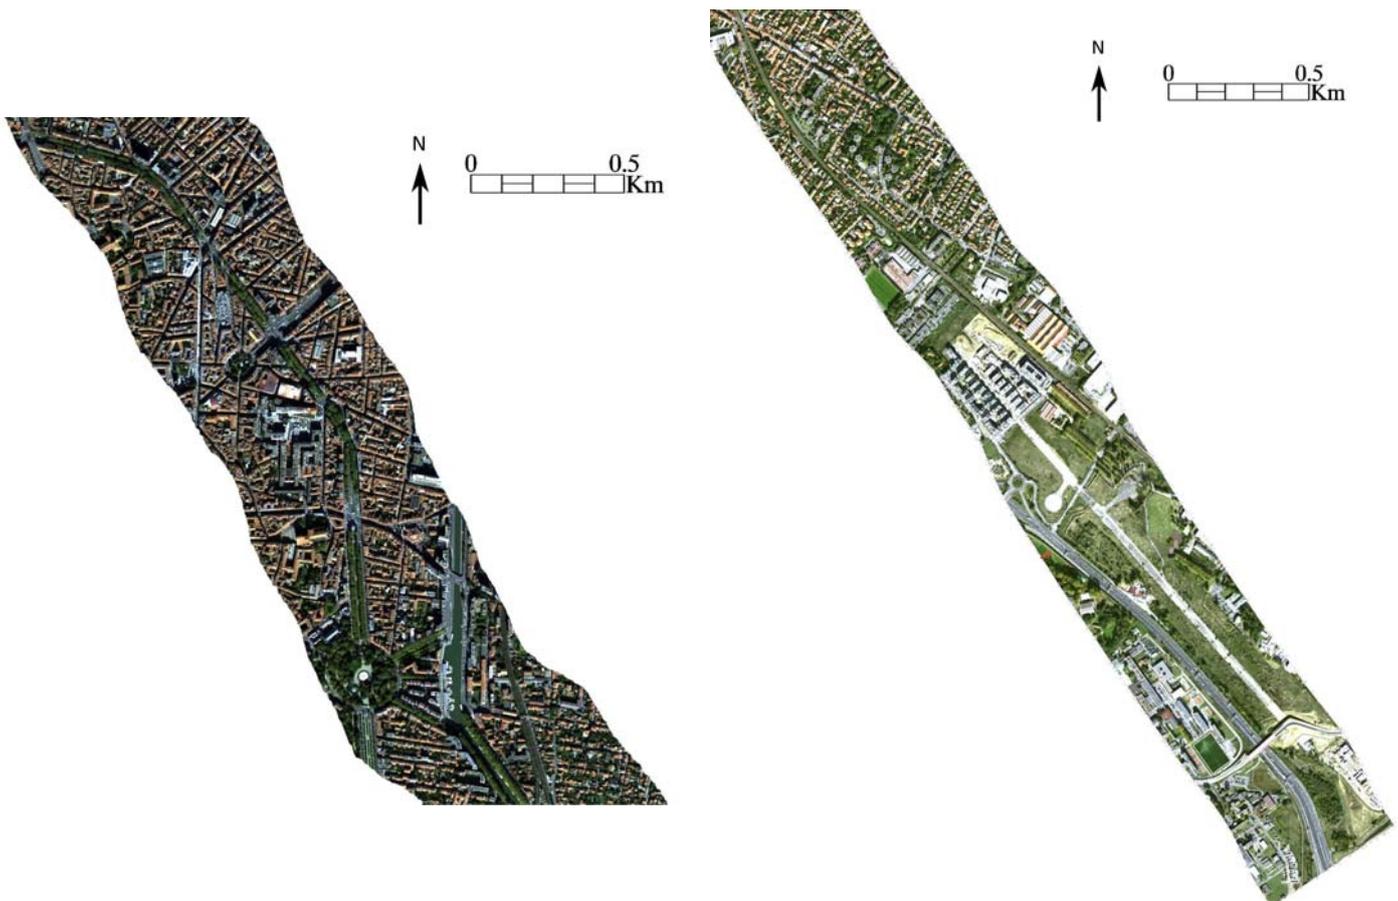


Figure 1 – Study areas: high housing density area in the city centre (left), low housing density area in the Montaudran zone (right)

1.2. Airborne data

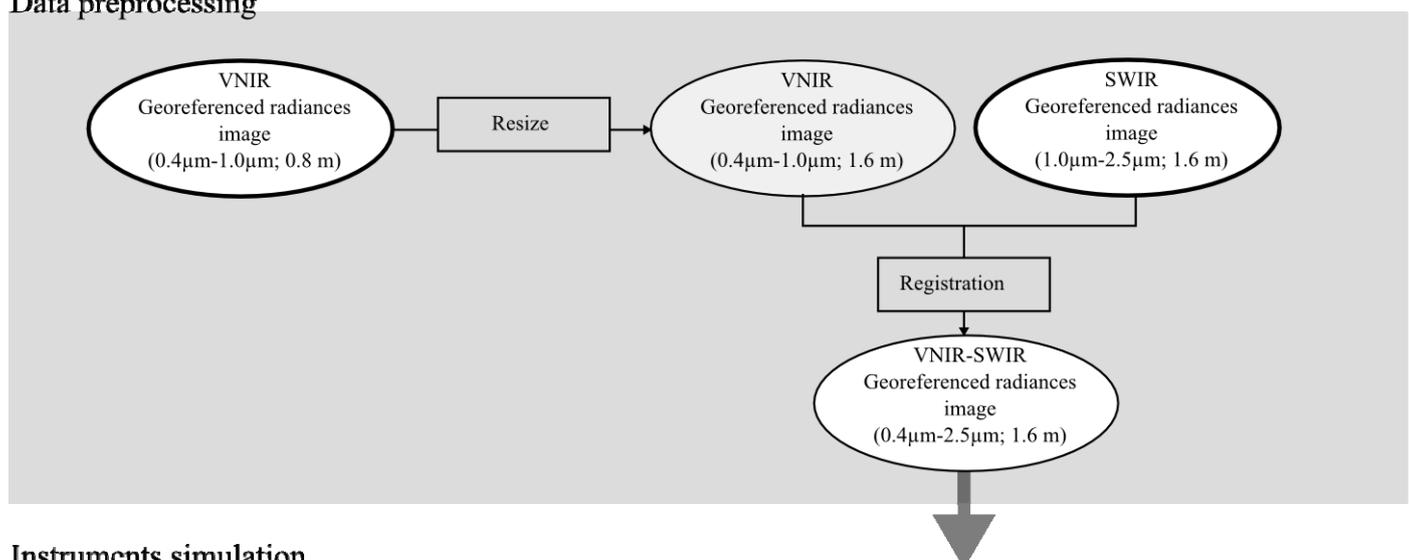
During the UMBRA campaign, the hyperspectral airborne acquisitions were done with the HySpex instrument (<http://www.hyspex.no/>). The instrument has two cameras: the Visible and Near Infrared (VNIR) one covers the spectral range between 0.4 μ m and 1.0 μ m and the Shortwave Infrared (SWIR) one covers the wavelength range 1.0 μ m to 2.5 μ m. Table 1 shows the HySpex spectral configuration and the Ground Sample Distance (GSD) of the images. In this work we are using the VNIR and SWIR georeferenced images, corresponding to the flight-line 04 of the UMBRA campaign.

Table 1 – HySpex configuration during the UMBRA experiment.

Port	Spectral range (μ m)	Number of bands	Full Width at Half Maximum (nm)	GSD (m)
VNIR	0.4-1.0	160	3.6	0.8
SWIR	1.0-2.5	256	6.0	1.6

2. METHODOLOGY

Data preprocessing



Instruments simulation

Simulation of new images with the spatial and spectral configuration of the following instruments:

- PLEIADES
- SENTINEL-2
- HYPXIM

Figure 2 shows the procedure. First, we did a preprocessing of the data: the VNIR and SWIR images were registered, obtaining a geometrically corrected VNIR-SWIR image. Then, this image was used to simulate different spatial and spectral resolutions, corresponding to three real instruments.

Data preprocessing

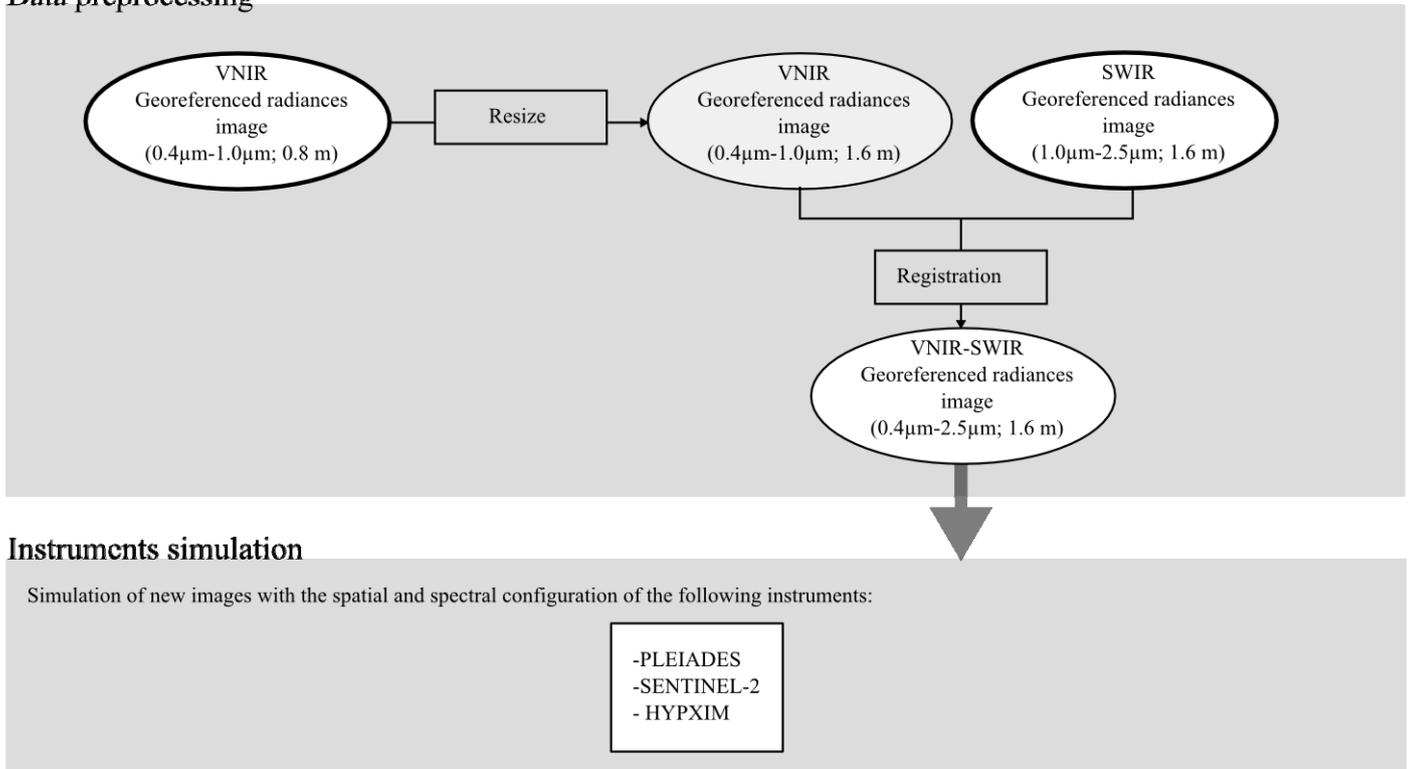


Figure 2 – Simulation flowchart

2.1. Data Preprocessing

To profit from the spectral range between 0.4 µm to 2.5 µm, we need to registrate VNIR and SWIR images, that is to match each pixel in the VNIR image to the corresponding pixel in the SWIR image.

First, the VNIR image was resized to fit the 1.6 m of GSD of the SWIR image. An aggregation process was applied to the VNIR 0.8 m GSD radiance image ($L_{0.8m}$). As proposed in Equation (1), the new aggregated radiances ($L_{1.6m}$) were obtained by averaging all the N pixels values that contributed to the output pixel, in our case, $N=4$ pixels at 0.8 m are needed to obtain a pixel at 1.6 m:

$$L_{1.6m} = \frac{1}{N} \sum_{i=1}^N L_{0.8m} \quad (1)$$

Then, ground control points (GCP), or tie points, were selected over both images. VNIR image was selected as the base image and the SWIR one was warped using a bilinear resampling method. The last step was performed with the ENVI tool (<http://www.exelisvis.com/>).

Last spectral bands of the VNIR port overlap with the first bands of the SWIR port. The VNIR bands were noisier than the SWIR ones, so final VNIR-SWIR image was composed by 408 spectral bands: 152 VNIR bands and 256 SWIR bands.

2.2. Instruments simulation

Different spatial and spectral configurations were generated. Three current instruments were chosen: the operative PLEIADES instrument (<http://smc.cnes.fr/PLEIADES/>), the SENTINEL-2 instrument (<https://earth.esa.int/web/guest/missions/esa-future-missions/sentinel-2>) to be launched in 2015 and the HYPXIM sensor [2], which is under study. As a first step, just the spectral configurations were taken into account. Secondly, both, spectral and spatial features were considered. Then, five cases were considered, Table 2 summarize some information for each one. Details, such as central wavelength or spectral resolution, are given in the next subsections.

Table 2 – Description of the different cases under study.

Name	Number of spectral bands used for classification purposes	Spectral range	GSD (m)
PLEIADES_1.6m	4	VNIR	1.6
SENTINEL2_1.6m	9	VNIR-SWIR	1.6
Hyper_1.6m	245	VNIR-SWIR	1.6
SENTINEL2_9.6m	9	VNIR-SWIR	9.6
Hyper_8m	245	VNIR-SWIR	8

The spectral configurations were obtained, for each central wavelength, by averaging the spectral radiances over the bandwidth of the simulated sensor. The required spatial resolution was obtained as indicated in Equation (1).

2.2.1. PLEIADES

The Pleiades system is developed by the Centre Nationale d'Etudes Spatiales (CNES) and it is a dual use optical camera with a metric resolution designed to offer a high acquisition capability with a revisit lower than 24 hours. It is composed of 5 spectral bands (see Table 3), including a Panchromatic band. The PLEIADES simulated product, with a GSD of 1.6 m is named PLEIADES_1.6m.

Table 3 – Spectral characteristics and ground sampling distance of PLEIADES

Band	Central wavelength (μm)	Bandwidth (μm)	GSD (m)
Panchromatic	0.650	0.360	0.7
Blue	0.490	0.120	2.8
Green	0.560	0.120	2.8
Red	0.650	0.120	2.8
NIR (<i>Near Infrared</i>)	0.840	0.200	2.8

2.2.2. SENTINEL 2

The Sentinel-2 ESA's (European Space Agency) mission is a land monitoring constellation of two satellites that will provide high resolution optical imagery. Sentinel-2 will carry an optical payload with visible, near infrared and shortwave infrared sensors comprising 13 spectral bands: 4 bands at 10 m, 6 bands at 20 m and 3 bands at 60 m spatial resolution (the latter is dedicated to atmospheric corrections and cloud

screening) (http://www.esa.int/Our_Activities/Observing_the_Earth/Copernicus/Sentinel-2). Table 4 summarizes the band characteristics. Two products were generated, the first one at 1.6 m of GSD (SENTINEL2_1.6m) and the second one at 9.6 m of GSD (SENTINEL2_9.6m).

Table 4 - Spectral characteristics and ground sampling distance of SENTINEL-2

Band	Central wavelength (μm)	Bandwidth (μm)	GSD (m)
1	0.443	0.020	60
2	0.490	0.065	10
3	0.560	0.035	10
4	0.665	0.030	10
5	0.705	0.015	20
6	0.740	0.015	20
7	0.783	0.020	20
8	0.842	0.115	10
8a	0.865	0.020	20
9	0.945	0.020	60
10	1.375	0.030	60
11	1.610	0.090	20
12	2.190	0.180	12

2.2.3. HYPXIM

The HYPXIM sensor is a future hyperspectral space borne instrument leaded by the CNES, with a spatial resolution of 8 m in the VNIR-SWIR range. In this study we took advantage of the HySpex configuration to simulate the HYPXIM maps. That is a Full Width at Half Maximum of 3.6 nm in the VNIR range and of 6.0 nm in the SWIR range. Two products were obtained, one at 1.6 m of GSD (Hyper_1.6m) and the other one at 8 m of GSD (Hyper_8m).

3. REFERENCES

- [1] K. Adeline, A. Le Bris, F. Coubard, X. Briottet, N. Pappadimitis, F. Viallefond, N. Rivière, J.P. Papelard, P. Deliot, J. Duffaut, S. Airault, N. David, G. Maillet, L. Poutier, P.Y. Foucher, V. Achard, J.P. Souchon, C. Thom. Description de la campagne aéroportée UMBRA : étude de l'impact anthropique sur les écosystèmes urbains et naturels avec de images THR multispectrales et hyperspectrales. *Revue Française de Photogrammétrie et de Télédétection*, 202, (2013).
- [2] S. Michel, M.J. Lefevre-Fonollosa, S. Hosford. HYPXIM-A hyperspectral satellite defined for science, security and defense users. Hyperspectral Workshop, Frascati, Italy, ESA SP-683, (2010).

DATABASE HYPERSPECTRALE



ANR HYEP

ANR HYEP ANR 14-CE22-0016-01

Spectral Data Base

HYEP Hyperspectral Database and Data Exploration Platform

Authors : Thomas Lampert, Sergii Zinko, Christiane Weber

1. Development Principles

List of actual Spectral databases (2016) and characteristics.

- Aster
- Ben-Dor
- Capitoul
- LIVE
- Luma-Slim
- Modis UCSB
- Santa Barbara
- Sophie
- USGS
- Madrid ESA
- Angers
- Memoires
- ONERA
- Nantes University

✓ DB LUMA, KAUNAS, MEMOIRES BRDF, LIVE CASI have been integrated.

ID	DB NAME	OWNER	DATA TYPE	DATE	SPECTRAL DOMAIN
1	Aster (jhu) spectral library	National Photographic Interpretation Center	laboratory	2008	0.4-25mkm
2	Ben-Dor spectral library	Ben-Dor	in situ	2001	0.35-2.5 mkm
3	Capitoul spectral library	CNRS	in situ	2005	0.35-2.5 mkm
4	Modis ucsb emis library	Univercity of California	laboratory	1994	3.33-14.55 mkm
5	Sophie spectral library	Aix-Marseille University	in situ	2004	0.35-2.5 mkm
6	Madrid esa spectral library	University of Valencia	in situ	2008	0.35-2.5 mkm
7	Angers	INRA Angers (France)	in situ	2003	0.4-2.45 mkm
8	Memoires	ONERA/DOTA L. Poutier	laboratory	2011	0.25-13.3 mkm
9	Nantes University spectral library	Nantes University	in situ	2001	0.35-2.5 mkm

Developing the HYPE database, which integrates the spectral libraries, was a large and novel undertaking. The database went through numerous developmental iterations before a satisfactory schema was derived that could account for all the information attributed to a hyperspectral sample in normalised form, see Appendix A, Figure 7.

It became evident during this development that dividing the spectra that existed from available libraries between multiple criteria (material, age, condition, plant type etc.) would result in a very low sample density. Moreover, a number of existing libraries contain spectra that are already the average of a number of samples. Removing these means that even fewer samples for each class remains. Therefore, any statistics derived from them would not be representative of the class' true variance.

This was corroborated when using the statistical samples to classify the hyperspectral images of Toulouse. Figure 1 is the result of detecting the samples that most closely match the average tree sample from the database; there is a large confusion between the vegetation, roof tiles, and highly reflective surfaces.

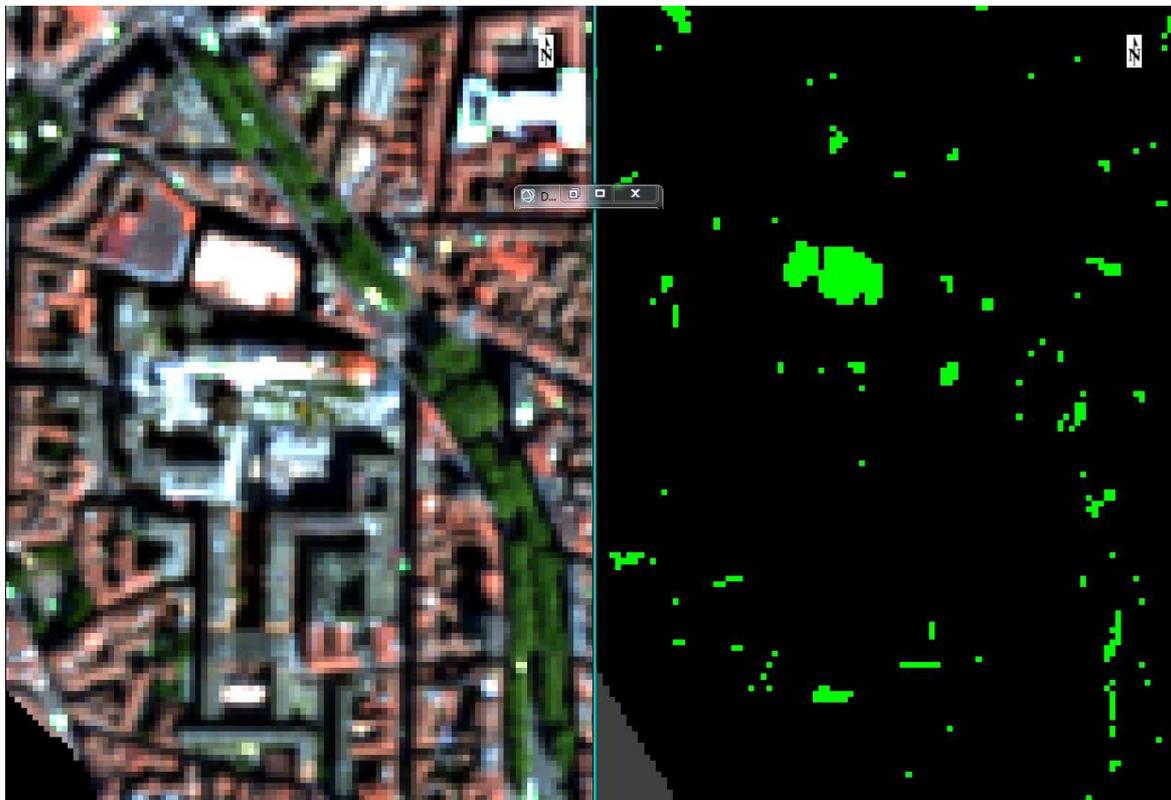


Figure 1. (left) Toulouse image 2015 (TC_2015_Hypxim_4m_refl_Cochise), (right) classification by spectral angle mapper, threshold 0.75 radians, to the average tree sample contained within the HYPE database.

To correct for this, it was decided that the system should be extended to follow five principles:

1. Dynamic repository — by allowing samples to be added to the database by users it is transformed into a dynamic repository instead of a static tool.
2. Data exploration — by building a data exploration platform on top of the database, the database can be used to easily extract the statistics of certain classes and

combinations of spectra when needed. These statistics become more representative as more data is added to the database.

3. Data visualisation — by allowing a user to graphically visualise the spectra contained in the database further insight into the data is gained, which enhances the database's usefulness.
4. Data exporting — by allowing users to export the data from the database in a form that is amenable to further machine learning and data analysis pipelines the database can become part of researcher's analysis, which builds visibility in the research domain.
5. Classification — allowing users to upload spectral samples and to classify them according to the data contained in the database further enhances its usability.

2. System Schema

To achieve these aims, a modular system was developed to allow scalability as the database and user base grows. It consists of the six components shown in Figure 2, each of which are described below.

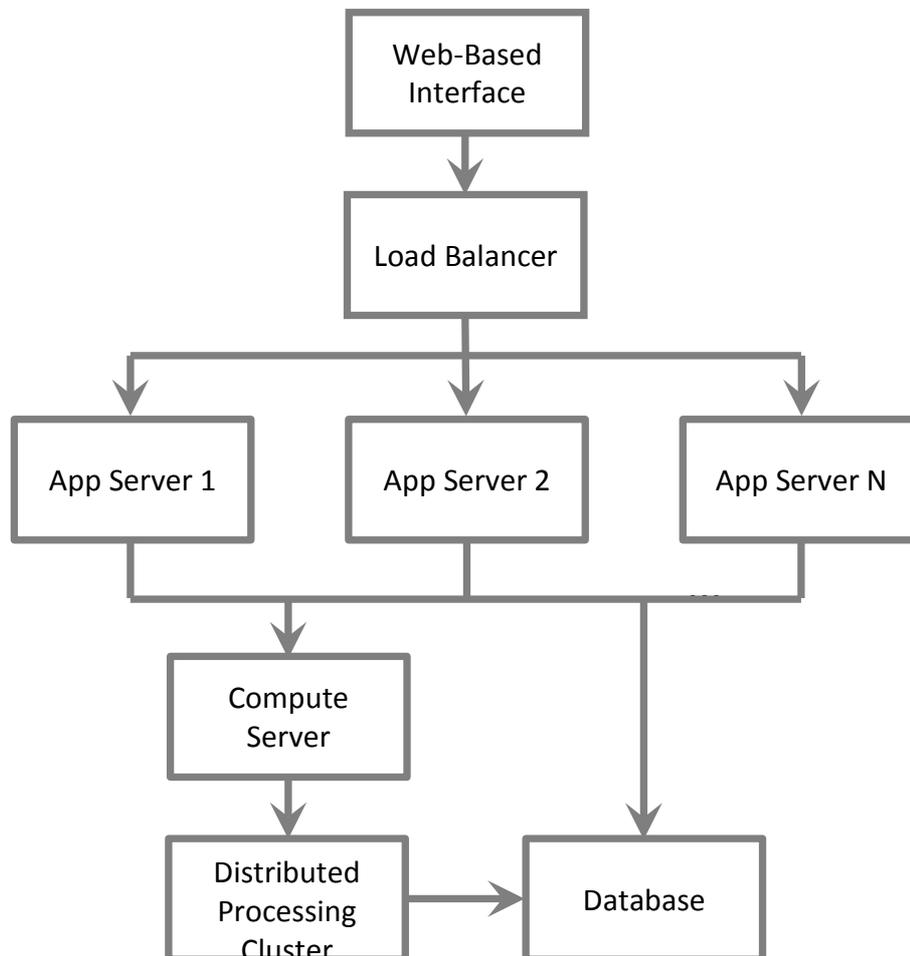


Figure 2. HYEP system schema.

Web-Based Interface – HTML and JavaScript

The frontend is the user's only interface with the system, it is web based and so can be viewed in any modern browser. The frontend communicates directly with the load balancer, which in turn distributes the requests to the app server to enable multiple users to interact with the system without any performance penalties.

Load Balancer – nginx

The load balancer distributes tasks evenly to each of the app servers so as not to swamp one server with all the tasks.

App Server – Node.js

The app server handles requests made by the frontend. To respond to these requests, it either directly queries the database or passes the computation onto the compute server. It implements the following functions that interact directly with the database:

- `getMaterials` – returns a list of the types of materials that have samples in the database, e.g. asbestos, concrete, etc.;
- `getNames` – returns the names of the libraries that are contained within the database, i.e. which libraries the spectra originate from;
- `getSensors` – returns a list of the sensor types that are associated with the samples in the database;
- `getSources` – returns a list of the sources of the samples in the database (currently 'in situ' and 'laboratory');
- `getSpectraList` – returns a list of all the spectra in the database;
- and the following that interact with the compute server:
- `availdists` – returns the distance measures that are supported in the compute server (currently unused);
- `clcdistances` – calculates the distances of the spectra to each of the nodes in the CLC tree (used to classify the spectra into a material type);
- `cluster` – embeds the selected spectra into a 2D plot;
- `getclctree` – interacts directly with the compute server, returns the CLC tree of the samples contained within the database;
- `resample` – resamples the selected spectral sample according to a defined sensor model;
- `spectravalues` – returns the values associated with a spectral sample;
- `stats` – returns the mean and standard deviation of the selected spectra;
- `uploadreferencespectra` – accepts a spectral sample upload (currently unused).

Compute Server – Python

The compute server is coded in Python and distributes the processing tasks to a Spark cluster. It fulfils the processing request that are passed on from the app server.

A previous version of the compute server that uses remote procedural calls (RPC) is also included in the package, however, due to the memory required to execute large processing queries on the database it was decided that Spark would alleviate these problems. This does come with the trade-off of slower processing times however.

Distributed Processing Cluster – Spark

The distributed processing cluster is a standard spark installation that is interfaced with using the PySpark package.

Database – MySQL

The database stores all the hyperspectral samples and is coded in MySQL.

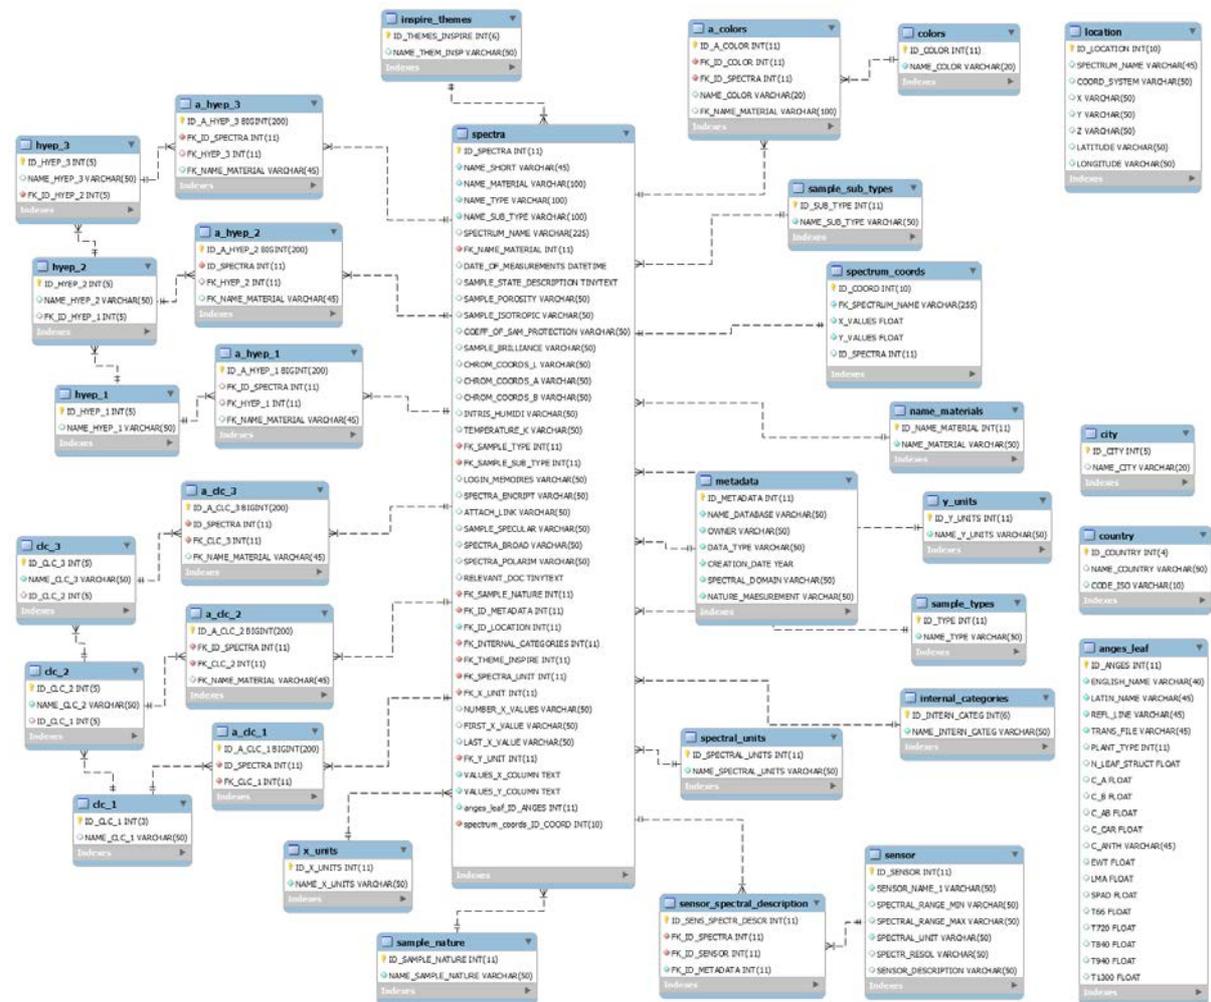


Figure 3 Relational DB MySQL - HYEP database schema, version 5

3. Features

Search

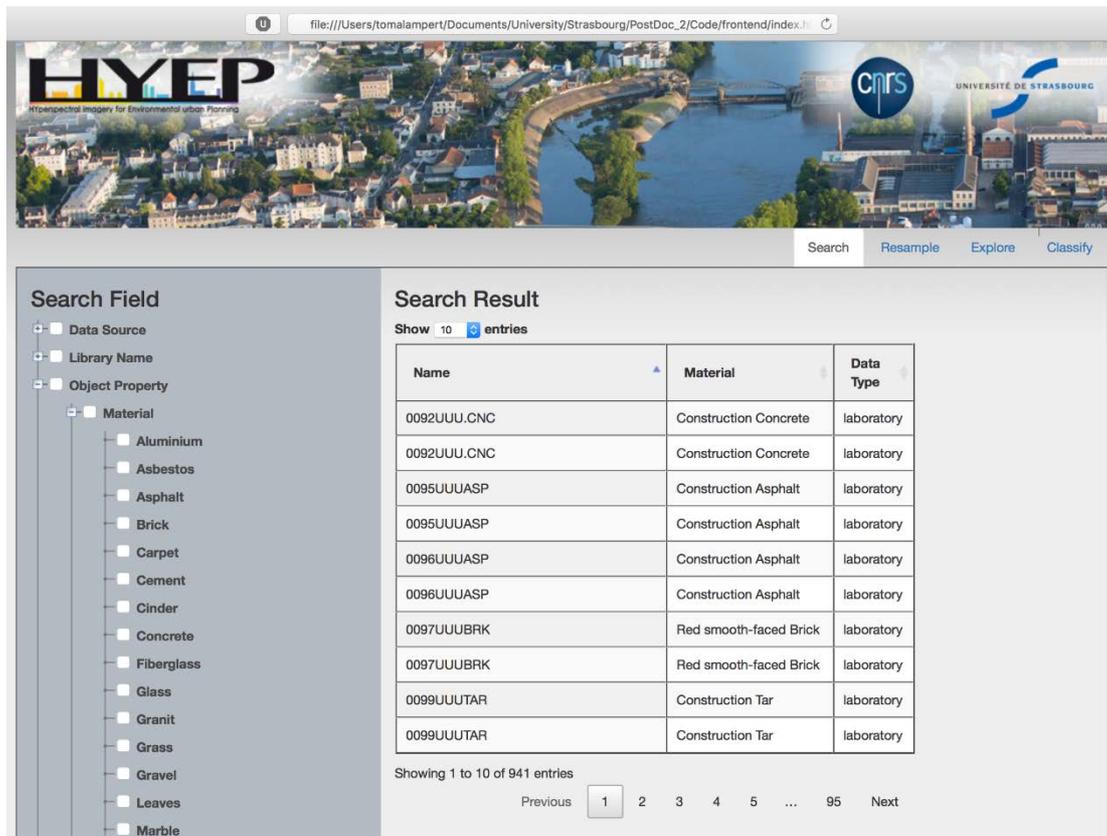


Figure 4: The Search page showing search results and search criteria.

A primary use of the interface is to allow users to list the spectra contained in the database and to select them according to certain criteria (sensor model, material, data source, etc.). Figure 3 shows this interface in which the user can easily select spectra required for further processing/exploration.

Resample

This part of the interface allows a user to export the spectra selected in the search page. There are two options for exporting: the original data or resampled data. The original data is of limited use in further data analysis as the spectra have different spectral resolutions and therefore cannot be directly compared to each other. This resample option allows the user to specify a spectral resolution (either through selecting a 'prototype' spectra, or entering the specification) and all the selected spectra are resampled to this specification prior to exporting. This allows the user to use them as training sets for classification, calculate statistics describing them, etc.

Explore

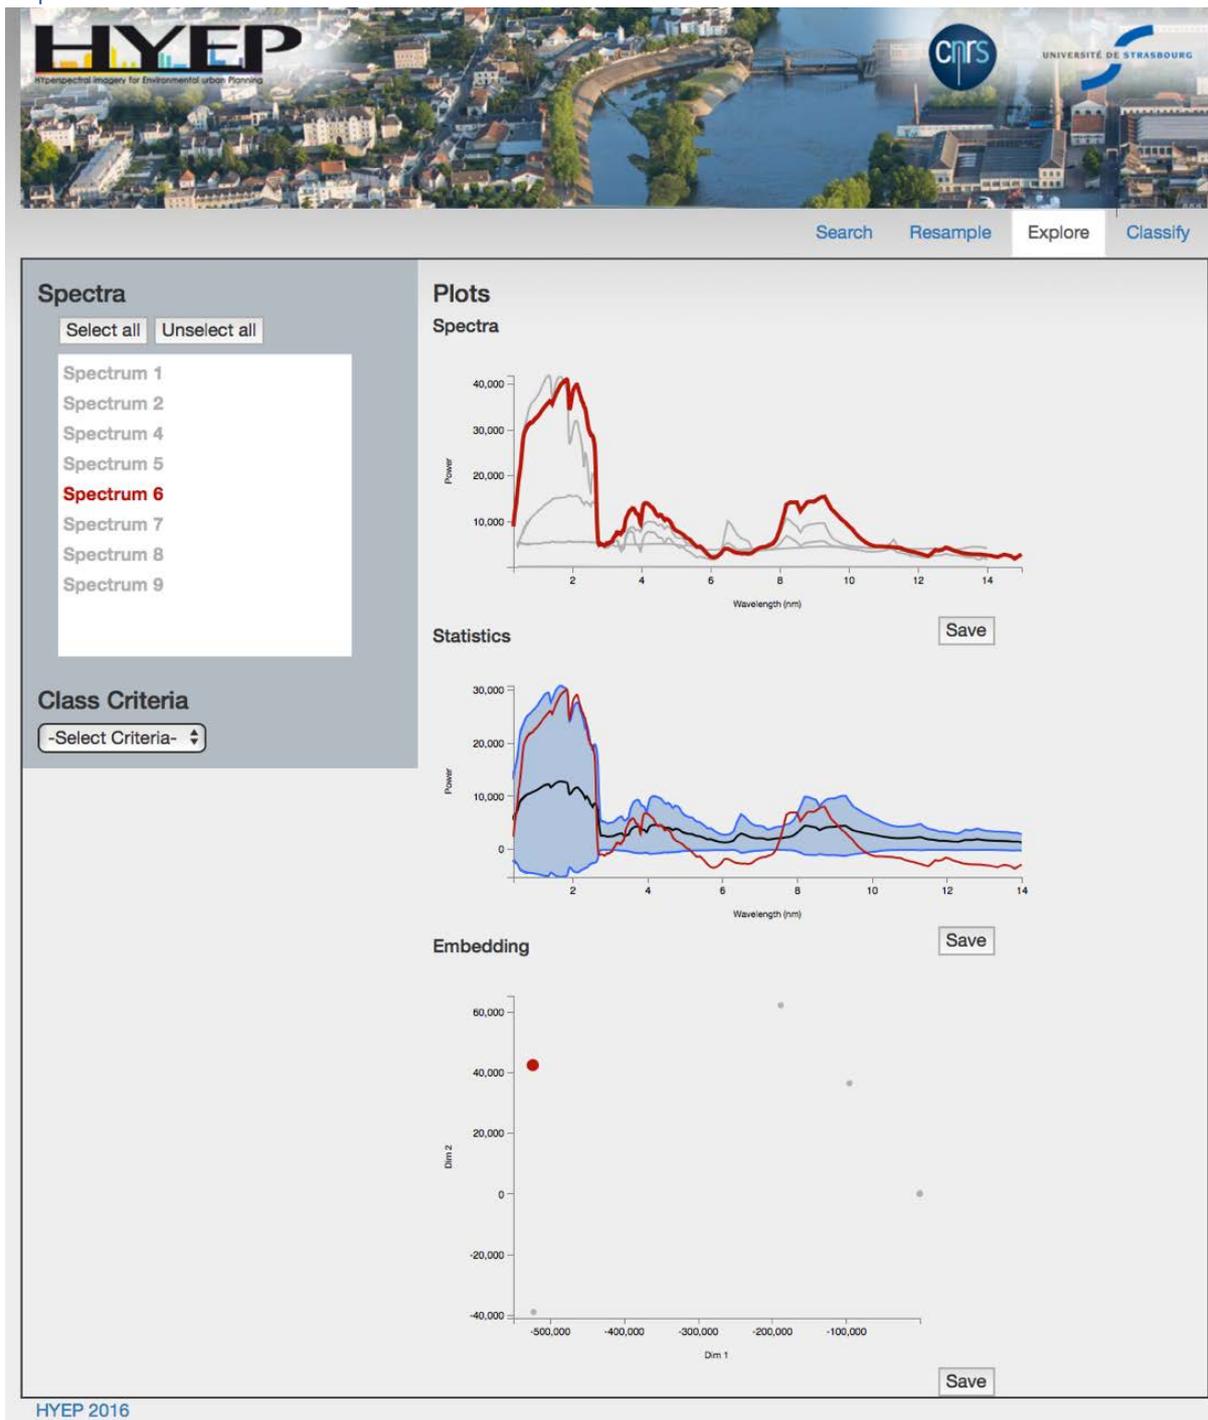


Figure 3: The Explore page, which allows a user to display the selected spectra, their statistical properties (mean and standard deviation), and their embedding in two-dimensional space. Spectra can be individually highlighted in all three plots.

The explore page presents the user with graphical plots that allow them to better understand the selected spectra. All the spectra are plotted on the same axis, see Figure 4 Spectra plot, the mean and variance of the selected spectra are calculated and plotted, see Statistics plot, and a 2D embedding of the spectra is plotted, allowing clusters and outliers to be easily identified, see Embedding plot.

The spectra are listed on the left of the page, hovering over them will highlight the corresponding line/point in all three plots. This highlighting can be fixed by clicking on the name. The spectra plots can be coloured according to criteria, for example all the concrete samples can be coloured the same, see Figure 5.



Figure 4: The Explore page, displaying the functionality of selecting a specific criterion to highlight all the spectra that belong to that criterion (Material, CLC classification, Sensor, Data Source, etc.).

All the figures can be downloaded directly from the webpage for use in publications/presentations.

Classification

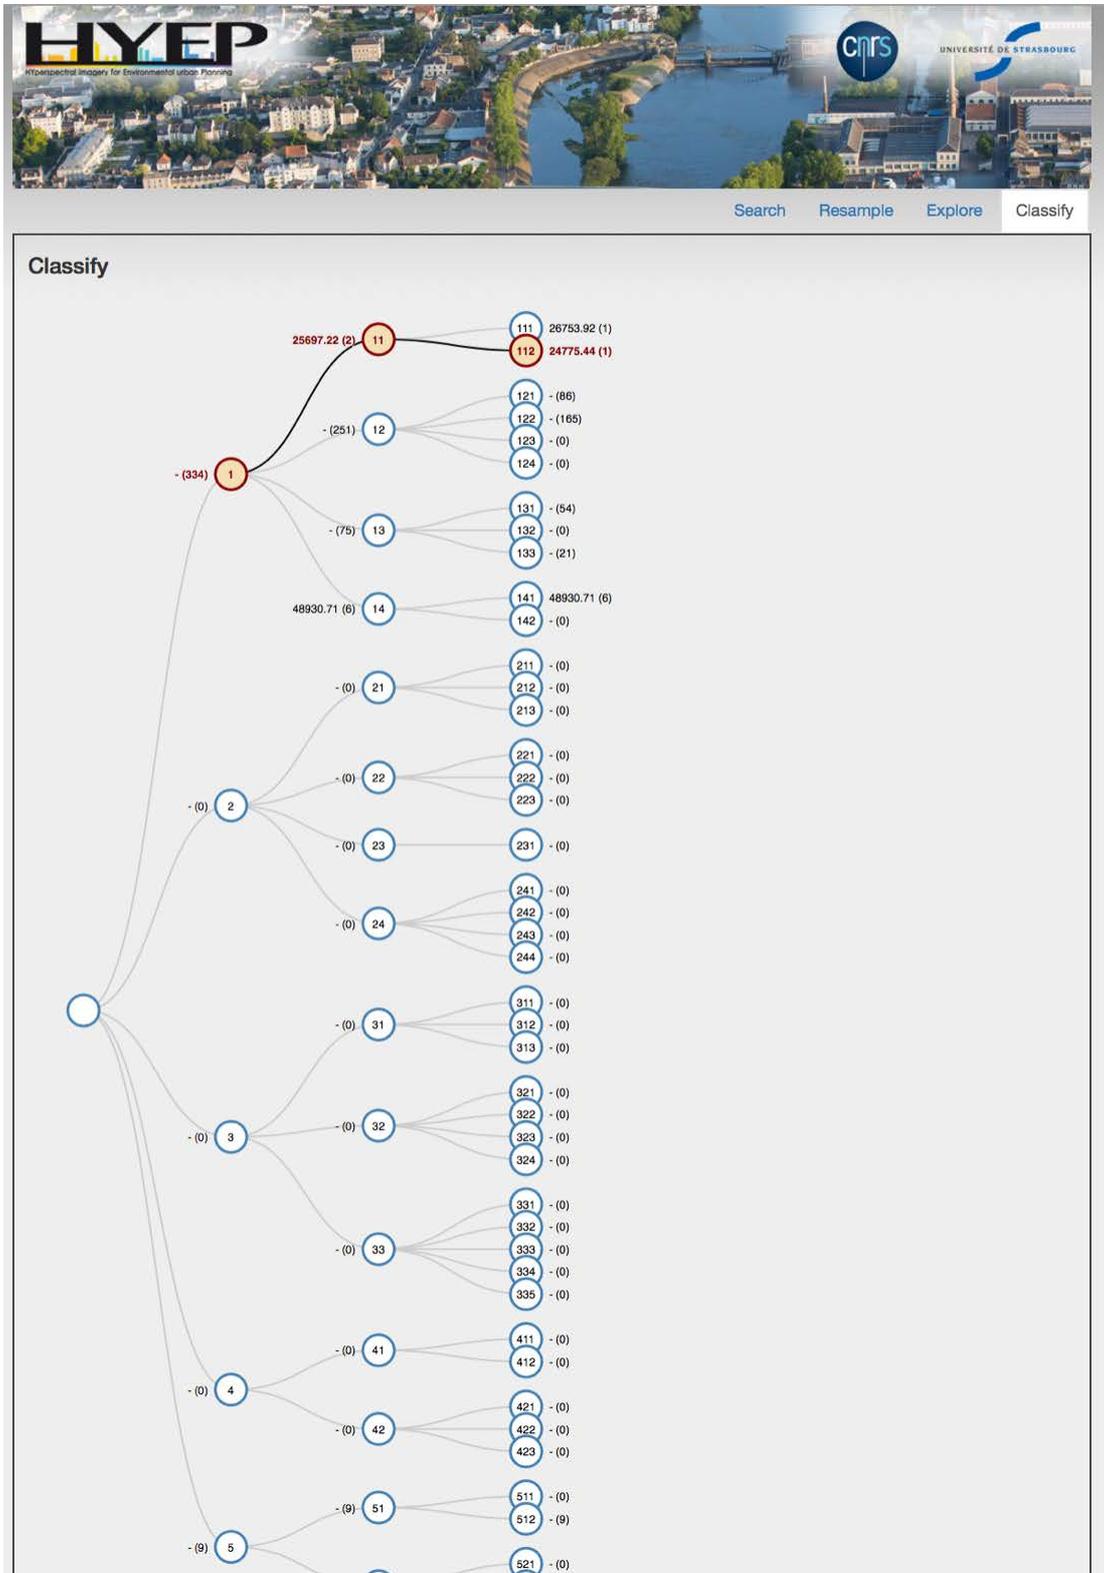


Figure 7: The Classification page, which allows a user to upload a spectral signature and retrieve a hierarchical classification according to which CLC code it most closely matches. The distances to all

CLC groups are returned, and the path that describes the hierarchical structure of the closest path highlighted (from CLC level 1 to level 3).

Figure 6 shows the classification page, in which a user is able to upload a hyperspectral sample and retrieve a tree describing its proximity to each of the CLC nodes. The distance is calculated by selecting all samples within the database that correspond to the CLC node, determining their average, and finding the user supplied sample's distance to it. The distance is returned, along with the number of samples corresponding to the node that exist in the database. This is a hierarchical process, in that the sample's distance to all levels of the CLC tree (levels 1 to 3) is returned.

4. Development

Known issues:

- There is no record in the database indicating which spectra have been averaged, this means that statistics derived from them are not valid.
- The processing chain should resample the spectral units to be equal, however, this does not always work (units do not appear correct in some samples). This could be a problem with the database data entry.
- The database allows spectra to be made-up of data from multiple sensors (each sampling a different spectral range), this is not accounted for in the interface (multiple entries for the same sample).
- Processing is slow, needs to be investigated (optimisation of code, or because of testing on local machine, or another reason).
- Not all samples cover the same spectral range. This causes problems when resampling and needs to be dealt with correctly. This is true for all processes the rely on resampling (mean and standard deviation calculation, classification, etc.).
- Implement user uploading of spectra for classification.
- Classification is very slow, it needs to be made more efficient.
- Embedding is currently broken.
- Add acknowledgements for the spectra that originate from external libraries.

Future developments:

- Website/server security (https, etc.).
- Correct error handling.
- Testing.
- Download calculated statistics.
- Educate the user as to what is being processed and what is being presented.
- User contributed spectra entry (interface and backend).
- Implement resampling (the backend process is implemented but the interface needs to be correctly designed and the API implemented).
- Computation is cancelled when different spectra are selected.
- Cache computation results when moving between webpages to prevent multiple backend processes being spawned for the same calculations.
- Additional embedding techniques (i.e. TSNE, MDS, etc.) and distance metrics for classification (spectral angle mapper, etc.). These should be user selectable.



Hyperspectral Imagery for Environmental urban Planning

Projet ANR 14-CE22-0016-01
<http://hyep.cnrs.fr/>

WP leader : C MALLET Livrable

WP 2 leader : IGN

ANR HYEP

Systèmes urbains durables (DS0601) – 2014

Versions:

v1.1: 9 June 2018
v1.2: 18 July 2018
v1.3: 20 July 2018

Contributors:

Fatima BENHALOUCHE	IRAP
Issam BOUKERCH	IRAP
Xavier BRIOTTET	ONERA
Xavier CEAMANOS	ONERA
Jocelyn CHANUSSOT	GIPSA-Lab
Nesrine CHEHATA	IGN
Yannick DEVILLE	IRAP
Sophie FABRE	GIPSA-Lab
Alexandre HERVIEU	IGN
Sofiane KAROUI	IRAP
Arnaud LE BRIS	IGN
Laetitia LONCAN	GIPSA-Lab
Clément MALLET	IGN
Abdelaziz OUAMRI	IRAP
Walid OUERGHEMMI	ESPACE
Guillaume ROUSSEL	ONERA
Christiane WEBER	TETIS

Objectifs

The goal of this work package is to develop methods for processing the variety of optical images that are available within this project. The idea is to focus or/and improve the most relevant methods with respect to the applications (land-cover LC/use classes, spatial indicators) that are targeted here. Consequently, this WP is highly linked to WP3 and proposes a dynamic set of methods that will really be efficient for the various scales of analysis instead of spending much effort in state-of-the-art but not HYPE-effective methods.

WP2.1: State of the art

Providing a state-of-the-art on the existing processing techniques on land-cover classification and change detection in urban areas using optical multi-/hyperspectral images, including fusion and unmixing techniques in case of multiple sources and various spatial resolutions. In conjunction with WP3, this state-of-the-art will be refined and pruned so as to (a) retain existing relevant techniques and (b) assess whether on-purpose methods should be developed.

WP2.2: Implementing relevant existing methods.

Such tools will be selected thanks to the expertise and the existing works of the members of the project. Both pixel and object-based methods will be included in order to be able to deal with the various spatial resolutions of the sensors. Several criteria will be established so as to objectively assess the most adapted methods for the HYPE project: computing time, complexity (in terms of training and testing), scalability or ability to be implemented in standard remote sensing image processing softwares (e.g., ENVI)

WP2.3: Developing new methods adapted to the HYPE context.

Even if efficient methods exist, it is already known that new approaches are required in order to address specific issues without predefined adequate solutions so far. This concerns data fusion (panchromatic ↔ hyperspectral data), spectral unmixing, and classification. The morpho-spectral database created in the Work Package 1 will be employed in the development of new method of image processing. Geometrical, statistical, spectral and jointed reasoning will be implemented for the development of change detection methods (for example how to efficiently prune false alarms after suitable LC classification? How to propose methods adapted to the monitoring issues?) The development of such methods should also take into account the criteria set up in WP4.2.

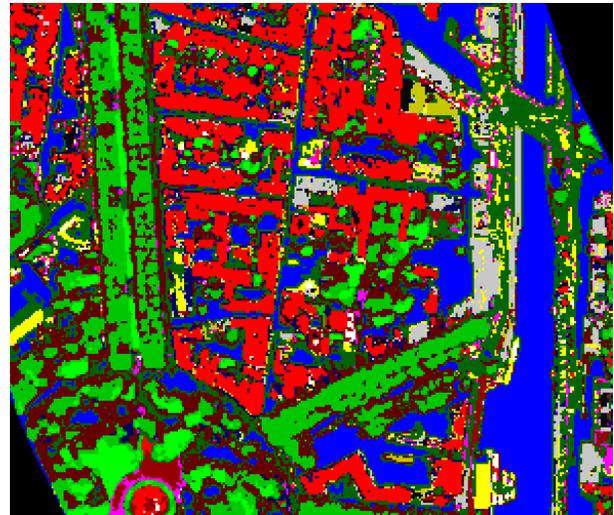
WP2.4: Assessing the relevance of airborne lidar data.

Lidar data is now available over more and more cities or can be easily acquired by airborne platforms simultaneously with optical data when working with reasonable point density (<10 pts/m²). This is an interesting input in urban areas due to its ability to finely describe vegetated areas (e.g., the internal structure of trees in addition to the top-most material) and opaque surfaces (in terms of geometry), as well as to provide height information in case of monoscopic optical images (Guo et al., 2011). The impact of such remote sensing data will be analyzed with respect to optical images in terms of classification performances (and its impact on final monitoring) for the various available spatial resolutions.

State-of-the-art on hyperspectral and multispectral image processing techniques

ANR HYEP 2014-2017

Deliverable WP 2.1



January 12, 2016

Versions:

v1.1: 18 December 2015
v1.2: 28 December 2015
v1.3: 12 January 2016

Contributors:

Jocelyn CHANUSSOT	GIPSA-Lab
Nesrine CHEHATA	IGN
Mauro DALLA MURA	GIPSA-Lab
Yannick DEVILLE	IRAP
Luca DRUMETZ	GIPSA-Lab
Alexandre HERVIEU	IGN
Arnaud LE BRIS	IGN
Laetitia LONCAN	GIPSA-Lab
Clément MALLET	IGN
Charlotte REVEL	ONERA
Guillaume ROUSSEL	ONERA

Introduction

This document gathers contributions from various authors of HYEP teams on the current state-of-the-art of image processing techniques with an emphasis on hyperspectral remote sensing data. The methods can be roughly splitted into two main parts (see Figure 1):

- Low-level methods. These are the core remote sensing techniques: pixel-based and object-based classifications (Section 1), feature selection and dimension reduction (Section 2), and unmixing (Section 3).
- High-level strategies that may integrate one or various outputs of above-mentioned techniques: pan and multi-sharpening (Section 4), multi-sensor classification (Section 5), and change detection (Lu et al., 2004; Radke et al., 2005; Hussain et al., 2013)).

The feature computation task has already extensively been addressed in the litterature. Therefore, it is not presented here in details: Sections 1.3 and 2.3 will only partly present the most salient techniques. The following sections may be more or less extensively described, depending whether state-of-the-part papers have been recently published. They also can be either written in English or in French.

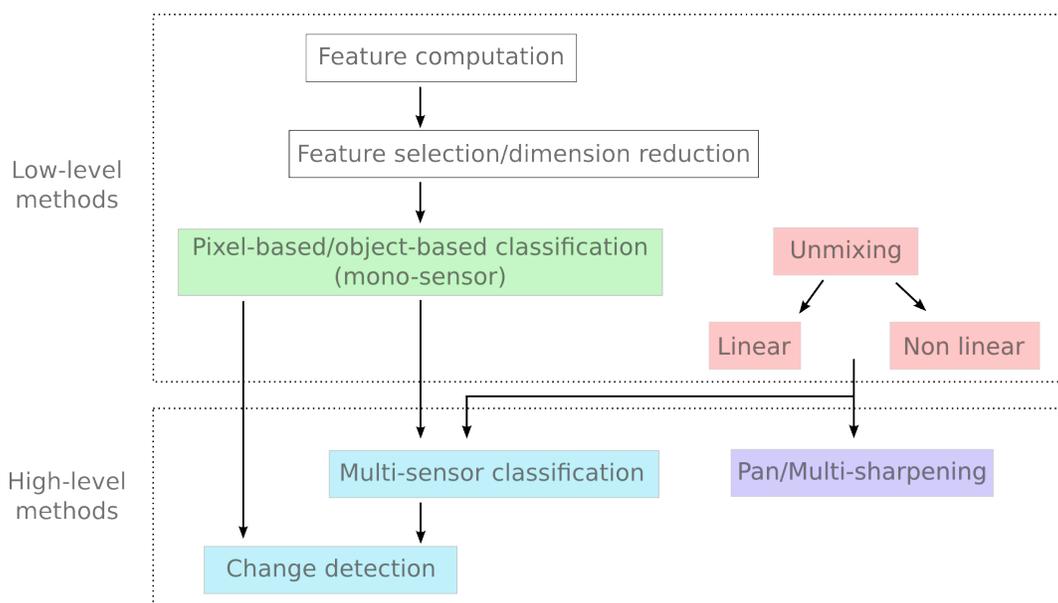


Figure 1: Workflow of the main techniques studied during the HYEP project.

1 Classification

La classification consiste à répartir en fonction d'un certain critère de similarité un ensemble d'échantillons en plusieurs sous-ensembles appelés **classes**. Les échantillons à classer sont décrits par un certain nombre d'attributs, autrement dit par des vecteurs d'une certaine dimension. Il existe un très grand nombre d'attributs, qui ne sont pas décrits dans ce document. Le lecteur peut par exemple se référer à (Gressin, 2014) pour une taxonomie récente. On distingue deux types d'algorithmes de classification (Bishop, 2006):

- Les algorithmes non supervisée (*clustering*), pour lesquels on ne dispose pas de connaissances a priori sur la nature des classes en présence. Il s'agit alors de répartir les différents échantillons du jeu de données à classer en différentes classes de manière à ce que les échantillons appartenant à une même

classe soient les plus semblables possibles, et que les échantillons appartenant à deux classes distinctes soient au contraire les plus différents possibles (au sens des attributs).

- Les algorithmes supervisés pour lesquels on fournit au classifieur des connaissances sur les différentes classes que l'on souhaite retrouver. Une méthode de classification supervisée comprend donc une phase d'apprentissage ou d'entraînement au cours de laquelle un modèle de classification est calculé à partir d'échantillons d'apprentissage fournis pour chacune des classes. Le modèle calculé à l'issue de cette étape décrit donc la manière dont le classifieur va modéliser les différentes étiquettes. Par la suite, la classification proprement dite consiste à prédire la classe de tout nouvel échantillon en fonction de ce modèle. Dans ce cas de figure, le nombre de classes est connu au préalable, ce qui n'est pas le cas en non supervisé.

1.1 Unsupervised classification

Parmi les algorithmes de *clustering*, on distingue les méthodes par agglomération, comme la classification ascendante hiérarchique, les méthodes de partitionnement comme les *k*-moyennes (*k-Means*, et leurs différentes variantes: *k*-médoides, *x-means*, nuées dynamiques et ISODATA), les méthodes de type Espérance-Maximisation pour lesquelles on formule l'hypothèse que les échantillons à classer suivent un modèle de mélange gaussien (Dempster et al., 1977).

La méthode des *k*-moyennes (*k-Means* en anglais) (MacQueen et al., 1967) est l'un des algorithmes les plus fréquemment utilisés. Il s'agit d'une méthode de partitionnement qui va séparer un jeu de données en *k* classes, représentées par leur barycentre. Le nombre de classes *k* est le seul paramètre fourni en entrée du processus. Plusieurs variantes de cet algorithme ont été proposées avec par exemple l'algorithme des *k*-médoides (Park and Jun, 2009) ou celui des nuées dynamiques (Diday, 1971) pour lesquels chaque classe n'est plus représentée par son barycentre, mais par un ou plusieurs éléments représentatifs de la classe, ce qui permet en particulier d'être plus robuste aux échantillons aberrants. Des variantes floues de cet algorithme ont aussi été proposées (Bezdek, 2013).

Une limite de l'algorithme des *k*-moyennes réside dans le fait qu'un de ses paramètres est le nombre de classes à identifier. Pour pallier à ce problème, certaines approches proposent d'automatiser la détermination de ce paramètre par le biais de critères mesurant le compromis entre attachement aux données et complexité du modèle, comme les critères BIC ou MDL dans la méthode *x-means* (Bischof et al., 1999; Pelleg et al., 2000; Hamerly and Elkan, 2003). L'algorithme ISODATA (Ball and Hall, 1965) constitue une autre réponse possible : cette variante des *k*-moyennes détermine automatiquement le nombre de classes au moyen de deux seuils fournis en paramètre sur deux mesures : l'inhomogénéité maximale au sein d'un cluster et la séparabilité minimale entre deux clusters.

Les cartes de Kohonen (*Self Organizing Maps*) (Kohonen, 1982) s'apparentent également aux méthodes de partitionnement, mais introduisent une notion de topologie entre les clusters.

La méthode de segmentation par propagation d'affinité (*Affinity propagation*) (Frey and Dueck, 2007) est une méthode de partitionnement plus récente, qui ne nécessite pas de connaissance a priori du nombre de clusters. Cette technique a notamment été mise en œuvre pour le traitement de données hyperspectrale par Soltani (2014).

Les méthodes de type Espérance-Maximisation sont une alternative aux algorithmes de partitionnement (Dempster et al., 1977). L'algorithme de classification EM cherche à obtenir des solutions qui vont maximiser la probabilité globale des données, compte tenu de la solution finale de classification avec le nombre souhaité de classes. Par conséquent, dans la classification EM, toutes les différences d'échelle ou d'étendues dans les variables choisies pour les analyses, ne vont pas affecter les résultats. On formule généralement l'hypothèse que les échantillons à classer suivent un modèle de mélange gaussien.

D'autres méthodes permettant de retrouver des clusters de forme plus complexe existent également. On pourra citer la méthode des *Support Vector Clustering* proposée par (Ben-Hur et al., 2002).

1.2 Supervised classification

1.2.1 Main families

Différents algorithmes de classification supervisée existent. Parmi ceux utilisés de manière générale en télédétection, on peut citer de manière non exhaustive les suivants :

- **Classification bayésienne** avec le classifieur par maximum de vraisemblance (*Maximum Likelihood* ou ML) ou sa variante par Maximum A Posteriori (MAP) (Trias-Sanz, 2006; Trias-Sanz and Boldo, 2005; Fauvel et al., 2014);
- **Séparateurs à Vaste Marge (SVM) ou *Support Vector Machines*** (Boser et al., 1992; Cortes and Vapnik, 1995; Vapnik, 1998; Belousov et al., 2002; Melgani and Bruzzone, 2004; Camps-Valls and Bruzzone, 2005; Tuia et al., 2010; Li et al., 2011; Fauvel, 2012; Fauvel et al., 2012a; Roussel, 2012) ;
- **Régression logistique** (Borges et al., 2006; Pal, 2012);
- **Import Vector Machines (IVM)**(Zhu and Hastie, 2005; Braun et al., 2012; Roscher et al., 2012a,b);
- **Arbres de Décisions** ou *Decision Tree* (DT) (Breiman et al., 1984)
- **Forêts Aléatoires ou *Random Forests* (RF)** (Breiman, 2001; Pal, 2005; Cheung-Wai Chan, 2008; Genuer, 2010; Criminisi and Shotton, 2013)
- **Réseaux de neurones artificiels** (Le Cun et al., 1998; Riedmiller and Braun, 1993; Atkinson et al., 1997; Kavzoglu and Mather, 2003; Hu et al., 2015).

Les méthodes fondamentales sont discutées en détails dans un certain nombre d'ouvrages traitant de l'analyse de données (Bishop, 2006).

1.2.2 Classifiers dedicated to high-dimension data and in particular to hyperspectral data

Le phénomène de fléau de la dimension ou phénomène de Hughes (Hughes, 1968) désigne le fait qu'au delà d'un certain nombre d'attributs, le fait d'ajouter de nouveaux attributs pour décrire les échantillons à classer n'améliore pas la classification, mais risque au contraire de la dégrader. Toutefois, si les classifieurs classiques comme par exemple les classifieurs bayésiens sont sensibles à ce phénomène, les approches plus modernes comme les SVM, les IVM ou les RF y sont peu sensibles (Melgani and Bruzzone, 2004; Camps-Valls and Bruzzone, 2005; Braun et al., 2012) et parviennent malgré tout à produire de bons résultats, sauf dans des cas où très (trop) peu de données d'apprentissage sont disponibles (Pal and Foody, 2010). Ces classifieurs sont également capables dans une certaine mesure de gérer des variabilités intra-classe importantes, autrement dit des classes d'aspect variable.

Ainsi, dans la littérature, les méthodes de type SVM avec noyau sont souvent adoptées (Camps-Valls and Bruzzone, 2009). D'autres méthodes utilisées plus généralement pour les données de grande dimension, dont la donnée hyperspectrale, sont par exemple les méthodes fondées sur des graphes (Camps-Valls et al., 2007) : chaque pixel est considéré comme un nœud d'un graphe, tandis que les arêtes portent des mesures de similarité entre nœuds. Le problème de classification devient alors un problème de coupe de graphe. Ces méthodes peuvent s'adapter à un apprentissage semi-supervisé ainsi qu'à l'introduction directe d'une régularisation spatiale.

D'autres approches plus originales et adaptées au traitement de données de grandes dimensions et de différentes modalités (spectral, texture, etc.) ont été proposées. On citera par exemple, l'approche proposée par (Li et al., 2014) qui consiste à construire une représentation par dictionnaire des échantillons d'apprentissage, puis utilise ce modèle pour classer de nouveaux échantillons : un échantillon se voit affecter la classe pour laquelle il est le mieux modélisable à partir de ces dictionnaires. Une autre méthode originale proposée par (Chiang et al., 2014) s'inspire des méthodes d'interpolation de type krigeage. Les valeurs d'appartenance aux différentes classes valent 1 ou 0 pour les échantillons d'apprentissage. L'algorithme interpole ensuite les valeurs d'appartenance aux classes pour tout nouvel échantillon à partir de ces valeurs.

1.2.3 Methods specific to hyperspectral data

Certains classifieurs sont plus spécifiques à la donnée hyperspectrale. Il s'agit notamment des classifieurs fondés sur les mesures suivantes :

- Angle spectral ou *Spectral Angle Mapper* (SAM) (Price, 1994). Il consiste à calculer l'angle entre deux spectres. Plus cet angle est faible, plus les deux spectres se ressemblent. Le spectre à classer se voit donc affecter la classe du spectre dont il est le plus proche au sens du SAM. Ce classifieur offre l'avantage de faire preuve d'une bonne robustesse aux variations d'intensité, et est donc relativement indépendant des conditions d'illuminations de la scène. L'angle spectral se calcule comme suit (avec 2 spectres \vec{a} et \vec{b} , i.e., 2 vecteurs de dimension N , N désignant le nombre de bandes).

$$SAM(\vec{a}, \vec{b}) = \cos^{-1} \left(\frac{\vec{a} \cdot \vec{b}}{\|\vec{a}\| \cdot \|\vec{b}\|} \right). \quad (1)$$

- Mesure "*Spectral Information Divergence*" ou SID (Chang, 2000). Elle trouve son origine dans les mesures de dissimilarité entre distributions statistiques, et notamment la formule de Kullback-Leibler.

$$SID(\vec{a}, \vec{b}) = \sum_{i=1}^N p(\vec{a})_i \cdot \log \frac{p(\vec{a})_i}{p(\vec{b})_i} + p(\vec{b})_i \cdot \log \frac{p(\vec{b})_i}{p(\vec{a})_i}, \quad (2)$$

pour $\vec{a} = [a_1 \dots a_i \dots a_N]$ et $\vec{P}(\vec{a}) = [p(\vec{a})_1 \dots p(\vec{a})_i \dots p(\vec{a})_N]$ avec $p(\vec{a})_i = \frac{a_i}{\sum_{i=1}^N a_i}$

- Mesure nommée SID-SAM et combinant les deux mesures précédentes du SAM et du SID (Du et al., 2004).

$$SID(\vec{a}, \vec{b}) \cdot \sin(SAM(\vec{a}, \vec{b})). \quad (3)$$

Un exemple d'utilisation récente de cette mesure est donné par Mende et al. (2011).

- Mesures de corrélation entre certaines parties du spectre (Van der Meer and Bakker, 1998).

Dans le cas de l'analyse de données hyperspectrales, certaines méthodes très spécifiques fondées sur des connaissances expert existent également (comme le système Tetracorder (Clark et al., 2003) pour la caractérisation de certains minéraux, ou (Heiden et al., 2007; Mohammadi, 2012) pour différents matériaux urbains). Elles se fondent sur des analyses des spectres d'un point de vue plus physique et prennent notamment en compte la présence de comportements particuliers le long du spectre comme par exemple des bandes d'absorption spécifiques à certains composés, ainsi que la profondeur de ces bandes d'absorption.

Ainsi, Clark et al. (1992, 2003) identifient des minéraux dans les images hyperspectrales par comparaison des spectres avec les spectres de l'image au voisinage de bandes spécifiques identifiées préalablement pour chaque minéral par des experts. Sont alors comparées à la fois la forme du spectre et la profondeur de cette bande d'absorption, par la méthode de "*Spectral Feature Fitting*" (SFF) (Clark et al., 1992). L'approche d'Heiden et al. (2007) utilise quant à elle dans un processus de classification supervisée (SVM) un certain nombre d'indices décrivant différentes caractéristiques spectrales (position et profondeur des bandes d'absorption, ratio entre bandes, aire sous la courbe dans certains domaines spectraux), initialement identifiées par analyse physique des spectres par des experts.

Un autre point concerne d'ailleurs le fait d'utiliser directement les données radiométriques (qu'elles soient en luminance ou réflectance), ou des indices dérivés à partir de ces mesures. De tels indices peuvent être des différences, des ratios entre bandes, ou encore des différences normalisées à l'exemple du célèbre indice *NDVI*, voire d'autres indicateurs de la forme du spectre (comme par exemple la pente ou encore l'aire sous

la courbe, (Heiden et al., 2007)). Ce type d'indice peut en effet s'avérer plus discriminant que les bandes originales pour certains phénomènes.

1.2.4 Classifier ensembles

Il est aussi possible de combiner plusieurs classifieurs de manière à construire un **ensemble de classifieurs** permettant d'obtenir de meilleurs résultats. Un ensemble de classifieurs se présente en effet comme l'agrégation de plusieurs classifieurs (que l'on peut proposer moins complexe que si l'on se limite à un seul classifieur), soit différents, soit entraînés à partir d'échantillons différents (*bagging*), soit sur des attributs différents. Le label finalement attribué à un échantillon à classer est souvent obtenu par vote majoritaire de ces différents classifieurs. L'utilisation d'ensemble de classifieurs permet généralement d'améliorer les résultats et notamment le degré de généralisation du modèle.

Les Forêts Aléatoires, en tant qu'agrégation d'arbres de décision, s'inscrivent au sein des méthodes d'ensemble de classifieurs.

Dans le cas de données hyperspectrales, plusieurs méthodes spécifiques ont été proposées. Ainsi, Prasad and Bruce (2008); Ceamanos et al. (2010); Bigdeli et al. (2013); Bruce (2014) proposent de définir par classification non supervisée un certain nombre de groupes de bandes corrélées. Un classifieur SVM est alors associé à chacun de ces groupes de bandes.

Les techniques de type *random subspace* (Ho, 1998) consistent à construire un ensemble de classifieurs en dupliquant un même classifieur, mais cette fois en l'entraînant à partir de sous-ensemble de bandes sélectionnées aléatoirement. L'introduction dans le processus de sélection aléatoire de ces jeux de bandes d'un a priori sur leur pertinence améliore les résultats et l'efficacité de ce type d'approche (Yang et al., 2010).

1.2.5 Multi-kernel and multi-modal approaches

Ainsi qu'il a été dit, les classifieurs de type SVM sont très utilisés pour la classification de données hyperspectrales (Melgani and Bruzzone, 2004; Camps-Valls and Bruzzone, 2005). Le classifieur SVM a été conçu à l'origine pour des problèmes de classification pour lesquels les classes sont linéairement séparables dans l'espace des attributs. La solution proposée pour pouvoir traiter des problèmes non linéairement séparables à l'aide des SVM consiste à transformer au moyen d'une fonction non-linéaire ϕ les données de manière à les projeter dans un espace de plus grande dimension, dans lequel le problème devient linéairement séparable. En pratique, cette projection ne se calcule pas de manière explicite, mais s'effectue par le biais de l'utilisation d'une fonction noyau (suivant les conditions de Mercer). Une multitude de noyaux sont possibles. Le noyau gaussien ou RBF (*radial basis function*) $K(\mathbf{a}, \mathbf{b}) = \exp^{-\gamma\|\mathbf{a}-\mathbf{b}\|^2}$ apparaît comme l'un des plus utilisés dans la littérature. Le paramètre γ permet de paramétrer l'écart-type de la gaussienne et la fidélité à l'ensemble d'apprentissage. Il s'agit de bien le choisir, car, tout comme la contrainte C de tolérance de généralisation du classifieur, il a un impact sur la qualité de la classification. En pratique, ces deux paramètres sont généralement déterminés conjointement par validation croisée (Hsu et al., 2003), ce qui peut prendre un peu de temps. On notera toutefois que d'autres méthodes plus rapides pour l'optimisation de ces paramètres existent (Fauvel, 2012; Li et al., 2012).

D'autres noyaux sont également utilisés, comme les noyaux polynomiaux ou sigmoïdes existent également (Hsu et al., 2003). On pourra aussi noter que des noyaux reprenant la fonction du SAM ont été proposés spécifiquement pour les données hyperspectrales (Mercier and Lennon, 2003; Fauvel et al., 2006b; Fauvel, 2007).

Par ailleurs, l'utilisation de noyaux composites, c'est-à-dire de la somme de plusieurs noyaux élémentaires est également possible. On parle de SVM multi-noyaux, comme par exemple pour intégrer connaissances spatiales et spectrales.

Ainsi, l'approche proposée par (Ceamanos et al., 2010) commence par définir par classification non supervisée un certain nombre de groupes de bandes corrélées puis à mettre en œuvre un SVM multi-noyaux au sein duquel un noyau élémentaire est associé à chacun de ces groupes de bandes corrélées. Le cas extrême est

alors d'utiliser un noyau par attribut : on parle alors de SVM à noyaux multiples (Tuia et al., 2010; Gu et al., 2012).

Les approches multi-noyaux ont souvent été utilisées pour une meilleure fusion de données hétérogènes comme par exemple des mesures spectrales brutes, des indices spectraux dérivés, des informations de texture ou de formes (profils morphologiques) (Dell'Acqua et al., 2004; Borghys et al., 2005; Camps-Valls et al., 2006; Fauvel, 2007; Fauvel et al., 2012a,b; Zhang et al., 2012), et même des informations issues d'autres capteurs, comme par exemple des données LiDAR aux images optiques multispectrales (Gu et al., 2015).

1.2.6 Probabilistic outputs - classifier confidence

La plupart des classifieurs ne se limitent pas à produire un simple étiquetage, mais vont également fournir des mesures d'appartenance aux différentes classes. Ainsi, pour chaque échantillon à classer, on obtient une mesure d'appartenance à chaque classe, la classe finalement attribuée à l'échantillon étant celle pour laquelle cette mesure d'appartenance est optimale.

De telles mesures sont notamment fournies par les classifieurs suivants :

- Forêts Aléatoires : ce classifieur construit un ensemble d'arbres de décisions qui attribue chacun un label à l'échantillon à classer. Le label finalement attribué est celui qui reçoit le plus grand nombre de votes. A chaque classe possible est donc associé le nombre de votes qu'elle a reçue.
- Séparateurs à Vaste Marge : différents modèles ont été proposés afin de fournir des probabilités d'appartenances aux différentes classes (Platt, 2000; Xu et al., 2014)
- Classification bayésienne : la classification s'effectue en affectant à chaque pixel sa classe la plus probable. On dispose donc d'emblée des probabilités d'appartenance aux classes.
- Angle Spectral (SAM), SID et SID-SAM : pour ces différentes méthodes, la classification s'effectue en affectant à chaque descripteur la classe la plus proche au sens d'une certaine distance avec les descripteurs de référence. On dispose donc d'emblée d'une mesure d'appartenance aux différentes classes.
- Une méthode originale s'inspirant des méthodes d'interpolation de type krigeage a été proposée dans (Chiang et al., 2014). Les valeurs d'appartenance aux différentes classes valent 1 ou 0 pour les échantillons d'apprentissage. L'algorithme interpole ensuite les valeurs d'appartenance aux classes pour tout nouvel échantillon à partir de ces valeurs.

1.2.7 Semi-supervised classification and active learning

Un problème fréquemment rencontré en télédétection concerne la disponibilité de faibles nombres d'échantillons d'apprentissage. Plusieurs approches ont été proposées pour pallier à cette difficulté.

Apprentissage semi-supervisé

L'apprentissage semi-supervisé consiste à calculer le modèle de classification à la fois à partir d'échantillons labellisés et non labellisés. Il s'agit alors de renforcer les échantillons d'apprentissage par d'autres informations extraites automatiquement de l'image. On pourra par exemple citer la méthode proposée par (Camps-Valls et al., 2007) qui se fonde sur une modélisation à l'aide de graphes. Chaque pixel est considéré comme un nœud du graphe, tandis que les arêtes portent des mesures de similarité entre nœuds, le problème de classification devenant alors un problème de coupe de graphe. Ces méthodes peuvent s'adapter à un apprentissage semi-supervisé ainsi qu'à l'introduction directe d'une régularisation spatiale.

D'autres approches d'apprentissage semi-supervisé reposant sur des modèles différents sont présentées dans (Jun and Ghosh, 2013; Li et al., 2013; Huo et al., 2015).

Apprentissage actif (ou *active learning*)

Il s'agit alors d'un processus itératif, au cours duquel on va progressivement améliorer le modèle. A chaque

étape, on classe les données, puis renforce le modèle en proposant de récupérer de nouveaux échantillons d'apprentissage parmi les éléments classés avec la confiance la plus faible (Rajan et al., 2008; Tuia et al., 2009; Joshi et al., 2009; Shi et al., 2012; Ghariani et al., 2014). La sélection est souvent couplée à des critères de diversité spatiale ou spectrale pour un bon échantillonnage des nouveaux éléments insérés dans le jeu d'apprentissage.

Adaptation de domaine

Ces méthodes peuvent être mises en œuvre dans les cas où l'on dispose d'un bon jeu de données d'apprentissage sur une image, et que l'on doit classer une nouvelle image (sur une zone différente, ou sur la même zone mais acquise à une autre date) pour laquelle on dispose d'un jeu de données d'apprentissage plus limité. En simplifiant, les méthodes d'adaptation de domaines consistent alors à proposer une transformation à appliquer à l'ancien jeu de données d'apprentissage pour pouvoir les utiliser conjointement avec les nouvelles données d'apprentissage afin d'estimer un modèle pour la classification des nouvelles images. Parmi ces approches, on peut notamment citer (Courty et al., 2014; Matasci et al., 2015).

1.3 Spectral-spatial classification with APs

A possible strategy for including the spatial information in the classification of hyperspectral images is to consider spatial features as additional entries in the classification process. Spatial features can be obtained for example by spatial filtering. Since the aim of these features is to reduce the intra-class and enhance the inter-class variability while preserving the spatial characteristics of the objects in the scene, the methods considered should be edge-preserving. Edge-preserving filters are available in the framework of mathematical morphology and they are called connected filters. Operators based on the geodesic reconstruction (e.g., opening and closing by reconstruction) and attribute filters are well known examples of this family of filters (Soille, 2003). Pesaresi and Benediktsson (2001) proposed to use a sequence of opening and closing by reconstruction with increasing filter size¹ in order to characterize the spatial information in a panchromatic image. This sequence of multiscale filtering was called Morphological Profile (MP). In (Benediktsson et al., 2005), the concept of MPs was extended to hyperspectral images, resulting in the Extended Morphological Profile (EMP). The EMP is obtained by first reducing the dimensionality of the hyperspectral image with a PCA and by computing an MP on each of its first few components. Although MP is a powerful technique for the extraction of spatial information, the concept has a few limitations:

- i) the shape of SEs is fixed and
- ii) SEs are unable to characterize information related to the gray-level characteristics of the regions.

To overcome this, the morphological Attribute Profile (AP) has been proposed as the generalization of the MP which provides a multilevel characterization of an image by using the sequential application of morphological Attribute Filters (AFs) (Dalla Mura et al., 2010b). AFs are connected operators which process an image by considering only its connected components. AFs include in their definition, the morphological operators based on geodesic reconstruction (Breen and Jones, 2013). Moreover, AP is a flexible tool since images can be processed based on many different types of attributes. In fact, the attributes can be of any type. For example, they can be purely geometric, or related to the spectral values of the pixels, or on different characteristics such as spatial relations to other connected components. An AP of a scalar image f is defined as in Equation 4 (Dalla Mura et al., 2010b):

$$AP(f) = \left\{ \underbrace{\phi^{P_{\lambda_L}}(f), \phi^{P_{\lambda_{L-1}}}(f), \dots, \phi^{P_{\lambda_1}}(f)}_{\text{thickening profile}}, f, \underbrace{\gamma^{P_{\lambda_1}}(f), \dots, \gamma^{P_{\lambda_{L-1}}}(f), \gamma^{P_{\lambda_L}}(f)}_{\text{thinning profile}} \right\}, \quad (4)$$

with $P_{\lambda} : \{P_{\lambda_i}\}$ ($i = 1, \dots, L$) a set of L ordered predicates (i.e., $P_{\lambda_i} \subseteq P_{\lambda_k}$, $i \leq k$) checking if the values of the attribute/s computed on regions in the image are within a given interval. The AP is obtained by the

¹Size of the spatial mask, called structuring element (SE), defining the neighborhood of each pixel on which the filter is applied.

sequential application of attribute thinning γ and attribute thickening ϕ , which, roughly speaking, operate on bright and dark features in the image, respectively. An example of APs computed with different attributes is shown in Figure 2.

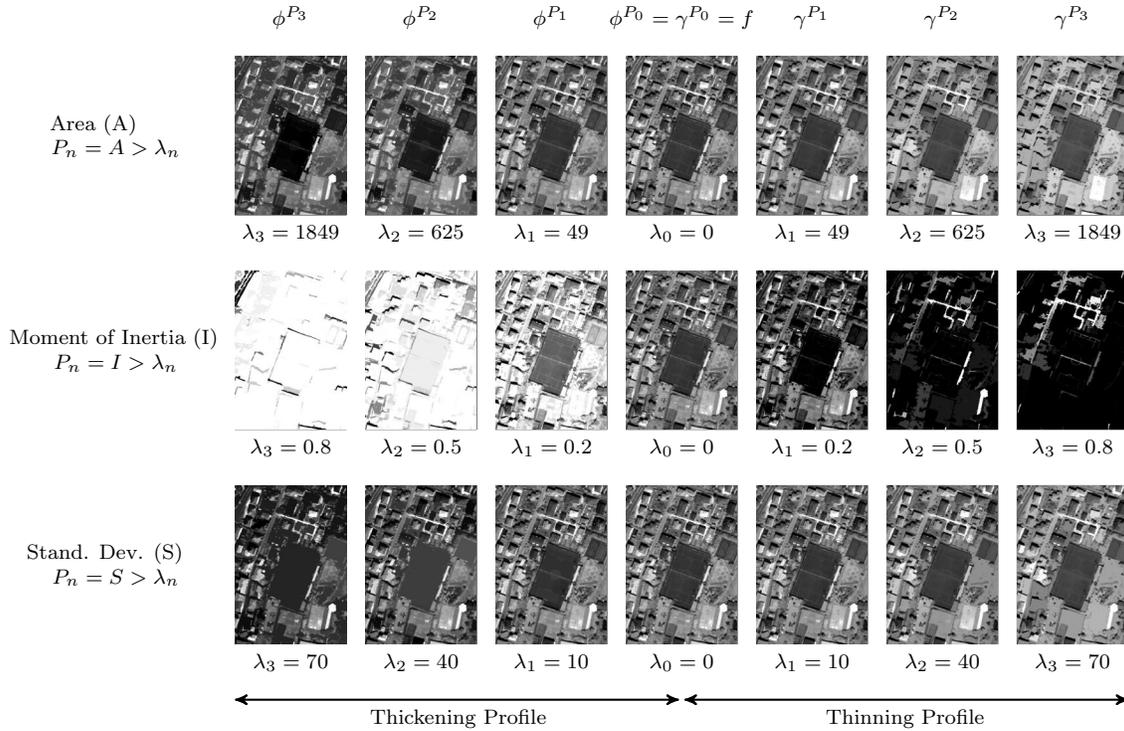


Figure 2: An example of different attribute profiles (Area, Moment of Inertia and Standard Deviation) with different threshold values (Ghamisi et al., 2015).

A possible way for applying the concept of the profile to vectorial images was proposed in (Benediktsson et al., 2005; Dalla Mura et al., 2010a). The proposed approach is based on the reduction of the dimensionality of a multivariate image (e.g., hyperspectral) \mathbf{f} with a generic dimensionality reduction transformation Ψ (i.e., $\mathbf{g} = \Psi(\mathbf{f})$, see Section 2 for more details) and then on the application of the AP to each g_i ($i = 1, \dots, m$) of the transformed image. This can be formalized as:

$$EAP(\mathbf{g}) = \{AP(g_1), AP(g_2), \dots, AP(g_m)\}. \quad (5)$$

It can be convenient to compute multiple EAPs considering different attributes in order to derive a more complete descriptor of an image. This is the underlying idea of the *Extended Multi-Attribute Profile* (EMAP) (Dalla Mura et al., 2010a) which is consequently defined considering k different attributes as:

$$EMAP(\mathbf{g}) = \{EAP_{\mathcal{A}_1}(\mathbf{g}), EAP'_{\mathcal{A}_2}(\mathbf{g}), \dots, EAP'_{\mathcal{A}_k}(\mathbf{g})\}, \quad (6)$$

where $EAP_{\mathcal{A}_i}$ is an EAP built with a set of predicates evaluating the attribute \mathcal{A}_i and $EAP' = EAP \setminus \{g_i\}_{i=1, \dots, m}$ in order to avoid redundancy since the original components $\{g_i\}$ are present in each EAP. Examples of applications of the concepts of EAP and EMAP to the classification of hyperspectral images can be found in (Dalla Mura et al., 2010a,c; Marpu et al., 2012; Ghamisi et al., 2014a,b; Bernabé et al., 2014; Pedergnana et al., 2013; Huang et al., 2014; Tuia et al., 2013). For a review on APs and EAPs the reader is referred to (Ghamisi et al., 2015).

1.4 Object-based techniques

La classification pixellaire est facile à mettre en œuvre mais conduit généralement à une classification bruitée qui nécessite donc des post-traitements de régularisation afin d’homogénéiser le résultat dans un voisinage donné, pour aboutir à une cartographie de l’occupation du sol lisse (Petropoulos et al., 2012; Blaschke et al., 2014). Afin de remédier à ce problème, différentes techniques ont été proposées et sont rappelées dans la partie 1.5.

Ce phénomène est d’autant plus sensible dans le cas de la très haute résolution spatiale, dès lors qu’un même objet sera représenté sur l’image par plusieurs pixels et que la variabilité intra-objet augmente sensiblement avec la désormais possible discrimination de sous-ensembles non pertinents (cheminées et autres superstructures de toîts, voitures ou marquages routiers etc.). Il apparaît donc intéressant de traiter conjointement les différents pixels correspondant à un même objet. Un tel traitement nécessite de disposer de régions issues d’une segmentation de l’image. Une **segmentation d’image** est un partitionnement de l’image en un ensemble de régions homogènes, toutes deux à deux disjointes et dont l’union constitue l’image de départ. Les régions sont alors parfois également appelées super-pixels si les régions sont petites et compactes et que leur taille est inférieure à celles des objets recherchés (Massoudifar et al., 2014; Roscher and Waske, 2014; Fu et al., 2015; Saranathan and Parente, 2015). Le choix de la segmentation peut être critique, le but étant d’avoir des régions à la fois d’occupation du sol homogène et de taille significative. En effet, une segmentation trop fine apportera peu par rapport à une classification par pixel et risquera toujours d’avoir pour conséquence une classification bruitée, alors qu’une segmentation trop grossière ayant des régions regroupant des classes différentes, conduira également à des erreurs de classifications.

De nombreux algorithmes de segmentation ont été proposés : on pourra par exemple mentionner (Baatz and Schäpe, 2000; Comaniciu and Meer, 2002; Guigues et al., 2006; Arbalaez et al., 2011), ou de manière spécifique à la donnée hyperspectrale (Tarabalka, 2010; Tarabalka et al., 2010).

Les régions issues d’une segmentation vont pouvoir être utilisées dans le cadre d’un processus de régularisation d’une classification pixellaire.

Une solution consiste alors à attribuer un label à une région en faisant voter les pixels qui la constitue, ce vote pouvant être pondéré par les probabilités d’appartenance aux différentes classes des différents pixels (Trias-Sanz, 2006). D’autres méthodes proposées dans (Trias-Sanz, 2006) et spécifiquement dédiées à la classification par région proposent également de comparer les distributions radiométriques au sein des régions à celles des classes.

Par ailleurs, d’autres approches vont associer des attributs aux différentes régions, chaque région étant ensuite classée directement. Ces approches de classification directement objet vont utiliser des attributs objet spécifiques (Mathieu et al., 2007; Zang et al., 2010; Myint et al., 2011) et d’emblée fournir une classification peu bruitée. Elles fonctionnent très bien quand les régions détectées couvrent parfaitement les objets d’intérêt (Liu and Bo, 2015). De tels attributs peuvent être :

- Statistiques au sein de la région (calculés à partir des attributs pixellaires);
- Géométriques décrivant la forme des régions (compacité, élongation);
- Contextuels : ces attributs prennent en compte le contexte de la région. Par exemple, la région voisine d’une zone d’ombre dans la direction du soleil appartiendra vraisemblablement au sursol.

L’utilisation d’une segmentation permet d’obtenir une classification plus régulière, mais il existe également un risque de propager des erreurs de segmentation à la classification, c’est pourquoi des méthodes de régularisation ont été développées.

1.5 Regularisation methods

Comme indiqué ci-dessus, ces méthodes visent à obtenir des classifications homogènes sans bruit pixellaire. Un aperçu général est fourni dans (Schindler, 2012) où les techniques sont divisées en deux catégories principales.

- Locales: elles analysent le voisinage autour de chaque pixel par filtrage. Les étiquettes des pixels voisins (ou les probabilités d’appartenance à chaque classe) sont combinées afin de produire une nouvelle

étiquette pour le pixel central. On pense au vote majoritaire, aux filtres gaussien et bilatéral, qui permet de moins lisser les bords de classe (Tomasi and Anduchi, 1998) ou à la relaxation probabiliste (Gong and Howarth, 1989; Fu and Yan, 1997).

- Globales: elles sont fondées sur des champs de Markov (MRF), ce qui fait que la configuration d'étiquettes optimale est obtenue en trouvant le Maximum A Posteriori sur l'intégralité du champ (Moser et al., 2013).

Ce problème est vu comme celui de minimisation d'une énergie E s'écrivant:

$$E(I, C) = \sum_{\mathbf{p} \in I} E_{\text{data}}(\mathbf{p}, C(\mathbf{p})) + \lambda \cdot \sum_{(\mathbf{p}, \mathbf{q}) \in V} E_{\text{prior}}(\mathbf{p}, \mathbf{q}, C(\mathbf{p}), C(\mathbf{q})), \quad (7)$$

où $C : \mathbb{R}^2 \rightarrow c_1, \dots, c_n$ est la classification pixellaire initiale à n labels de l'image I , V est le voisinage d'intérêt et λ un paramètre de pondération entre les deux termes de l'énergie.

Malgré un encodage simple de connections entre voisins, l'optimisation se propage en fait sur de grandes distances. En fonction de l'écriture de l'énergie à minimiser, le minimum global peut ne pas être atteignable. Toutefois, un grand nombre de techniques d'optimisation permettent d'atteindre des minima locaux proches de la vraie solution (Boykov et al., 2001; Felzenszwalb and Huttenlocher, 2006; Kolmogorov, 2006). Des récentes évaluations sont disponibles dans (Szeliski et al., 2008; Kappes et al., 2015).

Le terme d'attache aux données E_{data} se fonde très généralement sur les probabilités issues d'une classification pixellaire. Le terme de lissage E_{prior} encode les pénalités souhaitées entre pixels voisins, en tenant compte seulement des labels existants (e.g., modèle de Potts) ou en intégrant le contraste entre eux (*contrast-sensitive Potts*). Des contraintes de connectivité plus grande distance existent également Bai and Sapiro (2009); Criminisi et al. (2008).

Pour de vraies prédictions structurées, dans la famille des modèles probabilistes graphiques, on se tourne plutôt vers les *Conditional Random Fields* (CRF, (Lafferty et al., 2001)) qui permettent de modéliser les interactions entre objets voisins et *in fine* le contexte local. L'idée de base est la définition d'une distribution de probabilité conditionnelle sur des séquences de labels sachant une séquence d'observations particulière, plutôt qu'une distribution jointe sur des séquences d'observations et de labels. L'hypothèse traditionnelle des MRF d'indépendance des variables entre elles n'est plus nécessaire. Un sous-type particulier de CRF s'appelle les *Discriminative Random Fields* (DRF, (Kumar and Hebert, 2006)): ils sont définis sur des grilles régulières 2D et les potentiels unaires (association) et binaires (interaction) se fondent sur les résultats de classifications locales/pixellaires. C'est celui que l'on utilise pour la classification d'images de télédétection. Le terme d'association est semblable à celui d'attache aux données dans un MRF. Le terme d'interaction est une mesure sur comment les étiquettes des pixels voisins interagissent, connaissant l'image en entrée. Il est donc fonction de toutes les observations. Une grand nombre d'extensions et de techniques pour l'apprentissage et l'inférence des graphes ont été proposées dans la littérature (Vishwanathan et al., 2006; Kohli et al., 2009; Nowozin et al., 2011; Krähenbühl and Koltun, 2011; Ladicky et al., 2014). et appliquées aux images hyperspectrales (Zhong and Wang, 2010; Roscher and Waske, 2014; Li et al., 2015).

Une tendance très populaire depuis 1 an consiste à intégrer des résultats de sémantisation issues des méthodes d'apprentissage profond (*Deep learning*) dans des CRF afin d'obtenir des prédictions de très bonne qualité et ceci pour chaque pixel d'une image. Deux possibilités existent: soit les réseaux de neurones convolutifs sont optimisés avant l'application d'un CRF, soit l'apprentissage se fait de manière conjointe (Chen et al., 2015; Lin et al., 2015; Schwing and Urtasun, 2015; Zheng et al., 2015).

1.6 Shadow detection

La détection de zones d'ombre dans une image peut être effectuée de bien des manières. Dans (Adeline et al., 2013), les auteurs classent ces approches en quatre catégories : les méthodes orientées caractéristique, géométriques, physiques et enfin celles orientées apprentissage (Figure 3).

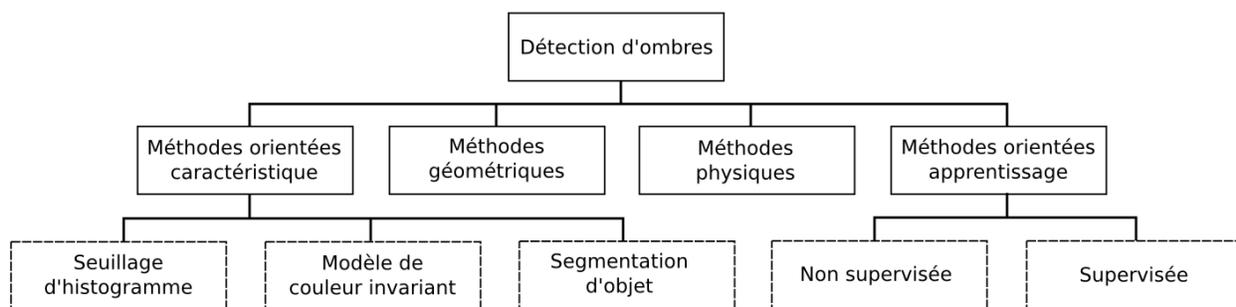


Figure 3: Taxonomie des méthodes de détection d'ombre.

La première catégorie de méthode ne requiert aucune information a priori et s'appuie sur des caractéristiques à la fois spectrales et texturales déduites directement des données image. Elle se divise elle-même en trois sous-catégories : les méthodes de seuillage d'histogramme, celles fondées sur un modèle de couleur invariant et enfin celles orientées segmentation d'objet.

Le seuillage d'histogramme est l'outil de détection d'ombre le plus simple. Il part du principe qu'il existe dans un sous-espace précis des données une séparation nette entre les niveaux d'histogrammes associés aux pixels ombragés et ceux associés aux pixels ensoleillés. Nagao et al. (1979) utilisent par exemple une combinaison de bandes RVB et PIR. Puis intervient une étape décisive : la recherche du seuil qui optimisera la séparation entre les deux classes recherchées. Celle-ci peut se faire suivant plusieurs hypothèses : histogramme bimodal (Dare, 2005), modèle de mélange gaussien (Otsu, 1979), étude du nombre de pics et de vallées (Chen et al., 2007) ou même inspection visuelle (Yamazaki et al., 2009).

Les méthodes fondées sur un modèle de couleur invariant tirent parti de la chromaticité des images, la plupart du temps par l'intermédiaire de combinaisons RVB. L'objectif est, en séparant les informations de luminance et de chromaticité, d'identifier des espaces de données invariants à l'ombre en termes de luminance. Les ombres sont supposées présenter une valeur de teinte élevée, une valeur de saturation forte dans les bandes bleu/violette et une faible valeur d'intensité. Zones ombragées et ensoleillées sont ensuite séparées via différentes méthodes impliquant un rapport spectral entre teinte et intensité (Polidorio et al., 2003; Huang et al., 2004; Tsai, 2006; Chung et al., 2009). D'autres approches visant à retrouver la couleur véritable des pixels ont été développées (projection en log-chromaticité par minimisation d'entropie (Finlayson et al., 2006, 2009), construction d'un modèle d'atténuation tricolore (Tian et al., 2009), calcul de chromaticité par sélection manuelle de paires de pixels ombre/soleil (Makarau et al., 2011)). Toutefois, ces dernières n'ont pour le moment pas été testées sur des données aéroportées, et ne sont pas toujours automatiques ni adaptées au milieu urbain.

Enfin, la dernière sous-catégorie entend améliorer les résultats de discrimination ombre/soleil en incluant au processus une information spatiale, texturale et/ou contextuelle (Yuan and Bauer, 2006; Chen et al., 2009). Remarquons également que dans la littérature, la segmentation (cf. partie 1.4) est souvent utilisée en tant que première étape d'un processus de détection d'ombre (Massalabi et al., 2004; Tian et al., 2009; Zhan et al., 2005).

Les méthodes géométriques nécessitent une connaissance du relief de la scène étudiée afin de déterminer la position des ombres dans l'image. Cette connaissance a priori prend généralement la forme d'un modèle numérique de surface ou d'élévation obtenu par photogrammétrie aérienne ou satellite, balayage laser terrestre ou aéroporté, interférométrie radar ou relevé topographique. La détection des zones d'ombre peut ensuite être réalisée de plusieurs façons : par lancer de rayon (Thirion, 1990; Tolt et al., 2011), en utilisant un Z-buffer associé à une orthophotographie multi-vues (Rau et al., 2002), par superposition d'un masque d'ombre simulé (dérivé du MNS) à l'image originale (Nakajima et al., 2002) ou par un algorithme d'ombre portée associé à une segmentation d'objet (Zhan et al., 2005). L'efficacité de ces méthodes est directement liée à la précision

du modèle 3D utilisé.

Les méthodes physiques tiennent pour leur part compte des conditions atmosphériques et d'illumination pour identifier les zones d'ombre. Elles nécessitent l'application d'un algorithme de correction atmosphérique afin de travailler sur des données en réflectance, et reposent sur des algorithmes de démixage considérant que les zones d'ombres correspondent au pôle de mélange le plus sombre (Boardman, 1993; Adler-Golden et al., 2002; Richter and Muller, 2005).

Enfin, les méthodes de détection d'ombre orientées apprentissage se divisent en deux sous-catégories, celles qui sont supervisées (accès à un ensemble d'échantillons d'apprentissage issus d'une vérité terrain) et celles qui ne le sont pas (cf. Section 1). Les méthodes non supervisées s'appuient la plupart du temps sur des algorithmes de regroupement tels que le k-Means (Ashton et al., 2008) ou le modèle de mélange gaussien (Martel-Brisson and Zaccarin, 2005). L'idée est de considérer que l'ensemble des pixels d'ombre constituent une seule et même classe, cette dernière étant celle dont le centroïde présente la plus faible intensité moyenne. Parallèlement, plusieurs approches supervisées ont été entreprises. Levine and Bhattacharyya (2005) utilisent un classifieur SVM pour identifier les bords des zones d'ombre après une phase de segmentation. Tappen et al. (2005) utilisent pour leur part deux classifieurs, l'un fondé sur l'information de couleur et l'autre entraîné à reconnaître les motifs d'image locaux afin de distinguer les changements de radiométrie dus à l'évolution de la réflectance et ceux dus à l'évolution de l'illumination. Enfin Lalonde et al. (2010) identifient les contours d'une image dus à l'ombre par l'intermédiaire d'un classifieur de type arbre de décision et d'attributs sensibles à l'ombre, avant de regrouper ces contours via un *Conditional Random Fields* (cf. partie 1.5). A noter que ces trois méthodes supervisées n'ont pour le moment pas été testées sur des données aéroportées.

2 Dimension reduction

2.1 High-dimension data

Les données de télédétection de très grande dimension, comme l'imagerie hyperspectrale, génèrent des volumes de données importants. Ainsi, dans le cas hyperspectral, ces données vont consister en plusieurs centaines de bandes spectrales contiguës. La corrélation entre ces bandes, et en particulier entre bandes voisines est souvent importante, d'où une information redondante. Aussi est il possible de réduire ce volume d'information sans perte excessive d'information utile.

Cette forte dimension des données a pour conséquence de générer un certain nombre de difficultés. En premier lieu, le phénomène bien connu de malédiction de la dimension ou phénomène de Hughes (1968) risque de se produire lorsque l'on va chercher à procéder à une classification de ces données. Ceci est toutefois à nuancer car les classifieurs "modernes" plus robustes comme les Séparateurs à Vaste Marge (SVM) ou les Forêts aléatoires (ou Random Forests (RF)) sont moins sensibles à ces problèmes (Melgani and Bruzzone, 2004; Camps-Valls and Bruzzone, 2005) et parviennent malgré tout à produire de bons résultats, sauf dans des cas où très (trop) peu de données d'apprentissage sont disponibles (Pal and Foody, 2010).

En second lieu, les temps de calculs requis pour traiter ces grands volumes de données vont également être importants. En troisième lieu, le stockage de ces données prend beaucoup de place. En dernier lieu, la question de l'affichage de l'imagerie hyperspectrale peut aussi se poser. Il s'agit alors de décider de ce que l'on va afficher quand la vision humaine est limitée à trois couleurs (Demir et al., 2009; Le Moan et al., 2011).

Il va donc souvent s'avérer intéressant de réduire la dimension de ces données. Cela va consister à réduire le volume de données (i.e., le nombre de bandes) de manière à optimiser un certain critère, comme par exemple minimiser la perte d'information utile, et en particulier dans le contexte d'une classification supervisée, de s'efforcer de conserver la meilleure séparabilité, la meilleure distinction entre les classes. Les méthodes de réduction de la dimension peuvent être distinguées en deux catégories : les méthodes d'**extraction de**

caractéristiques (*feature extraction*) et celles de **sélection d'attributs**.

Les méthodes d'extraction de caractéristiques consistent à reformuler et à résumer l'information contenue dans le jeu de données initial, par exemple en reprojétant les bandes initiales sur des axes choisis de manière optimale. Parmi les algorithmes d'extraction de caractéristiques les plus connus, on peut citer l'Analyse en Composantes Principales (ACP), le *Minimum Noise Fraction* (MNF) ou l'Analyse en Composantes Indépendantes (ACI) pour le cas non supervisé ainsi que l'Analyse Discriminante Linéaire, ou Analyse Discriminante de Fisher pour le cas supervisé (Bishop, 2006).

A l'inverse, les méthodes de sélection d'attributs vont choisir un sous-ensemble d'attributs issus du jeu de données initial, c'est-à-dire ne conserver que les quelques attributs les plus utiles, les plus pertinents, au sens d'un certain critère.

Cette seconde classe de méthodes de réduction de la dimension offre certains avantages par rapport à la première. En effet, elle conserve le sens physique des bandes qui sont sélectionnées, contrairement à une extraction d'attributs où cette information est noyée lors du calcul des attributs "synthétiques". On notera d'ailleurs au passage que cela correspond à ce qui a pu être fait de manière non automatique en spectroscopie: la détermination des bandes spectrales les plus intéressantes a souvent été faite par des spécialistes qui ont identifié des bandes d'absorption ou des comportements du spectre caractéristiques d'un matériau. Ces connaissances ont ensuite pu être intégrées dans des systèmes expert (comme par exemple (Clark et al., 2003) pour la caractérisation de certains minéraux, (Bassani et al., 2007) pour celle de l'amiante, (Mohammadi, 2012) pour celle des revêtements routiers asphaltés ou (Heiden et al., 2007) pour différents matériaux urbains). Néanmoins, ce genre d'approche n'est pas compatible avec une situation où l'on recherche à identifier un jeu limité de bandes qui soit un compromis pour la discrimination des différentes classes.

Les méthodes de sélection d'attributs sont donc parfaitement adaptées à la sélection d'un jeu de bandes spectrales optimal dans le cas de la conception d'un capteur multispectral/superspectral dédié à des applications spécifiques. On parle alors de **sélection de bandes**. En revanche, si l'on souhaite également définir la largeur optimale des bandes spectrales (et pas uniquement leur position le long du spectre), on se trouve à mi-chemin entre sélection de bandes et extraction de caractéristiques, puisque l'on reformule la donnée originale. On parlera alors d'**extraction de bandes spectrales**.

2.2 Spectral band and feature selection

La sélection d'attributs fait partie de la famille des problèmes d'optimisation. En effet, ce travail va consister à sélectionner le sous-ensemble d'attributs permettant d'optimiser un certain critère. Un algorithme de sélection d'attributs est donc l'association d'un critère de sélection que l'on va chercher à optimiser et d'une méthode d'optimisation. Ce critère de sélection d'attributs est une mesure/un score mesurant la pertinence du sous-ensemble d'attributs sélectionnés.

2.2.1 Different families

Les méthodes de sélection d'attributs (et en particulier le critère de sélection) sont souvent distinguées en 3 catégories : "filtres", "*wrapper*" and "imbriquées (*embedded*)". Un récapitulatif d'un certain nombre d'approches de la littérature triées selon cette grille est présenté dans le tableau 1. Dans le cas des filtres, on peut également distinguer les cas supervisés et non supervisés, selon que la notion de classes est prise en compte ou non.

Filtres

Les méthodes de type filtre utilisent un critère de sélection d'attribut indépendant de tout classifieur.

Ainsi, de nombreuses méthodes de sélection d'attributs vont calculer pour chaque attribut un score d'importance individuelle, classer les attributs en fonction de ce score puis n'en conserver que les n meilleurs. De tels scores, calculés pour chaque attribut, peuvent être supervisés ou non. Par exemple, le score utilisé par l'algorithme Relief (Kira and Rendell, 1992; Kononenko et al., 1997), le score de Fischer, ou encore d'autres scores

mesurant la corrélation des bandes avec la vérité terrain (Hall and Holmes, 2003) sont des scores supervisés. Ces mesures d'importance ne prennent toutefois pas en compte les dépendances entre attributs sélectionnés. Aussi un jeu d'attributs sélectionnés comme étant les n meilleurs attributs d'après ces mesures ne constituera pas forcément une solution optimale, ou du moins ne sera pas parcimonieuse.

Des méthodes non supervisées vont dériver de tels scores d'importance individuelle des attributs à partir du résultat d'une décomposition en ACP comme par exemple (Chang et al., 1999). Les bandes les plus corrélées à l'ensemble des autres sont alors progressivement retirées. Du et al. (2003); Hasanlou and Samadzadegan (2010) emploient des approches similaires, mais en utilisant l'ACI au lieu de l'ACP. D'autres approches non supervisée exploitent également les résultats d'une ACP en sélectionnant les attributs les plus semblables aux premières composantes principales (Kandasamy et al., 2009b,a).

Il est aussi possible de calculer des scores de pertinence, non plus pour chaque attribut indépendamment des autres, mais directement pour des jeux composés de plusieurs attributs. Ces mesures permettent donc de comparer des jeux d'attributs sélectionnés entre eux, et pas uniquement des attributs individuels.

Ainsi, dans le cas non supervisé, Chang and Wang (2006) proposent encore une autre approche consistant à minimiser une énergie contrainte (*constrained energy minimization*) afin de sélectionner un sous-ensemble d'attributs les moins corrélés entre eux.

Dans le cas supervisé, des mesures de séparabilité comme celle de Fisher (1936), celle de Bhattacharyya ou celle de Jeffries-Matusita (JM) permettent de mesurer la capacité d'une bande ou d'un ensemble de bandes à discriminer différentes classes (Bruzzone and Serpico, 2000; Herold et al., 2003; De Backer et al., 2005; Serpico and Moser, 2007). D'autres mesures existent, comme par exemple *Minimum Estimated Abundance Covariance (MEAC)* proposée par (Yang et al., 2012) et liée à la capacité du jeu de bandes sélectionnées à bien démêler différentes sources.

D'autres mesures statistiques issues de la théorie de l'information, comme la divergence, l'entropie ou l'information mutuelle, sont aussi utilisées pour sélectionner les meilleurs jeux de bandes, à la fois pour des problèmes non supervisés comme dans (Martínez-Usó et al., 2007; Le Moan et al., 2011) ou dans des problèmes supervisés comme dans (Battiti, 1994; Guo et al., 2008; Estévez et al., 2009; Sotoca and Filiberto, 2010; Cang and Hongnian, 2012). Dans le cas non supervisé, on va ainsi s'efforcer de sélectionner un jeu d'attributs les plus représentatifs possible du jeu de donnée initial, tout en étant les moins redondants entre eux. Ainsi, Martínez-Usó et al. (2007) commencent par regrouper les bandes les plus "corrélées" puis sélectionne la bande la plus représentative de chaque groupe. Pour répondre à un problème de visualisation de la donnée hyperspectrale, Le Moan et al. (2011) souhaitent sélectionner 3 bandes appartenant aux domaines rouge, vert et bleu du spectre, sous la contrainte que les 3 bandes sélectionnées soient les moins "corrélées" possible entre elles. Dans des cas supervisés, Battiti (1994); Guo et al. (2008); Estévez et al. (2009); Sotoca and Filiberto (2010); Cang and Hongnian (2012) sélectionnent des attributs les plus corrélés à la vérité terrain (i.e., aux différentes classes) et les moins redondants entre eux. La difficulté est alors de réussir à pondérer ces deux critères.

Une autre manière de mesurer la similarité entre bandes spectrales est l'OPD (*Orthogonal Projection Divergence*) utilisée par Du and Yang (2008) : la similarité entre bandes est mesurée par l'erreur entre une bande et sa modélisation par combinaison linéaire des bandes déjà sélectionnées. Une méthode de sélection non supervisée peut donc consister à sélectionner les bandes de manière incrémentale, de façon à ne conserver que les bandes les plus différentes au sens de l'OPD.

Enfin, une dernière méthode proposée dans (Campedel et al., 2004) utilise l'algorithme de *Support Vector Clustering* (un algorithme de classification non supervisée) en l'appliquant aux attributs afin d'identifier ceux qui sont les plus caractéristiques.

Wrappers

Dans le cas des méthodes de sélection d'attributs de type *wrapper*, le score mesurant la pertinence du jeu de bandes sélectionnées correspond à la mesure de qualité d'une classification effectuée en utilisant ce jeu de bandes. Une méthode *wrapper* sera donc associée à un classifieur. Quelques exemples de ce type d'approches peuvent être trouvés dans (Estévez et al., 2009; Li et al., 2011; Yang et al., 2007; Zhuo et al., 2008) en utilisant un classifieur de type SVM, dans (Zhang et al., 2007; Fauvel et al., 2014) avec un classifieur par maximum de vraisemblance, dans (Díaz-Urriarte and De Andres, 2006) avec un classifieur Forêts Aléatoires,

dans (Kandasamy et al., 2009b; Minghelli-Roman, 2010) avec une mesure de SAM ou même un détecteur de cibles dans (Minet et al., 2010; Minet, 2011).

Les score de type wrappers peuvent être utilisés pour la sélection d'attributs en association avec différentes méthodes d'optimisation. Ils conduisent généralement à sélectionner des jeux d'attributs réduits mais permettant d'atteindre de très bonnes performances de classification. Néanmoins, ces solutions peuvent aussi parfois manquer de généralité et être trop dépendantes du classifieur à partir duquel est calculé le score wrapper utilisé pour la sélection d'attributs. On pourra alors risquer d'obtenir de moins bons résultats si l'on utilise ensuite ce jeu d'attributs avec un autre classifieur.

Les temps de calculs sont généralement plus importants lorsque l'on utilise des scores de type wrapper : ceux-ci nécessitent en effet à la fois de réaliser l'apprentissage d'un classifieur, de classifier un jeu d'échantillons témoins suivant ce modèle et d'évaluer la qualité de la classification obtenue.

Embedded

Les méthodes de sélection d'attributs de type "imbriqué" ou "*embedded*" sont également liées à un classifieur, mais à la différence d'une méthode wrapper, le score mesurant la pertinence, la performance du jeu d'attributs sélectionnés sera différent d'une simple mesure de la qualité de la classification. En général, avec ce type d'approche, la sélection d'attributs est effectuée directement lors de la phase d'apprentissage. On peut distinguer plusieurs types de méthodes de sélection d'attributs *embedded* (Tang et al., 2014).

Modèles de régularisation : Certaines approches se fondent sur des modèles de régularisation. Un classifieur est entraîné de manière à optimiser une fonction objectif qui comprend un terme d'attache aux données (i.e., qui minimise le taux d'erreur de classification) et un terme de régularisation qui va pénaliser davantage le modèle au fur et à mesure que celui-ci utilise un nombre important d'attributs, ou qui va contraindre les coefficients attribués à certains attributs dans le modèle à rester les plus faibles. Les attributs avec les coefficients les plus proches de 0 sont alors éliminés. Des exemples de ce type d'approches sont présentés dans (Ma and Huang, 2008; Tuia et al., 2014b,a). Des méthodes de sélection d'attributs comme le L1-SVM (Zhu et al., 2004) ou le LASSO (*Least Absolute Shrinkage and Selection Operator*) (Tibshirani, 1996; Tuia et al., 2014a) font partie de ce type d'approches. Ces différentes approches ont l'avantage d'être efficaces et rapides. En revanche, il est plus difficile de les modifier par exemple pour y intégrer simplement des contraintes complémentaires. Critère de sélection d'attributs et méthode d'optimisation y sont également complètement liés.

Mécanisme d'apprentissage menant spontanément une sélection d'attributs : D'autres classifieurs sélectionnent d'emblée les attributs lors de la phase d'apprentissage, de part la nature même de leur méthode d'apprentissage. Ainsi, les Forêts Aléatoires (Breiman, 2001) (et certains arbres de décision) peuvent être considérés comme des méthodes de sélection d'attributs. En effet, pour ces classifieurs, seuls les attributs les plus discriminants (par exemple au sens du critère d'impureté de Gini (Breiman, 2001)) sont utilisés lors du découpage d'un nœud. Cette sélection d'attributs à la volée élimine les attributs les moins utiles mais n'est pas pour autant nécessairement parcimonieuse : elle ne garantit pas de ne pas conserver des attributs redondants (en particulier du fait de l'utilisation de sous-ensembles d'attributs choisis aléatoirement dans le cas des RF).

Mesures d'importance des attributs : Outre cette sélection d'attributs utiles lors de l'apprentissage, les Forêts Aléatoires fournissent également une mesure d'importance des différents attributs au sein de son modèle (Breiman, 2001). Cette importance est calculée pour chaque attribut à partir des échantillons *Out-Of-Bag* (OOB), c'est-à-dire non pris en compte pour la construction d'un arbre de la forêt. Ainsi, pour chaque arbre et pour un attribut donné, on va permuter aléatoirement ses valeurs pour tous les échantillons OOB. On calcule alors la différence entre le taux de bonne classification de ces échantillons OOB avant et après cette permutation. L'importance d'un attribut est alors estimée en moyennant ces différences sur l'ensemble des arbres de la forêt (Breiman, 2001). Les problèmes déjà rencontrés pour les mesures d'importance individuelle des attributs de type filtre sont également présents, mais dans une moindre mesure. En effet, l'importance individuelle RF d'un attribut prend en compte les autres bandes de manière sous-jacente. Toutefois, l'importance

d'une bande aura tendance à diminuer si celle-ci est très corrélée avec de nombreuses autres bandes (Genuer et al., 2010).

Le score utilisé par les SVM-RFE peut aussi être considéré comme une mesure d'importance individuelle des attributs (Guyon et al., 2002). Une autre approche *embedded* pour la sélection d'attributs associée à un classifieur SVM multi-noyau a été proposée par (Tuia et al., 2010): on associe alors un noyau différent à chaque attribut, on estime le modèle du classifieur SVM multi-noyaux, puis on utilise les poids estimés associés à chacun de ces noyaux comme des mesures de l'importance des différents attributs.

Méthodes d'élagage : Les importances individuelles des attributs peuvent ensuite être utilisées pour la sélection d'attributs par des méthodes d'élagage. Ces méthodes utilisent dans un premier temps l'intégralité des attributs disponibles pour entraîner un classifieur, avant d'en éliminer progressivement tout en maintenant à peu près à l'identique la performance du modèle de classification obtenu. Par exemple, l'algorithme SVM-RFE (SVM - Recursive Feature Elimination) proposé par (Guyon et al., 2002) est une méthode *embedded* de sélection d'attributs bien connue qui estime l'importance des différents attributs sélectionnés au sein d'un modèle SVM, c'est-à-dire leur influence dans ce modèle. On part d'une situation où tous les attributs sont pris en compte dans le modèle, puis on élimine progressivement les attributs les moins importants au sens de ce critère. Cette approche SVM-RFE lie donc complètement le score de pertinence des attributs et le processus d'optimisation.

Mesure de la qualité du modèle, de sa performance de généralisation : Contrairement aux exemples précédents pour lesquels on calculait des importances associées aux bandes individuelles, d'autres approches *embedded* mesurent directement la pertinence d'un jeu d'attributs. Ainsi, dans (Fröhlich et al., 2003; Pal, 2009) la marge d'un classifieur SVM est utilisée à la manière d'une mesure de séparabilité comme critère pour comparer des jeux d'attributs. Dans le même ordre d'idée, le taux de bonne classification des échantillons OOB d'un classifieur Forêt Aléatoire peut aussi être considéré comme un tel critère (Breiman, 2001). Ces scores se calculent sur des jeux de bandes et mesurent la généralisation du modèle fourni par le classifieur. Ils peuvent donc constituer une alternative intéressante aux mesures de séparabilité de type filtre et aux scores de type wrapper.

Enfin, on peut citer un cas d'approche *embedded* liée à un algorithme de démixage, et non pas à un classifieur: Zare and Gader (2007) intègrent directement la sélection des bandes les plus utiles au sein d'un algorithme de démixage incluant la détection d'*endmembers* et la détermination de leur abondance. Pour ce faire, des mesures d'importance associées aux différentes bandes ainsi qu'un terme de parcimonie, i.e., pénalisant la sélection d'un nombre trop important de bandes, sont introduits comme contrainte dans la fonction objectif de l'algorithme. Cette approche est très spécifique à la donnée hyperspectrale et au démixage, c'est-à-dire à des cas de figures où l'on traite des échantillons qui ne sont pas purs.

Des approches hybrides

La limite entre ces trois familles de méthodes de sélection d'attributs reste parfois floue. Par ailleurs, des critères appartenant à différentes familles peuvent être utilisés conjointement. Par exemple, Estévez et al. (2009) et Li et al. (2011) sélectionnent des attributs à l'aide d'une approche *wrapper* (taux de bonne classification) respectivement guidée ou associée à des critères de type filtre (information mutuelle entre les bandes sélectionnées et avec les différentes classes).

2.2.2 Différentes méthodes d'optimisation

Une fois le critère à optimiser choisi, le problème de sélection d'attributs va être de parvenir à identifier le meilleur jeu d'attributs au sens de ce critère.

Une recherche exhaustive est bien souvent impossible, en particulier dans le cas des wrappers où les temps de calcul liés à la classification/évaluation peuvent être importants. L'ensemble des solutions possibles est en effet généralement trop important pour pouvoir être visité dans sa totalité. Aussi, des heuristiques permettant

Table 1: Récapitulatif de différents critères de sélection d'attributs issus de l'état de l'art.

Filtres	
Non supervisés :	
Scores d'importances individuelles :	
ACP ou ACI ou corrélation inter-bandes	(Chang et al., 1999; Du et al., 2003), (Hasanlou and Samadzadegan, 2010) (Chang and Wang, 2006)
Scores calculés pour un jeu d'attributs :	
Information mutuelle	(Martínez-Usó et al., 2007; Le Moan et al., 2011)
Combinaison linéaire de bandes	(Du and Yang, 2008)
Autre :	
SVC (Support Vector Clustering)	(Campedel et al., 2004)
Méthode fondée sur la corrélation inter-bandes	(Chang and Wang, 2006)
Supervisés :	
Scores d'importances individuelles :	
ReliefF	(Kira and Rendell, 1992; Kononenko et al., 1997)
Autres mesures fondées sur la corrélation ou l'information mutuelle	(Hall and Holmes, 2003)
Scores calculés pour un jeu d'attributs :	
Mesures de séparabilité :	
Mesures de séparabilité : distance de Bhattacharyya ou distance de Jeffries-Matusita	(Bruzzone and Serpico, 2000; Herold et al., 2003) (De Backer et al., 2005),(Serpico and Moser, 2007), (Zhang et al., 2007)
<i>Minimum Estimated Abundance Covariance</i>	(Yang et al., 2012)
Corrélation à la vérité terrain :	
Information mutuelle	(Battiti, 1994; Guo et al., 2008) (Estévez et al., 2009; Sotoca and Filiberto, 2010) (Cang and Hongnian, 2012)
Wrapper	
Taux de bonne classification obtenu par :	
Classifieur SVM	(Estévez et al., 2009; Li et al., 2011) (Yang et al., 2007; Zhuo et al., 2008)
Classifieur par maximum de vraisemblance	(Zhang et al., 2007; Fauvel et al., 2014)
Classifieur Random Forests	(Díaz-Urriarte and De Andres, 2006)
Détecteur de cibles	(Minet et al., 2010)
Embedded	
Modèle de régularisation :	
L1-SVM	(Zhu et al., 2004)
Lasso	(Tibshirani, 1996; Tuia et al., 2014a)
Autres modèles de régularisation	(Ma and Huang, 2008; Tuia et al., 2014b)
Sélection directe lors de l'apprentissage :	
Classifieur Random Forests	(Breiman, 2001)
Classifieur Arbre de décision	(Breiman et al., 1984)
Mesure d'importance individuelle des attributs :	
Importances d'attributs fournies par Random Forests	(Breiman, 2001)
SVM multi-noyaux	(Tuia et al., 2010)
Méthodes d'élagage:	
SVM-RFE	(Guyon et al., 2002)
Performance de généralisation :	
Marge d'un SVM	(Fröhlich et al., 2003; Pal, 2009)
Erreur OOB d'un classifieur Random Forests fondée sur SAM	(Fröhlich et al., 2003; Pal, 2009) (Keshava, 2002)
Autre :	
Processus de démélange	(Zare and Gader, 2007)

Table 2: Récapitulatif avec avantages et inconvénients des différentes familles de critères de sélection d'attributs issus de l'état de l'art.

Filtres
Non supervisés :
<p>Scores d'importances individuelles : <u>Avantage</u> : Rapide. <u>Inconvénient</u> : Sélection par tri, mais sans prise en compte des redondances entre attributs sélectionnés, avec pour conséquence des solutions non parcimonieuses. Donc plutôt pour guider la recherche.</p> <p>Scores calculés pour un jeu d'attributs et combinaison linéaire de bandes : <u>Avantage</u> : Sélection des attributs à la fois les plus représentatifs et les moins redondants entre eux. <u>Inconvénient</u> : Comment pondérer ces deux termes ? <u>Inconvénient</u> : Pas nécessairement la meilleure solution (parcimonie/performance) pour un problème de classification précis.</p>
Supervisés :
<p>Scores d'importances individuelles : <u>Avantage</u> : Rapide. <u>Inconvénient</u> : Sélection par tri, mais sans prise en compte des redondances entre attributs sélectionnés, avec pour conséquence des solutions non parcimonieuses.</p> <p>Scores calculés pour un jeu d'attributs : Mesures de séparabilité : <u>Avantage</u> : Rapide. Donne de généralement de bons résultats. Prise en compte des redondances entre attributs sélectionnés. <u>Inconvénient</u> : Modélisation des classes par une loi statistique paramétrique sous-jacente (ex : gaussienne). Corrélation à la vérité terrain : <u>Avantage</u> : Plutôt rapide. <u>Avantage</u> : Sélection des attributs à la fois les plus corrélés à la vérité terrain et les moins redondants entre eux. <u>Inconvénient</u> : Comment pondérer ces deux termes ?</p>
Wrapper
<p><u>Avantage</u> : Donne de bons résultats, en particulier pour le classifieur utilisé pour le score. <u>Avantage</u> : Prise en compte à la fois des redondances entre attributs sélectionnés et de leur performance. <u>Inconvénient</u> : Temps de calcul plus ou moins long selon le classifieur utilisé <u>Inconvénient</u> : Risque d'être plus dépendant du classifieur utilisé</p>
Embedded
<p>Modèle de régularisation : <u>Avantage</u> : Bons résultats. Rapide. Prise en compte des redondances entre attributs sélectionnés. <u>Inconvénient</u> : Formulation plus verrouillée (plus difficile d'y introduire d'autres contraintes) <u>Inconvénient</u> : Méthode d'optimisation spécifique, pas générique</p> <p>Sélection directe lors de l'apprentissage : <u>Avantage</u> : Rapide. <u>Inconvénient</u> : Pas parcimonieux.</p> <p>Mesure d'importance individuelle des attributs / méthode d'élagage : <u>Avantage</u> : Rapide. <u>Inconvénient</u> : Solution pas nécessairement parcimonieuse (surtout si simple tri). <u>Inconvénient</u> : Méthode d'optimisation spécifique, pas générique dans le cas d'une méthode d'élagage.</p> <p>Performance de généralisation : <u>Avantage</u> : Utilisable comme un wrapper, mais plus rapide. <u>Avantage</u> : Prise en compte des redondances entre attributs sélectionnés. <u>Inconvénient</u> : Différence possible entre généralisation du modèle et performance de classification.</p>

de trouver une solution "proche" de la solution optimale tout en ne visitant qu'un nombre raisonnable de configurations vont être utilisées. On peut généralement distinguer ces méthodes d'optimisation en méthodes séquentielles ou incrémentales et méthodes stochastiques.

Stratégies séquentielles ou incrémentales

Ces méthodes vont consister à progressivement rajouter ou retirer des attributs au jeu d'attributs sélectionnés. Plusieurs de ces méthodes sont présentées dans (Pudil et al., 1994). Par exemple, la méthode *Sequential Forward Search* (SFS) commence par sélectionner un attribut puis ajoute progressivement à la sélection l'attribut non encore sélectionné permettant à la nouvelle sélection d'optimiser le critère de sélection. A l'inverse, la méthode *Sequential Backward Search* (SBS) commence par sélectionner l'ensemble des attributs puis supprime progressivement de la sélection le plus mauvais attribut au sens du critère de sélection. Les algorithmes d'optimisation (l, p) sont un compromis entre ces méthodes, ajoutant alternativement l nouveaux attributs et en retirant p de la sélection. Des variantes de ces stratégies comme les algorithmes *Sequential Forward Floating Search* (SFFS) ou *Sequential Backward Floating Search* (SBFS) ont été proposées (Pudil et al., 1994): ces approches dites "flottantes" autorise la remise en question la sélection d'attributs obtenue au niveau précédent, et donc dans une certaine mesure d'éviter de figer d'emblée les attributs sélectionnés. Serpico and Bruzzone (2001) proposent une autre variante de ces méthodes SFS et SBS avec l'algorithme *Steepest Ascent* (SA).

Dans le cas de notre problématique de conception d'un capteur, on souhaite finalement être parcimonieux en sélectionnant un nombre de bandes très limité par rapport à la donnée initiale. Il semble donc plus pertinent d'utiliser des approches ascendantes comme les algorithmes SFS, SA ou SFFS qui ajoutent progressivement des attributs à la sélection, plutôt que des approches descendantes (SBS ou SBFS) qui partent de l'intégralité des attributs et les éliminent progressivement.

Par ailleurs, on utilisera plus volontiers une approche "flottante" comme SFFS, qui remet en question les sélections obtenues aux étapes précédentes, et évitent donc de figer d'emblée à chaque niveau les attributs déjà sélectionnés, alors que l'ajout de nouveaux attributs peut avoir pour conséquence de trouver une configuration encore meilleure en changeant certains attributs sélectionnés précédemment.

Algorithmes stochastiques

Les algorithmes stochastiques font faire intervenir le hasard dans leur exploration de l'espace des solutions. Ce caractère en partie aléatoire d'initialisation et de recherche d'une solution peut donc permettre de proposer différentes solutions de qualité équivalente à partir d'un même jeu de données.

Plusieurs algorithmes d'optimisation stochastique ont été mis en œuvre pour la sélection d'attributs. On peut notamment citer :

- les algorithmes génétiques (AG)(Li et al., 2011; Estévez et al., 2009; Fröhlich et al., 2003; Zhuo et al., 2008; Minet et al., 2010);
- l'algorithme *Particle Swarm Optimization* (PSO) (Yang et al., 2007, 2012);
- l'algorithme *Clonal Selection* (Zhang et al., 2007);
- l'algorithme des colonies de fourmis (Zhou et al., 2009) ;
- le recuit simulé (De Backer et al., 2005; Chang et al., 2011).

Parmi ces différentes heuristiques, les algorithmes génétiques et PSO sont parmi ceux qui sont les plus utilisés. L'algorithme PSO semble être l'un des plus rapides et être apte à fournir de bons résultats. Les algorithmes génétiques donnent généralement de bons résultats. Ils présentent aussi l'avantage de pouvoir prendre en compte facilement des contraintes complémentaires pour guider la recherche d'une solution (Estévez et al., 2009).

Prise en compte de la corrélation entre bandes

Dans le cas hyperspectral, les bandes voisines sont le plus souvent corrélées. Certaines approches de sélection

d'attributs prennent en compte le fait que des groupes d'attributs sont fortement corrélés pour guider et accélérer leur processus de sélection d'attributs.

Ainsi, la clusterisation ou le regroupement de bandes est donc parfois mis en œuvre conjointement avec une méthode de sélection de bandes individuelles. Par exemple, Li et al. (2011) regroupent d'abord les bandes adjacentes corrélées au sens de leur information mutuelle conditionnelle. La sélection de bandes est ensuite effectuée, avec la contrainte qu'une seule bande soit sélectionnée par cluster. Su et al. (2011) effectuent une clusterisation des différentes bandes en appliquant l'algorithme des k-moyennes à la matrice de corrélation des bandes. Ensuite, les clusters les moins homogènes et les bandes trop différentes de la bande représentante du cluster auxquelles elles appartiennent sont progressivement éliminées.

Martínez-Usó et al. (2007); Jia et al. (2012) commencent par rassembler les attributs "corrélés" puis sélectionne l'attribut le plus représentatif (au sens de l'information mutuelle pour (Martínez-Usó et al., 2007)) de chaque cluster.

2.3 Feature extraction

Les méthodes d'extraction de caractéristiques ou d'extraction d'attributs (*feature selection*) consistent à reformuler et à résumer l'information contenue dans le jeu de données initial, par exemple en reprojétant les bandes initiales dans un autre espace de dimension inférieure, de manière à conserver l'information utile. Parmi les méthodes d'extraction d'attributs, on distingue les méthodes supervisées (on dispose alors de données déjà labellisées et on va chercher une transformation permettant de maximiser la séparabilité entre classes) des méthodes non supervisées.

Unsupervised methods

Parmi les algorithmes d'extraction de caractéristiques les plus connus, on peut citer

- l'Analyse en Composantes Principales (ACP) : l'ACP va s'intéresser à la variance des données et va reprojeter les données de manière à ce que chaque composante reprojétée soit décorrélée des autres. Les composantes reprojétées sont triées selon leur contribution à la variance des données. Ainsi, les premières composantes principales sont celles qui expliquent le plus la variance des données, autrement dit celles qui contiennent le plus d'information. Afin de réduire les temps de calcul, dans le cas de la donnée hyperspectrale où les bandes adjacentes sont souvent très corrélées, une méthode spécifique consistant à d'abord regrouper les bandes adjacentes en un certain de clusters puis à calculer une ACP au sein de chacun de ces clusters, et à ne conserver finalement que les premières composantes de chacune de ces transformations (Jia and Richards, 1999). L'ACP est sensible au bruit, aussi une variante a été proposée de manière à prendre en compte cette information (Lee et al., 1990).
- L'algorithme *Maximum Autocorrelation Factor* (MAF) (Larsen, 2002) explore une autre solution qui va chercher à maximiser l'autocorrélation entre pixels voisins spatialement. L'hypothèse sous-jacente est en effet celle que des échantillons voisins spatialement étant souvent assez semblables et donc corrélés; une mauvaise corrélation entre voisins étant alors le plus souvent due au bruit.
- la transformation *Minimum Noise Fraction* (MNF) (Green et al., 1988) est une autre transformation qui cherche à minimiser le bruit dans les composantes extraites.
- l'Analyse en Composantes Indépendantes (ACI) : l'ACI rejoint la famille des problèmes de séparation de source. L'ACI cherche à maximiser l'indépendance statistique entre les données (Jutten and Herault, 1991), et considère des indépendances statistiques de plus haut niveau que la corrélation utilisée par l'ACP. Une méthode de calcul de l'ACI est l'algorithme FastICA (Hyvärinen and Oja, 2000). Parmi les exemples d'utilisation de l'ACI sur la donnée hyperspectrale, on peut citer (Lennon et al., 2001; Homayouni, 2005; Villa et al., 2011).

- D'autres approches cherchent une transformation qui va reprojeter les données dans un espace de dimension inférieure tout en préservant la matrice de distances entre les échantillons, comme par exemple dans (Messick and Abelson, 1956).

Supervised methods

Dans le cas des méthodes supervisées, le calcul de la transformation s'effectue à partir de jeux d'échantillons labellisés. L'objectif est alors de trouver une transformation qui va favoriser la discrimination entre classes. Parmi les méthodes supervisées, on pourra mentionner :

- L'analyse Discriminante Linéaire ou analyse discriminante de Fisher (Fisher, 1936; Rao, 1948) est la méthode d'extraction d'attributs non supervisée la plus connue. On recherche alors une transformation linéaire qui va maximiser la dispersion (variance) entre classes distinctes tout en minimisant celle au sein d'une même classe. Des variantes semi-supervisées de cette approche ont également été proposées (Cai et al., 2007; Huang et al., 2012).
- D'autres méthodes à même de gérer des modèles moins simplistes existent, comme DBFE (*Decision Boundaries Feature Extraction*) (Lee and Landgrebe, 1993) ou NWFE (*Non parametric Weighted Feature Extraction for classification*) (Kuo and Landgrebe, 2004).

Non-linear methods

Les différentes méthodes (supervisées et non supervisées) qui viennent d'être présentées proposent toutes des transformations linéaires. Des méthodes non linéaires existent également : il s'agit souvent d'adaptation des méthodes linéaires avec la prise en compte de fonction noyau (permettant implicitement de projeter les données dans un autre espace où la transformation est linéaire). On peut mentionner quelques exemples de telles variantes non linéaires utilisant des noyaux dans le cas de l'ACP avec (Fauvel, 2007; Fauvel et al., 2009), dans le cas de l'ALD avec (Scholkopf and Mullert, 1999) ou dans celui de NWFE avec KNWFE (Kernel Decision Boundaries Feature Extraction) (Kuo et al., 2009).

Une approche non supervisée et non linéaire est mise en œuvre par l'algorithme ISOMAP (Tenenbaum et al., 2000).

2.4 Band fusion: band extraction

Dans le cas de la donnée hyperspectrale, les bandes adjacentes sont le plus souvent fortement corrélées. De ce fait, l'optimisation d'un jeu de bandes spectrales peut aller plus loin qu'une simple sélection des bandes originales du jeu de données hyperspectrales et consister en une extraction de bandes, c'est-à-dire la définition d'un jeu optimal de bandes spectrales dont à la fois la position le long du spectre et la largeur ont été optimisées. On se trouve alors à la frontière entre sélection de bandes et extraction de caractéristiques. Par rapport à la sélection de bandes individuelles, l'extraction de bandes spectrales est un problème qui semble avoir été moins abordé dans la littérature, alors qu'il est directement lié à la conception de capteurs multispectraux. Le problème d'extraction de bandes rejoint aussi celui de la clusterisation, du regroupement des bandes corrélées d'un jeu de données hyperspectrales.

2.4.1 Band clustering

La clusterisation ou le regroupement de bandes est parfois mis en œuvre conjointement avec une méthode de sélection de bandes individuelles (dans la littérature, on parle plutôt de regroupement pour les approches visant à obtenir des groupes de bandes adjacentes, et de clusterisation lorsque l'on s'efforce de rassembler des bandes ayant un même comportement sans tenir compte de leur position le long du spectre.) Par exemple, Li et al. (2011) regroupent d'abord les bandes adjacentes corrélées au sens de leur information mutuelle conditionnelle. La sélection de bandes est ensuite effectuée, avec la contrainte qu'une seule bande soit sélectionnée par cluster. Martínez-Usó et al. (2007); Jia et al. (2012) commencent par rassembler les attributs "corrélés"

puis sélectionnent l'attribut le plus représentatif (au sens de l'information mutuelle pour (Martínez-Usó et al., 2007)) de chaque cluster. Chang et al. (2011) effectuent une clusterisation des bandes spectrales sur la base d'un critère plus global fondé sur la corrélation entre bandes et prenant expressément en compte l'existence de plusieurs classes. On optimise alors au moyen d'un algorithme de recuit simulé une fonction de coût définie comme la somme sur tous les clusters et sur toutes les classes de la somme des coefficients de corrélations entre bandes appartenant à un même cluster.

Su et al. (2011) effectuent une clusterisation des différentes bandes en appliquant l'algorithme des k-moyennes à la matrice de corrélation des bandes. Ensuite, les clusters les moins homogènes et les bandes trop différentes de la bande représentante du cluster auxquelles elles appartiennent sont progressivement éliminées.

Bigdeli et al. (2013); Prasad and Bruce (2008) effectuent également une clusterisation des différentes bandes, mais s'en servent, à l'inverse des méthodes précédentes, au sein d'un classifieur SVM multiple : un classifieur SVM est entraîné pour chaque cluster (c'est-à-dire sur les différentes bandes appartenant à ce cluster). Les résultats fournis par ces classifieurs sont ensuite fusionnés. Dans cette optique, Bigdeli et al. (2013) ont comparé plusieurs méthodes de clusterisation ou de regroupement de bandes, incluant notamment les k-moyennes appliquées à la matrice de corrélation ou une approche utilisant les minima locaux de l'information mutuelle entre bandes adjacentes comme limite entre clusters.

Prasad and Bruce (2008) ont proposé une autre stratégie pour le regroupement de bandes : on part de la première bande du spectre et l'on ajoute progressivement au cluster les bandes adjacentes jusqu'à ce qu'un critère d'arrêt fondé sur l'information mutuelle soit atteint.

Les différentes approches qui viennent d'être présentées ont pour point commun de s'efforcer de regrouper les bandes les plus semblables au sens du coefficient de corrélation ou de l'information mutuelle. Les approches sont généralement de deux types :

- celles qui appliquent l'algorithme des k-moyennes, ou un autre algorithme de partitionnement à la matrice de corrélation;
- celles qui définissent les limites entre groupes de bandes comme les minima locaux de l'information mutuelle ou de la corrélation entre bandes adjacentes.

Néanmoins, pour le premier type de méthodes, la manière dont le nombre de clusters (i.e., le paramètre k des k-moyennes) est choisi est rarement précisé, et sa détermination ne semble pas être automatique. Pour le second type de méthodes, il n'est pas précisé si un lissage est appliqué au profil de corrélation/information mutuelle avant la détermination des minima locaux, afin de limiter le bruit, et le cas échéant, pour quel paramétrage.

2.4.2 Band extraction

Quelques approches de regroupement de bandes spécifiques à l'extraction de bandes ont été proposées pour l'optimisation spectrale.

De Backer et al. (2005) définissent les bandes spectrales par des fenêtres gaussiennes le long du spectre et proposent d'extraire les bandes de manière à optimiser un critère de séparabilité entre classes fondé sur la mesure de Bhattacharyya (*Bhattacharyya error bound*) au moyen d'un algorithme de recuit simulé. Serpico and Moser (2007) proposent une adaptation de l'algorithme *Steepest Ascent* pour le problème d'extraction de bandes. Le critère optimisé est alors la mesure de séparabilité de Jeffries-Matusita. Minet et al. (2010) mettent en œuvre un algorithme génétique (avec des individus correspondant à des bandes larges) pour définir les bandes spectrales les plus appropriées à la détection de cibles.

Ces méthodes sont intéressantes dans le sens où elles visent directement à extraire des jeux de bandes optimaux au sens d'un critère de sélection d'attributs. Par ailleurs, elles ne prennent en compte que ce critère, et ne tiennent donc pas compte des similarités/corrélations entre bandes. De ce fait, la combinatoire de ces méthodes est importante et il est dommage de ne pas intégrer ce type d'information afin de guider la recherche de la solution en excluant les plus irréalistes (i.e., celles qui fusionneraient des bandes très différentes).

A l'inverse, Cariou et al. (2011) fusionnent les bandes selon un critère fondé sur l'information mutuelle, afin d'obtenir la configuration optimale au sens de ce critère. Un processus de regroupement de bandes peut également se servir de la méthode de (Jensen and Solberg, 2007) pour décomposer les spectres de références de différentes classes en fonctions constantes par morceaux. Jensen and Solberg (2007) fusionnent en effet les bandes adjacentes de manière à décomposer des spectres de référence de différentes classes en fonctions constantes par morceaux ; le critère d'arrêt est un seuil sur l'erreur de reconstruction des spectres originaux. Wiersma and Landgrebe (1980) s'intéressent aussi à l'erreur de reconstruction mais dans le but de définir des jeux de bandes optimaux selon un modèle analytique prenant en compte les erreurs de reconstruction du spectre ; il s'agit donc cette fois à nouveau d'un problème d'extraction de bandes, mais pour un critère non supervisé. En revanche, les deux premières approches, à savoir celles de (Cariou et al., 2011) et (Jensen and Solberg, 2007), visent à partitionner le spectre en un ensemble de bandes larges, fournissant ainsi des configurations spectrales couvrant l'intégralité du spectre et composées de bandes de largeur variable. Par contre, aucune sélection d'un jeu optimal de bandes pour la classification n'est faite parmi les bandes de cette configuration.

Enfin, certaines études s'intéressent aussi à l'impact de la résolution spectrale sur les résultats d'une classification, sans forcément optimiser de bandes (Adeline et al., 2014), ou comme pour définir une résolution spectrale adaptée avant un processus de sélection de bandes (Tavin, 2008; Minghelli-Roman, 2010). La limite de ces approches est que l'information n'est pas nécessairement répartie de manière uniforme le long du spectre ² A l'inverse, la méthode présentée dans (Le Bris et al., 2015) propose une approche exploratoire reposant sur une hiérarchie de bandes fusionnées. On commence par construire cette hiérarchie au sein de laquelle les bandes adjacentes sont progressivement fusionnées de proche en proche au sens d'un critère de fusion (fondé sur la corrélation entre bandes, la contribution à la séparabilité ou l'erreur de reconstruction du spectre par une fonction constante par morceaux). Chaque niveau de cette hiérarchie correspond alors à une configuration spectrale. La sélection de jeux de bandes fusionnées optimaux s'effectue alors au sein de cette hiérarchie.

3 Unmixing

Hyperspectral unmixing is one of the most important research topics in hyperspectral imaging. Indeed, while hyperspectral images benefit from a high spectral resolution, this comes at the price of a limited spatial resolution. Hence it is very likely that the field of view of the sensor during the acquisition of a pixel corresponds to an area comprising several materials. Then, the spectral signature of such a pixel will be a mixture of the signatures of the pure materials present inside it, as illustrated in Figure 4. The goal of spectral unmixing is then to be able to recover the spectral signatures of the pure materials in the scene (called endmembers), as well as their relative proportions in each pixel (called fractional abundances).

In the field of remote sensing, basic unmixing problems lead to a linear (memoryless) mixing model. On the contrary, more complex configurations involve multiple reflections, e.g., due to three-dimensional structures in urban environments. This leads to linear-quadratic (memoryless) mixtures (when considering pure material spectra as the sources), as shown in (Meganem et al., 2014a). Various unmixing methods, i.e., source separation and/or mixture identification methods, have been developed to handle such mixtures. In (Deville and Duarte, 2015), we provided an overview of these methods, focusing on blind (i.e., unsupervised) configurations, which means, in the field of remote sensing, that the pure material spectra are unknown, in addition to the associated coefficients (these coefficients are abundance fractions in the standard linear case). We hereafter present the aspects of this overview which are of main interest with respect to the field of remote sensing. We first define the considered mixing model in more detail (linear in Section 3.1 and linear quadratic in Section 3.2) and then summarize the principles of the main classes of linear-quadratic

²A titre d'exemple, le spectre d'un matériau peut rester constant sur un domaine spectral assez étendu, mais présenter à un autre endroit un comportement beaucoup plus localisé, correspondant par exemple à des bandes d'absorption. Une résolution spectrale grossière risquera de faire disparaître ce comportement caractéristique, tandis qu'une résolution fine ne permettra pas de fusionner les bandes adjacentes présentant un même comportement alors que le fait de toutes les conserver n'apporte pas d'information utile.

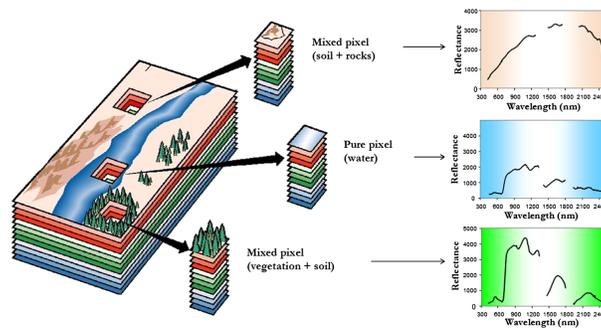


Figure 4: Hyperspectral unmixing concept (Bioucas-Dias et al., 2012).

(LQ) blind source separation (BSS) and/or blind mixture identification (BMI) methods reported so far (see Section 3.3). Applications of LQ BSS/BMI methods specifically dealing with the field of remote sensing are for instance reported in (Eches and Guillaume, 2014; Jarboui et al., 2014; Meganem et al., 2011a,b, 2014a,b),

3.1 Linear Spectral Unmixing

When, within a pixel, the mixture can be considered at the macroscopic scale (no intimate mixing) and when the incident light interacts with only one material, the resulting mixed spectral signature can be modelled as a linear combination of the endmember signatures, with the weights corresponding to the abundances (Bioucas-Dias et al., 2012).

$$\mathbf{y} = \mathbf{M}\boldsymbol{\alpha} + \mathbf{n}, \quad (8)$$

where $\mathbf{y} \in \mathbb{R}^L$ is a hyperspectral pixel (a vector whose size L is the number of spectral bands), $\mathbf{M} \in \mathbb{R}^{L \times P}$ is the endmember matrix containing the P endmembers in its columns, $\boldsymbol{\alpha} \in \mathbb{R}^P$ is the abundance vector, and \mathbf{n} is an additive noise.

When trying to solve this inverse problem, two additional constraints are generally considered: the abundance non-negativity constraint (ANC) and the abundance sum-to-one constraint (ASC). They simply correspond to the fact that the abundances are often interpreted as proportions.

Before using any method to unmix the data, it is necessary to know how many endmembers should be considered, which amounts to computing the Intrinsic Dimensionality (ID) of the data. Indeed, the number of materials in the scene is in general much lower than the number of spectral bands, meaning that the data live in a subspace which has a much lower dimension than the ambient space. State of the art methods to estimate this ID include the Hyperspectral Subspace Identification by Minimum Error (Hysime) (Bioucas-Dias and Nascimento, 2008) or a method based on Random Matrix Theory (RMT) results (Cawse-Nicholson et al., 2013)).

Then, there are three main classes of approaches for recovering the endmember signatures and abundances: the geometrical approaches, the statistical approaches, and the sparse-regression based approaches (Bioucas-Dias et al., 2012).

3.1.1 Geometrical approaches

The core idea around these techniques lies in the geometric interpretation of the Linear Mixing Model (LMM), considering the ASC and ANC, the linearly mixed data lie inside a simplex whose vertices are the endmembers (Figure 5).

Then, finding the endmembers boils down to being able to identify the vertices of the simplex. There are two kinds of Endmembers Extraction Algorithms (EEA) using this property, but they differ depending on whether they consider pure pixels are present in the scene or not (in other words, if there are some data points which correspond to the vertices of the simplex). Popular pure pixel-based EEA include the Vertex

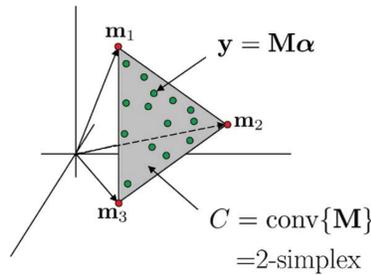


Figure 5: Linear Mixture Model (Bioucas-Dias et al., 2012).

Component Analysis (VCA) (Nascimento and Bioucas Dias, 2005) and the N-FINDR (Winter, 1999), while examples of the algorithms who do not require pure pixels (they are often based on trying to find a simplex of minimum volume which enclosed the data) are the Minimum Simplex Volume Analysis (MVSA) (Li and Bioucas-Dias, 2008), and the Minimum Volume Constraint-Nonnegative Matrix Factorization (MVC-NMF) (Miao and Qi, 2007) algorithms. Finally, once the endmembers have been extracted, the abundances can be estimated by constrained least squares regression, using for example the algorithm of (Heinz and Chang, 2001).

3.1.2 Statistical Approaches

These approaches rely on a different paradigm since they consider the parameters of the LMM as random variables and try to extract them in a Bayesian Estimation Framework. Given some priors distribution of the endmembers and abundances, plus assumption on the noise properties, it is possible to estimate the parameters of the model which maximize the a posteriori distribution (MAP) or compute the mean of the posterior distribution, giving the Minimum Mean Squared Error estimator (MMSE) of the parameters. The posterior density is derived using Bayes' rule from the data likelihood and the priors:

$$p(\mathbf{M}, \boldsymbol{\alpha} | \mathbf{y}) = \frac{p(\mathbf{y} | \mathbf{M}, \boldsymbol{\alpha})p(\mathbf{M})p(\boldsymbol{\alpha})}{p(\mathbf{y})}, \quad (9)$$

assuming \mathbf{M} and $\boldsymbol{\alpha}$ are statistically independent.

These methods are theoretically powerful since they do not require pure pixels and are capable to model endmember variability to some extent, but this comes at the cost of a high computational burden required to sample the posterior distribution. Besides, these methods can sometimes lead to physically unrealistic endmembers. A notable example of such algorithms is the Normal Compositional Model (Eches et al., 2010), although many more have been designed using particular models or assumptions.

3.1.3 Sparse Regression-based approaches

The last main strategy to perform hyperspectral unmixing is based on sparse regression. It assumes that a large dictionary of spectral signatures is available beforehand, and the objective is to find which signatures in this library fit the data best. The problem is no longer fully blind because the library is known, making it unnecessary to estimate the endmember signatures. However, due to the very large size of the spectral library, which constrains many signatures which are irrelevant for the scene of interest, it is useful to incorporate sparsity to the regression problem of the data on the dictionary, in order to select in every pixel the few signatures that explain in best (Iordache et al., 2011). This leads to constrained optimization problems involving sparsity inducing norms, such as the L1 norm, typically of the form:

$$\hat{\boldsymbol{\alpha}} = \arg \min_{\boldsymbol{\alpha} \geq 0} \|\mathbf{y} - \mathbf{M}\boldsymbol{\alpha}\|_2^2 + \lambda \|\boldsymbol{\alpha}\|_1. \quad (10)$$

Here, \mathbf{M} is the dictionary matrix. Note that the ASC has been dropped since it is incompatible with a minimization of the L1 norm (since the ASC forces $\|\alpha\|_1 = 1$).

This approach has opened a new research avenue, leading to new algorithms incorporation new types of sparsity (group sparsity, collaborative unmixing and sparse unmixing with a spatial regularization, just to name a few) into this semi-supervised unmixing problem.

3.2 Linear-quadratic mixing model

Considering continuous-valued signals which depend on a discrete variable n , the scalar form of the LQ (memoryless, or instantaneous) mixing model reads

$$x_i(n) = \sum_{j=1}^M a_{ij} s_j(n) + \sum_{j=1}^M \sum_{k=j}^M b_{ijk} s_j(n) s_k(n) \quad \forall i \in \{1, \dots, P\} \quad (11)$$

where $x_i(n)$ are the values of the P observed mixed signals for the sample index n and $s_j(n)$ are the values of the M unknown source signals which yield these observations, whereas a_{ij} and b_{ijk} are respectively the linear and quadratic mixing coefficients (with unknown values in the blind case) which define the considered source-to-observation transform. The specific version of this model which contains no second-order auto-terms (i.e., $b_{ijk} = 0$ when $k = j$) is called the bilinear mixing model. It corresponds to replacing the second sum in (Equation 11) by $\sum_{j=1}^{M-1} \sum_{k=j+1}^M$ (additional constant terms are considered in (Almeida and Almeida, 2012)). Similarly, the quadratic version of this model is obtained when all coefficients a_{ij} are zero.

A first matrix form of that model (Equation 11) reads

$$x(n) = As(n) + Bp(n) \quad (12)$$

where the source and observation vectors are

$$s(n) = [s_1(n), \dots, s_M(n)]^T, \quad x(n) = [x_1(n), \dots, x_P(n)]^T, \quad (13)$$

where T stands for transpose and matrix A consists of the mixing coefficients a_{ij} . The column vector $p(n)$ is composed of all source products $s_j(n)s_k(n)$ of Equation 11, i.e., with $1 \leq j \leq k \leq M$, arranged in a fixed, arbitrarily selected, order (see e.g., (Meganem et al., 2014b) for the natural order). The matrix B is composed of all entries b_{ijk} arranged so that i is the row index of B and the columns of B are indexed by (j, k) and arranged in the same order as the source products $s_j(n)s_k(n)$ in $p(n)$.

An even more compact model may be derived by stacking row-wise the vectors $s(n)$ and $p(n)$ of sources and source products in an extended vector

$$\tilde{s}(n) = \begin{bmatrix} s(n) \\ p(n) \end{bmatrix} \quad (14)$$

whereas the corresponding matrices A and B are stacked column-wise in an extended matrix

$$\tilde{A} = [A \ B]. \quad (15)$$

The LQ mixing model (Equation 12) then yields

$$x(n) = \tilde{A}\tilde{s}(n). \quad (16)$$

A third matrix-form model may eventually be derived by stacking column-wise all available signal samples, with n ranging from 1 to N , in the matrices

$$\tilde{S} = [\tilde{s}(1), \dots, \tilde{s}(N)], \quad X = [x(1), \dots, x(N)]. \quad (17)$$

The single-sample model (Equation 16) thus yields its overall matrix version

$$X = \tilde{A}\tilde{S}. \quad (18)$$

Some LQ BSS methods are based on the "original sources" $s_1(n), \dots, s_M(n)$ contained in $s(n)$, whereas other methods are based on the signals contained in $\tilde{s}(n)$, which are called the "extended sources" hereafter.

3.3 BSS/BMI methods for linear-quadratic mixtures

3.3.1 Independent component analysis (ICA)

A significant number of reported LQ BSS/BMI methods are based on Independent Component Analysis (ICA). They therefore request the sources to be mutually statistically independent (or at least uncorrelated, together with some additional properties). This constraint is not well-suited to hyperspectral remote sensing data, where the sources are the pure material spectra, as explained above. Therefore, we do not detail these methods here and refer the reader to our overview (Deville and Duarte, 2015).

3.3.2 Extensions of nonnegative matrix factorization (NMF)

Although the considered observations (Equation 11) are nonlinear mixtures of the original sources, the reformulated mixing model (Equation 18) shows that they are linear mixtures of the associated extended sources and that, from the point of view of the latter sources, they follow the matrix-form mixing model encountered in *linear* NMF. When \tilde{A} and \tilde{S} (and thus X) are nonnegative, this allows one to develop LQ BSS/BMI methods for jointly estimating them by extending linear NMF methods, especially by adapting (estimates of) \tilde{A} and the linear part of \tilde{S} so as to minimize the Frobenius norm $\|X - \tilde{A}\tilde{S}\|_F$. Resulting gradient-based and/or Hessian-based algorithms have more complex forms than for linear mixtures, because they also involve derivatives of the second-order terms of \tilde{S} with respect to the original sources. Several such methods are detailed in (Meganem et al., 2011b) (which also addresses polynomial mixtures) and (Meganem et al., 2014b) (the application of a standard NMF algorithm to the *extended* sources is also considered in (Meganem et al., 2011a,b)). A similar approach, dedicated to the case when both the sources and mixing coefficients follow bilinear models, is described in (Eches and Guillaume, 2014). Besides, Liu and Wang (2013) deals with a very specific configuration involving 2 mixtures of 2 original sources, with the same quadratic contribution in both mixtures.

3.3.3 Sparse component analysis (SCA)

For linear mixtures, two major principles used in the literature for performing SCA may be briefly defined as follows. The first one consists in minimizing a sparsity-based cost function, such as the L0 norm of an "error term". The second one consists in taking advantage of zones (i.e., adjacent samples) in the sources where only one source is active, i.e., non-zero. These two principles have been extended to LQ mixtures, respectively in (Duarte et al., 2012) and (Deville and Hosseini, 2007). Besides, (Jarboui et al., 2014) describes an approach which also takes advantage of small parts of the observed data where only one "contribution" is non-zero, more precisely pixels which correspond to only one pure material (i.e., pure pixels) in the considered application to unmixing of remote sensing spectra. However, the proposed criterion is only guaranteed to yield a *necessary* condition for detecting pure pixels.

4 Pansharpening

In the design of optical remote sensing systems, owing to the limited amount of incident energy, there are critical tradeoffs between the spatial resolution, the spectral resolution, and the signal-to-noise ratio (SNR). Optical systems can provide data with a high spatial resolution but with a small number of spectral bands (for example, panchromatic (PAN) data with decimetric spatial resolution or multispectral data with three to four bands and metric spatial resolution, like PLEIADES) or with a high spectral resolution but with reduced spatial resolution (for example, hyperspectral data, subsequently referred to as HS data, with more than one hundred of bands and decametric spatial resolution like HYPXIM).

To enhance the spatial resolution of multispectral data, several methods have been proposed in the literature under the name of pansharpening, which is a form of super-resolution. Fundamentally, these methods solve an inverse problem which consists in obtaining an enhanced image with both high spatial and high spectral resolutions from a panchromatic image and a multispectral image. The huge interest of the community on

this topic is evidenced by the existence of sessions dedicated to this topic in the most important remote sensing and Earth observation conferences as well as by the launch of public contests, of which the one sponsored by the data fusion committee of the IEEE Geoscience and Remote Sensing society (Alparone et al., 2007) is an example.

A taxonomy of pansharpening methods can be found in the literature (Thomas et al., 2008; Aiazzi et al., 2011; Vivone et al., 2014a). They can be broadly divided into four classes: component substitution (CS), multiresolution analysis (MRA), Bayesian, and variational.

The CS approach relies on the substitution of a component (obtained, e.g., by a spectral transformation of the data) of the multispectral (subsequently denoted as MS) image by the panchromatic (subsequently denoted as PAN) image. The CS class contains algorithms such as intensity-hue-saturation (IHS) (Carper et al., 1990), (Tu et al., 2001), (Chavez Jr. et al., 1991), principal component analysis (PCA) (Chavez and Kwarteng, 1989), (Shettigara, 1992), (Shah et al., 2008) and Gram-Schmidt (GS) spectral sharpening (Laben and Brower, 2000). The main advantages of the CS-based fusion techniques are the following: i) high fidelity in rendering the spatial details in the final image (Aiazzi et al., 2007), ii) fast and easy implementation (Tu et al., 2001), and iii) robustness to misregistration errors and aliasing (Baronti et al., 2011). On the negative side, the main shortcoming of these techniques is the generation of a significant spectral distortion, caused by the spectral mismatch between the PAN and the HS spectral ranges (Thomas et al., 2008).

The MRA approach is based on the injection of spatial details, which are obtained through a multiscale decomposition of the PAN image into the MS data. The spatial details can be extracted according to several modalities of MRA: decimated wavelet transform (DWT) (Mallat, 1989), undecimated wavelet transform (UDWT) (Nason and Silverman, 1995), "à-trous" wavelet transform (ATWT) (Shensa, 1992), Laplacian pyramid (Burt and Adelson, 1983), nonseparable transforms, either based on wavelets (e.g., curvelets (Starck et al., 2007)) or not (e.g., contourlets (Do and Vetterli, 2005)). The main advantages of the MRA-based fusion techniques are the following: i) temporal coherence (Aiazzi et al., 2011), ii) spectral consistency, and iii) robustness to aliasing, under proper conditions (Baronti et al., 2011). On the negative side, the main shortcomings are i) the implementation is more complicated due to the design of spatial filters, ii) the computational burden is usually larger when compared to CS approaches. Hybrid methods have been also proposed, which use both component substitution and multiscale decomposition, such as guided filter PCA (GFPCA) (Liao et al., 2015).

The Bayesian approach relies on the use of posterior distribution of the full resolution target image given the observed MS and PAN images. This posterior, which is the Bayesian inference engine, has two factors: a) the likelihood function, which is the probability density of the observed MS and PAN images given the target image, and b) the prior probability density of the target image, which promotes target images with desired properties, such as being segmentally smooth. The selection of a suitable prior allows us to cope with the usual misstated inverse problems of the pansharpening. Bayesian methods give good performance, which can be explained by the fact that they rely on a forward modelling of the PAN and HS images and explicitly exploit the spatial and spectral degradations applied to the target image. However, these algorithms may suffer from performance discrepancies when the parameters of these degradations (i.e., spatial blurring kernel, sensor spectral response) are not perfectly known.

The variational class is interpretable as particular case of the Bayesian one, where the target image is estimated by maximizing the posterior probability density of the full resolution image. The works of (Ballester et al., 2006), (Palsson et al., 2014), and (He et al., 2014) are representative of the Bayesian and variational classes.

With the increasing availability of HS systems, the pansharpening methods are now extending to the fusion of HS and panchromatic images (Moeller et al., 2009; Garzelli et al., 2010; Vivone et al., 2014b; Alparone et al., 2015). Pansharpening of HS images is still an open issue, and very few methods are presented in the literature to address it. The main advantage of HS image with respect to MS one is the more accurate spectral information they provide, which clearly benefits many applications such as unmixing (Bioucas Dias et al., 2012), change detection (Souza Jr et al., 2003), object recognition (Mohammadzadeh et al., 2006), scene interpretation (Laporterie-Déjean et al., 2005) and classification (Licciardi et al., 2012). Several of the

methods designed for HS pansharpener were originally designed for the fusion of MS and HS data (Yokoya et al., 2012; Wei et al., 2015b, 2014; Simões et al., 2015; Wei et al., 2015a) the MS data constituting the high spatial resolution image. In this case, HS pansharpener can be seen as a particular case, where the MS image is composed of a single band, and thus reduces to a PAN image. These methods can be divided into two classes: Bayesian methods (Wei et al., 2015b), (Wei et al., 2015a), and (Simões et al., 2015) and matrix factorization based methods (Yokoya et al., 2012).

As one may expect, performing pansharpener with HS data is more complex than performing it with MS data. Whereas PAN and MS data are usually acquired almost in the same spectral range, the spectral range of an HS image normally is much wider than the one of the corresponding PAN image. Usually, the PAN spectral range is close to the visible spectral range of 0.4-0.8 μm (for example, the advanced land imager–ALI–instrument acquires PAN data in the range 0.48-0.69 μm). The HS range often covers the visible to the shortwave infrared (SWIR) range (for example, Hyperion acquires HS data in the range 0.4-2.5 μm , the range 0.8-2.5 μm being not covered by the PAN data). The difficulty that arises, consists in defining a fusion model that yields good results in the part of the HS spectral range that is not covered by PAN data, in which the high resolution spatial information is missing. This difficulty already existed, to some extent, in MS+PAN pansharpener, but it is much more severe in the HS+PAN case.

A review paper has been written on this topic (Loncan et al., 2015) and is available with the associated Matlab toolbox at:
<http://openremotesensing.net>.

5 Classification by fusion at the decision level

Le problème de la fusion d’information apparaît dès que plusieurs sources d’information hétérogènes peuvent être utilisées pour une prise de décision. Les informations issues des différents capteurs peuvent alors être combinées afin de faire un choix plus justifié qu’en ne considérant qu’un des types d’information. Le traitement d’image est un terrain d’expérimentation idéal pour la fusion d’information puisqu’une même scène peut être observée par plusieurs caméras offrant des points de vue divers et dont les capteurs peuvent avoir des caractéristiques variées. Nous traitons ici du problème de fusion de données multi-modales au niveau des classifications. Une taxonomie des types de fusions (multi-capteurs/temporelle/fréquentielle/résolution etc.) est fournie dans (Simone et al., 2002). La fusion multi-modale/capteurs peut s’effectuer au niveau des observations (abordé en partie dans la section 4, des attributs ou des décisions (Pohl and Genderen, 1998). Nous abordons ici le niveau des **décisions** qui est en particulier utile pour l’imagerie hyperspectrale. On dispose très souvent d’une image multi-spectrale \tilde{A} plus haute résolution spectrale que l’image hyperspectrale, apportant elle de la richesse spectrale. On cherche alors à combiner les décisions pour bénéficier de la finesse spatiale et la forte capacité de discrimination thématique de l’une et de l’autre. Ce principe est également vrai lorsque des points de vue différents sont mélangés (Zhang, 2010): optique+lidar (F., 2007; Guo et al., 2011), optique+radar (Poulain et al., 2011; Wegner et al., 2014), lidar+radar (Barbanson et al., 2015; Kaasalainen et al., 2015).

La fusion de classifieurs (souvent faibles) a déjà été abordée dans la section 1.2.4. Nous nous concentrons ici sur l’intégration de classifications supposées ”fortes” et laissons également de côté la fusion d’opérateurs hétérogènes (classification + reconnaissance des formes). Le lecteur peut se référer à la littérature abondante sur le sujet, en particulier dans la communauté de vision par ordinateur (*semantic image segmentation* (Yu et al., 2002; Ladický et al., 2010; Maire et al., 2011; Arbelaez et al., 2012)).

Un certain nombre de panoramas des techniques de fusion en télédétection est disponible dans la littérature plus ou moins récente (Xu et al., 1992; Zhang, 2010), en particulier dans l’optique de la détection de changements (Du et al., 2013).

Dans la théorie de la fusion d’information ”classique”, plusieurs méthodes existent, applicables en fonction de certains critères précis liant l’observation à l’information.

- l'exhaustivité permet de savoir si les observations décrivent l'ensemble des phénomènes possiblement observables,
- l'exclusivité du lien entre observation et information correspond à la possibilité d'une même observation pour plusieurs informations distinctes,
- le lien entre information et observation est dit total si l'information décrit totalement l'observation. Si ce n'est pas le cas, par exemple si une observation correspond en réalité à un mélange d'information, on dit que le lien entre information et observation est partiel.

Une information exhaustive, exclusive et dont le lien avec l'observation est total et connu serait parfaite, ce qui n'est en général pas le cas, et les différentes méthodes de fusion d'information peuvent s'appliquer en fonction de la satisfaction ou non aux critères présentés. Par exemple, si une information est exhaustive, exclusive et de lien total mais non connu, on dira que l'information est incertaine. D'une autre manière, si une information n'est pas exclusive et que le lien peut ne pas être total, l'information est dite ambiguë.

Ayant défini cela, plusieurs méthodes de fusion peuvent être considérées: probabiliste, floue, crédibiliste ou possibiliste (Tupin et al., 2014).

La fusion **possibiliste**, qui suppose une information incertaine, va par exemple chercher à maximiser des probabilités conditionnelles de l'information par rapport aux différents types d'observation. Elle nécessite donc la mise en place d'une modélisation probabiliste des liens existant entre information et observation (Le Bris and Chehata, 2011).

La fusion **floue**, qui se place dans le contexte d'un lien partiel entre information et observation, modélise le problème en cherchant à déterminer la probabilité que le lien entre une observation donnée et l'information qui peut la décrire soit total. Cette méthode, bien que plus souple que la méthode probabiliste, reste néanmoins compliquée car elle nécessite également la mise en place d'une modélisation du lien existant entre information et observation (Fauvel et al., 2006a; Nemmour and Chibani, 2006; F., 2007; Poulain et al., 2011; Sportouche et al., 2011).

La fusion **crédibiliste**, ou théorie des fonctions de croyance, méthode la plus populaire actuellement, s'applique à des données incertaines dont le lien information/observation est inconnu. L'idée est ici de considérer que le lien est connu sur des sous-ensembles des observations et d'utiliser cette relaxation d'hypothèse afin de discerner l'information là où le lien est considéré comme inconnu (Hegarar-Masclé et al., 2006; André, 2014).

La fusion **possibiliste** peut être utilisée lorsque le lien existant entre information et observation est partiel, et l'information incertaine. Ces méthodes, proches de la fusion floue, décrivent l'information disponible sur des ensembles de segments de l'espace des observations permettant de mieux justifier la prise de décision qu'en prenant en compte l'ensemble des observations d'un seul bloc.

En traitement d'images et plus particulièrement en télédétection, la fusion de décisions se fait sous en comparant les étiquettes pixel à pixel soit pour chaque pixel en comparant les voisinages des deux images (Author et al., 2004). Les probabilités d'appartenance à chaque classe issues du classifieur (cf. Partie 1.2.6) sont souvent privilégiées. Par exemple, les décisions peuvent être fusionnées par des méthodes simples, comme un vote majoritaire (comme dans les FA), par somme ou produit des décisions, par seuillage (Steele, 2000; Liu, 2004), par régression linéaire (Wolpert, 1992), ou encore par *Aggregation Weight-Functional Operators* (AWFO, (Arif, 2006)). Cette dernière méthode prend en compte la distribution générale des données afin de pondérer de manière efficace les différentes classifications. D'autre part, un grand nombre de méthodes s'appuie sur la théorie des ensembles flous. Par exemple, la théorie de l'évidence (Dempster-Shafer, DST) a été utilisée sur des applications variées comme la classification de milieux urbains par imagerie satellitaire THR (IKONOS, (Fauvel et al., 2006a)) ou sur des données SAR (Tupin et al., 1999). Par suite, la théorie de Dezert-Smarandache (DSmT) est une extension de la DST qui en améliore les performances. Elle est utilisée par exemple dans (Corgne, 2004) pour la détection de changements d'occupation du sol.

Parfois, les probabilités même insérées comme entrée d'un nouveau classifieur (Merz and Stolfo, 1998; Mojirshibani, 1999; LeBlanc and Tibshirani, 1996). Un SVM est adopté dans (Waske, 2007) pour la fusion de

données multi-capteurs alors que Ceamanos et al. (2010) l'appliquent sur des données hyperspectrales. Dans cet article, les bandes spectrales sont regroupées par sous-ensembles ayant une forte corrélation, puis une classification est réalisée sur chaque sous-ensemble. Finalement, les classifications sont fusionnées grâce à un nouveau SVM.

Le contexte spatial peut enfin être conservé comme dans (Roussel, 2012) et (Hervieu et al., 2016) où des approches énergétiques fondées sur des CRF ou des coupes de graphe (cf. Partie 1.5) ont été adoptées.

References

- Adeline, K., Chen, M., Briottet, X., Pang, S., and Paparoditis, N. (2013). Shadow detection in very high spatial resolution aerial images: A comparative study. *ISPRS Journal of Photogrammetry and Remote Sensing*, 80:21 – 38. 10
- Adeline, K., Gomez, C., Gorretta, N., and Roger, J. (2014). Sensitivity of soil property prediction obtained from vnir/swir data to spectral configurations. In *Proc. of the 4th International Symposium on Recent Advances in Quantitative Remote Sensing: RAQRS'IV*. 22
- Adler-Golden, S. M., Matthew, M. W., Anderson, G. P., Felde, G. W., and Gardner, J. A. (2002). An algorithm for de-shadowing spectral imagery. *Proc. SPIE, Imaging Spectrometry*, pages 203–210. 11
- Aiazzi, B., Alparone, L., Baronti, S., Garzelli, A., and Selva, M. (2011). 25 years of pansharpening: a critical review and new developments. In Chen, C. H., editor, *Signal and Image Processing for Remote Sensing*, chapter 28, pages 533–548. CRC Press, Boca Raton, FL, 2 edition. 27
- Aiazzi, B., Baronti, S., and Selva, M. (2007). Improving component substitution Pansharpening through multivariate regression of MS+Pan data. *IEEE Transactions on Geoscience and Remote Sensing*, 45(10):3230–3239. 27
- Almeida, M. and Almeida, L. (2012). Nonlinear separation of show-through image mixtures using a physical model trained with ICA. *Signal Processing*, 92(4):872–884. 25
- Alparone, L., Aiazzi, B., Baronti, S., and Garzelli, A. (2015). *Remote Sensing Image Fusion*. Signal and Image Processing of Earth Observations. CRC Press, Boca Raton, FL. 27
- Alparone, L., Wald, L., Chanussot, J., Thomas, C., Gamba, P., and Bruce, L. M. (2007). Comparison of pansharpening algorithms: Outcome of the 2006 GRS-S data fusion contest. *IEEE Transactions on Geoscience and Remote Sensing*, 45(10):3012–3021. 27
- André, C. (2014). *Approche crédibiliste pour la fusion multi capteurs décentralisée*. PhD thesis, Université Paris Sud, France. 29
- Arbalaez, P., Maire, M., Fowlkes, C., and Malik, J. (2011). Contour detection and hierarchical image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 33(5):898–916. 9
- Arbalaez, P., Hariharan, B., Gu, C., Gupta, S., Bourdev, L., and Malik, J. (2012). Semantic segmentation using regions and parts. In *Proc. of CVPR*, pages 3378–3385. 28
- Arif, M., H. S. B. T. V. N. (2006). Awfo (un opérateur d'agrégation) pour la reconnaissance des formes. In *Proc. of RFIA*, pages 31–40. 29
- Ashton, E. A., Wemett, B. D., Leathers, R. A., and Downes, T. V. (2008). A novel method for illumination suppression in hyperspectral images. In *Proc. of SPIE*, volume 6966, pages 69660C–69660C–8. 11
- Atkinson, P., Cutler, M., and Lewis, H. (1997). Mapping sub-pixel proportional landcover with avhrr imagery. *International Journal of Remote Sensing*, 18(4). 3

- Author, P. C. C., Jonckheere, I., Nackaerts, K., Muys, B., and Lambin, E. (2004). Digital change detection methods in ecosystem monitoring: a review. *International Journal of Remote Sensing*, 25(9):1565–1596. 29
- Baatz, M. and Schäpe, A. (2000). *Angewandte Geographische Informationsverarbeitung XII*, chapter Multiresolution segmentation – an optimization approach for high quality multi-scale image segmentation, pages 12–23. Wichmann, Heidelberg. 9
- Bai, X. and Sapiro, G. (2009). Geodesic matting: A framework for fast interactive image and video segmentation and matting. *International Journal of Computer Vision*, 82(2):113–132. 10
- Ball, G. H. and Hall, D. J. (1965). Isodata, a novel method of data analysis and pattern classification. Technical report, DTIC Document. 2
- Ballester, C., Caselles, V., Igual, L., Verdera, J., and Rougé, B. (2006). A variational model for P+XS image fusion. *International Journal of Computer Vision*, 5969(1):43–58. 27
- Barbanson, C., Mallet, C., Gressin, A., Frison, P.-L., and Rudant, J.-P. (2015). Fusion of lidar and radar data for land-cover mapping in natural environments. In *Proc. of IGARSS*, pages 3715–3718. 28
- Baronti, S., Aiazzi, B., Selva, M., Garzelli, A., and Alparone, L. (2011). A theoretical analysis of the effects of aliasing and misregistration on pansharpened imagery. *IEEE JSTSP*, 5(3):446–453. 27
- Bassani, C., Cavalli, R., Cavalcante, F., Cuomo, V., Palombo, A., Pascucci, S., and Pignatti, S. (2007). Deterioration status of asbestos-cement roofing sheets assessed by analyzing hyperspectral data. *Remote Sensing of Environment*, 109:361–378. 12
- Battiti, R. (1994). Using mutual information for selecting features in supervised neural net learning. *IEEE Transactions on Neural Networks*, 5(4). 13, 14, 17
- Belousov, A., Verzakov, S., and Frese, J. (2002). A flexible classification approach with optimal generalisation performance : support vector machines. *Chemometrics and Intelligent Laboratory Systems*, 64(1):15–25. 3
- Ben-Hur, A., Horn, D., Siegelmann, H. T., and Vapnik, V. (2002). Support vector clustering. *The Journal of Machine Learning Research*, 2:125–137. 2
- Benediktsson, J. A., Palmason, J. A., and Sveinsson, J. R. (2005). Classification of hyperspectral data from urban areas based on extended morphological profiles. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3):480–491. 7
- Bernabé, S., Marpu, P. R., and Plaza, A. (2014). Spectral-spatial classification of multispectral images using kernel feature space representation. *IEEE Geoscience and Remote Sensing Letters*, 11(1):288–292. 8
- Bezdek, J. C. (2013). *Pattern recognition with fuzzy objective function algorithms*. Springer Science & Business Media. 2
- Bigdeli, B., Samadzadegan, F., and Reinartz, P. (2013). Band grouping versus band clustering in svm ensemble classification of hyperspectral imagery. *Photogrammetric Engineering & Remote Sensing*, 79(6):523–533. 5, 21
- Bioucas-Dias, J. and Nascimento, J. (2008). Hyperspectral subspace identification. *IEEE Transactions on Geoscience and Remote Sensing*, 46(8):2435–2445. 23
- Bioucas-Dias, J., Plaza, A., Dobigeon, N., Parente, M., Du, Q., Gader, P., and Chanussot, J. (2012). Hyperspectral unmixing overview: Geometrical, statistical, and sparse regression-based approaches. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2):354–379. 23, 24

- Bioucas Dias, J. M., Plaza, A., Dobigeon, N., Parente, M., Du, Q., Gader, P., and Chanussot, J. (2012). Hyperspectral unmixing overview: Geometrical, statistical, and sparse regression-based approaches. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2):354–379. 27
- Bischof, H., Leonardis, A., and Selb, A. (1999). Mdl principle for robust vector quantisation. *Pattern Analysis & Applications*, 2(1):59–72. 2
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer. 1, 3, 12
- Blaschke, T., Hay, G., Kelly, M., Lang, S., Hofmann, P., Addink, E., Feitosa, R., van der Meer, F., van der Werff, H., van Coillie, F., and Tiede, D. (2014). Geographic object-based image analysis â towards a new paradigm. *ISPRS Journal of Photogrammetry and Remote Sensing*, 87:180 – 191. 8
- Boardman, J. W. (1993). Automated spectral unmixing of aviris data using convex geometry concepts. *Proc. 4th JPL Airborne Geoscience Workshop*, pages 11–14. 11
- Borges, J., Bioucas-Dias, J., and Marçal, A. (2006). Fast sparse multinomial regression applied to hyperspectral data. In *Image Analysis and Recognition*, pages 700–709. Springer. 3
- Borghys, D., Shimoni, M., and Perneel, C. (2005). Supervised classification of hyperspectral images using a combination of spectral and spatial information. In *Proc. of the SPIE International Conference on Remote Sensing*. 5
- Boser, B., Guyon, I., and Vapnik, V. (1992). A training algorithm for optimal margin classifier. In *Proceedings of the Annual Workshop on Computational Learning Theory*, pages 144–152, New York, États-Unis. 3
- Boykov, Y., Veksler, O., and Zabih, R. (2001). Fast approximate energy minimization via graph cuts. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23(11):1222–1239. 9
- Braun, A., Weidner, U., and Hinz, S. (2012). Classification in high-dimensional feature spaces - assessment using SVM, IVM and RVM with focus on simulated EnMap data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2):436–443. 3
- Breen, E. J. and Jones, R. (2013). Attribute openings, thinnings and granulometries. *IEEE Transactions on Geoscience and Remote Sensing*, 40(11):2486–2494. 7
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1):5–32. 3, 15, 17
- Breiman, L., Friedman, J., Stone, C., and Olshen, R. (1984). *Classification and regression trees*. CRC press. 3, 17
- Bruce, L. (2014). Game theory models for spectral band grouping and classifier ensembles for hyperspectral image classification. In *Proc. of WHISPERS*. 5
- Bruzzzone, L. and Serpico, S. B. (2000). A technique for feature selection in multiclass problem. *International Journal of Remote Sensing*, 21(3):549–563. 13, 17
- Burt, P. J. and Adelson, E. H. (1983). The Laplacian pyramid as a compact image code. *IEEE COM*, 31(4):532–540. 27
- Cai, D., He, X., and Han, J. (2007). Semi-supervised discriminant analysis. In *Proc. of ICCV*. 20
- Campedel, M., Maître, H., and Moulines, E. (2004). Indexation des images satellitaires - comparaison et évaluation des caractéristiques pour la classification. Technical report, Télécom Paris, Paris, France. 14, 17
- Camps-Valls, G., Bandos Marsheva, T., and Zhou, D. (2007). Semi-supervised graph-based hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 45(10):3044–3054. 3, 6

- Camps-Valls, G. and Bruzzone, L. (2005). Kernel-based methods for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 43(6):1351–1362. 3, 5, 12
- Camps-Valls, G. and Bruzzone, L. (2009). *Kernel Methods for Remote Sensing Data Analysis*. Wiley, Hoboken, États-Unis. 3
- Camps-Valls, G., Gomez-Chova, L., Munoz-Mari, J., Vila-Frances, J., and Calpe-Maravilla, J. (2006). Composite kernels for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 3(1):93–97. 5
- Cang, S. and Hongnian, Y. (2012). Mutual information based input feature selection for classification problems. *Decision Support Systems*, 54:691–698. 13, 14, 17
- Cariou, C., Chehdi, K., and Le Moan, S. (2011). BandClust: an unsupervised band reduction method for hyperspectral remote sensing. *IEEE Geoscience and Remote Sensing Letters*, 8(3):565–569. 22
- Carper, W., Lillesand, T. M., and Kiefer, P. W. (1990). The use of intensity-hue-saturation transformations for merging SPOT panchromatic and multispectral image data. *Photogrammetric Engineering & Remote Sensing*, 56(4):459–467. 27
- Cawse-Nicholson, K., Damelin, S., Robin, A., and Sears, M. (2013). Determining the intrinsic dimension of a hyperspectral image using random matrix theory. *IEEE Transactions on Image Processing*, 22(4):1301–1310. 23
- Ceamanos, X., Waske, B., Benediktsson, J. A., Chanussot, J., Fauvel, M., and Sveinsson, J. R. (2010). A classifier ensemble based on fusion of support vector machines for classifying hyperspectral data. *International Journal of Image and Data Fusion*, 1(4):293–307. 5, 29
- Chang, C. (2000). An information-theoretic approach to spectral variability, similarity and discrimination for hyperspectral image analysis. *IEEE Transactions on Information Theory*, 46(15):1927–1932. 4
- Chang, C.-I., Du, Q., Sun, T.-L., and Althouse, M. (1999). A joint band prioritization and band-decorrelation approach to band selection for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 37(6):2631–2641. 13, 17
- Chang, C.-I. and Wang, S. (2006). Constrained band selection for hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 44(6):1575–1585. 13, 17
- Chang, Y.-L., Chen, K.-S., Huang, B., Chang, W.-Y., Benediktsson, J., and Chang, L. (2011). A parallel simulated annealing approach to band selection for high-dimensional remote sensing images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 4(3):579–590. 19, 21
- Chavez, P. S. and Kwarteng, A. Y. (1989). Extracting spectral contrast in landsat thematic mapper image data using selective principal component analysis. *Photogrammetric Engineering & Remote Sensing*, 55(3):339–348. 27
- Chavez Jr., P. S., Sides, S. C., and Anderson, J. A. (1991). Comparison of three different methods to merge multiresolution and multispectral data: Landsat TM and SPOT panchromatic. *Photogrammetric Engineering & Remote Sensing*, 57(3):295–303. 27
- Chen, L., Papandreou, G., Kokkinos, I., Murphy, K., and Yuille, A. (2015). Semantic Image Segmentation with Deep Convolutional Nets and Fully Connected CRFs. In *Proc. of ICLR*. 10
- Chen, Y., Su, W., Li, J., and Sun, Z. (2009). Hierarchical object oriented classification using very high resolution imagery and LIDAR data over urban areas. *Advances in Space Research*, 43(7):1101 – 1110. 11
- Chen, Y., Wen, D., Jing, L., and Shi, P. (2007). Shadow information recovery in urban areas from very high resolution satellite imagery. *International Journal of Remote Sensing*, 28(15):3249–3254. 11

- Cheung-Wai Chan, J. and Paelinckx, D. (2008). Evaluation of random forest and adaboost tree-based ensemble classification and spectral band selection for ecotope mapping using airborne hyperspectral imagery. *Remote Sensing of Environment*, 112:2999–3011. 3
- Chiang, J.-L., Liou, J.-J., Wei, C., and Cheng, K.-S. (2014). A feature-space indicator kriging approach for remote sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 52(7):4046–4055. 3, 6
- Chung, K.-L., Lin, Y.-R., and Huang, Y.-H. (2009). Efficient shadow detection of color aerial images based on successive thresholding scheme. *IEEE Transactions on Geoscience and Remote Sensing*, 47(2):671–682. 11
- Clark, R., Swayze, G., Gallagher, A., Gorelick, N., and Kruse, F. (1992). Mapping with imaging spectrometer data using the complete band shape least-squares algorithm simultaneously fit to multiple spectral features from multiple materials. In *Summaries of the Third Annual JPL Airborne Geoscience Workshop : JPL Publication 92-14, Vol 1*, pages 11–13. 4
- Clark, R. N., Swayze, G. A., Livo, K. E., Kokaly, R. F., Sutley, S. J. ., Dalton, J. B., McDougal, R. R., and Gent, C. A. (2003). Imaging spectroscopy: Earth and planetary remote sensing with the usgs tetracorder and expert systems. *Journal of Geophysical Research*, 108(E12):5–1–5–44. 4, 12
- Comaniciu, D. and Meer, P. (2002). Mean shift: a robust approach toward feature space analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(5):603–619. 9
- Corgne, S., H.-M. L. D. J. M. G. (2004). *Advances and Applications of DSMT for Information Fusion*, chapter Land cover change prediction with a new theory of plausible and paradoxical reasoning. Am. Res. Press, Rehoboth, États-Unis. 29
- Cortes, C. and Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3):273–297. 3
- Courty, N., Flamary, R., Rakotomamonjy, A., and Tuia, D. (2014). Optimal transport for domain adaptation. In *NIPS, Workshop on Optimal Transport and Machine Learning*. 7
- Criminisi, A., Sharp, T., and Blake, A. (2008). Geos: Geodesic image segmentation. In *Proc. of ECCV*, volume 5302 of *Lecture Notes in Computer Science*, pages 99–112. Springer. 10
- Criminisi, A. and Shotton, J. (2013). *Decision forests for computer vision and medical image analysis*. Springer-Verlag, London, UK. 3
- Dalla Mura, M., Benediktsson, J. A., Waske, B., and Bruzzone, L. (2010a). Extended profiles with morphological attribute filters for the analysis of hyperspectral data. *International Journal of Remote Sensing*, 31(22):5975–5991. 7, 8
- Dalla Mura, M., Benediktsson, J. A., Waske, B., and Bruzzone, L. (2010b). Morphological attribute profiles for the analysis of very high resolution images. *IEEE Transactions on Geoscience and Remote Sensing*, 48(10):3747–3762. 7
- Dalla Mura, M., Villa, A., Benediktsson, J. A., Chanussot, J., and Bruzzone, L. (2010c). Classification of hyperspectral images by using extended morphological attribute profiles and independent component analysis. *IEEE Geoscience and Remote Sensing Letters*, 8(3):541–545. 8
- Dare, P. M. (2005). Shadow analysis in high-resolution satellite imagery of urban areas. *Photogrammetric Engineering & Remote Sensing*, 71(2):169–177. 11
- De Backer, S., Kempeneers, P., Debruyne, W., and Scheunders, P. (2005). A band selection technique for spectral classification. *IEEE Geoscience and Remote Sensing Letters*, 2(3):319–232. 13, 17, 19, 21

- Dell'Acqua, F., Gamba, P., Ferrari, A., Palmason, J., Benediktsson, J. A., and Arnason, K. (2004). Exploiting spectral and spatial information in hyperspectral urban data with high resolution. *IEEE Geoscience and Remote Sensing Letters*, 1(4):322–326. 5
- Demir, B., Celebi, A., and Ertürk, S. (2009). A low-complexity approach for the color display of hyperspectral remote-sensing images using one-bit-transform-based band selection. *IEEE Transactions on Geoscience and Remote Sensing*, 47(1):97–105. 12
- Dempster, A. P., Laird, N. M., and Rubin, D. B. (1977). Maximum likelihood from incomplete data via the em algorithm. *Journal of the royal statistical society. Series B (methodological)*, pages 1–38. 2
- Deville, Y. and Duarte, L. T. (2015). An overview of blind source separation methods for linear-quadratic and post-nonlinear mixtures. In *Proc. of the 12th International Conference on Latent Variable Analysis and Signal Separation (LVA/ICA 2015)*. LNCS 9237, pages 155–167, Liberec, Czech Republic. Available on-line at http://userpages.irap.omp.eu/~ydeville/papers/yddd_LVA2015_overview.pdf. 23, 26
- Deville, Y. and Hosseini, S. (2007). Blind identification and separation methods for linear-quadratic mixtures and/or linearly independent non-stationary signals. In *Proc. of ISSPA*, Sharjah, United Arab Emirates. 26
- Díaz-Uriarte, R. and De Andres, S. A. (2006). Gene selection and classification of microarray data using random forest. *BMC bioinformatics*, 7(3):1–13. 14, 17
- Diday, E. (1971). Une nouvelle méthode en classification automatique et reconnaissance des formes la méthode des nuées dynamiques. *Revue de statistique appliquée*, 19(2):19–33. 2
- Do, M. N. and Vetterli, M. (2005). The contourlet transform: an efficient directional multiresolution image representation. *IEEE Transactions on Image Processing*, 14(12):2091–2106. 27
- Du, H., Qi, H., Wang, X., Ramanath, R., and Snyder, W. (2003). Band selection using independent component analysis for hyperspectral image processing. In *Proceedings of the 32nd Applied Imagery Pattern Recognition Workshop*, pages 93–98. 13, 17
- Du, P., Liu, S., Xia, J., and Zhao, Y. (2013). Information fusion techniques for change detection from multi-temporal remote sensing images. *Information Fusion*, 14(1):19 – 27. 28
- Du, Q. and Yang, H. (2008). Similarity-based unsupervised band selection for hyperspectral image analysis. *IEEE Geoscience and Remote Sensing Letters*, 5(4):564–568. 14, 17
- Du, Y., Chang, C.-I., Ren, H., Chang, C.-C., Jensen, J. O., and D'Amico, F. M. (2004). New hyperspectral discrimination measure for spectral characterization. *Optical Engineering*, 43(8):1777–1786. 4
- Duarte, L. T., Ando, R., Attux, R., Deville, Y., and Jutten, C. (2012). Separation of sparse signals in overdetermined linear-quadratic mixtures. In *Proc. of the 12th International Conference on Latent Variable Analysis and Signal Separation (LVA/ICA 2012)*, pages 239–246, Tel-Aviv, Israel. 26
- Eches, O., Dobigeon, N., Mailhes, C., and Tourneret, J.-Y. (2010). Bayesian estimation of linear mixtures using the normal compositional model. application to hyperspectral imagery. *IEEE Transactions on Image Processing*, 19(6):1403–1413. 24
- Eches, O. and Guillaume, M. (2014). A bilinear-bilinear nonnegative matrix factorization method for hyperspectral unmixing. *IEEE Geoscience and Remote Sensing Letters*, 11(4):778–782. 23, 26
- Estévez, P. A., Tesmer, M., Perez, C. A., and Zurada, J. M. (2009). Normalized mutual information feature selection. *IEEE Transactions on Neural Networks*, 20(2):189–201. 13, 14, 16, 17, 19

- F., R. (2007). Building change detection from digital surface models and multi-spectral images. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences (IAPRS)*, 36(3/W49B): 28, 29
- Fauvel, M. (2007). *Spectral and spatial methods for the classification of urban remote sensing data*. PhD thesis, Institut National Polytechnique de Grenoble, Grenoble, France. 5, 20
- Fauvel, M. (2012). Kernel matrix approximation for learning the kernel hyperparameters. In *Proc. of IGARSS*, pages 5418–5421. 3, 5
- Fauvel, M., Chanussot, J., and Benediktsson, J. (2006a). Decision fusion for the classification of urban remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 44(10):2828–2838. 29
- Fauvel, M., Chanussot, J., and Benediktsson, J. A. (2006b). Decision fusion for the classification of urban remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 44(10):2828–2838. 5
- Fauvel, M., Chanussot, J., and Benediktsson, J. A. (2009). Kernel principal component analysis for the classification of hyperspectral remote-sensing data over urban areas. *EURASIP Journal on Advances in Signal Processing*, 2009:1–14. 20
- Fauvel, M., Chanussot, J., and Benediktsson, J. A. (2012a). A spatial-spectral kernel based approach for the classification of remote sensing images. *Pattern Recognition*, 45(4):281–392. 3, 5
- Fauvel, M., Tarabalka, Y., Benediktsson, J. A., Chanussot, J., and Tilton, J. C. (2012b). Advances in spectral-spatial classification of hyperspectral images. *Proceedings of the IEEE*, 101(3):652–675. 5
- Fauvel, M., Zullo, A., and Ferraty, F. (2014). Nonlinear parsimonious feature selection for the classification of hyperspectral images. In *Proc. of WHISPERS*. 3, 14, 17
- Felzenszwalb, P. and Huttenlocher, D. (2006). Efficient belief propagation for early vision. *International Journal of Computer Vision*, 70(1):41–54. 9
- Finlayson, G., Drew, M., and Lu, C. (2009). Entropy minimization for shadow removal. *International Journal of Computer Vision*, 85(1):35–57. 11
- Finlayson, G., Hordley, S., Lu, C., and Drew, M. (2006). On the removal of shadows from images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 28(1):59–68. 11
- Fisher, R. (1936). The use of multiple measurements in taxonomic problems. *Annals of Eugenics*, 7(2):179–188. 13, 20
- Frey, B. J. and Dueck, D. (2007). Clustering by passing messages between data points. *science*, 315(5814):972–976. 2
- Fröhlich, H., Chapelle, O., and Schölkopf, B. (2003). Feature selection for support vector machines by means of genetic algorithms. In *Proc. of the 15th IEEE International Conference on Tools with Artificial Intelligence*, pages 142–148. 15, 17, 19
- Fu, A. and Yan, H. (1997). A new probabilistic relaxation method based on probability space partition. *Pattern Recognition*, 30(11):1905–1917. 9
- Fu, W., Li, S., and Fang, L. (2015). Spectral-spatial hyperspectral image classification via superpixel merging and sparse representation. In *Proc. of IGARSS*, pages 4971–4974. 9
- Garzelli, A., Aiazzi, B., Baronti, S., Selva, M., , and Alparone, L. (2010). Hyperspectral image fusion. In *Proc. of Hyperspectral Workshop*, pages 17–19. 27
- Genuer, R. (2010). *Forêts aléatoires : aspects théoriques, sélection de variables et applications*. PhD thesis, Université Paris-Sud 11, Paris, France. 3

- Genuer, R., Poggi, J.-M., and Tuleau-Malot, C. (2010). Variable selection using random forests. *Pattern Recognition Letters*, 31:2225–2236. 15
- Ghamisi, P., Benediktsson, J. A., Cavallaro, G., and Plaza, A. (2014a). Automatic framework for spectral-spatial classification based on supervised feature extraction and morphological attribute profiles. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6):2147–2160. 8
- Ghamisi, P., Benediktsson, J. A., and Sveinsson, J. R. (2014b). Automatic spectral-spatial classification framework based on attribute profiles and supervised feature extraction. *IEEE Transactions on Geoscience and Remote Sensing*, 52(5):342–346. 8
- Ghamisi, P., Dalla Mura, M., and Benediktsson, J. (2015). A survey on spectral&spatial classification techniques based on attribute profiles. *IEEE Transactions on Geoscience and Remote Sensing*, 53(5):2335–2353. 8
- Ghariani, K., Chehata, N., Le Bris, A., and Lagacherie, P. (2014). Agricultural field delimitation using active learning and random forests margin. In *Proc. of IGARSS*. 6
- Gong, P. and Howarth, P. (1989). Performance analyses of probabilistic relaxation methods for land-cover classification. *Remote Sensing of Environment*, 30(1):33–42. 9
- Green, A., Berman, M., Switzer, P., and Craig, M. (1988). A transformation for ordering multispectral data in terms of image quality with implications for noise removal. *IEEE Transactions on Geoscience and Remote Sensing*, 26(1):65–74. 20
- Gressin, A. (2014). *Détection de changement dans une base de données 2D d'occupation du sol à grande échelle en milieux naturels*. PhD thesis, Université Paris V - René Descartes, France. 1
- Gu, Y., Wang, C., Jia, X., and Benediktsson, J. (2015). A novel MKL model of integrating LiDAR data and MSI for urban area classification. *IEEE Transactions on Geoscience and Remote Sensing*, 53(10):5312–5325. 5
- Gu, Y., Wang, C., You, D., Zhang, Y., Wang, S., and Zhang, Y. (2012). Representative multiple kernel learning for classification in hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 50(7):2852–2865. 5
- Guigues, L., Cocquerez, J., and Le Men, H. (2006). Scale sets analysis. *International Journal of Computer Vision*, 68(3):289–317. 9
- Guo, B., Damper, R., Gunn, S., and Nelson, J. (2008). A fast separability-based feature-selection method for high-dimensional remotely sensed image classification. *Pattern Recognition*, 41:1653–1662. 13, 14, 17
- Guo, L., Chehata, N., Mallet, C., and Boukir, S. (2011). Relevance of airborne lidar and multispectral image data for urban scene classification using random forests. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(1):56–66. 28
- Guyon, I., Weston, J., Barnhill, S., and Vapnik, V. (2002). Gene selection for cancer classification using support vector machines. *Machine Learning*, 46:289–422. 15, 17
- Hall, M. A. and Holmes, G. (2003). Benchmarking attribute selection techniques for discrete class data mining. *IEEE Transactions on Knowledge and Data Engineering*, 15(6):1437–1447. 13, 17
- Hamerly, G. and Elkan, C. (2003). Learning the K in K-Means. In *Proc. of NIPS*. 2
- Hasanlou, M. and Samadzadegan, F. (2010). ICA/PCA base geneticly band selection for classification of hyperspectral images. In *Proc. of the Asian Conference on Remote Sensing (ACRS)*. 13, 17

- He, X., Condat, L., Bioucas Dias, J., Chanussot, J., and Xia, J. (2014). A new pansharpening method based on spatial and spectral sparsity priors. *IEEE Transactions on Image Processing*, 23(9):4160–4174. 27
- Hegar-Masclé, S. L., Seltz, R., Hubert-Moy, L., Corgne, S., and Stach, N. (2006). Performance of change detection using remotely sensed data and evidential fusion: comparison of three cases of application. *International Journal of Remote Sensing*, 27:3515–3532. 29
- Heiden, U., Segl, K., Roessner, S., and Kaufmann, H. (2007). Determination of robust spectral features for identification of urban surface materials in hyperspectral remote sensing data. *Remote Sensing of Environment*, 111(4):537 – 552. 4, 12
- Heinz, D. and Chang, C.-I. (2001). Fully constrained least squares linear spectral mixture analysis method for material quantification in hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 39(3):529–545. 24
- Herold, M., Gardner, M. E., and Roberts, D. A. (2003). Spectral resolution requirements for mapping urban areas. *IEEE Transactions on Geoscience and Remote Sensing*, 41(9):1907–1919. 13, 17
- Hervieu, A., Le Bris, A., and Mallet, C. (2016). Fusion of multispectral and hyperspectral aerial image classifications in urban areas. *Submitted to ISPRS Congress*. 29
- Ho, T. (1998). The random subspace method for constructing decision forests. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(8):832–844. 5
- Homayouni, S. (2005). *Caractérisation des scènes urbaines par analyse des images hyperspectrales*. PhD thesis, Ecole Nationale des Télécommunications de Paris, France. 20
- Hsu, C., Chang, C., and Lin, C. (2003). A practical guide to support vector classification. Technical report, Department of Computer Science, National Taiwan University, Taiwan. 5
- Hu, F., Xia, G., Hu, J., and Zhang, L. (2015). Transferring deep convolutional neural networks for the scene classification of high-resolution remote sensing imagery. *Remote Sensing*, 7(11):14680–14707. 3
- Huang, H., Liu, J., and Pan, Y. (2012). Semi-supervised marginal Fisher analysis for hyperspectral image-classification. *International Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, I(3):377–382. 20
- Huang, J., Xie, W., and Tang, L. (2004). Detection of and compensation for shadows in colored urban aerial images. In *Proc. of WCICA*, volume 4, pages 3098–3100 Vol.4. 11
- Huang, X., Guan, X., Benediktsson, J. A., Zhang, L., Li, J., Plaza, A., and Dalla Mura, M. (2014). Multiple morphological profiles from multicomponent base images for hyperspectral image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(12):1939–1404. 8
- Hughes, G. (1968). On the mean accuracy of statistical pattern recognizers. *IEEE Transactions on Information Theory*, 14(1):55–63. 3, 12
- Huo, L., Tang, P., Zhang, Z., and Tuia, D. (2015). Semisupervised classification of remote sensing images with hierarchical spatial similarity. *IEEE Transactions on Geoscience and Remote Sensing*, 12(1):150–154. 6
- Hussain, M., Chen, D., Cheng, A., Wei, H., and Stanley, D. (2013). Change detection from remotely sensed images: From pixel-based to object-based approaches. *ISPRS Journal of Photogrammetry and Remote Sensing*, 80:91 – 106. 1
- Hyvärinen, A. and Oja, E. (2000). Independent component analysis: algorithms and applications. *Neural networks*, 13(4):411–430. 20

- Iordache, M.-D., Bioucas-Dias, J., and Plaza, A. (2011). Sparse unmixing of hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 49(6):2014–2039. 24
- Jarboui, L., Hosseini, S., Deville, Y., Guidara, R., and Hamida, A. B. (2014). A new unsupervised method for hyperspectral image unmixing using a linear-quadratic model. In *Proc. of ATSIIP 2014*, pages 423–428, Sousse, Tunisia. 23, 26
- Jensen, A.-C. and Solberg, A.-S. (2007). Fast hyperspectral feature reduction using piecewise constant function approximations. *IEEE Geoscience and Remote Sensing Letters*, 4(4):547–551. 22
- Jia, S., Ji, Z., Qian, Y., and Shen, L. (2012). Unsupervised band selection for hyperspectral imagery classification without manual band removal. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2):531–543. 19, 21
- Jia, X. and Richards, J. (1999). Segmented principal components transformation for efficient hyperspectral remote-sensing image display and classification. *IEEE Transactions on Geoscience and Remote Sensing*, 37(1):538–542. 19
- Joshi, A. J., Porikli, F., and Papanikolopoulos, N. (2009). Multi-class active learning for image classification. In *Proc. of CVPR*, pages 2372–2379. 6
- Jun, G. and Ghosh, D. (2013). Semisupervised learning of hyperspectral data with unknown land-cover classes. *IEEE Transactions on Geoscience and Remote Sensing*, 51(1):273–282. 6
- Jutten, C. and Herault, J. (1991). Blind separation of sources, part i: An adaptive algorithm based on neuromimetic architecture. *Signal processing*, 24(1):1–10. 20
- Kaasalainen, S., Holopainen, M., Karjalainen, M., Vastaranta, M., Kankare, V., Karila, K., and Osmanoglu, B. (2015). Combining lidar and synthetic aperture radar data to estimate forest biomass: Status and prospects. *Forests*, 6(1):252. 28
- Kandasamy, S., Minghelli-Roman, A., Tavin, F., Mathieu, S., Baret, F., and Gouton, P. (2009a). Optimal band selection for future satellite sensor dedicated to soil science. In *Proc. of WHISPERS*, pages 1–4. 13
- Kandasamy, S., Tavin, F., Minghelli-Roman, A., Mathieu, S., Weidong, L., Baret, F., and Gouton, P. (2009b). Optimization of image parameters using a hyperspectral library application to soil identification and moisture estimation. In *Proc. of IGARSS*, volume 3, pages 141–144. 13, 14
- Kappes, J. H., Andres, B., Hamprecht, F. A., Schnörr, C., Nowozin, S., Batra, D., Kim, S., Kausler, B. X., Kröger, T., Lellmann, J., Komodakis, N., Savchynskyy, B., and Rother, C. (2015). A comparative study of modern inference techniques for structured discrete energy minimization problems. *International Journal of Computer Vision*, 115(2):155–184. 9
- Kavzoglu, T. and Mather, P. (2003). The use of backpropagating artificial neural networks in land cover classification. *International Journal of Remote Sensing*, 24(23):4907–4938. 3
- Keshava, N. (2002). Distance metrics and band selection in hyperspectral processing with applications to material identification and spectral libraries. Technical report, Lincoln Laboratory - Massachusetts Institute of Technology, United States. 17
- Kira, K. and Rendell, L. (1992). A practical approach to feature selection. In *Proc. of ICML*, pages 249–256. 13, 17
- Kohli, P., Ladick \tilde{A} $\frac{1}{2}$, L., and Torr, P. (2009). Robust higher order potentials for enforcing label consistency. *International Journal of Computer Vision*, 82(3):302–324. 10
- Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. *Biological cybernetics*, 43(1):59–69. 2

- Kolmogorov, V. (2006). Convergent tree-reweighted message passing for energy minimization. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 28(10):1568–1583. 9
- Kononenko, I., Simec, E., and Robnik-Sikonja, M. (1997). Overcoming the myopia of inductive learning algorithms with relief. *Applied Intelligence*, 7(1):39–55. 13, 17
- Krähenbühl, P. and Koltun, V. (2011). Efficient inference in fully connected CRFs with Gaussian edge potentials. In *Proc. of NIPS*, pages 109–117. 10
- Kumar, S. and Hebert, M. (2006). Discriminative random fields. *International Journal of Computer Vision*, 68(2):179–201. 10
- Kuo, B.-C. and Landgrebe, D. (2004). Nonparametric weighted feature extraction for classification. *IEEE Transactions on Geoscience and Remote Sensing*, 42(5):1096–1105. 20
- Kuo, B.-C., Li, C.-H., and Yang, J.-M. (2009). Kernel nonparametric weighted feature extraction for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 47(4):1139–1155. 20
- Laben, C. and Brower, B. (2000). Process for enhancing the spatial resolution of multispectral imagery using pan-sharpening. 27
- Ladicky, L., Russell, C., Kohli, P., and Torr, P. (2014). Associative hierarchical random fields. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 36(6):1056–1077. 10
- Ladický, L., Sturges, P., Alahari, K., Russell, C., and Torr, P. (2010). What, where and how many? combining object detectors and CRFs. In *Proc. of ECCV*, pages 424–437. Springer Berlin Heidelberg. 28
- Lafferty, J. D., McCallum, A., and Pereira, F. (2001). Conditional random fields: Probabilistic models for segmenting and labeling sequence data. In *Proc. of ICML*, pages 282–289, San Francisco, CA, USA. Morgan Kaufmann Publishers Inc. 10
- Lalonde, J.-F., Efros, A. A., and Narasimhan, S. G. (2010). Detecting ground shadows in outdoor consumer photographs. In *ECCV*, volume 6312 of *Lecture Notes in Computer Science*, pages 322–335. Springer Berlin Heidelberg. 11
- Laporterie-Déjean, F., de Boissezon, H., Flouzat, G., and Lefèvre-Fonollosa, M.-J. (2005). Thematical and statistical evaluations of five panchromatic/multispectral fusion methods on simulated PLEIADES-HR image. *Information Fusion*, 6:193–212. 27
- Larsen, R. (2002). Decomposition using maximum autocorrelation factors. *Journal of Chemometrics*, 16(8-10):427–435. 19
- Le Bris, A. and Chehata, N. (2011). Change detection in a topographic building database using submetric satellite images. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 38(3/W22):25–30. 29
- Le Bris, A., Chehata, N., Briottet, X., and Paparoditis, N. (2015). Extraction of optimal spectral bands using hierarchical band merging out of hyperspectral data. *ISPRS Annals of Photogrammetry, Remote Sensing and the Spatial Information Sciences*, XL-3/W3:459–465. 22
- Le Cun, Y., Bottou, L., Orr, G. B., and Muller, K.-R. (1998). *Neural Networks—Tricks of the Trade*, Springer Lecture Notes in Computer Sciences, volume 1524, chapter Efficient backprop, pages 5–50. Springer. 3
- Le Moan, S., Mansouri, A., Voisin, Y., and Hardeberg, J. (2011). A constrained band selection method based on information measures for spectral image color visualization. *IEEE Transactions on Geoscience and Remote Sensing*, 49(12):5104–5115. 12, 13, 14, 17

- LeBlanc, M. and Tibshirani, R. (1996). Combining estimates in regression and classification. *Journal of the American Statistical Association*, 91(436):1641–1650. 29
- Lee, C. and Landgrebe, D. (1993). Feature extraction based on decision boundaries. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 15(4):388–400. 20
- Lee, J. B., Berman, M., et al. (1990). Enhancement of high spectral resolution remote-sensing data by a noise-adjusted principal components transform. *IEEE Transactions on Geoscience and Remote Sensing*, 28(3):295–304. 19
- Lennon, M., Mercier, G., Mouchot, M.-C., and Hubert-Moy, L. (2001). Independent component analysis as a tool for the dimensionality reduction and the representation of hyperspectral images. In *Proc. of IGARSS*, pages 2893–2895. 20
- Levine, M. D. and Bhattacharyya, J. (2005). Removing shadows. *Pattern Recognition Letters*, 26(3):251–265. 11
- Li, C.-H., Ho, H.-H., Liu, Y.-L., Lin, C.-T., Kuo, B.-C., and Taur, J.-S. (2012). An automatic method for selecting the parameter of the normalized kernel function to support vector machines. *Journal of Information Science and Engineering*, 28:1–15. 5
- Li, F., Xu, L., Siva, P., Wong, A., and Clausi, D. (2015). Hyperspectral image classification with limited labeled training samples using enhanced ensemble learning and conditional random fields. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(6):2427–2438. 10
- Li, J. and Bioucas-Dias, J. (2008). Minimum volume simplex analysis: A fast algorithm to unmix hyperspectral data. In *Proc. of IGARSS*, volume 3, pages 250–253. 24
- Li, J., Bioucas-Dias, J., and Plaza, A. (2013). Semisupervised hyperspectral image classification using soft sparse multinomial logistic regression. *IEEE Geoscience and Remote Sensing Letters*, 10(2):318–322. 6
- Li, J., Zhang, H., Zhang, L., Huang, X., and Zhang, L. (2014). Joint collaborative representation with multitask learning for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 52(9):5923–5936. 3
- Li, S., Wu, H., Wan, D., and Zhu, J. (2011). An effective feature selection method for hyperspectral image classification based on genetic algorithm and support vector machine. *Knowledge-based Systems*, 24:40–48. 3, 14, 16, 17, 19, 21
- Liao, W., Huang, X., Coillie, F., Gautama, S., Pizurica, A., Philips, W., Liu, H., Zhu, T., Shimoni, M., Moser, G., and Tuia, D. (2015). Processing of multiresolution thermal hyperspectral and digital color data: Outcome of the 2014 IEEE GRSS data fusion contest. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 27
- Licciardi, G. A., Villa, A., Khan, M. M., and Chanussot, J. (2012). Image fusion and spectral unmixing of hyperspectral images for spatial improvement of classification maps. In *Proc. of IGARSS*, pages 7290–729. 27
- Lin, G., Shen, C., Reid, I. D., and van den Hengel, A. (2015). Efficient piecewise training of deep structured models for semantic segmentation. *CoRR*, abs/1504.01013. 10
- Liu, W., G. S. W. C. (2004). Uncertainty and confidence in land cover classification using a hybrid classifier approach. *Photogrammetric Engineering & Remote Sensing*, 70(8):963–972. 29
- Liu, Q. and Wang, W. (2013). Show-through removal for scanned images using non-linear nmf with adaptive smoothing. In *Proc. of ChinaSIP*, pages 650–654, Beijing, China. 26

- Liu, X. and Bo, Y. (2015). Object-based crop species classification based on the combination of airborne hyperspectral images and lidar data. *Remote Sensing*, 7(1):922. 9
- Loncan, L., Fabre, S., Almeida, L., Bioucas-Dias, J., Liao, W., Briottet, X., Licciardi, G., Chanussot, J., Simões, M., Dobigeon, N., Tourneret, J.-Y., Veganzones, M., Wei, Q., Vivone, G., and Yokoya, N. (2015). Hyperspectral pansharpening: A review. *IEEE Geoscience and Remote Sensing Magazine*, 3(3):27–46. 28
- Lu, D., Mausel, P., Brondízio, E., and Moran, E. (2004). Change detection techniques. *International Journal of Remote Sensing*, 25(12):2365–2401. 1
- Ma, S. and Huang, J. (2008). Penalized feature selection and classification in bioinformatics. *Briefings in bioinformatics*, 8(5):392–403. 14, 17
- MacQueen, J. et al. (1967). Some methods for classification and analysis of multivariate observations. In *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*, volume 1, pages 281–297. Oakland, CA, USA. 2
- Maire, M., Yu, S. X., and Perona, P. (2011). Object detection and segmentation from joint embedding of parts and pixels. In *Proc. of ICCV*. 28
- Makarau, A., Richter, R., Muller, R., and Reinartz, P. (2011). Adaptive shadow detection using a blackbody radiator model. *IEEE Transactions on Geoscience and Remote Sensing*, 49(6):2049–2059. 11
- Mallat, S. (1989). A theory for multiresolution signal decomposition: the wavelet representation. *IEEE TPAMI*, 11(7):674–693. 27
- Marpu, P. R., Pedergrana, M., Dalla Mura, M., Peeters, S., Benediktsson, J. A., and Bruzzone, L. (2012). Classification of hyperspectral data using extended attribute profiles based on supervised and unsupervised feature extraction techniques. *International Journal of Image and Data Fusion*, pages 1–30. 8
- Martel-Brisson, N. and Zaccarin, A. (2005). Moving cast shadow detection from a gaussian mixture shadow model. In *Proc. of CVPR*, volume 2, pages 643–648 vol. 2. 11
- Martínez-Usó, A., Pla, F., Martínez Sotoca, J., and García-Sevilla, P. (2007). Clustering-based hyperspectral band selection using information measures. *IEEE Transactions on Geoscience and Remote Sensing*, 45(12):4158–4171. 13, 14, 17, 19, 21
- Massalabi, A., He, D. C., Benie, G. B., and Beaudry, E. (2004). Restitution of information under shadow in remote sensing high space resolution images: application to ikonos data of sherbrooke city. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science 35 (Part B3)*, pages 173–178. 11
- Massoudifar, P., Rangarajan, A., and Gader, P. (2014). Superpixel estimation for hyperspectral imagery. In *IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, pages 287–292. 9
- Matasci, G., Volpi, M., Kanevski, M., Bruzzone, L., and Tuia, D. (2015). Semisupervised transfer component analysis for domain adaptation in remote sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 53(7):3550–3564. 7
- Mathieu, R., Aryal, J., and Chong, A. (2007). Object-based classification of ikonos imagery for mapping large-scale vegetation communities in urban areas. *Sensors*, 7(11):2860–2880. 9
- Meganem, I., Déliot, P., Briottet, X., Deville, Y., and Hosseini, S. (2011a). Physical modelling and non-linear unmixing method for urban hyperspectral images. In *Proc. of WHISPERS*, pages 650–654, Lisbon, Portugal. 23, 26

- Meganem, I., Déliot, P., X.Briottet, Deville, Y., and Hosseini, S. (2014a). Linear-quadratic mixing model for reflectances in urban environments. *IEEE Transactions on Geoscience and Remote Sensing*, 52(1):544–558. 22, 23
- Meganem, I., Deville, Y., Hosseini, S., Déliot, P., Briottet, X., and Duarte, L. (2011b). Linear-quadratic and polynomial non-negative matrix factorization; application to spectral unmixing. In *Proc. of EUSIPCO*, pages 1859–1863, Barcelona, Spain. 23, 26
- Meganem, I., Deville, Y., Hosseini, S., Déliot, P., and X.Briottet (2014b). Linear-quadratic blind source separation using nmf to unmix urban hyperspectral images. *IEEE Transactions on Signal Processing*, 62(7):1822–1833. 23, 25, 26
- Melgani, F. and Bruzzone, L. (2004). Classification of hyperspectral remote sensing images with Support Vector Machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42(8):1778–1790. 3, 5, 12
- Mende, A., Heiden, U., Bachmann, M., Hoja, D., and Buchroithner, M. (2011). Development of a new spectral library classifier for airborne hyperspectral images on heterogeneous environments. In *Proc. of the EARSeL 7th SIG-Imaging Spectroscopy Workshop*, Edinburgh, Scotland. 4
- Mercier, G. and Lennon, M. (2003). Support vector machines for hyperspectral image classification with spectral-based kernels. In *Proc. of IGARSS*, volume 1, pages 288–290. 5
- Merz, C. and Stolfo, S. (1998). Using correspondence analysis to combine classifiers. In *Machine Learning*, pages 33–58. Kluwer Academic Publishers. 29
- Messick, S. and Abelson, R. (1956). The additive constant problem in multidimensional scaling. *Psychometrika*, 21(1):1–15. 20
- Miao, L. and Qi, H. (2007). A constrained non-negative matrix factorization approach to unmix highly mixed hyperspectral data. In *Proc. of ICIP*, volume 2, pages 185–188. 24
- Minet, J. (2011). *Imagerie multispectrale, vers une conception adaptée à la détection de cibles*. PhD thesis, Université Paris 11, France. 14
- Minet, J., Taboury, J., Pealat, M., Roux, N., Lonnoy, J., and Ferrec, Y. (2010). Adaptive band selection snapshot multispectral imaging in the vis/nir domain. *Proceedings of SPIE the International Society for Optical Engineering*, 7835:10. 14, 17, 19, 22
- Minghelli-Roman, A. (2010). Simulation, analyse, fusion d'images multi/hyperspectrales et applications. Habilitation à diriger des recherches, Université du Sud Toulon Var, France. 14, 22
- Moeller, M., Wittman, T., and Bertozzi, A. L. (2009). A variational approach to hyperspectral image fusion. In *SPIE Defense, Security, and Sensing*. 27
- Mohammadi, M. (2012). Road classification and condition determination using hyperspectral imagery. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XXXIX-B7. 4, 12
- Mohammadzadeh, A., Tavakoli, A., and Zoej, M. J. V. (2006). Road extraction based on fuzzy logic and mathematical morphology from pansharpened IKONOS images. *The Photogrammetric Record*, 21(113):44–60. 27
- Mojirsheibani, M. (1999). Combining classifiers via discretization. *Journal of the American Statistical Association*, 94(446):600–609. 29
- Moser, G., Serpico, S., and Benediktsson, J. (2013). Land-cover mapping by markov modeling of spatial contextual information in very-high-resolution remote sensing images. *Proceedings of the IEEE*, 101(3):631–651. 9

- Myint, S., Gober, P., Brazel, A., Grossman-Clarke, S., and Weng, Q. (2011). Per-pixel vs. object based classification of urban land cover extraction using high spatial resolution imagery. *Remote Sensing of Environment*, 115(5):1145–1161. 9
- Nagao, M., Matsuyama, T., and Ikeda, Y. (1979). Region extraction and shape analysis in aerial photographs. *Computer Graphics and Image Processing*, 10(3):195 – 223. 10
- Nakajima, T., Tao, G., and Yasuoka, Y. (2002). Simulated recovery of information in shadow areas on ikonos image by combining als data. *Proc. Gis, Development*, pages 1–7. 11
- Nascimento, J. and Bioucas Dias, J. (2005). Vertex component analysis: a fast algorithm to unmix hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 43(4):898–910. 24
- Nason, G. P. and Silverman, B. W. (1995). The stationary wavelet transform and some statistical applications. In Antoniadis, A. and G. Oppenheim, editors, *Wavelets and Statistics*, volume 103, pages 281–299. Springer-Verlag, New York, NY. 27
- Nemmour, H. and Chibani, Y. (2006). Multiple support vector machines for land cover change detection: An application for mapping urban extensions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 61(2):125 – 133. 29
- Nowozin, S., Rother, C., Bagon, S., Sharp, T., Yao, B., and Kohli, P. (2011). Decision tree fields. In *Proc. of ICCV*. 10
- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man and Cybernetics*, 9(1):62–66. 11
- Pal, M. (2005). Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26(1):217–222. 3
- Pal, M. (2009). Margin-based feature selection for hyperspectral data. *International Journal of Applied Earth Observation and Geoinformation*, 11:121–220. 15, 17
- Pal, M. (2012). Multinomial logistic regression-based feature selection for hyperspectral data. *International Journal of Applied Earth Observation and Geoinformation*, 14:214–220. 3
- Pal, M. and Foody, G. (2010). Feature selection for classification of hyperspectral data by SVM. *IEEE Transactions on Geoscience and Remote Sensing*, 48(5):2297–2307. 3, 12
- Palsson, F., Sveinsson, J., Ulfarsson, M., and Benediktsson, J. A. (2014). A new pansharpening algorithm based on total variation. *IEEE Geoscience and Remote Sensing Letters*, 11(1):318–322. 27
- Park, H.-S. and Jun, C.-H. (2009). A simple and fast algorithm for k-medoids clustering. *Expert Systems with Applications*, 36(2):3336–3341. 2
- Pedergnana, M., Marpu, P. R., Dalla Mura, M., Benediktsson, J. A., and Bruzzone, L. (2013). A novel technique for optimal feature selection in attribute profiles based on genetic algorithms. *IEEE Transactions on Geoscience and Remote Sensing*, 51(6):3514–3528. 8
- Pelleg, D., Moore, A. W., et al. (2000). X-means: Extending k-means with efficient estimation of the number of clusters. In *Proc. of ICML*, pages 727–734. 2
- Pesaresi, M. and Benediktsson, J. A. (2001). A new approach for the morphological segmentation of high-resolution satellite imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 39(2):309–320. 7
- Petropoulos, G., Kalaitzidis, C., and Vadrevu, K. P. (2012). Support vector machines and object-based classification for obtaining land-use/cover cartography from hyperion hyperspectral imagery. *Computers & Geosciences*, 41:99 – 107. 8

- Platt, J. (2000). *Advances in large margin classifiers*, chapter Probabilistic outputs for Support Vector Machines and comparisons to regularized Maximum Likelihood methods. MIT Press, USA. 6
- Pohl, C. and Genderen, J. L. V. (1998). Multisensor image fusion in remote sensing: Concepts, methods and applications. *International Journal of Remote Sensing*, 19(5):823–854. 28
- Polidorio, A., Flores, F., Imai, N., Tommaselli, A., and Franco, C. (2003). Automatic shadow segmentation in aerial color images. In *Proc. of SIBGRAPI*, pages 270–277. 11
- Poulain, V., Inglada, J., Spigai, M., Tourneret, J.-Y., and Marthon, P. (2011). High-resolution optical and sar image fusion for building database updating. *IEEE Transactions on Geoscience and Remote Sensing*, 49(8):2900–2910. 28, 29
- Prasad, S. and Bruce, L. M. (2008). Decision fusion with confidence-based weight assignment for hyperspectral target recognition. *IEEE Transactions on Geoscience and Remote Sensing*, 46(5):1448–1456. 5, 21
- Price, J. (1994). How unique are spectral signatures ? *Remote Sensing of Environment*, 49(3):181–186. 4
- Pudil, P., Novovicova, J., and Kittler, J. (1994). Floating search methods in feature selection. *Pattern Recognition Letters*, 15:1119–1125. 16
- Radke, R., Andra, S., Al-Kofahi, O., and Roysam, B. (2005). Image change detection algorithms: a systematic survey. *IEEE Transactions on Image Processing*, 14(3):294–307. 1
- Rajan, S., Ghosh, J., and Crawford, M. (2008). An active learning approach to hyperspectral data classification. *IEEE Transactions on Geoscience and Remote Sensing*, 46(4):1231–1242. 6
- Rao, C. R. (1948). The utilization of multiple measurements in problems of biological classification. *Journal of the Royal Statistical Society. Series B (Methodological)*, 10(2):159–203. 20
- Rau, J. Y., Chen, N. Y., and Chen, L. C. (2002). True orthophoto generation of built-up areas using multi-view images. *Photogrammetric Engineering & Remote Sensing*, 68:581–588. 11
- Richter, R. and Muller, A. (2005). De-shadowing of satellite/airborne imagery. *International Journal of Remote Sensing 26 (15)*, pages 3137–3148. 11
- Riedmiller, M. and Braun, H. (1993). A direct adaptive method for faster backpropagation learning: The rprop algorithm. In *Proc. of ICNN*. 3
- Roscher, R., Förstner, W., and Waske, B. (2012a). I2vm: Incremental import vector machines. *Image and Vision Computing*, 30(4-5):263–278. 3
- Roscher, R. and Waske, B. (2014). Superpixel-based classification of hyperspectral data using sparse representation and conditional random fields. In *Proc. of IGARSS*, pages 3674–3677. 9, 10
- Roscher, R., Waske, B., and Förstner, W. (2012b). Incremental import vector machines for classifying hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 50(9):3463–3473. 3
- Roussel, G. (2012). *Développement et évaluation de nouvelles méthodes de classification spatiale-spectrale d’images hyperspectrales*. PhD thesis, ISAE Institut Supérieur de l’Aéronautique et de l’Espace, Toulouse, France. 3, 29
- Saranathan, A. and Parente, M. (2015). Uniformity-based superpixel segmentation of hyperspectral images. *IEEE Transactions on Geoscience and Remote Sensing*, PP(99):1–12. 9
- Schindler, K. (2012). An overview and comparison of smooth labeling methods for land-cover classification. *IEEE Transactions on Geoscience and Remote Sensing*, 50(11):4534–4545. 9

- Scholkopf, B. and Mullert, K.-R. (1999). Fisher discriminant analysis with kernels. *Neural networks for signal processing IX*, 1:1. 20
- Schwing, A. G. and Urtasun, R. (2015). Fully connected deep structured networks. *CoRR*, abs/1503.02351. 10
- Serpico, S. B. and Bruzzone, L. (2001). A new search algorithm for feature selection in hyperspectral remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 39:1360–1367. 16
- Serpico, S. B. and Moser, G. (2007). Extraction of spectral channels from hyperspectral images for classification purposes. *IEEE Transactions on Geoscience and Remote Sensing*, 45(2):484–495. 13, 17, 21
- Shah, V. P., Younan, N., and King, R. L. (2008). An efficient pan-sharpening method via a combined adaptive-PCA approach and contourlets. *IEEE Transactions on Geoscience and Remote Sensing*, 56(5):1323–1335. 27
- Shensa, M. J. (1992). The discrete wavelet transform: wedding the a trous and Mallat algorithms. *IEEE Transactions on Signal Processing*, 40(10):2464–2482. 27
- Shettigara, V. (1992). A generalized component substitution technique for spatial enhancement of multispectral images using a higher resolution data set. *Photogrammetric Engineering & Remote Sensing*, 58(5):561–567. 27
- Shi, Q., Zhang, L., and Du, B. (2012). An novel active learning strategy for hyperspectral image classification. In *Proc. of WHISPERS*, pages 1–4. 6
- Simões, M., Bioucas Dias, J., Almeida, L., and Chanussot, J. (2015). A convex formulation for hyperspectral image superresolution via subspace-based regularization. *IEEE Transactions on Geoscience and Remote Sensing*, 53(6):3373–3388. 27, 28
- Simone, G., Farina, A., Morabito, F., Serpico, S., and Bruzzone, L. (2002). Image fusion techniques for remote sensing applications. *Information Fusion*, 3(1):3 – 15. 28
- Soille, P. (2003). *Morphological Image Analysis, Principles and Applications*. Springer, 2nd edition. 7
- Soltani, M. (2014). *Partitioning of large size hyperspectral images by affinity propagation*. PhD thesis, Université Rennes 1, France. 2
- Sotoca, J. and Filiberto, P. (2010). Supervised feature selection by clustering using conditional mutual information-based distances. *Pattern Recognition*, 43(6):2068–2081. 13, 14, 17
- Souza Jr, C., Firestone, L., Silva, L. M., and Roberts, D. (2003). Mapping forest degradation in the Eastern Amazon from SPOT 4 through spectral mixture models. *Remote Sensing of Environment*, 87(4):494–506. 27
- Sportouche, H., Tupin, F., and Denise, L. (2011). Extraction and three-dimensional reconstruction of isolated buildings in urban scenes from high-resolution optical and sar spaceborne images. *IEEE Transactions on Geoscience and Remote Sensing*, 49(10):3932–3946. 29
- Starck, J.-L., Fadili, J., and Murtagh, F. (2007). The undecimated wavelet decomposition and its reconstruction. *IEEE Transactions on Image Processing*, 16(2):297–309. 27
- Steele, B. (2000). Combining multiple classifiers: An application using spatial and remotely sensed information for land cover type mapping. *Remote Sensing of Environment*, 74(3):545 – 556. 29
- Su, H., Yang, H., Du, Q., and Sheng, Y. (2011). Semisupervised band clustering for dimensionality reduction of hyperspectral imagery. *IEEE Geoscience and Remote Sensing Letters*, 8(6):1135–1139. 19, 21

- Szeliski, R., Zabih, R., Scharstein, D., Veksler, O., Kolmogorov, V., Agarwala, A., Tappen, M., and Rother, C. (2008). A comparative study of energy minimization methods for markov random fields with smoothness-based priors. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 30(6):1068–1080. 9
- Tang, J., Alelyani, S., and Liu, H. (2014). *Data Classification: Algorithms and Applications*, chapter Feature selection for classification: a review, pages 37–64. CRC Press. 14
- Tappen, M., Freeman, W., and Adelson, E. (2005). Recovering intrinsic images from a single image. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27(9):1459–1472. 11
- Tarabalka, Y. (2010). *Classification of hyperspectral data using spectral-spatial approaches*. PhD thesis, Université de Grenoble, France. 9
- Tarabalka, Y., Chanussot, J., and Benediktsson, J. (2010). Segmentation and classification of hyperspectral images using watershed transformation. *Pattern Recognition*, 43(7):2367 – 2379. 9
- Tavin, F. (2008). *Analyse et utilisation d’une bibliothèque hyperspectrale pour l’optimisation des paramètres d’acquisition d’images de télédétection : application À la pédologie*. PhD thesis, Université de Bourgogne, France. 22
- Tenenbaum, J., De Silva, V., and Langford, J. (2000). A global geometric framework for nonlinear dimensionality reduction. *Science*, 290(5500):2319–2323. 20
- Thirion, J.-P. (1990). Realistic 3D simulation of shapes and shadows for image processing. Research Report RR-1344, INRIA, France. 11
- Thomas, C., Ranchin, T., Wald, L., and Chanussot, J. (2008). Synthesis of multispectral images to high spatial resolution: a critical review of fusion methods based on remote sensing physics. *IEEE Transactions on Geoscience and Remote Sensing*, 46(5):1301–1312. 27
- Tian, J., Sun, J., and Tang, Y. (2009). Tricolor attenuation model for shadow detection. *IEEE Transactions on Image Processing*, 18(10):2355–2363. 11
- Tibshirani, R. (1996). Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society (Series B)*, 58:267–288. 14, 17
- Tolt, G., Shimoni, M., and Ahlberg, J. (2011). A shadow detection method for remote sensing images using VHR hyperspectral and LIDAR data. In *Proc. of IGARSS*, pages 4423–4426. 11
- Tomasi, C. and Anduchi, R. (1998). Bilateral filtering for gray and color images. In *Proc. of ICCV*, pages 836–846. 9
- Trias-Sanz, R. (2006). *Semi-automatic high-resolution rural land cover classification*. PhD thesis, Université Paris 5, Paris, France. 3, 9
- Trias-Sanz, R. and Boldo, D. (2005). A high-reliability, high-resolution method for land cover classification into forest and non-forest. In *Proc. of SCIA*, pages 831–840. 3
- Tsai, V. (2006). A comparative study on shadow compensation of color aerial images in invariant color models. *IEEE Transactions on Geoscience and Remote Sensing*, 44(6):1661–1671. 11
- Tu, T.-M., Su, S.-C., Shyu, H.-C., and Huang, P. S. (2001). A new look at IHS-like image fusion methods. *Information Fusion*, 2(3):117–186. 27
- Tuia, D., Courty, N., and Flamary, R. (2014a). A group-lasso active set strategy for multiclass hyperspectral image classification. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, II-3:1–8. 14, 17

- Tuia, D., Ratle, F., Pacifici, F., Kanevski, M., and Emery, W. (2009). Active learning methods for remote sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 47(7):2218–2232. 6
- Tuia, D., Volpi, M., Dalla Mura, M., Rakotomamonjy, A., and Flamary, R. (2014b). Automatic feature learning for spatio-spectral image classification with sparse SVM. *IEEE Transactions on Geoscience and Remote Sensing*, 52(10):6062–6074. 14, 17
- Tuia, D., Volpi, M., Dalla Mura, M., Rakotomamonjy, A., Flamary, R., et al. (2013). Automatic feature learning for spatio-spectral image classification with sparse svm. *IEEE Transactions on Geoscience and Remote Sensing*. 8
- Tuia, D. and Camps-Valls, G., Matasci, G., and Kanevski, M. (2010). Learning relevant image features with multiple-kernel classification. *IEEE Transactions on Geoscience and Remote Sensing*, 48(10):3780–3791. 3, 5, 15, 17
- Tupin, F., Bloch, I., and Maitre, H. (1999). A first step toward automatic interpretation of sar images using evidential fusion of several structure detectors. *IEEE Transactions on Geoscience and Remote Sensing*, 37(3):1327–1343. 29
- Tupin, F., Inglada, J., and Nicolas, J.-M. (2014). *Remote Sensing Imagery*. Signal and Image Processing of Earth Observations. ISTE/Wiley, Boca Raton, FL. 29
- Van der Meer, F. and Bakker, W. (1998). Validated surface mineralogy from high-spectral resolution remote sensing: a review and a novel approach applied to gold exploration using aviris data. *Terra Nova*, 10(2):112–119. 4
- Vapnik, V. (1998). *Statistical learning theory*. Wiley, Hoboken, États-Unis. 3
- Villa, A., Benediktsson, J., Chanussot, J., and Jutten, C. (2011). Hyperspectral image classification with independent component discriminant analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 49(12):4865–4876. 20
- Vishwanathan, S. V. N., Schraudolph, N. N., Schmidt, M. W., and Murphy, K. P. (2006). Accelerated training of conditional random fields with stochastic gradient methods. In *Proc. of ICML*, pages 969–976, New York, NY, USA. 10
- Vivone, G., Alparone, L., Chanussot, J., Dalla Mura, M., Garzelli, and Licciardi, G. (2014a). A critical comparison of pansharpening algorithms. In *Proc. of IGARSS*, pages 191–194. 27
- Vivone, G., Alparone, L., Chanussot, J., Dalla Mura, M., Garzelli, and Licciardi, G. (2014b). Multi-resolution analysis and component substitution techniques for hyperspectral pansharpening. In *Proc. of IGARSS*, pages 2649–2652. 27
- Waske, B., B. J. (2007). Fusion of support vector machines for classification of multisensor data. *IEEE Transactions on Geoscience and Remote Sensing*, 45(12):3858–3866. 29
- Wegner, J., Ziehn, J., and Soergel, U. (2014). Combining high-resolution optical and insar features for height estimation of buildings with flat roofs. *IEEE Transactions on Geoscience and Remote Sensing*, 52(9):5840–5854. 28
- Wei, Q., Bioucas Dias, J. M., Dobigeon, N., and Tourneret, J.-Y. (2015a). Hyperspectral and multispectral image fusion based on a sparse representation. *IEEE Transactions on Geoscience and Remote Sensing*, 53(7):3658–3668. 27, 28
- Wei, Q., Dobigeon, N., and Tourneret, J.-Y. (2014). Bayesian fusion of hyperspectral and multispectral images. In *Proc. of ICASSP*, pages 3176–3180, Florence, Italy. 27

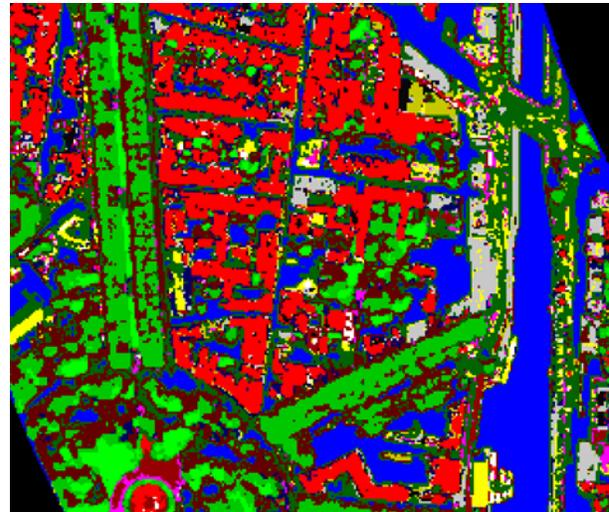
- Wei, Q., Dobigeon, N., and Tournet, J.-Y. (2015b). Bayesian fusion of multi-band images. *IEEE Journal of Selected Topics in Signal Processing*, 9(6):1117–1127. 27, 28
- Wiersma, D. and Landgrebe, D. (1980). Analytical design of multispectral sensors. *IEEE Transactions on Geoscience and Remote Sensing*, GE-18(2):180–189. 22
- Winter, M. E. (1999). N-findr: an algorithm for fast autonomous spectral end-member determination in hyperspectral data. In *Proc. SPIE*, volume 3753, pages 266–275. 24
- Wolpert, D. (1992). Stacked generalization. *Neural Networks*, 5:241–259. 29
- Xu, L., Krzyżak, A., and Suen, C. Y. (1992). Methods of combining multiple classifiers and their applications to handwriting recognition. *IEEE Transactions on Systems, man and cybernetics*, 22(3):418–435. 28
- Xu, P., Davoine, F., and Denoeux, T. (2014). Transformation de scores svm en fonctions de croyance. In *Proc. of RFIA*. 6
- Yamazaki, F., Liu, W., and Takasaki, M. (2009). Characteristics of shadow and removal of its effects for remote sensing imagery. In *Proc. of IGARSS*, volume 4, pages IV–426–IV–429. 11
- Yang, H., Du, Q., and Chen, G. (2012). Particle swarm optimization-based hyperspectral dimensionality reduction for urban land cover classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2):544–554. 13, 17, 19
- Yang, H., Zhang, S., Deng, K., and Du, P. (2007). Research into a feature selection method for hyperspectral imagery using pso and svm. *Journal of China University of Mining and Technology*, 17(4):473–478. 14, 17, 19
- Yang, J.-M., Kuo, B.-C., Yu, P.-T., and Chuang, C.-H. (2010). A dynamic subspace method for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 48(7):2840–2853. 5
- Yokoya, N., Yairi, T., and Iwasaki, A. (2012). Coupled nonnegative matrix factorization unmixing for hyperspectral and multispectral data fusion. *IEEE Transactions on Geoscience and Remote Sensing*, 50(2):528–537. 27, 28
- Yu, S., Gross, R., and Shi, J. (2002). Concurrent object recognition and segmentation by graph partitioning. In *Proc. of NIPS*, pages 1383–1390. MIT Press. 28
- Yuan, F. and Bauer, M. E. (2006). Mapping impervious surface area using high resolution imagery: a comparison of object-oriented classification to perpixel classification. *Proc. American Society of Photogrammetry and Remote Sensing Annual Conference*. 11
- Zang, X., Feng, X., and Jiang, H. (2010). Object-oriented method for urban vegetation mapping using ikonos imagery. *International Journal of Remote Sensing*, 31(1):177–196. 9
- Zare, A. and Gader, P. (2007). Hyperspectral band selection and endmember detection using sparsity promoting priors. *IEEE Geoscience and Remote Sensing Letters*, 5(2):256–260. 15, 17
- Zhan, Q., Shi, W., and Xia, Y. (2005). Quantitative analysis of shadow effects in high-resolution images of urban areas. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science* 36 (8/W27). 11
- Zhang, J. (2010). Multi-source remote sensing data fusion: status and trends. *International Journal of Image and Data Fusion*, 1(1):5–24. 28
- Zhang, L., Zhang, L., Tao, D., and Huang, X. (2012). On combining multiple features for hyperspectral remote sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 50(3):879–893. 5

- Zhang, L., Zhong, Y., Huang, B., Gong, J., and Li, P. (2007). Dimensionality reduction based on clonal selection for hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 45(12):4172–4186. 14, 17, 19
- Zheng, S., Jayasumana, S., Romera-Paredes, B., Vineet, V., Su, Z., Du, D., Huang, C., and Torr, P. (2015). Conditional random fields as recurrent neural networks. In *Proc. of ICCV*. 10
- Zhong, P. and Wang, R. (2010). Learning conditional random fields for classification of hyperspectral images. *IEEE Transactions on Image Processing*, 19(7):1890–1907. 10
- Zhou, S., Zhang, J., and Su, B. (2009). Feature selection and classification based on ant colony algorithm for hyperspectral remote sensing images. In *Proc. of the 2nd International Congress on Image and Signal Processing (CISP'09)*, pages 1–4. 19
- Zhu, J. and Hastie, T. (2005). Kernel logistic regression and the import vector machine. *Journal of Computational and Graphical Statistics*, 14:185–205. 3
- Zhu, J., Rosset, S., Hastie, T., and Tibshirani, R. (2004). 1-norm support vector machines. *Proc. of NIPS*, 16(1):49–56. 14, 17
- Zhuo, L., Zheng, J., Wang, F., Li, X., Bin, A., and Qian, J. (2008). A genetic algorithm based wrapper feature selection method for classification of hyperspectral images using support vector machine. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 37(B7):397–402. 14, 17, 19

Main achievements on hyperspectral and multispectral image processing techniques

ANR HYEP 2014-2018

Deliverable WP 2.2 et 2.3



July 20, 2018

Versions:

v1.1: 9 June 2018
v1.2: 18 July 2018
v1.3: 20 July 2018

Contributors:

Fatima BENHALOUCHE	IRAP
Issam BOUKERCH	IRAP
Xavier BRIOTTET	ONERA
Xavier CEAMANOS	ONERA
Jocelyn CHANUSSOT	GIPSA-Lab
Nesrine CHEHATA	IGN
Yannick DEVILLE	IRAP
Sophie FABRE	GIPSA-Lab
Alexandre HERVIEU	IGN
Sofiane KAROUI	IRAP
Arnaud LE BRIS	IGN
Laetitia LONCAN	GIPSA-Lab
Clément MALLET	IGN
Abdelaziz OUAMRI	IRAP
Walid OUERGHEMMI	ESPACE
Guillaume ROUSSEL	ONERA
Christiane WEBER	TETIS

Introduction

This document gathers contributions from HYEP teams on the current state-of-the-art of hyperspectral image processing techniques within the period 2014-2018. The methods can be roughly categorized into two main parts (see Figure 1):

- Low-level methods. These are the core remote sensing techniques: atmospheric correction (Section 1) and unmixing strategies (Section 2).
- High-level strategies that may integrate one or various outputs of above-mentioned techniques: pan-, multi-, and hyper-sharpening (Sections 3, 4 and 5), multi-sensor classification, and change detection (Section 6).

In Deliverables WP2.2 and WP2.3, we limit ourselves to pure image-based techniques. The contribution of lidar point clouds is presented in **Deliverable WP2.4**.

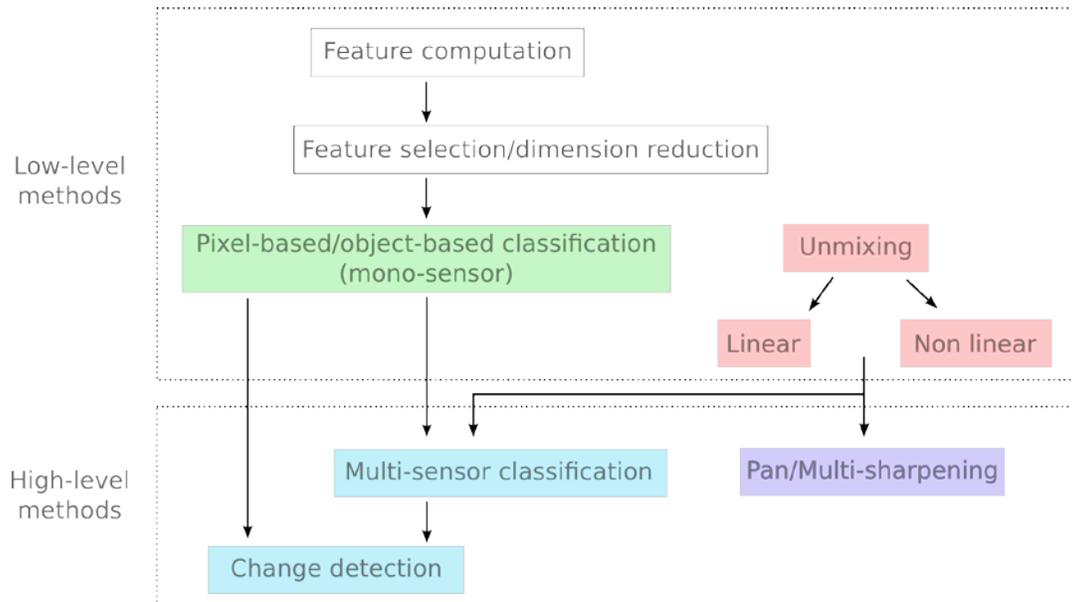


Figure 1: Workflow of the main techniques studied during the HYEP project.

All proposed and implemented strategies are presented in a similar way: a short summary, accompanied by the technical description of the engaged methods, as well as references from HYEP teams and their competitors. Many of these algorithms can be found in the website Open Remote Sensing, which targets a free distribution of codes and data for the remote sensing community: <http://openremotesensing.net/http://openremotesensing.net/>

1 Comparaison des méthodes de correction atmosphérique d'image hyperspectrale en fonction de la résolution spatiale - Applications

Guillaume Roussel, Christiane Weber, Xavier Briottet, Xavier Ceamanos

ONERA, DOTA, Toulouse, France
UMR TETIS, Montpellier, France

1.1 Résumé

L'étape de correction atmosphérique d'image hyperspectrale est nécessaire en télédétection pour des applications d'identification de matériaux basées sur l'utilisation de la réflectance spectrale. Cette étape est particulièrement critique en milieu urbain où les effets de pente de toit ou d'ombrage altèrent le signal à estimer au niveau de la surface. L'objectif de cette étude est de comparer deux outils développés à l'ONERA fonctionnant sous des hypothèses différentes : COCHISE (atmospheric Correction Code for Hyperspectral Images of remote sensing Sensors) qui fait l'hypothèse d'un sol plat et une méthode empirique tenant compte des effets de relief et des effets d'ombre. Cette comparaison est évaluée en sortie de classification sur des données hyperspectrales acquises lors d'une campagne aéroportée sur Toulouse, utilisées pour simuler des senseurs à différentes résolutions spatiales (de 1,6 to 9,6 m). Quatre classifieurs sont utilisés : k-means (non supervisé), Support Vector Machine (SVM, supervisé), complétés pour chacune de ces méthodes par une amélioration pour prendre en compte les ombres. Les résultats montrent que les performances des méthodes de correction atmosphérique dépendent de la résolution spatiale. La méthode empirique a de meilleures performances à haute résolution spatiale qui décroissent en dégradant la résolution spatiale. Aux faibles résolutions spatiales, la méthode COCHISE donne les meilleurs résultats.

1.2 Synthèse technique

La question initiale était: quelles sont les performances des méthodes de correction atmosphériques pour la classification en milieu urbain en fonction de la résolution spatiale ?

1.2.1 Méthode

L'étude est réalisée en 2 étapes.

Tout d'abord, les images hyperspectrales exprimées en unité de luminance en entrée instrument sont corrigées de l'atmosphère afin d'obtenir des images en unité de réflectance de surface. Deux méthodes sont utilisées : Cochise et empirique.

La méthode COCHISE fait l'hypothèse que le sol est plat, et que chaque pixel de l'image reçoit un éclairage incident identique d'où ses limitations dans les zones à l'ombre.

La méthode empirique vise à améliorer ces corrections en appliquant une correction atmosphérique différente dans les zones d'ombres en tenant compte ou pas de l'éclairage solaire direct, de l'éclairage diffus incident pondéré par un facteur de vue du ciel moyen et de la luminance montante due à l'environnement. Une étape préliminaire est nécessaire pour détecter les zones au soleil et à l'ombre afin d'appliquer la méthode de correction adaptée, la détection des ombres.

Dans une deuxième étape, les images résultantes sont classifiées suivant le schéma proposé dans la Figure 2. Ainsi, à partir du masque des ombres, les pixels au soleil sont extraits et classés soit de façon supervisée (SVM) soit non supervisées (k-means) avec un nombre de classe fixé par l'utilisateur. Puis le centroïde de chaque classe est utilisé comme entrée pour une classification supervisée des pixels à l'ombre (après correction atmosphérique) à l'aide du critère SAM. La fusion des cartes de classification au soleil et à l'ombre donne la nouvelle classification. Ainsi, quatre classifications sont réalisées :

- KM : Classification non supervisée (k-means) appliquée de façon indifférenciée sur toute l'image,

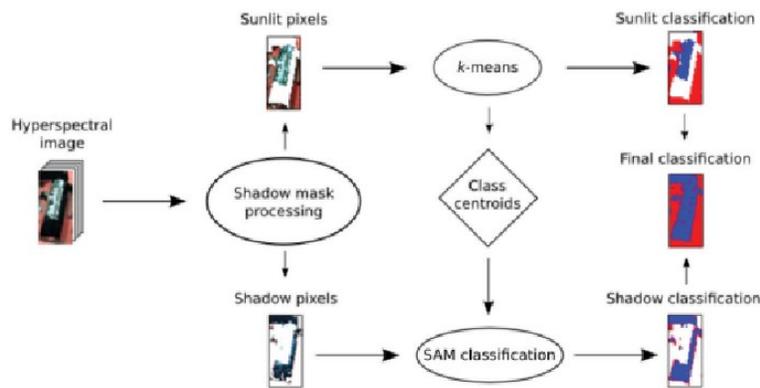


Figure 2: Schéma de la classification en fonction des zones à l'ombre et au soleil.

- SS-KM : Classification non supervisée (k-means) appliquée de façon différenciée sur l'image suivant que le pixel est à l'ombre ou au soleil (cf. Figure 2),
- SVM : Classification supervisée (SVM) appliquée de façon indifférenciée sur toute l'image,
- SS-SVM : Classification supervisée (SVM) appliquée de façon différenciée sur l'image suivant que le pixel est à l'ombre ou au soleil (cf. Figure 2).

La méthode supervisée utilise deux sortes d'apprentissage : soit en utilisant à la fois des données au soleil et à l'ombre (GTWS) soit des données uniquement au soleil (SGT). Enfin, une analyse a été entreprise afin de comparer les performances de classification entre différents instruments spatiaux : HYPXIM, Sentinel-2 et Pléiades. La comparaison avec WorldView 3 n'a pas été faite car les caractéristiques de bruit pour simuler l'instrument ne sont pas accessibles. Chaque instrument a été simulé en haut de l'atmosphère dans ses bandes spectrales. Une classification supervisée SVM a ensuite été appliquée.

1.2.2 Données utilisées et zones d'étude.

Les images ont été acquises le 24 octobre 2012 par les caméras Hypspec (400-1000 nm de résolution spectrale 3,7nm et 1000-2500nm de résolution spectrale de 6 nm) sur la ville de Toulouse à bord d'un avion volant à l'altitude de 2392 m (résolution spatiale de 80 cm). Ces images sont ensuite utilisées pour synthétiser une image du futur instrument hyperspectral de la mission HYPXIM en haut de l'atmosphère à la résolution spatiale de 8m et spectrale de 10nm et en rajoutant un bruit de la forme $a + b \cdot L$ avec L la luminance du pixel considéré.

1.2.3 Analyses quantitatives et qualitatives

Des premiers résultats comparent nos méthodes de correction atmosphérique associées aux différents types de classification (Figure 3). La méthode empirique améliore la classification dans les ombres qu'elle soit supervisée ou non supervisée.

En dégradant la résolution spatiale, les performances de la classification non supervisée (Tableau 1) sont comparées par rapport à une carte de classification de référence construite à la résolution spatiale des images acquises par l'instrument aéroporté. Les performances de classification sans prise en compte des ombres sont meilleures avec la méthode empirique (EM-KM) à 1,6 m qu'avec la méthode COCHISE (CM-KM), résultats qui s'inverse au fur et à mesure que la résolution spatiale se dégrade. En revanche, avec notre nouvelle méthode de classification tenant compte des ombres, les performances sont équivalentes à haute résolution voir meilleures lorsque la résolution spatiale se dégrade avec la méthode COCHISE (CM-SS-KM). Enfin, on peut noter que notre nouvelle méthode, quelle que soit la méthode de correction atmosphérique, améliore de

façon significative les performances de classification.

		EM		CM	
		KM	SS-KM	KM	SS-KM
1.6 m	AA	82.8	84.1	79.1	83.2
	OA	85.6	88.1	81.3	87.9
4.8 m	AA	74.1	76.1	77.2	87.1
	OA	76.5	79	80.5	90.6
8 m	AA	61.4	78	78.9	85.8
	OA	65.8	83.4	85.2	88.1
9.6 m	AA	61.4	75.6	75.5	77.3
	OA	63.9	79.2	78.6	81.3

EM stands for Empirical method and CM for COCHISE method.

Table 1: Précision moyenne (AA) et complète (OA) obtenues par classification non supervisée à différentes résolutions.

Les résultats sont également donnés dans le pour la classification supervisée. Tout d'abord, les performances sont globalement meilleures qu'avec la classification non supervisée, et tout particulièrement lorsque l'apprentissage est réalisé avec les pixels au soleil (SGT). La méthode empirique (EM) donne de meilleurs résultats avec pour une résolution spatiale de 1,6m seulement lorsque que l'on effectue une classification SVM seule. De même qu'avec la classification non supervisée, les limites de la correction atmosphérique avec une hypothèse sol plat (COCHISE) sont compensées par les performances de la classification avec prise en compte des ombres (SS-SVM).

		EM		CM		
		SVM	SS-SVM	SVM	SS-SVM	
1.6 m	SGT	AA	85.7	86.7	82.3	89.9
		OA	89.3	92.4	87.1	93.4
	GTWS	AA	86.8	85.2	92.2	90.7
		OA	89.8	89.2	95.5	94.3
4.8 m	SGT	AA	86.2	86.5	88.6	93.6
		OA	90.1	91	91.7	96.2
	GTWS	AA	94.3	88.4	96.1	93.8
		OA	96	91.7	97.5	95.9
8 m	SGT	AA	81.9	85.8	83.6	89.1
		OA	85.4	89.2	87.8	92.2
	GTWS	AA	86.2	83	89.3	88.3
		OA	89	87.5	92.8	92.5
9.6 m	SGT	AA	69.7	73.6	78.2	80.6
		OA	75.5	77.2	82.5	83.9
	GTWS	AA	83.9	82.9	90.1	90.3
		OA	87.4	86.9	93	93.6

SGT stands for sunlit ground truth, GTWS for ground truth with shadows.

Table 2: Précision moyenne (AA) et complète (OA) obtenues par classification supervisée à différentes résolutions.

Enfin, la comparaison des performances de classification entre différents instruments spatiaux : HYXIM, Sentinel-2 et Pléiades a été faite dans un premier temps à la même résolution spatiale de 1,6 m (Figure 4, haut) afin d'évaluer l'apport de la richesse spectrale, puis à leur résolution respective (Figure 4, haut).

A la même résolution spatiale, l'apport de la voie SWIR améliore de façon significative les performances de classification. En revanche, avec leurs résolutions nominales, Pléiades et HYPXIM présentent des performances similaires.

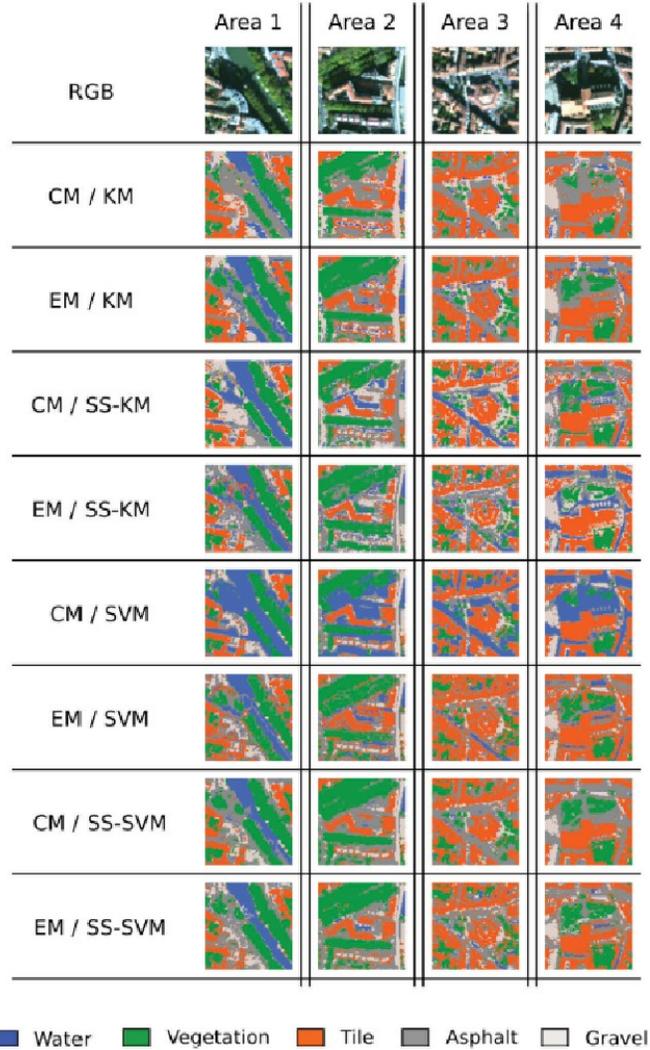


Figure 3: Classification de 4 zones de Toulouse pour deux méthodes de correction atmosphériques COCHISE (CM) et empirique (EM), et les 4 méthodes de classification KM, SS-KM, SVM et SS-SVM à la résolution de 1,6m.

Instrument	Kappa	Overall accuracy (%)
SENTINEL 2_ 1.6m	0,88	89,7
Hyper_ 1.6m	0,86	87,9
PLEIADES_ 1.6m	0,80	82,6
HYPXIM_ 8m	0,77	80,7
SENTINEL-2_ 9.6m	0,66	71,4

Table 3: Précision complète (OA) et Kappa obtenues par classification supervisée (SVM) pour différents instruments.

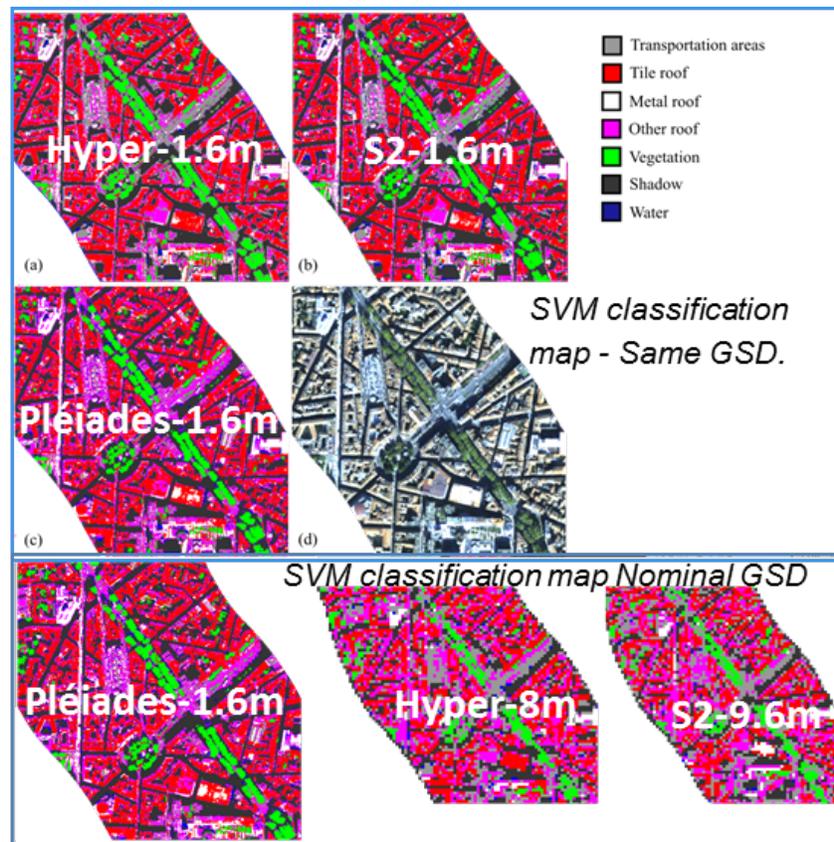


Figure 4: Classification supervisée (SVM) d'une zone de Toulouse appliquée sur des images simulant les instruments HYPXIM, Sentinel-2 et Pléiades à la résolution de 1,6m (Haut) et à leurs résolutions nominales (Pléiades 1,6m, HYPXIM 8m et Sentinel-2 9,6m, la bande SWIR de Sentinel-2 a été également simulée à 9,6m).

1.2.4 Perspectives

Une troisième méthode de correction atmosphérique a été développée à l'ONERA (ICARE) qui a fait l'objet au cours de cette ANR d'amélioration (passage du code de transfert 6S à MODTRAN afin de traiter des données hyperspectrales, meilleure estimation du terme de couplage). Sa principale particularité est qu'il prend en compte un modèle numérique de surface. Il serait intéressant d'évaluer l'apport d'ICARE-HS sur les performances de classification d'image à haute résolution spatiale. Une telle méthode va apporter des améliorations sur la discrimination des toits en prenant en compte les effets radiométriques dus à la pente des toits, et sur la détection des surfaces imperméables. Une limitation actuelle de l'outil ICARE est la correction atmosphérique à l'ombre des arbres pour des arbres à faible densité de feuille. Des travaux ont été réalisés pour développer une nouvelle version ICARE-VEG afin d'améliorer ce point qui doivent être poursuivis.

1.3 Références

1.3.1 Papiers majeurs avant HYEP

1. K. Adeline, A. Le Bris, F. Coubar, X. Briottet, N. Pappadimitis, F., Viallefont, N. Rivière, J.-P. Pappelard, N. David, P. Déliot, J. Duffaut, L. Poutier, P.-Y. Foucher, V. Achard, J.-P. Souchon, C. Thom, S. Airault, G. Maillet, "Description de la campagne aéroportée Umbra: étude de l'impact anthropique

sur les écosystèmes urbains et naturels avec des images THR multispectrales et hyperspectrales - Urban Material characterization in the sun and shade of Built-up structures and trees and their Retrieval from Airborne image acquisitions over two French cities (UMBRA)", *Revue Française de Photogrammétrie et de Télédétection*, 200, 2012.

2. M. Chen, X. Briottet, S.K. Pang, "Efficient Empirical Reflectance Retrieval in Urban Environments", *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 6(3), pp. 1596-1602, 2013.
3. K. Adeline, M. Chen, X. Briottet, S.K. Pang, N. Paparoditis, "Shadow Detection in very high spatial Resolution aerial Images: a Comparative Study", *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 80, pp. 21-38, 2013.
4. C. Thomas, S. Doz, X. Briottet and S. Lachérade, "AMARTIS v2: 3D Radiative Transfer Code in the [0.4; 2.5 μm] Spectral Domain Dedicated to Urban Areas", *Remote Sensing*, vol. 3, pp. 1914-1942, 2013.

1.3.2 Papiers publiés hors HYEP par la communauté pendant la période 2014-2018

1. X. Ceamanos, X. Briottet, G. Roussel, H. Gilardy, K. Adeline, "Using 3D information for atmospheric correction of airborne hyperspectral images of urban areas", in *Proc. JURSE*, 2017.
2. X. Ceamanos, X. Briottet, G. Roussel, H. Gilardy, "ICARE-HS: atmospheric correction of airborne hyperspectral urban images using 3D information", in *Proc. SPIE* 2016.
3. R. Oltra-Carrió, X. Briottet, X. Bonhomme, "Impact of spatial and spectral resolutions on the classification of urban areas", in *Proc. 9th International Conference on Urban Climate jointly with 12th Symposium on the Urban Environment*, 2015.
4. K. Adeline, X. Briottet, X. Ceamanos, T. Dartigalongue, J.-P. Gastellu-Etchegorry, "ICARE-VEG: a 3D physics-based atmospheric correction method for tree shadows in urban areas", *ISPRS Journal of Photogrammetry and Remote Sensing*, soumis en 2018.
5. S. Lachérade, C. Miesch, D. Boldo, X. Briottet, C. Valorge, H. Le Men, "ICARE: A physically-based model to correct atmospheric and geometric effects from high spatial and spectral remote sensing images over 3D urban areas", *Meteorology and Atmospheric Physics*, vol. 102(3-4), pp. 209-222, 2008.

1.3.3 Papiers publiés par HYEP

1. G. Roussel, C. Weber, X. Briottet and X. Ceamanos, "Comparison of two atmospheric correction methods for the classification of spaceborne urban hyperspectral data depending on the spatial resolution", *International Journal of Remote Sensing*, vol. 39(5), pp. 1593-1614, 2018.
2. G. Roussel, C. Weber, X. Ceamanos and X. Briottet, "A sun/shadow approach for the classification of hyperspectral data", in *Proc. IGARSS*, 2016.

2

Fusion de classifications

Alexandre Hervieu, Walid Ouerghemmi, Arnaud Le Bris, Clément Mallet, Nesrine Chehata

Univ. Paris Est, LASTIG MATIS, IGN, ENSG, Saint-Mandé, France
UMR ESPACE, Aix-en-Provence, France

2.4 Résumé

L'imagerie multispectrale (MS) à très haute résolution spatiale (THR) et l'imagerie hyperspectrale (HS) de résolution spatiale généralement plus faible sont deux sources complémentaires pour la classification des objets urbains. La première permet en effet une délimitation géométriquement fine des objets, tandis que la seconde doit favoriser une discrimination de classes plus détaillée. Ce travail propose une utilisation conjointe de ces deux sources de données par le biais d'un processus de fusion au niveau des décisions, prenant en entrée les classifications issues d'un traitement indépendant de ces deux types de données et produisant une classification en tirant le meilleur parti de manière à gérer à la fois les incertitudes spatiales et sémantiques.

2.5 Synthèse technique

2.5.1 Verrou technique

La cartographie de l'environnement urbain requiert de l'imagerie optique à très haute résolution spatiale (<5 m) car cette résolution s'avère nécessaire pour individualiser et délimiter précisément les objets urbains et pour considérer plus finement les détails géométriques. Néanmoins, les capteurs multispectraux (MS) à très haute résolution spatiale possèdent généralement une configuration spectrale limitée à trois ou quatre bandes larges (Rouge - Vert - Bleu - Proche Infrarouge), ce qui limite leur aptitude à discriminer des classes fines et limite la performance de classification en comparaison aux capteurs superspectraux ou hyperspectraux (HS). Ces derniers présentent toutefois généralement une résolution spatiale moindre. Afin de compenser les faiblesses de ces deux types de capteurs, l'imagerie multispectrale (MS) et (HS) peuvent être fusionnées afin de bénéficier de leurs caractéristiques complémentaires, de manière à bénéficier 1) de détails géométriques et texturaux fins pour une délimitation précise des objets et 2) d'une information spectrale riche afin de séparer efficacement les classes d'intérêt.

La fusion peut s'exercer à différents niveaux : on parle de fusion précoce, intermédiaire ou tardive. Dans le cas de ce type de données, la plupart des travaux s'intéressent à la fusion précoce, à savoir la création d'une nouvelle image hyperspectrale de même résolution spectrale que l'image hyperspectrale originale et de même résolution spatiale que l'image THR originale. Ce type d'approche a également été investiguée dans le cadre de HYEP [Loncan et al., 2015] et se justifie parfaitement dans la perspective de capteurs réalisant l'acquisition simultanée de ces deux types d'images.

Il apparaissait toutefois également pertinent de s'intéresser à des approches de fusion tardive. On cherche en effet à obtenir une classification bien précise pour la production de laquelle on n'a alors pas nécessairement besoin de passer par la création d'une nouvelle image hyperspectrale mieux résolue, mais d'utiliser l'information pertinente pour cette classification contenue dans les données. Par ailleurs, ce type d'approches peut permettre d'exploiter des résultats de traitements spécifiques à chaque source de données (classifieurs différents, démélange), mais également à s'appliquer à d'autres types de données (comme une fusion entre séries temporelles Sentinel-2 et imagerie optique THR).

2.5.2 Méthode proposée

La méthode proposée (Fig. 6) est une méthode de fusion tardive. Elle se situe donc à l'issue de la classification des images hyperspectrales et multispectrales, et exploite les cartes de probabilités a posteriori d'appartenance aux différentes classes selon ces deux sources. La méthode proposée s'efforce de gérer les incertitudes sémantiques et spatiales : elle effectue d'abord la fusion au niveau pixel au moyen de règles classiques, puis régularise le résultat de manière à corriger les erreurs résiduelles (bruit dans les zones les plus

incertaines) et à suivre au mieux les contours des objets de l'image THR. Elle se déroule donc en deux étapes :

1. On fusionne d'abord les mesures d'appartenance aux classes d'après les deux types d'images. Plusieurs règles de fusion ont été comparées dans cette étude. Elles utilisent exclusivement les probabilités d'appartenance générées à l'échelle du pixel par le classifieur (ici un classifieur SVM, mais l'approche vise justement à exploiter des résultats issus de différents traitements). La fusion s'effectue indépendamment pour chaque pixel, en combinant les probabilités d'appartenance de chaque source de données. Lors de cette étude, dix règles ont été testées. Elles provenaient de différents formalismes : probabilistes (ex : règles bayésiennes), flous possibilistes et évidentiels (ex : Dempster-Shafer). On notera que l'on se trouve ici dans un cas où des méthodes de fusion fondées sur l'apprentissage ne sont pas éligibles du fait de la rareté de la donnée d'apprentissage.

2. La carte de classification finale est ensuite obtenue à l'issue d'une régularisation globale. Il s'agit de favoriser la classification la plus fidèle tout en étant la plus régulière. En pratique, cela consiste à optimiser un modèle énergétique composé d'un terme d'attache à la données lié aux mesures d'appartenance aux classes issues de l'étape précédente ainsi que d'un terme de régularisation tenant compte du contraste de l'image MS THR. Ce problème se formalise sous la forme d'un modèle graphique et est résolu par un algorithme de coupe optimale de graphe (*graph cut*).

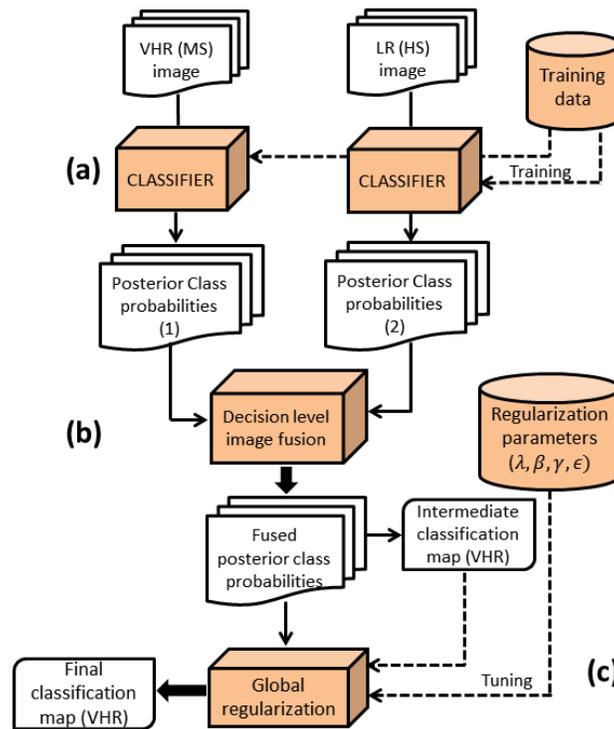


Figure 6: Fusion de données multi-sources.

2.5.3 Données utilisées et zones d'étude

Le processus proposé a été testé sur trois jeux de données incluant les jeux de données de la littérature Pavie Université et Pavie Centre, ainsi que le jeu de données UMBRA sur Toulouse. Les images hyperspectrales de ces jeux de données ont été dégradées de manière à simuler des images multispectrales de même résolution spatiale ainsi que des images hyperspectrales de résolution spatiale plus basse. En particulier, on s'est attaché

à avoir un rapport entre résolution de capteurs de l'ordre de celui entre celle d'une acquisition multispectrale native Pléiades et celle du projet de mission HypXim.

Les deux jeux de données appelés "Pavie Université" et "Pavie Centre" présentent respectivement 103 bandes et 102 bandes spectrales, un intervalle spectral allant de 430 à 860 nm, et une résolution spatiale de 1,3m. Ils comprennent neuf classes d'occupation du sol : asphalte, herbe, gravier, arbres, toitures métalliques peintes, sol nu, toitures en bitume, briques de blocage, ombre pour Pavie Université, et eau, arbres, herbe, briques de blocage, sol nu, asphalte, toitures en bitume, toitures en tuiles, ombre pour Pavie Centre. Ces images ont été dégradées pour simuler des images multispectrales de même résolution spatiale (i.e., 1,3m), et ayant une résolution spectrale de type Pléiades (limitée à trois bandes RGB) et des images hyperspectrales rééchantillonnées à une résolution spatiale inférieure de 7,8m et utilisant toute l'intervalle spectrale d'origine (i.e., 103 et 102 bandes spectrales).

Le dernier jeu de données concerne la ville de Toulouse, il est composé de 405 bandes spectrales, acquises dans un intervalle spectral allant de 400 à 2500nm, la résolution au sol est de 1,6m. Quinze classes d'occupation du sol sont considérées : toitures en ardoise, asphalte, ciment, eau, pavés, sol nu, toitures en gravier, toitures métalliques 1, toitures métalliques 2, toitures en tuiles, herbe/gazon, arbres, réseau ferroviaire, toitures en matériau plastique, ombre. Ces images ont été dégradées pour simuler des images multispectrales de même résolution spatiale (i.e., 1,6m), et ayant une résolution spectrale de type Pléiades (trois bandes RGB et une bande infrarouge) et des images hyperspectrales rééchantillonnées à une résolution spatiale inférieure de 8m et utilisant toute l'intervalle spectrale d'origine (i.e., 405 bandes spectrales).

2.5.4 Analyses quantitative et qualitative

Parmi les règles de fusion de type logique floue, les opérateurs "Minimum" et "Compromis" ont donné les meilleures performances, tandis que l'opérateur "Maximum" est souvent affecté par des erreurs de classification, dues à sa dépendance de la probabilité d'appartenance la plus élevée (i.e. la confiance est attribuée systématiquement à la probabilité d'appartenance la plus élevée). Les règles basées sur la priorité (i.e., donner une priorité à l'une des sources), permettent de favoriser une source par rapport à une autre, mais tendent à donner des résultats biaisés si cette priorité est donnée à une source peu fiable. Des règles intégrant la précision de la classification, permettent d'introduire la précision statistique des classifieurs dans le processus de fusion mais dépendent de la disponibilité d'une vérité de terrain de qualité, ce qui reste souvent problématique pour ces problèmes où l'on souhaite des nomenclatures plus fines que l'existant. Ces règles ont donné des résultats encourageants sur Pavie, les résultats sur Toulouse étant en retrait. Les règles d'inspiration bayésiennes utilisant les opérateurs de Somme et de Produit ont fourni des résultats acceptables pour les trois jeux de données utilisés. Ces règles seront plutôt conseillées lorsque les sources sont peu conflictuelles. Des règles basées sur la Marge statistique des classifieurs ont été proposées : leurs performances sont correctes pour Pavie Centre et Toulouse, mais moins bonnes sur Pavie Université. Enfin, les règles fondées sur le formalisme de Dempster-Shafer ont présenté des performances homogènes et correctes sur les trois jeux de données. Pour ces dernières, différentes manières de calculer les masses associées aux classes composées ont été proposées et testées.

Des exemples de résultats obtenus sur Toulouse sont présentés ci-dessous. Le classifieur utilisé ici pour classer les images multispectrales et hyperspectrales est un SVM à noyau gaussien. Plusieurs méthodes de fusion donnent de bons résultats ; de bons résultats (présentés sur la figure 7.c) ont été obtenus ici par la règle floue du "Compromis", avec une précision globale de 73,5%, tandis que les précisions globales des classifications des images HS et MS avant fusion étaient respectivement de 71,2% et 69,2% (Fig 7.a-b). La régularisation améliore ensuite le résultat (précision globale = 74,6%) notamment dans les zones les plus incertaines en lissant davantage la classification finale (Fig 7.d). Qualitativement, la fusion corrige certaines erreurs de classification de l'image MS et rend visibles certaines petites structures qui n'apparaissaient pas dans la classification de l'image HS. Plus généralement, la forme des objets est mieux restituée et rend le résultat plus facile à interpréter.

Il n'a pas été facile de départager les règles de fusion utilisées, la performance étant dépendante de plusieurs facteurs relatifs aux données et à la construction même de ces règles. Nous retenons tout de même que les règles ayant donné le meilleur rapport stabilité/performance sont les opérateurs "Minimum", "Compromis"

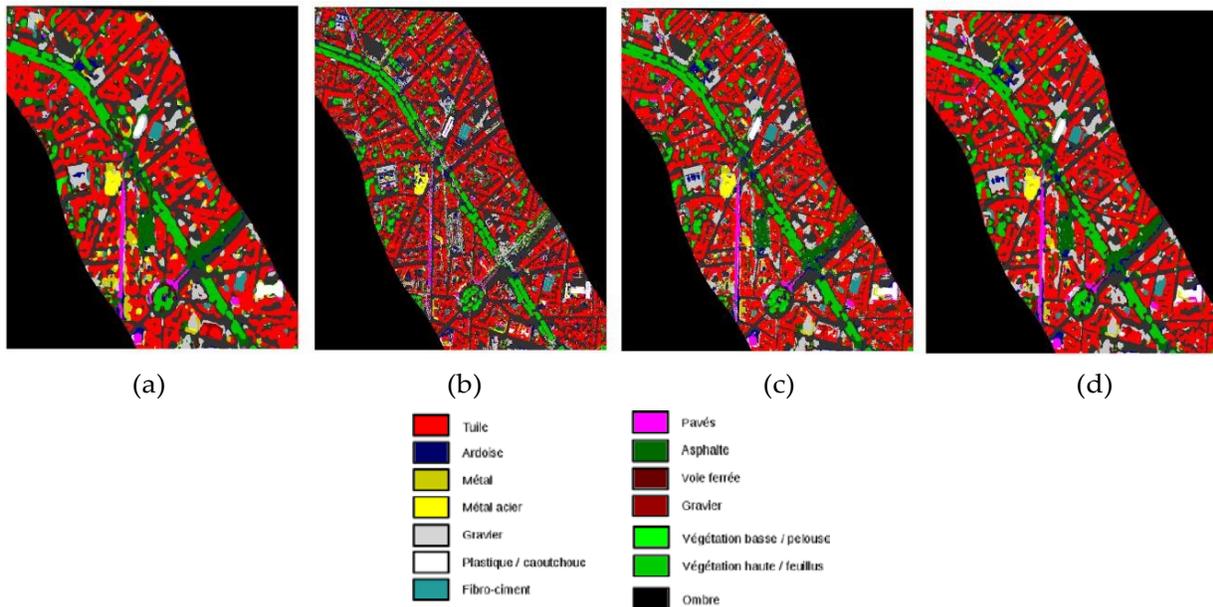


Figure 7: Exemples de résultats pour le jeu de données Toulouse ; a) classification SVM d'une image hyperspectrale de résolution spatiale dégradée, b) classification SVM d'une image multispectrale à très haute résolution spatiale, c) classification issue de la fusion par la règle "*Compromis*", d) classification finale à l'issue de la régularisation globale.

2.5.5 Perspectives

Il serait intéressant d'intégrer directement dans le modèle de régularisation une gestion explicite du conflit entre source. Il s'agirait alors de donner dans le terme de régularisation (terme d'a priori) plus d'influence aux pixels sur lesquels le conflit est faible. Le premier modèle de régularisation [Hervieu et al. 2016] proposait une solution dans ce sens, mais c'était la probabilité d'appartenance aux classes selon une source et non le conflit entre sources qui était alors pris en compte.

L'approche proposée est une approche de fusion tardive. Ce type d'approche a été retenu car permettant d'exploiter des résultats de traitements spécifiques à chaque source de données (classifieurs différents, démixage). Pour le moment, elle n'a toutefois été ici mise en œuvre que sur des probabilités d'appartenance aux classes issues de classification supervisée (SVM à noyau gaussien). Il serait donc intéressant, pour le traitement de la donnée HS avant fusion, de se tourner vers les méthodes de démixage au lieu de la classification, les cartes d'abondance générées par le démixage étant utilisées par la suite dans le processus de fusion. On notera également que la méthode proposée a été mise en œuvre pour une problématique différente sur d'autres données, à savoir des séries temporelles issue du satellite Sentinel-2 (richesse temporelle et spectrale) et des images mono-date SPOT-6 (MS THR).

Enfin, une meilleure gestion des ombres serait également à envisager. En effet, les ombres sont une cause importante d'erreurs, en particulier lorsque les deux images n'ont pas été acquises simultanément. Leur détection précise voire leur correction dans les données originale permettrait de régler ce problème. Des travaux dans ce sens étant réalisés dans le cadre du WP1, cette question n'a pas été abordée ici.

2.3 Références

2.3.1 Papiers majeurs avant HYEP

1. J.A. Benediktsson, and I. Kanellopoulos, "Decision fusion methods in classification of multisource and hyperdimensional data", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 37(3), pp.1367-1377, 1999.
2. X. Ceamanos, B. Waske, J.A. Benediktsson, J. Chanussot, M. Fauvel, and J.R. Sveinsson, "A classifier ensemble based on fusion of Support Vector Machines for classifying hyperspectral data", *International Journal of Image and Data Fusion*, vol. 1(4), pp.293-307, 2010.
3. M. Fauvel, J. Chanussot, and J.A. Benediktsson, "Decision fusion for the classification of urban remote sensing images", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 44(10), pp. 2828-2838, 2006.
4. A. Mohammad-Djafari, "A Bayesian approach for data and image fusion", in *Proc. American Institute of Physics Conference*, 659:386-408, 2003.
5. B. Waske, and J.A. Benediktsson, "Fusion of support vector machines for classification of multisensor data", *IEEE Transactions in Geoscience and Remote Sensing*, vol. 45(12), pp.3858-3866, 2007.

2.3.2 Papiers publiés hors HYEP par la communauté pendant la période 2014-2018

1. B. Abbasi, H. Arefi, B. Bigdeli, M. Motagh, and S. Roessner, "Fusion of Hyperspectral and LiDAR Data Based on Dimension Reduction and Maximum Likelihood", *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XL-7/W3, 2015.
2. Z. Ye, L. Bai, and Y. Nian, "Decision fusion for hyperspectral image classification based on multiple features and locality-preserving analysis", *European Journal of Remote Sensing*, vol. 50(1), pp.166-178, 2017.
3. G.D. Stavrakoudis, E. Dragozi, Z.I. Gitas, and G.C. Karydas, "Decision Fusion Based on Hyperspectral and Multispectral Satellite Imagery for Accurate Forest Species Mapping", *Remote Sensing*, vol. 6(8), 2014.
4. S. Paisitkriangkrai, J. Sherrah, P. Janney, and A. Van-Den Hengel, "Effective semantic pixel labelling with convolutional networks and Conditional Random Fields", in *Proc. IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 2015.

2.3.3 Papiers publiés par HYEP

1. L. Loncan, L. B. Almeida, J. M. Bioucas-Dias, X. Briottet, J. Chanussot, N. Dobigeon, S. Fabre, W. Liao, G. Licciardi, M. Simoes, J-Y. Tourneret, M. Veganzones, G. Vivone, Q. Wei and N. Yokoya, "Hyperspectral pansharpener: a review," *IEEE Geoscience and Remote Sensing Magazine* vol. 3(3), 2015.
2. A. Hervieu, A. Le Bris, and C. Mallet, "Fusion of hyperspectral and VHR multispectral image classifications in urban areas", *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol.III(3):457-464, 2016.
W. Ouergemmi, A. Le Bris, N. Chehata, and C. Mallet, "A two-step decision fusion strategy: application to hyperspectral and multispectral images for urban classification", *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII(1/W1):167-174, 2017.

3 Méthode de fusion d'images panchromatique et hyperspectrale

Laëtitia Loncan, Sophie Fabre, Jocelyn Chanussot, Xavier Briottet

GIPSA-Lab
ONERA

3.1 Résumé

Ce poste visait à fusionner une image hyperspectrale (haute résolution spectrale, mais faible résolution spatiale, de art les caractéristiques de l'instrument) avec une image panchromatique (très haute résolution spatiale, mais aucune diversité spectrale) afin de générer une image hyperspectrale possédant une très haute résolution spatiale. Ce problème, classique dans le cadre de la fusion d'une image multispectrale et d'une image panchromatique (appelé pansharpening) été étendu aux images hyperspectrales dans le cadre de la thèse de Laetitia Loncan financée par l'ONERA et la DGA et co-encadrée par X. Briottet, S. Fabre (ONERA) et J. Chanussot (GIPSA-Lab). Un état de l'art a été effectué et un article de synthèse publié dans le IEEE Geoscience and Remote Sensing Magazine. Cet article est accompagné d'une toolbox développée en langage Matlab mise à disposition de la communauté : <http://openremotesensing.net/knowledgebase/hyperspectral-pansharpening-a-review/> Une méthode originale de fusion basée sur le démélange spectral de chaque pixel hyperspectral, puis générant une image de synthèse à très haute résolution en guidant la répartition spatiale sub-pixellique des abondances obtenues avec l'image panchromatique a été proposée et publiée (IEEE WHISPERS 2015).

3.2 Synthèse technique

3.2.1 Verrou technique

La majorité des méthodes de fusion de type « pansharpening » ont été appliquées sur des images panchromatique et multispectrales. Leur extension à de l'imagerie hyperspectrale doit être évaluée en levant les verrous suivants : Quel est le comportement de ces méthodes en imagerie hyperspectrale ayant un domaine spectral étendu (0,4-2,5 μm) au lieu du domaine classiquement utilisé (0,4-0,8 μm)? Quelles performances attendre en fonction du type de paysage ? Quelles performances sont atteintes en fonction du rapport des résolutions spatiales des images en entrée de la fusion ?

3.2.2 Méthode proposée

Le travail s'est déroulé en deux étapes : une étape ayant pour but de comparer les performances de méthodes de fusion de l'état de l'art, d'identifier leurs limitations en les appliquant sur des images synthétiques et réelles. La deuxième étape avait pour but de proposer une nouvelle méthode. La comparaison des méthodes de l'état de l'art a fait l'objet d'une publication. A partir d'une synthèse bibliographique, les méthodes suivantes ont été sélectionnées pour être évaluées :

- Classe des méthodes par substitution (CS) qui ont pour principe de préserver l'information spatiale mais introduisent des distorsions spectrales : GSA (Gram Schmidt Adaptive),
- Classe des méthodes d'analyse multirésolution (MRA) : MTF GLP HPM (Modulation Transfert Function Generalized Laplacian Pyramid with High Pass Filter),
- Classe des méthodes Bayésienne nécessitant des connaissances a priori sur le système d'acquisition : la méthode retenue est la méthode BAYESIAN SPARSE est retenue pour ses performances,
- Classe de méthodes factorisation de matrices : CNMF (Coupled NonNegative Matrix Factorization).

Différents critères ont été utilisés pour cette comparaison : visuel, spatial (corrélation jointe), spectral (spectral angle mapper,) et globaux (écart quadratique moyen, erreur relative globale adimensionnelle de synthèse).

Cette comparaison conduit à une identification des limitations de chaque méthode et a permis de mettre en place une nouvelle méthode basée sur le schéma général suivant :

- Une première étape vise à identifier les pixels mixtes et les pixels purs dans l'image hyperspectrale,
- Un algorithme de démixage spectral est appliqué sur les pixels mixtes,
- Pour les pixels purs, l'image finale est synthétisée en dupliquant les valeurs hyperspectrales pour chaque sub-pixel (partage des pixels originaux en 3x3, ou 5x5 petits pixels, à la même résolution que l'image panchromatique) après application d'un gain permettant d'adapter chaque pixel à l'intensité lumineuse correspondante telle que mesurée sur l'image panchromatique,
- Pour les pixels mixtes, les abondances observées sont quantifiées afin de pouvoir être distribuées sur l'ensemble des sub-pixels. L'affectation se fait selon un critère de minimisation de l'écart entre l'intensité correspondante et celle mesurée sur l'image panchromatique. A nouveau une correction de gain est appliquée en dernière étape.

3.2.3 Données utilisées et zones d'étude

Plusieurs images ont été utilisées acquises sur des paysages différents :

- Image HYMAP (2007, DLR) d'un paysage rural en Camargue (domaine spectral 0,4-2,5 μm , nombre de bandes 113, résolution spatiale 4m),
- Image HYMAP (2009, DLR) d'un paysage rural et urbain sur Garons (proche de Montpellier) (domaine spectral 0.4-2.5 μm , nombre de bandes 113, résolution spatiale 4m),
- Image HYSPEX (ONERA) d'un paysage urbain sur Toulouse (domaine spectral 0,4-2,5 μm , nombre de bandes 292, résolution spatiale 2m).

Ces images sont utilisées pour simuler les images panchromatiques et hyperspectrales avec les caractéristiques indiquées dans le Tableau 4.

Dataset	Dimensions (columns x lines)	GSD (m)
Camargue	PAN 500 × 500	4
	HS 125 × 125	16
Garons	PAN 400 × 400	4
	HS 100 × 100	16
Toulouse	PAN 240 × 200	2
	HS 60 × 50	8

Table 4: Caractéristiques des images synthétiques panchromatiques et hyperspectrales.

3.2.4 Analyses quantitatives et qualitatives

Les images fusionnées résultantes pour l'image de Camargue sont données sur la Figure 5.

La méthode par substitution (MTF GLP HPM) génère une image floutée. La méthode GSA a de bonnes performances spatiale et la méthode CNMF combine de bonnes performances spatiales et spectrales. En revanche la méthode Bayesian Sparse donne des performances faibles qui dépendent fortement des données d'entrée.

Les principales limitations de ces méthodes résident aux zones de transition dans les pixels mixtes à l'échelle de l'image hyperspectrale car les méthodes de l'état de l'art visent à ajouter une information spatiale sans modification de l'information spectrale.



Figure 5: -a- Image de référence acquise sur la Camargue, -b- Image fusionnée par la méthode GSA, -c- Image fusionnée par la méthode MTF GLP HPM, -d- Image fusionnée par la méthode CNMF, -e- Image fusionnée par la méthode Bayesian Sparse.

3.2.5 Perspectives

Les travaux futurs s'orientent vers une meilleure prise en compte de ces pixels mixtes. Dans ce but, des travaux préliminaires ont été effectués pour le développement d'une nouvelle méthode. Celle-ci se décompose en plusieurs étapes : détection des pixels mixtes, recherche des pôles purs, démelange puis ordonnancement des pôles purs dans le pixel hyperspectral à l'échelle de la résolution panchromatique. Des améliorations sont nécessaires pour une meilleure prise en compte des ombres et des objets de tailles réduites. Cette méthode devra être validée et comparée aux méthodes existantes.

3.3 Références

3.3.1 Papiers majeurs avant HYEP

1. B. Aiazzi, S. Baronti and M. Selva, "Improving component substitution Pansharpening through multi- variate regression of MS+Pan data," IEEE Transactions on. Geosci. and Remote Sens., vol. 45(10), pp. 3230-3239, 2007.
2. G. Vivone, R. Restaino, M. Dalla Mura, G. Licciardi and J. Chanussot, "Contrast and error-based fusion schemes for multispectral image pansharpening," IEEE Geosci. and Remote Sensing Lett., vol. 11(5), pp. 930-934, 2014.
3. A. Villa, J. Chanussot, J. A. Benediktsson and C. Jutten, "Spectral Unmixing for the Classification of Hyperspectral Images at a Finer Spatial Resolution", IEEE Journal of Selected Topics in Signal Processing, vol.5(3), pp.521-533, 2011.

4. M. M. Khan, J. Chanussot, and L. Alparone, "Hyperspectral pansharpening using QNR optimization constraint", in Proc. First Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, 2009.
5. G. Vivone, R. Restaino, M. Dalla Mura, G. Licciardi and J. Chanussot, "Contrast and error-based fusion schemes for multispectral image pansharpening," IEEE Geosci. and Remote Sensing Lett., vol. 11(5), pp. 930-934, 2014.
6. A. Villa, J. Chanussot, J. A. Benediktsson and C. Jutten, "Spectral Unmixing for the Classification of Hyperspectral Images at a Finer Spatial Resolution", IEEE Journal of Selected Topics in Signal Processing, vol.5(3), pp.521-533, 2011.
7. M. M. Khan, J. Chanussot, and L. Alparone, "Hyperspectral pansharpening using QNR optimization constraint", in Proc. First Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, 2009.

3.3.2 Papiers publiés hors HYEP par la communauté pendant la période 2014-2018

1. M. Selva, B. Aiazzi, F. Butera, L. Chiarantini and S. Baronti, "Hyper-Sharpener: A First Approach on SIM-GA Data", IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 8(6), pp.3008-3024, 2015.
2. Z. H. Nezhad, Azam Karami, R. Heylen and P. Scheunders, "Fusion of Hyperspectral and Multispectral Images Using Spectral Unmixing and Sparse Coding", IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol.9(6), pp.2377-2389, 2016.
3. J. Qu, Y. Li, W. Dong, "Hyperspectral Pansharpening With Guided Filter", IEEE Geoscience and Remote Sensing Letters, vol.14(11), pp.2152-2156, 2016.

3.3.3 Papiers publiés par HYEP

1. L. Loncan, L. B. Almeida, J. M. Bioucas-Dias, X. Briottet, J. Chanussot, N. Dobigeon, S. Fabre, W. Liao, G. Licciardi, M. Simoes, J-Y. Tourneret, M. Veganzones, G. Vivone, Q. Wei and N. Yokoya, "Hyperspectral pansharpening: a review," IEEE Geoscience and Remote Sensing Magazine vol. 3(3), 2015.
2. L. Loncan, J. Chanussot, S. Fabre and X. Briottet, "Hyperspectral Pansharpening based on unmixing techniques", in Proc. WHISPERS 2015.
3. L. Loncan, L. B. Almeida, J. Bioucas Dias, X. Briottet, J. Chanussot, N. Dobigeon, S. Fabre, W. Liao, G. Licciardi, M. Simoes, J. Y. Tourneret, M. A. Veganzones, G. Vivone, Q. Wei, N. Yokoya, "Comparison of nine Hyperspectral Pansharpening methods", in Proc. IGARSS, 2015.

Method	Quality criteria				Method	Quality criteria			
	CC	SAM	RMSE	ERGAS		CC	SAM	RMSE	ERGAS
MTF GLP HPM	0.93	3.57	5.04	4.02	MTF GLP HPM	0.81	5.38	6.92	5.81
GSA	0.94	3.37	4.31	3.58	GSA	0.85	5.10	5.56	5.17
CNMF	0.96	3.02	3.67	3.22	CNMF	0.89	4.79	5.32	4.58
Bayesian Sparse	0.90	3.96	5.63	4.65	Bayesian Sparse	0.75	6.04	7.87	6.61

Method	Quality criteria			
	CC	SAM	RMSE	ERGAS
MTF GLP HPM	0.89	7.60	5.34	9.41
GSA	0.83	9.95	6.58	11.73
CNMF	0.84	7.96	4.77	9.27
Bayesian Sparse	0.89	7.99	4.78	9.28

Table 5: Comparaison des méthodes de l'état de l'art sur la Camargue (en haut à gauche), sur Garons (en haut à droite) et sur Toulouse (en bas).

4 Démélange spectral linéaire-quadratique/bilinéaire des images hyperspectrales de milieux urbains basé sur la factorisation linéaire- quadratique/bilinéaire en matrices non-négatives

Fatima Zohra Benhalouche, Yannick Deville, Moussa Sofiane Karoui, Abdelaziz Ouamri
IRAP, Université de Toulouse, UPS, CNRS, CNES, Toulouse, France Centre des Techniques Spatiales, Arzew, Algérie LSI, Université des Sciences et de la Technologie d'Oran Mohamed Boudiaf, Oran, Algérie

4.1 Résumé

Dans ce travail, deux méthodes de démélange spectral non-linéaire sont proposées pour l'extraction des spectres d'endmembers hyperspectraux à partir de données hyperspectrales de télédétection spatiale de milieux urbains. Les deux méthodes proposées sont basées sur la factorisation non-linéaire en matrices non-négatives. La première méthode est conçue pour le mélange bilinéaire, tandis que la seconde méthode traite le mélange linéaire-quadratique. Pour chacune des deux méthodes, deux algorithmes sont proposés. Le premier algorithme est basé sur la descente en gradient avec un taux d'apprentissage fixe, alors que le second est multiplicatif.

4.2 Synthèse technique

Avec les progrès dans les domaines du traitement du signal et de l'image, l'observation de la Terre basée sur l'imagerie hyperspectrale a été largement utilisée ces dernières années pour mieux comprendre et gérer nos ressources naturelles et notre environnement. Les capteurs d'imagerie hyperspectrale acquièrent simultanément des images à partir de centaines de bandes étroites et contiguës du spectre électromagnétique. Ces capteurs ont une résolution spectrale élevée, mais une faible résolution spatiale, ce qui donne des pixels caractérisés par des spectres mélangés contenant plus d'un matériau pur. Un tel cas empêche la reconnaissance directe des matériaux présents dans une scène imagée et nécessite un traitement supplémentaire pour séparer ces spectres mélangés.

Le démélange spectral aveugle est l'une des techniques les plus utilisées pour l'analyse d'images hyperspectrales. Ce procédé non-supervisé vise, dans un premier temps, à extraire les spectres purs des matériaux contenus dans une forme mélangée dans les données hyperspectrales analysées. Suivant les méthodes considérées, les cartes d'abondance des matériaux purs sont extraites conjointement à leurs spectres ou lors d'une deuxième étape de traitement.

Lorsque le paysage de la scène imagée est plat et lorsque l'irradiance de la zone observée est homogène, le modèle de mélange considéré dans les techniques de démélange est linéaire. Autrement, c'est-à-dire lorsque le paysage n'est pas plat (comme dans les environnements urbains) ou lorsque nous sommes en présence d'une hétérogénéité de l'irradiance de la zone observée, le modèle de mélange devient non-linéaire. Ce modèle de mélange non-linéaire peut être réduit à un modèle linéaire-quadratique ou bilinéaire, comme l'ont montré les travaux de nos équipes. Le modèle de mélange bilinéaire est un sous-ensemble de la forme de mélange linéaire-quadratique, qui considère les interactions de second ordre uniquement entre différents membres de la scène observée (i.e., les auto-interactions de second ordre ne sont pas prises en compte).

Dans ce travail, deux nouvelles méthodes, basées sur la factorisation linéaire-quadratique/bilinéaire en matrices non-négatives, sont proposées pour l'extraction linéaire-quadratique/bilinéaire des spectres purs des matériaux présents dans les données considérées. La première méthode est conçue pour le mélange linéaire- quadratique, et la seconde méthode traite le cas du modèle bilinéaire.

Dans un travail préliminaire, l'accent a été mis sur le développement d'un nouveau principe de démélange, et sa fonction de coût associée qui a été optimisée en utilisant l'algorithme standard de Nelder-Mead. Puis, pour chacune des deux méthodes, deux nouveaux algorithmes d'optimisation

(pour la même fonction de coût) ont été développés. Ces algorithmes tiennent compte de la non-négativité des données manipulées. Le premier algorithme proposé utilise le schéma de descente en gradient projeté. Le second algorithme utilise des règles de mise à jour multiplicatives.

Les algorithmes développés ont été utilisés sur des données semi-synthétiques, c.-à-d. des spectres réels de matériaux purs mélangés d'une manière bilinéaire ou linéaire-quadratique. Les spectres purs réels considérés sont issus de bibliothèques spectrales. Les coefficients de mélange utilisés sont issus d'une classification réelle. Les performances obtenues sont comparées à celles de méthodes de la littérature et détaillées dans les articles cités ci-dessous. Globalement, ces performances démontrent que les méthodes de démixage proposées donnent des résultats satisfaisants. Aussi, ces mêmes performances révèlent que ces méthodes d'extraction surpassent les méthodes testées de la littérature.

4.3 Références

4.3.1 Papiers majeurs avant HYEP

1. W. Fan, B. Hu, J. Miller, and M. Li, "Comparative study between a new nonlinear model and common linear model for analyzing laboratory simulated-forest hyperspectral data," *International Journal of Remote Sensing*, vol. 30(11), pp. 2951-2962, 2009.
2. J. M. Bioucas-Dias, A. Plaza, N. Dobigeon, M. Parente, Q. Du, P. Gader, and J. Chanussot, "Hyperspectral Unmixing Overview: Geometrical, Statistical, and Sparse Regression-Based Approaches," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 5(2), pp. 354-379, 2012.
3. I. Meganem, P. Deliot, X. Briottet, Y. Deville, and S. Hosseini, "Linear-Quadratic Blind Source Separation Using NMF to Unmix Urban Hyperspectral Images," *IEEE Transactions on Signal Processing*, vol. 62, pp. 1822-1833, 2014.
4. I. Meganem, P. Deliot, X. Briottet, Y. Deville, and S. Hosseini, "Linear-quadratic mixing model for reflectances in urban environments," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 52, pp. 544-558, 2014.

4.3.2 Papiers publiés hors HYEP par la communauté pendant la période 2014-2018

1. N. Dobigeon, J.-Y. Tourneret, C. Richard, J.C.M. Bermudez, S. McLaughlin, A.O. Hero, "Nonlinear Unmixing of Hyperspectral Images: Models and Algorithms," *IEEE Signal Processing Magazine*, vol. 31(1), pp. 82-94, 2014.
2. Y. Deville and L.T. Duarte, "An Overview of Blind Source Separation Methods for Linear-Quadratic and Post-nonlinear Mixtures," *Latent Variable Analysis and Signal Separation, Lecture Notes in Computer Science*, vol. 9237, Liberec, Czech Republic, pp. 155-167, 2015.

4.3.3 Papiers publiés par HYEP

1. Y. Deville, "Matrix Factorization for Bilinear Blind Source Separation: Methods, Separability and Conditioning," in *Proc. EUSIPCO 2015, Nice, France*, 2015.
2. F. Z. Benhalouche, Y. Deville, M. S. Karoui, and A. Ouamri, "Bilinear matrix factorization using a gradient method for hyperspectral endmember spectra extraction," in *Proc. IEEE IGARSS 2016, Beijing, China*, 2016.
3. F. Z. Benhalouche, Y. Deville, M. S. Karoui, and A. Ouamri, "Hyperspectral endmember spectra extraction based on constrained linear-quadratic matrix factorization using a projected gradient method," in *Proc. IEEE MLSP 2016, Vietri sul Mare, Italy*, 2016.

5 Hypersharping des images hyperspectrales de télédétection spatiale par factorisation linéaire-quadratique en matrices non- négatives

Fatima Zohra Benhalouche, Moussa Sofiane Karoui, Yannick Deville, Abdelaziz Ouamri, Issam Boukerch

IRAP, Université de Toulouse, UPS, CNRS, CNES, Toulouse, France Centre des Techniques Spatiales, Arzew, Algérie LSI, Université des Sciences et de la Technologie d'Oran Mohamed Boudiaf, Oran, Algérie

5.1 Résumé

Le processus d'hypersharping (ou multisharping, suivant les auteurs) des données hyperspectrales consiste à combiner des données observables hyperspectrales de faible résolution spatiale avec des images multispectrales, observables aussi, de haute résolution spatiale. Les données obtenues, non observables, sont caractérisées par une haute résolution spectrale et une haute résolution spatiale. Dans ce travail, plusieurs approches d'hypersharping sont proposées. Celles-ci sont basées sur le démixage linéaire-quadratique des données considérées de milieux urbains et utilisent différents algorithmes de factorisation linéaire-quadratique en matrices non-négatives.

5.2 Synthèse technique

En imagerie hyperspectrale de télédétection spatiale, les capteurs collectent des centaines ou des milliers de canaux spectraux dans le domaine du visible et de l'infrarouge (0,4-2,5 μm). Les capteurs hyperspectraux ont une résolution spectrale élevée qui permet une détection et une identification précise des matériaux présents dans une scène observée, mais leur résolution spatiale est souvent inférieure à celle des capteurs multispectraux à faible résolution spectrale.

Plusieurs méthodes de fusion ont été conçues pour fusionner des données multispectrales ou hyperspectrales avec une image panchromatique à haute résolution spatiale. Ces processus de pansharpening ont été étendus, au cours des dernières décennies, afin de fusionner des images hyperspectrales et multispectrales. La fusion des deux derniers types d'images diffère du processus de pansharpening traditionnel étant donné que les informations spatiales de haute résolution ne sont pas contenues uniquement dans une seule bande spectrale (image panchromatique), mais dans plusieurs bandes spectrales (image multispectrale). Par conséquent, beaucoup de méthodes de pansharpening sont inapplicables pour fusionner des images hyperspectrales et multispectrales.

Les méthodes de fusion des données hyperspectrales et multispectrales, appelées multisharping ou hypersharping, sont une nouvelle façon d'améliorer la résolution spatiale des données hyperspectrales. Ces méthodes visent à fusionner les informations spectrales des données hyperspectrales avec les informations spatiales obtenues à partir de données multispectrales à haute résolution spatiale.

Récemment, quelques méthodes linéaires ont été proposées pour réaliser le processus d'hypersharping des données hyperspectrales. Ces méthodes utilisent les techniques de démixage linéaire des données considérées et sont basées sur la factorisation en matrices non-négatives. Les techniques de démixage linéaire consistent à décomposer linéairement les données manipulées en une collection de spectres purs et leurs fractions d'abondance correspondantes. Cette décomposition linéaire est réalisée avec la prise en compte de la contrainte de non-négativité dans les méthodes de factorisation en matrices non-négatives. Ces méthodes de la littérature ne prennent pas en compte les effets de multi-réflexions présents dans les milieux urbains. Ces effets traduisent une nature différente, en matière de modèle de mélange (dans ce cas un modèle linéaire-quadratique), des données considérées.

Dans les travaux que nous avons réalisés dans le cadre du projet HYEP, plusieurs méthodes d'hypersharpening des images hyperspectrales sont proposées. Ces méthodes, liées aux techniques de démixage linéaire- quadratique que nous développons aussi dans le cadre de HYEP, sont basées sur la factorisation linéaire- quadratique en matrices non-négatives. La première méthode démixage indépendamment, d'une manière

linéaire-quadratique, les deux types de données considérés. La seconde méthode procède au démixage linéaire-quadratique d'une manière couplée et itérative entre les données hyperspectrales et celles multispectrales en utilisant une boucle principale et deux sous-boucles. Dans chaque sous-boucle, un seul type de données est démixé. La troisième méthode réalise ce même démixage d'une manière conjointe dans une seule boucle. La dernière méthode optimise un critère conjoint de démixage linéaire-quadratique incluant la dégradation spatiale entre les données considérées. Après la phase de démixage, les méthodes proposées recombinent, aussi d'une manière linéaire-quadratique, les informations de haute résolution spectrale avec les informations de haute résolution spatiale pour l'obtention de données spatialement et spectralement bien résolues.

Les méthodes proposées ont été testées sur une série de données synthétiques et sur des données réelles (données hyperspectrales EO-1 Hyperion et données multispectrales EO-1 ALI et Landsat ETM+) couvrant une partie de la région d'Oran (Algérie). Les résultats obtenus sont comparés à ceux issus de méthodes linéaires de la littérature et sont détaillés dans les articles cités ci-dessous. Les performances des méthodes proposées sont nettement meilleures que celles des méthodes testées de la littérature. Ces performances sont analysées sur le plan des distorsions spatiale et spectrale, ainsi qu'en matière de temps de calcul.

Les résultats obtenus avec les méthodes proposées sont très satisfaisants et encourageants. Ces mêmes résultats ouvrent la perspective de l'utilisation des données panchromatiques afin d'améliorer davantage les performances obtenues.

5.3 Références

5.3.1 Papiers majeurs avant HYEP

1. R. B. Gomez, A. Jazaeri, and M. Kafatos, "Wavelet-based hyperspectral and multispectral image fusion," in Proc. SPIE, vol. 4383, pp. 36-42, 2001.
2. M. T. Eismann, R. C. Hardie, "Hyperspectral resolution enhancement using high-resolution multispectral imagery with arbitrary response functions," IEEE Transactions on Geoscience and Remote Sensing, vol. 43(3), pp. 455-465, 2005.
3. O. Berné, A. Tielens, P. Pilleri, and C. Joblin, "Non-negative matrix factorization pansharpening of hyperspectral data: An application to mid-infrared astronomy," in Proc. IEEE WHISPERS, 2010.
4. N. Yokoya, T. Yairi, and A. Iwasaki, "Coupled Nonnegative Matrix Factorization Unmixing for Hyperspectral and Multispectral Data Fusion," IEEE Transactions on Geoscience and Remote Sensing, 50(2), pp. 528-537, 2012.
5. M. S. Karoui, Y. Deville, and S. Kreri, "Joint Nonnegative Matrix Factorization for Hyperspectral and Multispectral Remote Sensing Data Fusion," in Proc. IEEE WHISPERS, 2013.

5.3.2 Papiers publiés hors HYEP par la communauté pendant la période 2014-2018

1. Q. Wei, N. Dobigeon, and J.-Y. Tourneret, "Bayesian Fusion of Hyperspectral and Multispectral Images," in Proc. IEEE ICASSP, pp. 3176-3180, 2014.
2. M. A. Bendoumi, M. He, and S. Mei, "Hyperspectral Image Resolution Enhancement Using High-Resolution Multispectral Image Based on Spectral Unmixing," IEEE Transactions on Geoscience and Remote Sensing, 52(10), pp. 6574-6583, 2014.
3. Q. Wei, J. M. Bioucas-Dias, N. Dobigeon, and J.-Y. Tourneret, "Hyperspectral and

Multispectral Images Fusion Based on a Sparse Representation," IEEE Transactions on Geoscience and Remote Sensing, 53(7), pp. 3658-3668, 2015.

4. Q. Wei, N. Dobigeon, and J.-Y. Tourneret, "Fast Fusion of Multi-Band Images Based on Solving a Sylvester Equation," IEEE Transactions on Image Processing, 24(11), pp. 4109-4121, 2015.

5. M. Selva, B. Aiazzi, F. Butera, L. Chiarantini, and S. Baronti, "Hyper-sharpening: A first approach on SIM-GA data," IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 8(6), pp. 3008-3024, 2015.

5.3.3 Papiers publiés par HYEP

1. F. Z. Benhalouche, M. S. Karoui, Y. Deville, and A. Ouamri, "Hyperspectral Data Multi-sharpening based on Linear-Quadratic Nonnegative Matrix Factorization," in Proc. IEEE IGARSS, pp. 3290-3293, Milan, Italy, 2015.

2. F. Z. Benhalouche, M. S. Karoui, Y. Deville, and A. Ouamri, "Hyperspectral and multispectral data fusion based on linear-quadratic nonnegative matrix factorization," Journal of Applied Remote Sensing, 11(2), pp. 025008-1-18, 2017.

3. F. Z. Benhalouche, M. S. Karoui, Y. Deville, I. Boukerch, and A. Ouamri, "Multi-sharpening hyper- spectral remote sensing data by Multiplicative Joint-Criterion Linear-Quadratic Nonnegative Matrix Factorization," in Proc. IEEE ECMSM, pp. 1-6, San Sebastian, Spain, 2017.

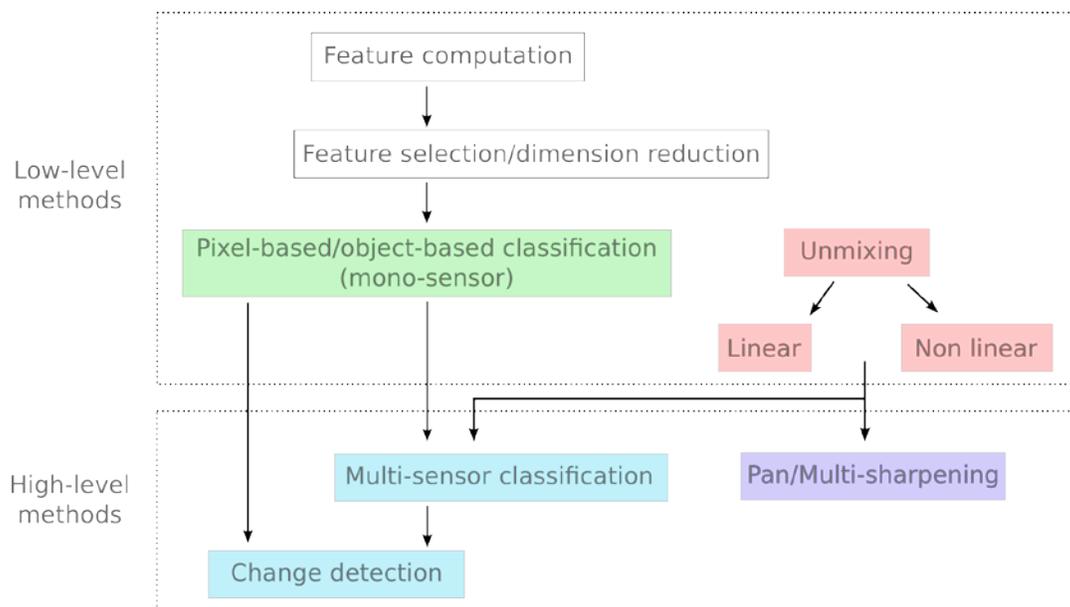


Figure 1: Workflow of the main techniques studied during the HYEP project.

6 Hypersharping des images hyperspectrales de télédétection spatiale par factorisation linéaire en matrices non-négatives

Moussa Sofiane Karoui, Yannick Deville, Fatima Zohra Benhalouche, Issam Boukerch

IRAP, Université de Toulouse, UPS, CNRS, CNES, Toulouse, France

Centre des Techniques Spatiales, Arzew, Algérie

LSI, Université des Sciences et de la Technologie d'Oran Mohamed Boudiaf, Oran, Algérie

6.1 Résumé

Le processus d'hypersharping (ou multisharping, suivant les auteurs) des données hyperspectrales consiste à combiner des données observables hyperspectrales de faible résolution spatiale avec des images multispectrales, observables aussi, de haute résolution spatiale. Les données obtenues, non observables, sont caractérisées par une haute résolution spectrale et une haute résolution spatiale. Dans ce travail, deux approches d'hypersharping sont proposées. Celles-ci sont basées sur le démélange linéaire des données considérées et utilisent un critère conjoint de factorisation en matrices non-négatives. Ce critère inclut la dégradation spatiale entre les deux types de données considérées.

6.2 Synthèse technique

En imagerie hyperspectrale de télédétection spatiale, les capteurs collectent des centaines ou des milliers de canaux spectraux dans le domaine du visible et de l'infrarouge ($0,4-2,5 \mu\text{m}$). Les capteurs hyperspectraux ont une résolution spectrale élevée qui permet une détection et une identification précise des matériaux présents dans une scène observée, mais leur résolution spatiale est souvent inférieure à celle des capteurs multispectraux à faible résolution spectrale.

Plusieurs méthodes de fusion ont été conçues pour fusionner des données multispectrales ou hyperspectrales avec une image panchromatique à haute résolution spatiale. Ces processus de pansharping peuvent être regroupés en quatre classes : projection-substitution de composantes, analyse multi-résolution, méthodes bayésiennes et variationnelles. L'hybridation entre les méthodes de ces quatre classes est aussi possible.

Les approches de pansharping ont été étendues, au cours des dernières décennies, afin de fusionner des images hyperspectrales et multispectrales. La fusion des deux derniers types d'images diffère du processus de pansharping traditionnel étant donné que les informations spatiales de haute résolution ne sont pas contenues uniquement dans une seule bande spectrale (image panchromatique), mais dans plusieurs bandes spectrales (image multispectrale). Par conséquent, beaucoup de méthodes de pansharping sont inapplicables pour fusionner des images hyperspectrales et multispectrales.

Les méthodes de fusion des données hyperspectrales et multispectrales, appelées multisharping ou hypersharping, sont une nouvelle façon d'améliorer la résolution spatiale des données hyperspectrales. Ces méthodes visent à fusionner les informations spectrales des données hyperspectrales avec les informations spatiales obtenues à partir de données multispectrales à haute résolution spatiale.

Récemment, quelques méthodes ont été proposées pour réaliser le processus d'hypersharping des données hyperspectrales. Ces méthodes utilisent les techniques de démélange linéaire des données considérées et sont basées sur la factorisation en matrices non-négatives. Les techniques de démélange linéaire consistent à décomposer linéairement les données manipulées en une collection de spectres purs et leurs fractions d'abondance correspondantes. Cette décomposition est réalisée avec la prise en compte de la contrainte de non-négativité dans les méthodes de factorisation en matrices non-négatives. Ces méthodes de la littérature soit sont gourmandes en temps de calcul, soit ne prennent pas en compte, dans le critère optimisé, la dégradation spatiale entre les données hyperspectrales et celles multispectrales.

Dans le travail que nous avons réalisé dans le cadre du projet HYEP, deux méthodes d'hypersharping des images hyperspectrales ont été proposées. Ces méthodes, liées aux techniques de démélange linéaire, sont basées sur la factorisation linéaire en matrices non-négatives. Dans ces méthodes proposées, une mise à jour conjointe des fractions d'abondance à haute et basse résolution spatiale est utilisée. Cette mise à

jour, découlant directement du critère optimisé, prend en compte la dégradation spatiale entre les images considérées. La première méthode proposée utilise un algorithme de descente en gradient projeté avec des taux d'apprentissage adaptatifs. Dans la seconde méthode, un algorithme multiplicatif est proposé. Cette deuxième méthode utilise de nouvelles règles de mise à jour multiplicatives qui sont déduites de la première méthode proposée en exprimant les taux d'apprentissage en tant que fonctions des variables hyperspectrales et multispectrales manipulées.

Les méthodes proposées ont été testées sur une série de données synthétiques et sur des données réelles (données hyperspectrales EO-1 Hyperion et données multispectrales EO-1 ALI et Landsat ETM+) couvrant une partie de la région d'Oran (Algérie). Les résultats obtenus sont comparés à ceux issus de méthodes de la littérature et détaillés dans l'article cité ci-dessous. Les performances des méthodes proposées sont nettement meilleures que celles des méthodes testées de la littérature. Ces performances sont analysées sur le plan des distorsions spatiale et spectrale, ainsi qu'en matière de temps de calcul.

Les résultats obtenus avec les méthodes proposées sont très satisfaisants et encourageants. Ces mêmes résultats ouvrent la perspective de l'utilisation des données panchromatiques afin d'améliorer davantage les performances obtenues.

6.3 Références

6.3.1 Papiers majeurs avant HYEP

1. R. B. Gomez, A. Jazaeri, and M. Kafatos, "Wavelet-based hyperspectral and multispectral image fusion," in Proc. SPIE, vol. 4383, pp. 36-42, 2001.
2. M. T. Eismann, R. C. Hardie, "Hyperspectral resolution enhancement using high-resolution multispectral imagery with arbitrary response functions," IEEE Transactions on Geoscience and Remote Sensing, vol. 43(3), pp. 455-465, 2005.
3. O. Berné, A. Tielens, P. Pilleri, and C. Joblin, "Non-negative matrix factorization pansharpening of hyperspectral data: An application to mid-infrared astronomy," in Proc. IEEE WHISPERS, 2010.
4. N. Yokoya, T. Yairi, and A. Iwasaki, "Coupled Nonnegative Matrix Factorization Unmixing for Hyperspectral and Multispectral Data Fusion," IEEE Transactions on Geoscience and Remote Sensing, 50(2), pp. 528-537, 2012.
5. M. S. Karoui, Y. Deville, and S. Kreri, "Joint Nonnegative Matrix Factorization for Hyperspectral and Multispectral Remote Sensing Data Fusion," in Proc. IEEE WHISPERS, 2013.

6.3.2 Papiers publiés hors HYEP par la communauté pendant la période 2014-2018

1. Q. Wei, N. Dobigeon, and J.-Y. Tourneret, "Bayesian Fusion of Hyperspectral and Multispectral Images," in Proc. IEEE ICASSP, pp. 3176-3180, 2014.
2. M. A. Bendoumi, M. He, and S. Mei, "Hyperspectral Image Resolution Enhancement Using High-Resolution Multispectral Image Based on Spectral Unmixing," IEEE Transactions on Geoscience and Remote Sensing, 52(10), pp. 6574-6583, 2014.
3. Q. Wei, J. M. Bioucas-Dias, N. Dobigeon, and J.-Y. Tourneret, "Hyperspectral and Multispectral Images Fusion Based on a Sparse Representation," IEEE Transactions on Geoscience and Remote Sensing, 53(7), pp. 3658-3668, 2015.
4. Q. Wei, N. Dobigeon, and J.-Y. Tourneret, "Fast Fusion of Multi-Band Images Based on Solving a Sylvester Equation," IEEE Transactions on Image Processing, 24(11), pp. 4109-4121, 2015.
5. M. Selva, B. Aiuzzi, F. Butera, L. Chiarantini, and S. Baronti, "Hyper-sharpening: A first approach on SIM-GA data," IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 8(6), pp. 3008-3024, 2015.

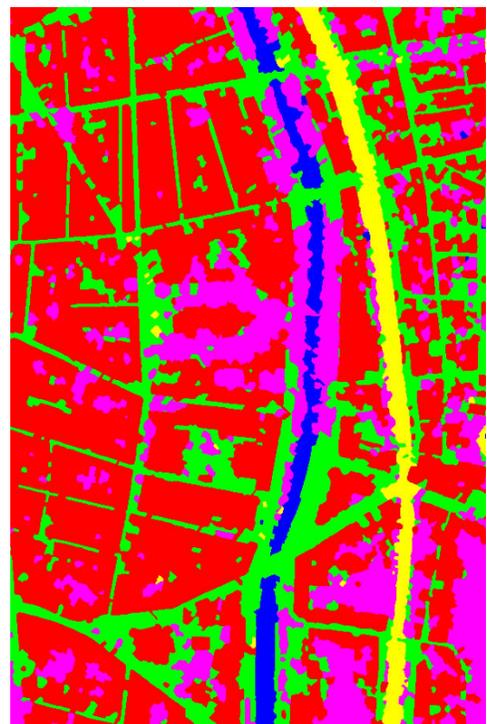
6.3.3 Papiers publiés par HYEP

1. M. S. Karoui, Y. Deville, F. Z. Benhalouche, and I. Boukerch, "Hypersharpener by Joint Criterion Nonnegative Matrix Factorization," IEEE Transactions on Geoscience and Remote Sensing, 55(3), pp. 1660-1670, 2017.

Assessing the relevance of airborne lidar data for hyperspectral-based urban area classification

ANR HYEP 2014-2018

Deliverable WP 2.4



August 1, 2018

Versions:

v1.1: 9 January 2018
v1.2: 1 August 2018

Contributors:

Clément DECHESNE	IGN
Valérie GOUET-BRUNET	IGN
Arnaud LE BRIS	IGN
Clément MALLET	IGN

1 General flowchart

In the literature, it appears that there is no operational automatic framework that can process both hyperspectral images and lidar point clouds for land-cover mapping purposes, where both sources are equally handled, and that can satisfactorily handle a large number of classes (>5). This problem has indeed been barely investigated and only *ad hoc* methods have been developed. The proposed framework developed in the context of the HYEP project is fully automatic, modular and versatile for the task of semantic segmentation. It strongly relies on the exploitation of an existing land-cover (LC) geodatabase (in order to update and improve it), taking into account potential errors that it may contain, subsequently providing an adapted model for the studied area. The proposed framework is based on a supervised classification at the object level. It exhibits the following characteristics:

- No heavy and sensitive parameter tuning;
- Several steps can be substituted with almost equivalent solution, depending on the requirements: accuracy, speed, memory usage, etc.
- Depending on the input and the prior knowledge, one can select the shape and the level of details of the output maps.

The framework is composed of four main steps.

1. Ad-hoc features are first computed at the pixel level for the optical images and at the point level for the lidar data. An over-segmentation is then performed in order to retrieve small object that will be employed for subsequent classification. The object extracted from the over-segmentation and the computed features allow to derive features at the object level.
2. Such features are then used by the classification of the land-cover types. Indeed, performing classification at the object level significantly improves the discrimination results compared to a pixel-based classification. Here, the training set is automatically derived from an existing LC database. Specific attention is paid to the extraction of the most relevant training pixels, which is highly challenging with partly outdated and generalized vector databases.
3. Because of the high number of features, a feature selection is also carried out in order to have a more efficient classification and reduce the computational load and time, but also in order to assess the complementarity of the multi-source features (namely multispectral optical images/lidar point cloud).
4. Finally, a regularization of the label map is performed in order to remove the noise and to retrieve homogeneous land-cover patches according to a given criteria. Each step is presented in the next sections.

This framework was initially developed for **forest stand segmentation**. The land-cover classes were tree species. Such an approach was then tuned for the HYEP project to urban areas. The reader can refer to the following manuscript for more details:

C. Dechesne. *Semantic segmentation of forest stands of pure species combining airborne lidar data and very high resolution multispectral imagery*. PhD thesis, Paris Est University, 2017.

1.1 Feature extraction

The extraction of discriminative features is an important preliminary step in order to obtain an accurate classification. The features can be handcrafted. Such strategy has been extensively employed for remote sensing applications. The features could also be learned for a specific classification task using convolutional neural networks (Demuth et al., 2014). Here, the proposed features have been derived manually, since they are physically interpretable. Most are standards in the literature. The lidar features are derived at the 3D level and the spectral features at the 2D (image) level. Two strategies can be envisaged:

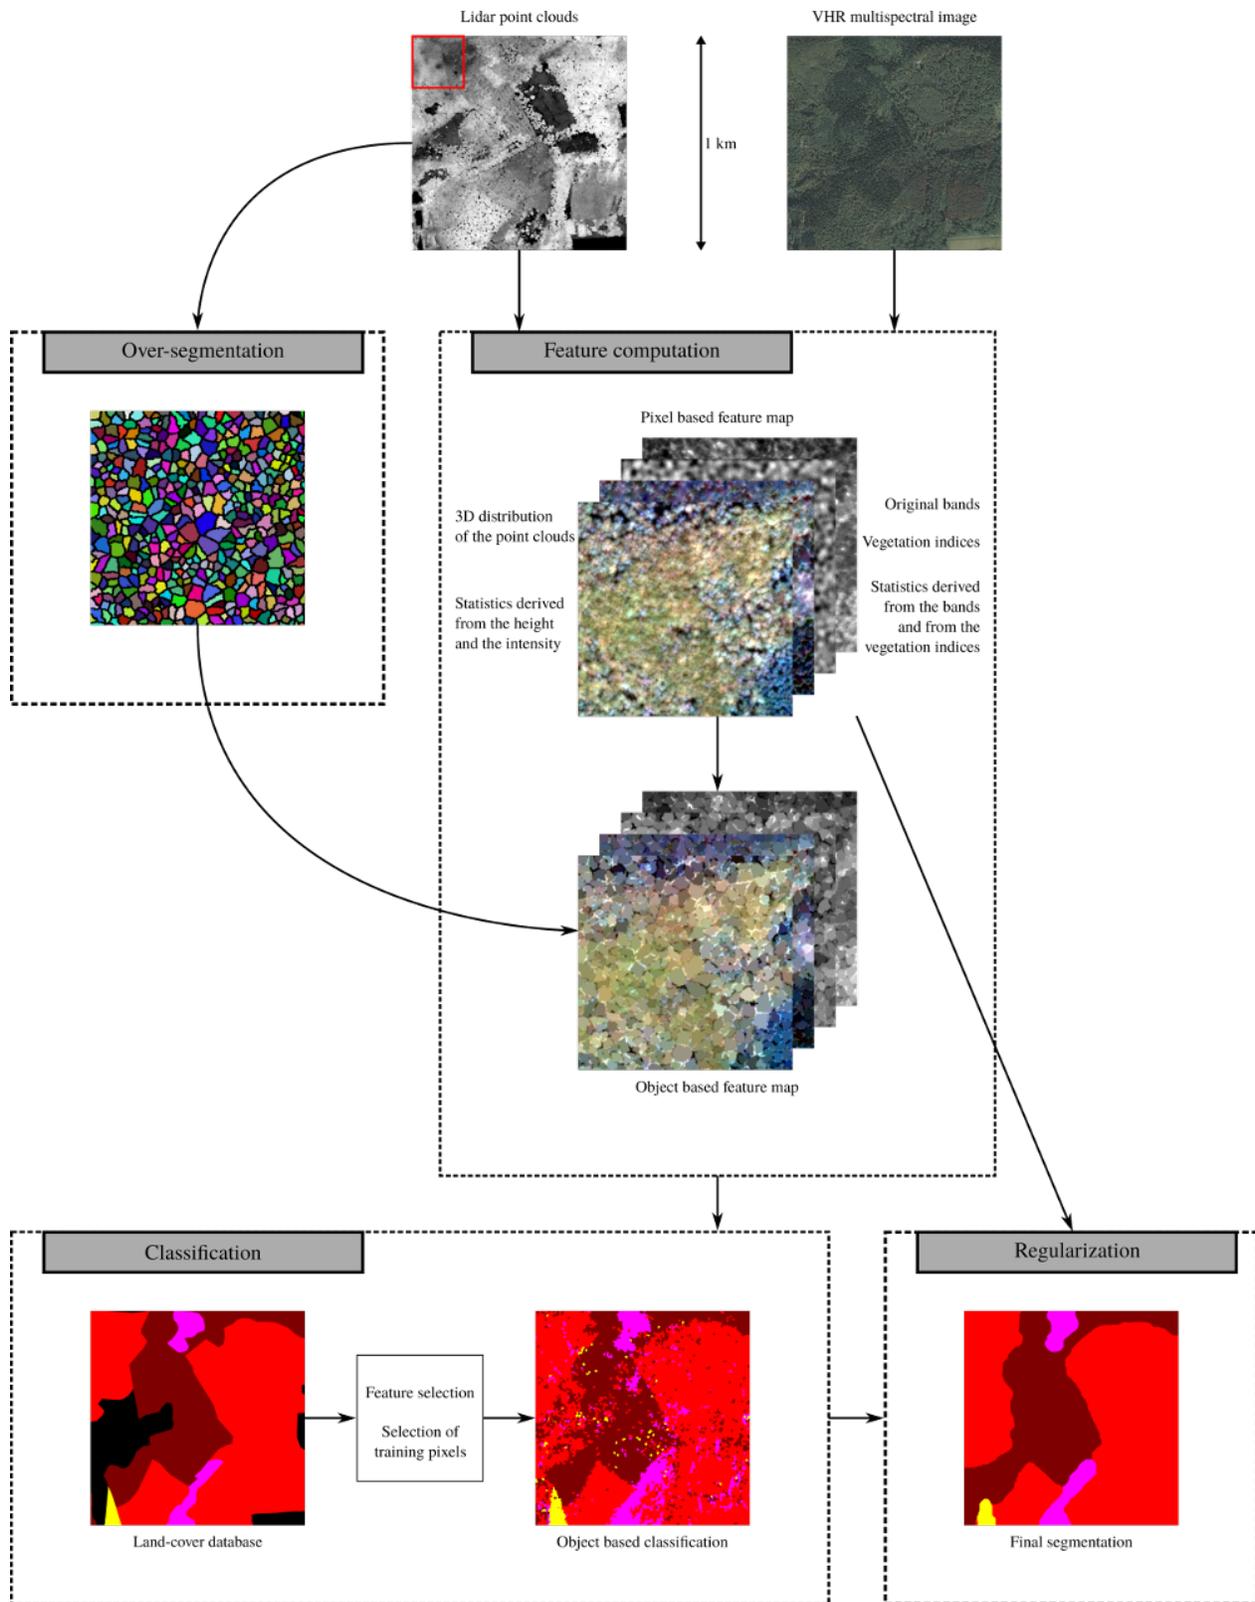


Figure 1: Flowchart of the proposed framework, see text for more details.

- The rasterization of the 3D lidar features at the same spatial resolution as the spectral features.
- The projection of the 2D spectral features in the 3D point cloud.

The projection of the 2D spectral features raises three main issues:

- In the 3D space, it is impossible to attribute a relevant spectral value to a point below the tree canopy (i.e. not visible in the optical image).
- A single pixel can be attributed to many 3D points, the information will be then duplicated. As an example for an image of 1 km² at a spatial resolution of 0.5 m there are 4 millions of pixels, while the number of 3D points is about 16 millions.
- The processing of 3D points is tedious (especially for classification and regularization) while pixels are more easy to handle.

On the opposite, the rasterization of the 3D lidar features has been widely employed, many efficient rasterization algorithms have been proposed. Thus this strategy was adopted.

1.1.1 Point-based lidar features.

24 features are extracted during this step; 2 related to vegetation density, 2 related to the 3D local distribution of the point cloud (planarity and scatter), and 20 statistical features.

Lidar-derived features require a consistent neighborhood for their computation (Demantké et al., 2011; Filin and Pfeifer, 2005). For each lidar point, 3 cylindrical neighborhoods, aligned with the vertical axis, are used (1 m, 3 m and 5 m radii, infinite height). A cylinder appears to be the most relevant environment in urban and forested areas so as to take into account the variance in altitude of the lidar points. Three radius values are considered so as to handle the various sizes of the objects (buildings and mainly trees), assuming a feature selection step will prune the initial set of attributes.

Density features.

Two vegetation density features, \mathcal{D}_1 and \mathcal{D}_2 , are computed: the first one based on the number of local height maxima within the neighborhoods, and the second one related to the number of non-ground points within the neighborhoods (ground points were previously determined by a filtering step). \mathcal{D}_1 and \mathcal{D}_2 are calculated as follows:

$$\mathcal{D}_1 = \sum_{r_1 \in \{1,3,5\}} \sum_{r_2 \in \{1,3,5\}} Nt_{r_1, r_2}, \quad (1)$$

$$\mathcal{D}_2 = \frac{1}{3} \sum_{r \in \{1,3,5\}} \frac{Ns_r}{Ntot_r}, \quad (2)$$

where Nt_{r_1, r_2} is the number of local maxima retrieved from a r_1 maximum filter within the cylindrical neighborhood of radius r_2 . Ns_r is the number of points classified as ground points within the cylindrical neighborhood of radius r and $Ntot_r$ is the total number of points within the cylindrical neighborhood of radius r . \mathcal{D}_1 describes how trees are close to each other and gives information about the tree crown width. Such information is very discriminative for tree species classification (Korpela et al., 2010). \mathcal{D}_2 provides information on the penetration rate of the lidar beam. It has been proven to be relevant for tree species classification (Vauhkonen et al., 2013).

Shape features.

Additionally, the scatter \mathcal{S} and the planarity \mathcal{P} features are computed following (Weinmann et al., 2015):

$$\mathcal{S} = \frac{1}{3} \sum_{r \in \{1,3,5\}} \frac{\lambda_{3,r}}{\lambda_{1,r}}, \quad (3)$$

$$\mathcal{P} = \frac{1}{3} \sum_{r \in \{1,3,5\}} 2 \times (\lambda_{2,r} - \lambda_{3,r}), \quad (4)$$

where $\lambda_{1,r} \geq \lambda_{2,r} \geq \lambda_{3,r}$ are the eigenvalues of the covariance matrix within the cylindrical neighborhood of radius r . They are retrieved with a standard Principal Component Analysis. They have been shown to be relevant for classification tasks (Weinmann et al., 2015).

Statistical features.

Statistical features, known to be relevant for vegetation type (mainly tree species) classification (Dalponte et al., 2014; Torabzadeh et al., 2015), are also derived. For each lidar point, the same 3 cylindrical neighborhoods are used. Two basic information from the lidar data, namely height and intensity (Kim et al., 2011), are used to derive statistical features. A statistical feature f_d , derived from an original feature f_o , (normalized height or intensity) is computed as follows:

$$f_d = \frac{1}{3} \sum_{r \in \{1,3,5\}} f_s(\mathbf{p}_r, \mathbf{f}_o), \quad (5)$$

where f_s is a statistical function, and $\mathbf{p}_r, \mathbf{f}_o$ a vector containing the sorted values of the original feature f_o within the cylindrical neighborhoods of radius r . The statistical functions f_s employed are standard ones (minimum; maximum; mean; median; standard deviation; median absolute deviation from median (*medADmed*); mean absolute deviation from median (*meanADmed*); skewness; kurtosis; 10th, 20th, 30th, 40th, 50th, 60th, 70th, 80th, 90th and 95th percentiles).

All the statistical functions are used for the height. Only the mean is used for the intensity: indeed it is hard to know how well the sensor is calibrated and a suitable correction of intensity values within tree canopies has not yet been proposed.

1.1.2 Pixel-based lidar features.

The lidar features are rasterized at the resolution of the multispectral image using a pit-free method proposed in (Khosravipour et al., 2014). Indeed, the main problem for the rasterization of lidar features is that the point density is not homogeneous, thus applying a regular grid can lead to a pixel-based feature map with pits. Therefore, a special pit-free rasterization methods need to be employed. The idea is to retain points within a cylindrical neighborhood. The axis of the cylindrical neighborhood is the center of the pixels, the radius is chosen in order to have enough retained points (at least 10). The features values of the points are weighted according to their distance to the center of the pixel. The value of the pixel is the mean of the weighted feature values of the points. The rasterization method used here is interesting because it produces smooth images, compared to rough rasterization and will lead to better results for classification and regularization (Li et al., 2013). This rasterization process at the feature level is valid since both datasets have approximately the same initial spatial resolution.

A nDSM is also computed using this method, at the same spatial resolution using an existing 1 m Digital Terrain Model computed from the initial point cloud (Ferraz et al., 2016). The nDSM is very important as it allows to derive the height above the ground and is known as a very discriminative feature for classification (Mallet et al., 2011; Weinmann, 2016). Some lidar features are presented in Figure 2.

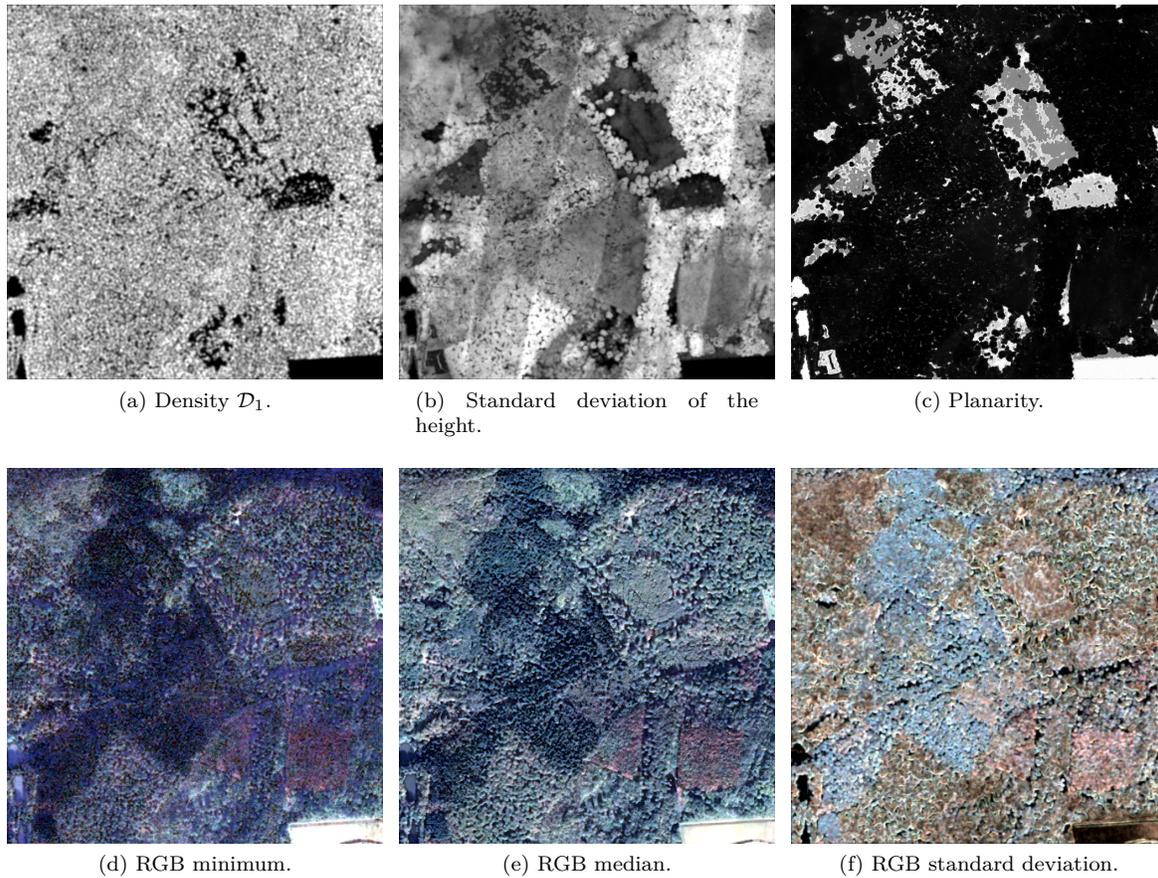


Figure 2: Some features at the pixel level (1 km²).

1.1.3 Pixel-based multispectral images features.

The original spectral bands of the VHR airborne optical image are kept and considered as multispectral features. The Normalized Difference Vegetation Index (NDVI), (Tucker, 1979), the Difference Vegetation Index (DVI), (Bacour et al., 2006) and the Ratio Vegetation Index (RVI) (Jordan, 1969) are also computed as they are standard relevant vegetation indices (Anderson and Hanson, 1992; Lee and Nakane, 1997). Many other vegetation indices have been proposed (Bannari et al., 1995) that have shown relevance for urban material and vegetation classification tasks. Indeed, they mainly provide information about the material and chlorophyll contents and are therefore more relevant for material and vegetation discrimination more than the original bands alone (Zargar et al., 2011) (emphasizing specific spectral behaviors).

As for the point-based lidar features, statistical features are also derived from each band and each vegetation index according to Equation 5 (3 circular neighborhoods of 1m, 3m and 5m radii). Other statistical functions are used (minimum; maximum; mean; median; standard deviation; mean absolute deviation from median (*meanADmed*); mean absolute deviation from mean (*meanADmean*); median absolute deviation from median (*medADmed*); median absolute deviation from mean (*medADmean*). Such features are related to texture features that are relevant for classification tasks (Haralick et al., 1973).

Finally, the pixel-based hyperpectral feature set is composed of 70 attributes. Some of these spectral features are presented in Figure 2.

The pixel-based features (lidar and spectral) that have been derived are summarized in Figure 3.

1.1.4 Object-based feature map.

The pixel-based multispectral and lidar maps are merged so as to obtain a pixel-based feature map. Then, an object-based feature map is created using the over-segmentation and the pixel-based feature map. The value v_t associated to an object t in the object-based feature map is computed as follows:

$$v_t = \frac{1}{N_t} \sum_{p \in t} v_p, \quad (6)$$

where N_t is the number of pixels in object t , and v_p is the value of the pixel p . If a pixel does not belong to an object (e.g. when the extracted objects are trees or buildings), it keeps the value of the pixel-based feature map. Here, only the mean value of the pixels within the object is envisaged but one can also consider other statistical values (minimum, maximum, percentiles etc.). It has not been considered here since it would drastically increase the total number of features and there is no warranty that such statistical values are relevant or are not redundant with the features already produced here.

Other morphological features could also be directly derived from the lidar points cloud at the object-level. For instance, an alpha-shape could be performed on the individual trees (Vauhkonen et al., 2010) and buildings, and penetration features could be derived as it can help to classify vegetation type (mainly tree species) (Ko et al., 2013). However, low point densities (1-5 points/m²) compatible with large-scale lidar surveys are not sufficient in order to derive such discriminative features, they are therefore not considered here.

An illustration of the pixel-based and object-based feature map is presented in Figure 4.

1.2 Over-segmentation

Over-segmentation proposes a full coarse partition of the area of interest. "Objects" are detected so as to ease and strengthen subsequent classification task. An accurate object extraction is not mandatory since the labels are refined after. Both 3D and 2D mono-modal solutions are investigated, depending on the input data and the desired level of detail for the objects. Indeed, multi-modal segmentation has also been proposed (Tochon, 2015) and can be adopted for over-segmentation. However, they are not employed here since they mostly aim at producing very accurate segmentation results which are not needed in this framework. In this section, the over-segmentation aims at extracting objects at the tree scale (i.e. extract trees or objects of size that are similar to trees). Individual Tree Crown (ITC) delineation is a complex task and no universal automatic solution has been proposed so far. Thus different methods have been tested in order to extract consistent objects (i.e., object similar to trees). Five existing image-based segmentation methods have been tested either on VHR optical images or rasterized lidar features. In addition a coarse 3D tree extraction method has been developed.

1.2.1 Segmentation of lidar data

Two approaches can be envisaged: the direct segmentation in 3D of the point cloud or the segmentation of a given rasterized lidar feature using standard image-based segmentation algorithms.

The tree extraction directly from the 3D point cloud is a complex task that has been widely tackled and discussed (Dalponte et al., 2014; Véga et al., 2014; Morsdorf et al., 2003; Kandare et al., 2014; Wang et al., 2016). Variations exist according to the tree species, the number of vegetation strata, forest complexity, location and data specification. However, a precise tree extraction is not needed here, since the extracted objects are only needed to improve the classification task. A coarse and standard method is therefore adopted: the tree tops are first extracted from the lidar points cloud using a local maximum filter (Figure 5b). A point is considered as a tree top when it has the highest height value within a 5 meter radius neighborhood. Only

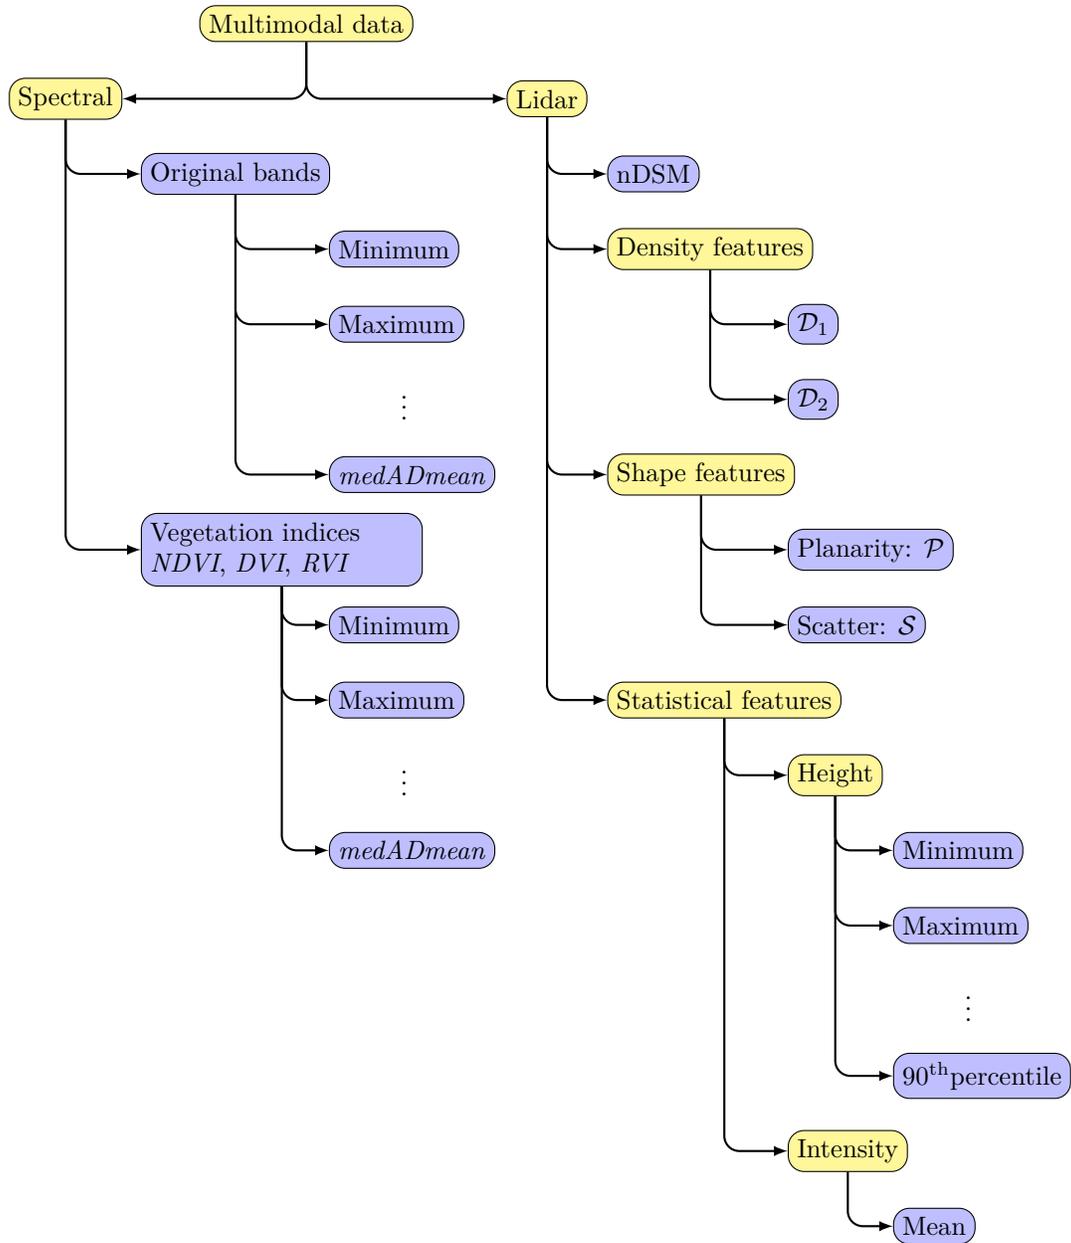


Figure 3: Features derived at the pixel level, yellow corresponds to the categories of the features, blue corresponds to the computed features.

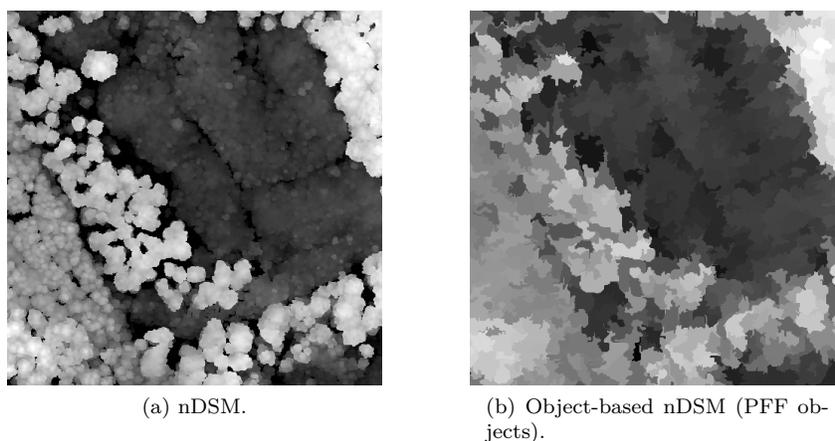


Figure 4: Illustration of the pixel-based and object-based features (250 m×250 m).

the points above 3 meters are retained as it is a common threshold of the literature (Eysn et al., 2012), and appears to be highly discriminative in non-urban areas. Points belonging to a tree are obtained through a two step procedure.

1. If the height of a point within a 5 m radius is greater or equal than 80% the height of the closest tree top, it is aggregated to the tree top (Figure 5c).
2. If the distance in the (x, y) plane between an unlabeled point and the closest tree point is smaller than 3 m they are also aggregated (Figure 5d).

This delineation method allows to discard low vegetation, but buildings might be extracted and considered as trees. However, it is not a big issue since the purpose of this segmentation is not to precisely extract trees but only provide relevant object for the subsequent object-based classification.

The segmentation of lidar data can be performed using image-based segmentation algorithm on a given rasterized lidar feature. They are mainly applied on the normalized Digital Surface Model (i.e. true height of topographic objects on the ground). Thus a method using a single feature must/can be employed. The watershed algorithm (Vincent and Soille, 1991) with specific parameters allows to obtain quickly a consistent over-segmentation of the image. A hierarchical segmentation (Guigues et al., 2006) is also relevant with the advantages that only one parameter that controls the segmentation level needs to be provided and different suitable segmentations can be obtained. These two algorithms are detailed below.

Watershed.

Watershed has been proposed after the natural observation of water raining onto a landscape topology and flowing with gravity to collect in low basins (Beucher and Lantuéjoul, 1979). The size of those basins will grow with increasing amounts of precipitation until they spill into one another, causing small basins to merge together into larger basins. Regions (catchment basins) are formed by using local geometric structure to associate points in the image domain with local extrema in some feature measurement such as curvature or gradient magnitude. This technique is less sensitive to user-defined thresholds than classic region-growing methods, and may be better suited for fusing different types of features from different data sets. The watershed technique is also more flexible in that it does not produce a single image segmentation, but rather a hierarchy of segmentations from which a single region or set of regions can be extracted a-priori (Vincent and Soille, 1991).

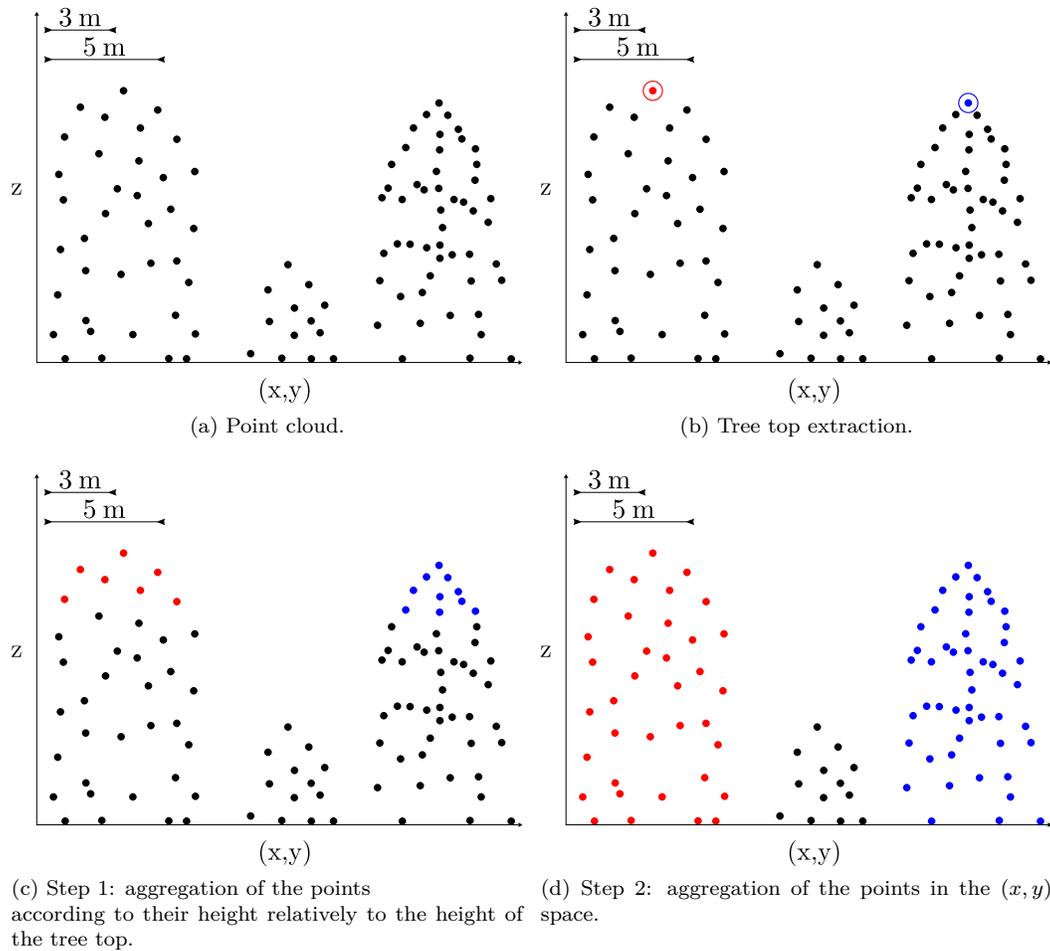


Figure 5: The proposed tree extraction procedure. Red and blue points are the points assigned to different trees, black points correspond to unlabeled points.

Hierarchical segmentation.

This segmentation method (Guigues et al., 2006) introduces a multi-scale theory of piecewise image modeling, called the scale-sets theory, and which can be regarded as a region-oriented scale-space theory. A general formulation of the partitioning problem which involves minimizing a two-term-based energy, of the form $D + \mu C$, where D is a goodness-of-fit term and C is a regularization term. Such energies arise from basic principles of approximate modeling and relate them to operational rate/distortion problems involved in lossy compression problems. An important subset of these energies constitutes a class of multi-scale energies in that the minimal cut of a hierarchy gets coarser and coarser as parameter μ increases. This allows to define a procedure to find the complete scale-sets representation of this family of minimal cuts. Considering then the construction of the hierarchy from which the minimal cuts are extracted, ending up with an exact and parameter-free algorithm to build scale-sets image descriptions whose sections constitute a monotone sequence of upward global minima of a multi-scale energy, which is called the "scale climbing" algorithm. This algorithm can be viewed as a continuation method along the scale dimension or as a minimum pursuit along the operational rate/distortion curve. Furthermore, the solution verifies a linear scale invariance property which allows to completely postpone the tuning of the scale parameter to a subsequent stage.

1.2.2 Segmentation of optical images

Many algorithms have been developed for the over-segmentation of optical RGB (Red-Green-Blue) images. Superpixels methods (Achanta et al., 2012) are specific over-segmentation methods that put a special effort on the size and shape of the extracted objects. Pseudo-superpixels can be generated using segmentation algorithms (Shi and Malik, 2000; Felzenszwalb and Huttenlocher, 2004; Comaniciu and Meer, 2002; Vedaldi and Soatto, 2008; Vincent and Soille, 1991). A special attention must be paid to the choice of the parameters. These methods produce superpixels that might not be homogeneous in terms of size and shape but with a good visual delineation. Superpixels algorithms have then been developed. They allow to control one or many parameters of the superpixels; their number, their size and their shape (Moore et al., 2008; Veksler et al., 2010; Levinshstein et al., 2009; Achanta et al., 2012).

For the over-segmentation of the optical images, we will use both "traditional" (i.e. non superpixels methods) and superpixels methods.

The three methods have been employed for the segmentation of RGB VHR optical images are detailed below:

- "PFF": A segmentation algorithm based on graph-cut (Felzenszwalb and Huttenlocher, 2004),
- Quickshift: A segmentation algorithm based on the mean shift algorithm (Vedaldi and Soatto, 2008),
- SLIC: A genuine superpixel algorithm working in the CIELab space (Achanta et al., 2012).

PFF.

This algorithm defines a predicate for measuring the evidence for a boundary between two regions using a graph-based representation of the image (Felzenszwalb and Huttenlocher, 2004). An efficient segmentation algorithm based on this predicate is employed, and shows that although this algorithm makes greedy decisions, it produces a segmentation that satisfies global properties. The algorithm runs in near linear time with the number of graph edges. An important characteristic of the method is its ability to preserve details in low-variability image regions while ignoring details in high-variability regions.

Quickshift

Quickshift (Vedaldi and Soatto, 2008) is a kernelized version of a mode seeking algorithm similar in concept to mean shift (Comaniciu and Meer, 2002; Fukunaga and Hostetler, 1975) or metroid shift (Sheikh et al., 2007). Quickshift is faster and reports better results than traditional mean shift or metroid shift for standard segmentation tasks. Given N data points x_1, \dots, x_N , it computes a Parzen density estimate around each

point using, for example, an isotropic Gaussian window of standard deviation σ :

$$P(x) = \frac{1}{2\pi\sigma^2N} \sum_{i=1}^N e^{-\frac{\|x-x_i\|^2}{2\sigma^2}} \quad (7)$$

Once the density estimate $P(x)$ has been computed, Quickshift connects each point to the nearest point in the feature space which has a higher density estimate. Each connection has a distance d_x associated with it, and the set of connections for all pixels forms a tree, where the root of the tree is the point with the highest density estimate. To obtain a segmentation from a tree of links formed by quick shift, a threshold τ is chosen and break all links in the tree with $d_x > \tau$. The pixels which are a member of each resulting disconnected tree form each segment.

SLIC superpixels.

The SLIC superpixel algorithm (Achanta et al., 2012) clusters pixels in the combined five-dimensional color (CIE Lab color space) and image plane (x,y) space to efficiently generate compact, nearly uniform superpixels. It is basically based on the k-means algorithm. The number of desired clusters corresponds to the number of desired superpixels. The employed distance is based on a weighted sum of a color based distance and a plane space distance. This method produces superpixels achieving a good segmentation quality measured by boundary recall and under-segmentation error. The benefits of superpixels approaches have already been shown, as they increase classification performance over pixel-based methods. A major advantage of this superpixels method is that the produced segments are compact and regularly distributed.

1.3 Feature selection

Due to the high number of possible features involved (95), an automatic Feature Selection (FS) step has been also integrated. This selection is composed of two steps: the choice of the number of features to select and the selection of the feature subset itself. Indeed, the choice of the number of features is very important because it enables to greatly decrease the classification complexity and computation times without limiting the classification quality.

An incremental optimization heuristic called the Sequential Forward Floating Search (SFFS) (Pudil et al., 1994) algorithm is used for both steps. The SFFS algorithm has two main advantages:

- it can be used with many FS scores (in this study, the Kappa coefficient of the classification),
- it enables to access to the evolution of the classification score/accuracy according to the number of selected features.

Here, the classification accuracy is assessed through the Kappa coefficient of the RF classifier and the SFFS algorithm selects p features by maximizing this FS score criterion. In order to retrieve the optimal number of features, the SFFS algorithm was performed n times on different sample sets (i.e., training pixels from different areas of France that exhibit different tree species) with p equal to the total number of features (95, but in order to reduce the computation times of this step, one can choose a lower value). The classification accuracy a_s is conserved for each selection of s features ($s \in \llbracket 1, p \rrbracket$) and averaged over the n iterations. The number of optimal features n_{opt} is obtained as follow:

$$n_{\text{opt}} = \operatorname{argmax}_{s \in \llbracket 1, p \rrbracket} \left(\frac{1}{n} \sum_{i=1}^n a_s \right). \quad (8)$$

It corresponds to the size of the selection of s features having the maximal mean accuracy.

The feature selection was carried out for different areas of interest (one selection for each area) with $p = n_{\text{opt}}$. The selected features then are used for both the classification (at the object level) and the energy minimization (at the pixel level) steps.

The feature selection has been carried out only once on different training sets (i.e., training pixels from 3 different regions of France that exhibit different tree species, cf Chapter ??, Section ??). The selected features are then retained as the single relevant features. It is therefore not necessary to compute the others features. Such process greatly decreases the computation times but also might reduce the performance of the classification since the selected features are relevant for many regions but not necessarily for a given area of interest.

1.4 Classification

The classification is performed using a supervised classifier, in order to discriminate the vegetation types (mainly tree species) provided by the existing forest LC DB. Only the "pure" polygons (i.e., polygons containing at least 75% of a single tree specie) are employed. The classifier used in this study is the Random Forest (RF), implemented in OpenCV (Bradski and Kaehler, 2008), as it has been extensively shown relevant in the remote sensing literature (Belgiu and Drăguț, 2016; Fernández-Delgado et al., 2014). It was compared to Support Vector Machine (SVM) (Dechesne et al., 2016), and provided similar results while being faster. The RF has many advantages:

- It can handle a large number of classes. In our problem more than 20 classes can be envisaged but in most cases the studied areas exhibit between 4 and 7 different classes.
- It is an ensemble learning method, which brings a high level of generalization.
- It can handle a large number of features, even if they are derived from different remote sensing modalities (which is the case in this study).
- The feature importance can be easily assessed.
- The posterior probabilities/uncertainties are natively obtained.
- Only few parameters are needed, the tuning of the parameters is not investigated in this study since a standard parametrization produces satisfactory results.
- It is robust to noise and mislabels (Mellor et al., 2013, 2014, 2015)

The SVM classifier is very efficient (Vapnik, 2013), however, the training of such classifier is time consuming, especially when the number of training samples increases (which is the case when the learning is based on a database). Furthermore, when using different types of features (here spectral and lidar features) a special attention should be paid to the employed kernel. The RF classifier is therefore preferred because it natively handles features of different types and works better when the number of samples increases.

The outputs of the classification are:

- a label map that allow to evaluate the accuracy of the classification,
- a probability map (posterior class probabilities for each pixel/object). This probability map is the main input for the subsequent regularization step.

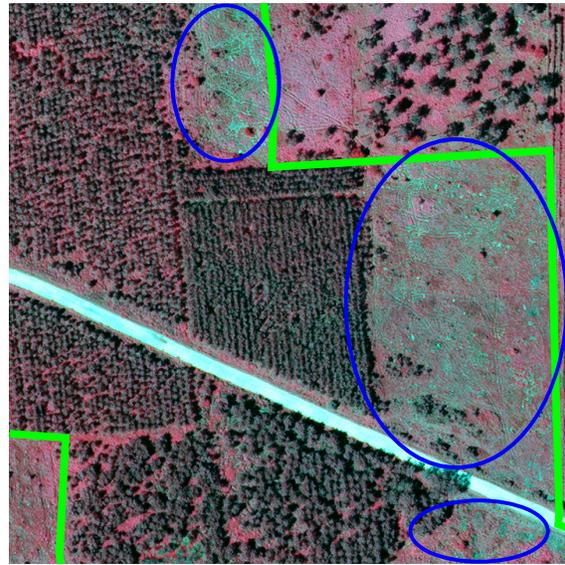
In order to overcome the issues of the generalized and partly outdated forest LC DB, a strategy is proposed in order to automatically select the most suitable training set out of an existing land-cover forest maps, subsequently improving the classification accuracy. Additionally, in order to reduce the classification complexity and computation times, a feature selection has previously carried out in order to identify an "optimal" feature subset.

1.4.1 Training set design

Using an existing LC DB to train a model is not straightforward (Pelletier et al., 2016; Gressin et al., 2013; Radoux et al., 2014; Maas et al., 2016; ?). First, locally it can suffer from a lack of semantic information (not all the classes of interest are present). Secondly, this database may also be semantically mislabeled and, more frequently, geometrically incorrect: changes may have happened (forest cut or grow, see Figure 6a) and the geodatabase may have been generalized (see Figure 6b), resulting in sharp polygon vertices that do not exactly correspond to the class borders. Thirdly, in many forest LC databases, polygons of a given vegetation type (mainly tree species) may contain other vegetation types in a small proportion. This is the case in the French forest LC DB where a vegetation type is assigned to a polygon if the latter is composed at least of 75% of this type. Such errors might highly penalize the classification (Carlotto, 2009), especially if random sampling is performed for constituting the training set. Deep neural networks can handle noisy labels without specific approach but it requires larger amount of training samples.



(a) Stand of pure *maritime pine*, green corresponds to the borders of the stand. Blue circle corresponds to hardwoods labeled as *maritime pine*.



(b) Stand of pure *maritime pine*, green corresponds to the borders of the stand. Blue circles correspond to bare soils labeled as *maritime pine*.

Figure 6: Two frequent errors in LC DB; generalization (6a) and miss-labeling/change (6b).

In order to correct the potential errors of the LC database or discard pixels that do not correspond to the class of interest, a k-means clustering has been therefore performed for each label in the training area (which is the area covered by the polygons of this label). It is assumed that erroneous pixels are present but in a small proportion and that therefore the main clusters corresponds to the class of interest. Let $p_{i-c,t}$ be the i^{th} pixel of the vegetation type (mainly tree species) t in the cluster c of the k-means. The pixels P_t used to train the model for the vegetation type (mainly tree species) t correspond to the set:

$$P_t = \{p_{i-c,t} \mid c = \operatorname{argmax}_{c \in [1,k]} \operatorname{Card}(\cup_i p_{i-c,t})\}. \quad (9)$$

That is to say, only samples belonging to the main k-means cluster among training pixels for one class are kept in the training dataset.

Such selection is a bit exclusive and does not allow a lot of variability of the selected training pixels. Thus,

a more reasonable way to select training pixels is to keep the pixels such as:

$$P_t = \{p_{i-c,t} \mid \frac{\text{Card} \left(\bigcup_{\forall i} p_{i-c,t} \right)}{\text{Card} \left(\bigcup_{\forall i, \forall c_k} p_{i-c_k,t} \right)} \geq u_p\}, \quad (10)$$

where u_p is a proportion defined by the user. Such selection is equivalent to select the pixels that are in a cluster which size represents a significant proportion of the total pixels labeled as t in the Forest LC. in this case, the number of clusters for the k-means can be increased. In the experiments, u_p was set to 0.25 (i.e. 25%) and k to 4. The second formulation is preferred since it allows to keep some inter-class variability.

1.4.2 Training and prediction

For the prediction, the RF classifier is employed. It is performed at the object level. On each area, the RF model is trained using 1000 samples per class. The samples are randomly drawn from the pixels selected by the training set design. The selected features are employed for the construction of the model and for the prediction.

Four main parameters are needed for the construction of the RF model. Firstly, the maximum number of trees in the forest needs to be set. Typically the more trees are employed, the better the accuracy is. However, the improvement in accuracy generally diminishes and asymptotes pass a certain number of trees. The number of trees increases the prediction time linearly. Here, 100 trees are computed in order to reach sufficient accuracy without huge computation times. The maximal depth of the tree needs then to be set. A low value will likely underfit and conversely a high value will likely overfit. The optimal value can be obtained using cross validation or other suitable methods but a depth of 25 is commonly accepted. The number of features employed at each tree node and that are used to find the best split(s) is another parameter. It is commonly set to the square root of the total number of features. Since 20 features are employed for the classification, this number is here set to 4. Besides, the tree computation can be stopped when each leaf of the tree has reached a sufficient purity or maximum population. Here, when the OOB error is below 0.01, the tree computation stops.

To summarize, the parameters of the RF employed in this study are the following:

- Number of trees: 100.
- Maximum depth of the trees: 25.
- Sufficient accuracy (OOB error): 0.01.
- Number of features at each tree node: 4

1.5 Regularization

The obtained classification might remain very noisy due to the complexity of the tree species discrimination task. The forest stand could not be clearly defined and a refinement should be employed in order to smooth the classification results. Many smoothing methods have been proposed and are evaluated in Chapter ?? . They can be based on the classification label map results or on a class membership probability map. More advanced framework can include object contours (Ronfard, 1994; Chan and Vese, 2001) or output of object detection for higher level regularization. Here for such unstructured environments, it does not appear to be relevant.

The smoothing is here performed at the pixel level. Both local and global methods have been investigated. The local methods only consider a limited number of pixels while the global methods consider all the pixels of the image.

The global smoothing method uses only a small number of relation between neighboring pixels (8-connexity) to describe the smoothness. An energy is computed and its minimum leads to a smoothed result. The energy $E(I, C, A)$ for an image I is expressed as follows:

$$E(I, C, A) = \sum_{\mathbf{u} \in I} E_{\text{data}}(\mathbf{u}, P(C(\mathbf{u}))) + \gamma \sum_{\mathbf{u} \in I, \mathbf{v} \in \mathcal{N}_{\mathbf{u}}} E_{\text{pairwise}}(\mathbf{u}, \mathbf{v}, C(\mathbf{u}), C(\mathbf{v}), A(\mathbf{u}), A(\mathbf{v})), \quad (11)$$

where $A(\mathbf{u})$ is a vector of the values of the features at pixel \mathbf{u} to be selected so as to constrain the problem according to a given criterion (height for instance) and $\mathcal{N}_{\mathbf{u}}$ is the 8-connexity neighborhood of the pixel \mathbf{u} . When $\gamma = 0$, the pairwise prior term has no effect in the energy formulation; the most probable class is attributed to the pixel, leading to the same result as the classification output. When $\gamma > 0$, the resulting label map becomes more homogeneous.

In spite of having only connections between local neighbors, the optimization propagates information over large distances (Schindler, 2012). The problem is NP-hard to solve but an efficient algorithm called Quadratic Pseudo-Boolean Optimization (QPBO) allows to efficiently solve it.

The principal difficulty lies in the formulation of E_{data} and E_{pairwise} , several formulation are investigated in Chapter ???. The ones that produce the best results and were finally retained are defined as follows:

$$E_{\text{data}} = 1 - P(C(\mathbf{u})). \quad (12)$$

$$E_{\text{pairwise}}(C(\mathbf{u}) = C(\mathbf{v})) = 0, \quad (13)$$

$$E_{\text{pairwise}}(C(\mathbf{u}) \neq C(\mathbf{v})) = \frac{1}{n} \sum_{i=1}^n \exp(-\lambda_i |A_i(\mathbf{u}) - A_i(\mathbf{v})|),$$

where $A_i(\mathbf{u})$ is the value of the i^{th} feature of the pixel \mathbf{u} and $\lambda_i \in \mathbb{R}^{+*}$ the importance given to feature i in the regularization (λ_i are set to 1 $\forall i$). To compute such energy, the features need to be first normalized (i.e., zero mean, unit standard deviation) in order to ensure that they all have the same range.

1.6 Conclusion and discussions

In this contribution, an automatic framework for the extraction of forest stand has been proposed. It is composed of four main steps. An over-segmentation is firstly performed in order to retrieve small object that will be employed for subsequent classification. Multi-modal features are computed at the pixel level and object level. Because of the high number of features, a feature selection is also carried out in order to have a more efficient classification and reduce the computational load and time, but also in order to assess the complementarity of the multi-modal features. Classification is then performed at the object level since it improves the discrimination of tree species. When training this classifier, a specific attention is paid to the design of the training set, in order to cope with the errors of the Forest LC DB. Finally, a regularization of the label map is performed in order to remove the noise and to retrieve homogeneous forest stands according to a given criteria (here tree species).

The contribution of our framework is multiple:

- The extraction of features from VHR optical images and lidar 3D point cloud. From the VHR optical images, vegetation indices are derived. From the original bands and the vegetation indices, statistical features are derived. From the lidar point cloud, 3 types of features are extracted. The first ones are related to vegetation density. The seconds are related to the local shape of the lidar point cloud. Finally, statistical features (related to height or intensity of the 3D points) are extracted.
- The feature selection that allow to reduce computation times. It also allow to assess the relevance of the extracted feature and the complementarity of data sources. It is perform using an incremental

optimization heuristic called the Sequential Forward Floating Search based on the κ of the Random Forest.

- The classification is performed using the Random Forest classifier. A special attention is paid to the selection of training pixel using unsupervised classification algorithm (namely *k-means*). The training of the classifier is performed with standard parameters.
- The regularization can be performed using local or global methods. It is possible to integrate informations from the derived features. The regularization allows to smooth the classification that might be noisy. It is a necessary step in order to obtain relevant forest stands.

The use of deep-based features could be interesting since they produce good discrimination results for remote sensing application (Kontschieder et al., 2015). Furthermore, such methods can also be employed for classification, reporting good results (Paisitkriangkrai et al., 2016; Workman et al., 2017). However, since we wanted to draw the best from the data sources (especially lidar), handcrafted features have been preferred. Indeed, the integration of lidar is generally limited to a simple nDSM (Audebert et al., 2016).

2 Flowchart assessment

2.1 Data

An airborne Very High Resolution optical image coupled with a 3D lidar point cloud (Optech 3100EA device) acquired over the city of Toulouse (France) were used for this study. Forested areas were first processed so as to validate the proposed framework, that was subsequently applied on our urban area. The lidar footprint was 0.8m in order to increase the probability of the laser beam to reach the ground and subsequently acquire ground points, below tree canopy. The point density for all echoes ranges from 2 to 4 points/m². The points are given with an intensity value that correspond to the quantity of energy that came back to the sensor. Such information is hard to interpret since the beam might have been reflected multiple times and it is therefore difficult to calibrate the sensor, even in urban areas.

A prerequisite for data fusion is the most accurate alignment of the two remote sensing data sources (Torabzadeh et al., 2014). A frequently used technique is to geo-rectify images using ground controls points (GCPs). A geometric transformation is established between the coordinates of GCPs and their corresponding pixels in the image or 3D point in the point cloud. It is then applied to each pixel/point, so that coordinate differences on those points are reduced to the lowest possible level. This method can be easily applied and is relatively fast in terms of computation time.

The land-cover database used for training and evaluation corresponds to the ground truth available within the HYEP project over the city of Toulouse. We limited ourselves to 5 main classes: *building*, *road*, *water*, *railways*, *vegetation*, for which lidar point clouds can have a certain contribution. Indeed, it is worthless discriminating roof and ground material with lidar point clouds if the targets exhibit the same geometry. As mentioned above, the spectral content of lidar is currently weak, especially without decent correction and calibration steps.

2.2 Experiments

The proposed framework is composed of different steps that were evaluated separately on a forested area. Each step was evaluated at two levels; the direct output was first considered and the impact on the final segmentation was also investigated. This allowed us to define a standard pipeline:

- Feature selection:
 - Selection of training samples, to cope with the potential errors in the land-cover database (LC DB),
 - Selection of 20 features,

- Object-based features (lidar and spectral) obtained from the PFF over-segmentation,
- Pixel-based features (lidar and spectral) for the regularization.
- Classification performed with:
 - Selection of 500 per class training samples ($k = 4$ and clusters that amount for more than 25% of the total labeled pixel of the processed class are kept), to cope with the LC DB errors,
 - Object-based features (lidar and spectral) obtained from the feature selection.
- Regularization using global method with:
 - $\gamma = 10$,
 - Linear data formulation for the unary term,
 - *Exponential-feature model* with pixel-based features obtained from the feature selection.

The validity of the framework was assessed by a visual analysis and 4 standard accuracy metrics that are derived from the confusion matrices. The employed metrics are the Intersection over Union (IoU), the mean F-score, the overall accuracy and the κ coefficient. They are standard metrics for the evaluation of a classification/object detection: they are not detailed here.

2.3 Computation times

In the proposed framework, the object-extraction step is the only step that exhibits different computation times depending on the over-segmentation method employed. All these methods are fast (less than 5 minutes for a 1 km² area), except for the tree extraction from the Lidar point cloud. Indeed, the tree extraction needs to iterate several times on all the points from the lidar cloud, leading to high computation times (about 1 h 30 for a 1 km² area). These computation times, with regard to results of the over-segmentation methods confirm that the tree extraction is not necessary. It produces similar results compared to other methods, but with higher computation times.

For the other steps of the framework, the computation times are presented in Table 1. The computation of the features is the most time consuming step (2 h). The feature selection (1 h) here appears also quite long but can easily be reduced if necessary (e.g., by employing an other method). The implementation of the different steps of the framework can be improved). This times are provided for the retrieval of the best features within the whole feature set. However, once they are identified, only a limited number of optimal features needs to be computed. It results in a decrease of the computation times (less features are computed and no feature selection is carried out). Initial, the proposed framework takes 4 h for 1 km², with optimal features identified, it takes 1 h 30.

	Computation time
<i>Lidar features (all)</i>	~ 1 h
<i>Optical features (all)</i>	~ 1 h
<i>Object-based feature map</i>	~ 10 min
<i>Feature selection</i>	~ 1 h
<i>Classification</i>	~ 10 min
<i>Regularization</i>	~ 30 min
<i>Full algorithm</i>	~ 4 h

Table 1: Average computation times of the different steps of the framework for a 1 km² area.

3 Results

The 5-class outputs of our method over the city of Toulouse (Figure 7) are available in Figure 8, before and after regularization and with different regularization levels. Quantitative assessment was also performed and is provided in Table 2.

One can first see that the map stemming from the direct object-based classification step is already of satisfactory quality with limited noise. A limited regularization ($\gamma=2$) also slightly smooths the results and provides a more coherent classification map. Better results are also noticed for the four metrics. Qualitatively, main contours of the objects remain preserved, conversely to a more significant smoothing with $\gamma=10$. Most of the contours are blurred, resulting in a progressive disappearance of thin objects, and in particular roads. Since the ground truth is not dense enough, accuracy metrics increase with higher smoothing, despite a less meaningful result. Once again, it advocates for a denser ground truth for hyperspectral mapping in urban areas.

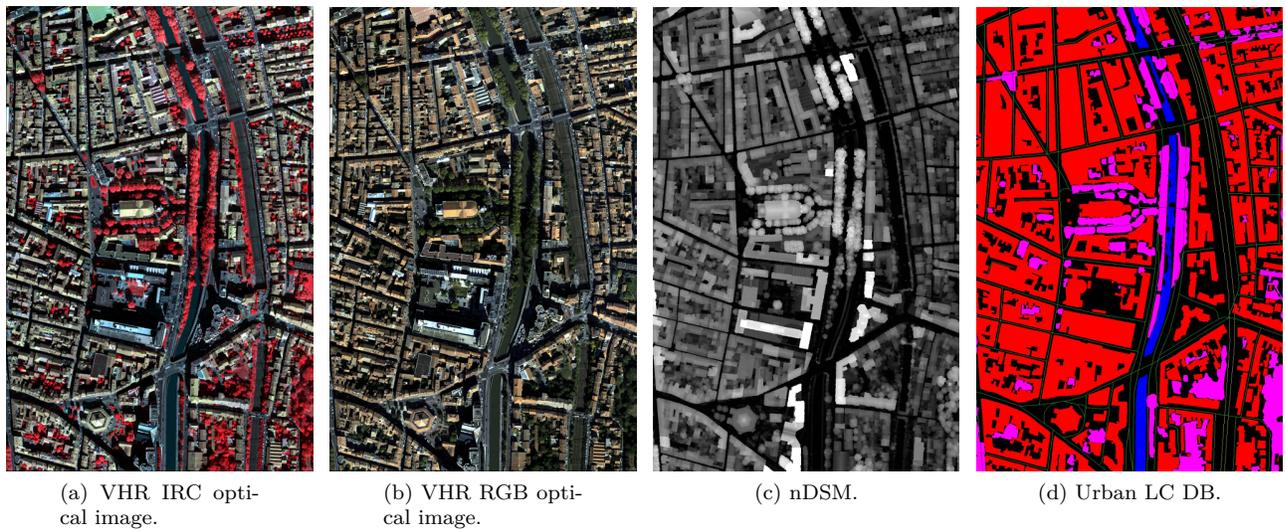


Figure 7: VHR optical images, rasterized nDSM and urban LC of the urban area (600 m×900 m). Color code: ● building, ● road, ● water, ● railways, ● vegetation.

Metric	Classification	Regularization ($\gamma = 2$)	Regularization ($\gamma = 10$)
OA	86.48	88	90.16
κ	0.6887	0.7172	0.7551
F-score	74.57	77	78.66
IoU	64.33	67.6	70.25

Table 2: Accuracy metrics of the different results of the method on the urban area.

4 Conclusion

4.1 Final outlook

The fusion was operated at different levels in each step of the framework.

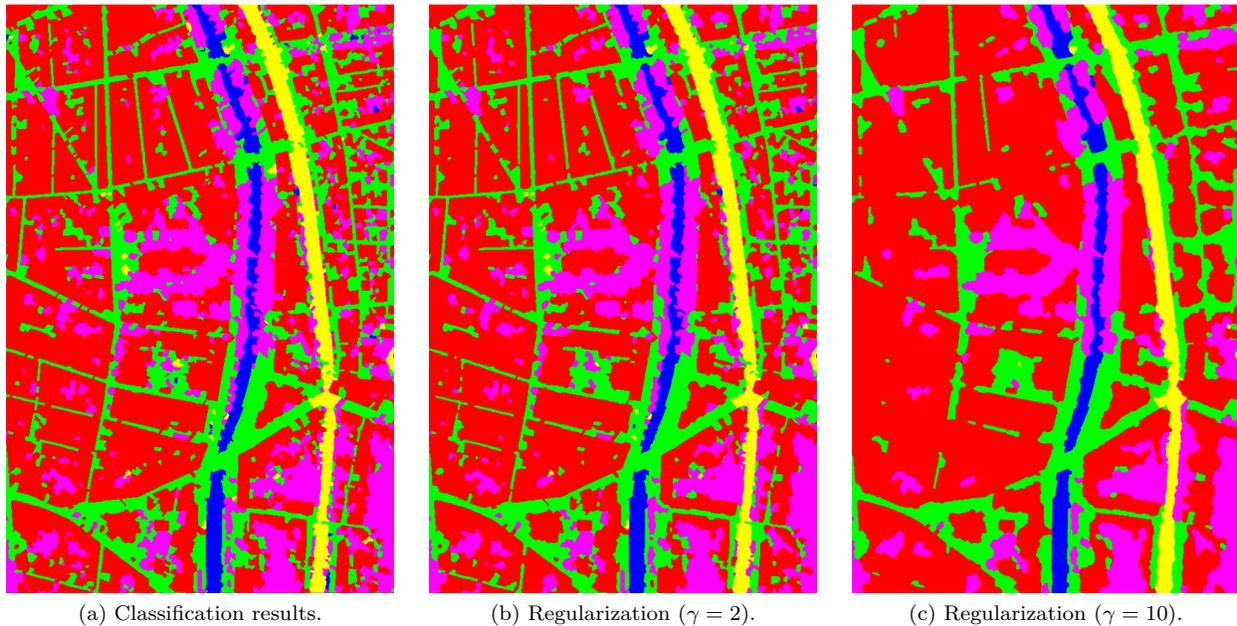


Figure 8: Results of the proposed method on the urban area (600 m×900 m). Color code: ● building, ● road, ● water, ● railways, ● vegetation.

- In the feature computation step, the data and algorithm employed for the object extraction correspond to a medium level of fusion and more precisely to a cooperative understanding of the data.
- In the classification step, the fusion is operated at both low and medium level. The feature selection has selected a relevant amount of features among the 95 available (70 spectral-based + 25 Lidar-based). The selected features are employed for the supervised classification and show the complementarity of both data sources.
- In the regularization step, the fusion can be performed at the high and medium level (since the output of the classification and features are jointly employed) when a global model that takes into account features is employed. In such model, the classification output (posterior probabilities) and the features values are both employed in order to obtain a final smooth decision.

Here, the modularity of the framework allows to efficiently assess where the fusion is crucial. We can conclude that there is not a single best fusion scheme;

- In the feature computation step, the object extraction has not an important impact on the final results. It only slightly impacts the classification results. Thus any over-segmentation method can be employed. For better classification results, an over-segmentation based on VRH optical image is recommended.
- In the classification step, both spectral and Lidar features are required. Indeed, even with an unbalanced proportion of spectral features (70 over 95) and Lidar features (25 over 95), 60% of the selected features are spectral-based features and 40% are Lidar-based features. When employing only a single data source in the classification, the accuracy of the results greatly decreases. The fusion is crucial in the classification step. The two remote sensing modalities are here complementary.
- In the regularization step, when not taking into account the features through global methods, the obtained results already report very good accuracies. Slightly better results can be obtained when

employing feature values in the energy formulation. Here again, employing both data sources leads to the best results (but is not mandatory).

Eventually, it appears that Lidar is only useful in the classification process. This is probably due to the low point cloud density. If the spectral information allows to discriminate efficiently the tree species, ground and roof material, lidar provides information about the vertical structure of the forest and sharp delineation of objects.

4.2 Perspectives

New features could be derived when employing other data sources. However, even with VHR optical images and low density lidar, other meaningful features that have not been tested in this work could be envisaged. The most interesting and obvious possibility would be to derive deep-based features. Indeed, deep-learning algorithms allow to directly learn features. It may appear interesting in such an unstructured environment. Deep-based features are optimal for specific classification tasks and can be employed as an input of traditional classification algorithms (such as Random Forest or Support Vector Machines) (Kontschieder et al., 2015). The classification could also be performed directly using deep neural networks (Paisitkriangkrai et al., 2016, 2015; Wegner et al., 2016; Workman et al., 2017). They have shown to deliver better results than traditional classification algorithms. The main advantage of the deep methods is that once a model is learned, it can be applied to other areas without being retrained. Postadjian et al. (2017) have shown that it is possible to automatically derive training samples from noisy LC DB for large scale classification. No preprocessing is required and the training procedure is validated at very large scales ($> 10000 \text{ km}^2$). Indeed, the model can be refined for small costs, leading to better results. The main drawback of these methods is their training times and system requirement; even if the transfer is important, the training of such model needs specific architecture and graphic cards.

Efforts could be envisaged on the smoothing methods. One can consider fusion of different complementary classification outputs (Ouerghemmi et al., 2017). Thus, the integration of a classification from different data sources at different spatial resolutions could be assessed.

Finally, for urban areas, the results could be improved with two procedures:

- Extracting features that are more related to urban environments,
- Propose a new formulation of the energy that can take into account the variation in the gradient of height (i.e. integrate borders constraints) and/or continuity in classes (e.g. roads are connected to each other) (Wegner et al., 2015, 2013), and/or meaningful transition between classes (Volpi and Ferrari, 2015).

5 Papers

5.1 Main papers before HYEP

1. C. Berger, F. Riedel, J. Rosentreter, E. Stein, S. Hese, "Fusion of Airborne Hyperspectral and LiDAR Remote Sensing Data to Study the Thermal Characteristics of Urban Environments", *Computational Approaches for Urban Environments*, Springer pp. 273-292, 2015.
2. C. Debes, A. Merentitis, R. Heremans, J. Han et al., "Hyperspectral and LiDAR Data Fusion: Outcome of the 2013 GRSS Data Fusion Contest", *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, volume 7(6), pp. 2405-2418, 2014.

5.2 Main papers published in the remote sensing community during HYEP

1. L. Liu, N.C. Coops, N.W. Aven, Y. Pang, "Mapping urban tree species using integrated airborne hyperspectral and LiDAR remote sensing data", *Remote Sensing of Environment* volume 200, pp. 170-182, 2017.

2. M. Zhang, P. Ghamisi, and W. Li, "Classification of hyperspectral and LiDAR data using extinction profiles with feature fusion", *Remote Sensing Letters*, volume 8(10), pp. 957-966, 2017.
3. P. Ghamisi, B. Hofle, X. X. Zhu, "Hyperspectral and LiDAR Data Fusion Using Extinction Profiles and Deep Convolutional Neural Network", *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, volume 10(6), pp. 3011-3024, 2017.
4. M. Khodadadzadeh, J. Li, S. Prasad, A. Plaza. Fusion of Hyperspectral and LiDAR Remote Sensing Data Using Multiple Feature Learning, "IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing", volume 8(6), pp. 2971-2983, 2015.

5.3 Main papers published by HYEP partners

1. C. Dechesne, C. Mallet, A. Le Bris, V. Gouet-Brunet, "Semantic segmentation of forest stands of pure species combining airborne lidar data and very high resolution multispectral imagery". *ISPRS Journal of Photogrammetry and Remote Sensing*, volume 126 (2017), pp.129-145, 2017.
2. C. Dechesne, C. Mallet, A. Le Bris, V. Gouet-Brunet, "Semantic segmentation of forest stands of pure specie as a global optimisation problem", *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2017.
3. C. Dechesne, C. Mallet, A. Le Bris, V. Gouet-Brunet, "Segmentation sémantique de données de télédétection multimodale : application aux peuplements forestiers", ORASIS, Colleville-sur-Mer, France, June 2017.

References

- Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P., and Süsstrunk, S. (2012). Slic superpixels compared to state-of-the-art superpixel methods. *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)*, 34(11):2274–2282. 10, 11
- Anderson, G. L. and Hanson, J. (1992). Evaluating hand-held radiometer derived vegetation indices for estimating above ground biomass. *Geocarto International*, 7(1):71–78. 5
- Audebert, N., Le Saux, B., and Lefèvre, S. (2016). Semantic segmentation of earth observation data using multimodal and multi-scale deep networks. In *Asian Conference on Computer Vision*, pages 180–196. Springer. 16
- Bacour, C., Bréon, F.-M., and Maignan, F. (2006). Normalization of the directional effects in NOAA–AVHRR reflectance measurements for an improved monitoring of vegetation cycles. *Remote Sensing of Environment*, 102(3):402–413. 5
- Bannari, A., Morin, D., Bonn, F., and Huete, A. (1995). A review of vegetation indices. *Remote Sensing Reviews*, 13(1-2):95–120. 5
- Belgiu, M. and Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114:24–31. 12
- Beucher, S. and Lantuéjoul, C. (1979). Use of watersheds in contour detection. 8
- Bradski, G. and Kaehler, A. (2008). *Learning OpenCV: Computer vision with the OpenCV library*. " O'Reilly Media, Inc.". 12
- Carlotto, M. J. (2009). Effect of errors in ground truth on classification accuracy. *International Journal of Remote Sensing*, 30(18):4831–4849. 13

- Chan, T. F. and Vese, L. A. (2001). Active contours without edges. *IEEE Transactions on image processing*, 10(2):266–277. 14
- Comaniciu, D. and Meer, P. (2002). Mean shift: A robust approach toward feature space analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(5):603–619. 10
- Dalponte, M., Ørka, H. O., Ene, L. T., Gobakken, T., and Næsset, E. (2014). Tree crown delineation and tree species classification in boreal forests using hyperspectral and ALS data. *Remote Sensing of Environment*, 140:306–317. 4, 6
- Dechesne, C., Mallet, C., Le Bris, A., Gouet-Brunet, V., and Hervieu, A. (2016). Forest stand segmentation using airborne lidar data and very high resolution multispectral imagery. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 41-B3, pages 207–214. 12
- Demantké, J., Mallet, C., David, N., and Vallet, B. (2011). Dimensionality based scale selection in 3d lidar point clouds. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 38(Part 5):W12. 3
- Demuth, H. B., Beale, M. H., De Jess, O., and Hagan, M. T. (2014). *Neural network design*. Martin Hagan. 1
- Eysn, L., Hollaus, M., Schadauer, K., and Pfeifer, N. (2012). Forest delineation based on airborne lidar data. *Remote Sensing*, 4(3):762–783. 8
- Felzenszwalb, P. F. and Huttenlocher, D. P. (2004). Efficient graph-based image segmentation. *International Journal of Computer Vision*, 59(2):167–181. 10
- Fernández-Delgado, M., Cernadas, E., Barro, S., and Amorim, D. (2014). Do we need hundreds of classifiers to solve real world classification problems. *J. Mach. Learn. Res*, 15(1):3133–3181. 12
- Ferraz, A., Mallet, M., and Chehata, N. (2016). Large-scale road detection in forested mountainous areas using airborne topographic lidar data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 112:23 – 36. 4
- Filin, S. and Pfeifer, N. (2005). Neighborhood systems for airborne laser data. *Photogrammetric Engineering & Remote Sensing*, 71(6):743–755. 3
- Fukunaga, K. and Hostetler, L. (1975). The estimation of the gradient of a density function, with applications in pattern recognition. *IEEE Transactions on Information Theory*, 21(1):32–40. 10
- Gressin, A., Mallet, C., Vincent, N., and Paparoditis, N. (2013). Updating land cover databases using a single very high resolution satellite image. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, II-3/W2:13–18. 13
- Guigues, L., Cocquerez, J.-P., and Le Men, H. (2006). Scale-sets image analysis. *IJCV*, 68(3):289–317. 8, 10
- Haralick, R. M., Shanmugam, K., and Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, (6):610–621. 5
- Jordan, C. F. (1969). Derivation of leaf-area index from quality of light on the forest floor. *Ecology*, 50(4):663–666. 5
- Kandare, K., Dalponte, M., Gianelle, D., and Chan, J. C.-W. (2014). A new procedure for identifying single trees in understory layer using discrete lidar data. In *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pages 1357–1360. 6
- Khosravipour, A., Skidmore, A. K., Isenburg, M., Wang, T., and Hussin, Y. A. (2014). Generating pit-free canopy height models from airborne lidar. *Photogrammetric Engineering & Remote Sensing*, 80(9):863–872. 4

- Kim, S., Hinckley, T., and Briggs, D. (2011). Classifying individual tree genera using stepwise cluster analysis based on height and intensity metrics derived from airborne laser scanner data. *Remote sensing of environment*, 115(12):3329–3342. 4
- Ko, C., Sohn, G., and Rimmel, T. K. (2013). Tree genera classification with geometric features from high-density airborne lidar. *Canadian Journal of Remote Sensing*, 39(s1):S73–S85. 6
- Kontschieder, P., Fiterau, M., Criminisi, A., and Rota Bulo, S. (2015). Deep neural decision forests. In *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, pages 1467–1475. 16, 20
- Korpela, I., Ørka, H. O., Maltamo, M., Tokola, T., and Hyyppä, J. (2010). Tree species classification using airborne lidar—effects of stand and tree parameters, downsizing of training set, intensity normalization, and sensor type. *Silva Fennica*, 44(2):319–339. 3
- Lee, N. J. and Nakane, K. (1997). Forest vegetation classification and biomass estimation based on landsat tm data in a mountainous region of west japan. In *The use of remote sensing in the modeling of forest productivity*, pages 159–171. Springer. 5
- Levinshtein, A., Stere, A., Kutulakos, K. N., Fleet, D. J., Dickinson, S. J., and Siddiqi, K. (2009). Turbopixels: fast superpixels using geometric flows. *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)*, 31(12):2290–2297. 10
- Li, J., Hu, B., and Noland, T. L. (2013). Classification of tree species based on structural features derived from high density lidar data. *Agricultural and Forest Meteorology*, 171&172:104 – 114. 4
- Maas, A., Rottensteiner, F., and Heipke, C. (2016). Using label noise robust logistic regression for automated updating of topographic geospatial databases. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, III-7:133–140. 13
- Mallet, C., Bretar, F., Roux, M., Soergel, U., and Heipke, C. (2011). Relevance assessment of full-waveform lidar data for urban area classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(6):S71–S84. 4
- Mellor, A., Boukir, S., Haywood, A., and Jones, S. (2014). Using ensemble margin to explore issues of training data imbalance and mislabeling on large area land cover classification. In *IEEE International Conference on Image Processing (ICIP)*, pages 5067–5071. 12
- Mellor, A., Boukir, S., Haywood, A., and Jones, S. (2015). Exploring issues of training data imbalance and mislabelling on random forest performance for large area land cover classification using the ensemble margin. *ISPRS Journal of Photogrammetry and Remote Sensing*, 105:155–168. 12
- Mellor, A., Haywood, A., Stone, C., and Jones, S. (2013). The performance of random forests in an operational setting for large area sclerophyll forest classification. *Remote Sensing*, 5(6):2838–2856. 12
- Moore, A. P., Prince, S. J., Warrell, J., Mohammed, U., and Jones, G. (2008). Superpixel lattices. In *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 1–8. 10
- Morsdorf, F., Meier, E., Allgöwer, B., and Nüesch, D. (2003). Clustering in airborne laser scanning raw data for segmentation of single trees. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 34(part 3):W13. 6
- Ouerghemmi, W., Le Bris, A., Chehata, N., and Mallet, C. (2017). A two-step decision fusion strategy: application to hyperspectral and multispectral images for urban classification. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, 42. 20
- Paisitkriangkrai, S., Sherrah, J., Janney, P., and Hengel, V. (2015). Effective semantic pixel labelling with convolutional networks and conditional random fields. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 36–43. 20

- Paisitkriangkrai, S., Sherrah, J., Janney, P., and Van Den Hengel, A. (2016). Semantic labeling of aerial and satellite imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(7):2868–2881. 16, 20
- Pelletier, C., Valero, S., Inglada, J., Champion, N., and Dedieu, G. (2016). Assessing the robustness of random forests to map land cover with high resolution satellite image time series over large areas. *Remote Sensing of Environment*, 187:156–168. 13
- Postadjian, T., Le Bris, A., Sahbi, H., and Mallet, C. (2017). Investigating the potential of deep neural networks for large-scale classification of very high resolution satellite images. *ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences*, 4. 20
- Pudil, P., Novovičová, J., and Kittler, J. (1994). Floating search methods in feature selection. *Pattern Recognition Letters*, 15(11):1119–1125. 11
- Radoux, J., Lamarche, C., Van Bogaert, E., Bontemps, S., Brockmann, C., and Defourny, P. (2014). Automated training sample extraction for global land cover mapping. *Remote Sensing*, 6(5):3965. 13
- Ronfard, R. (1994). Region-based strategies for active contour models. *International Journal of Computer Vision*, 13(2):229–251. 14
- Schindler, K. (2012). An overview and comparison of smooth labeling methods for land-cover classification. *IEEE Transactions on Geoscience and Remote Sensing*, 50(11):4534–4545. 15
- Sheikh, Y. A., Khan, E. A., and Kanade, T. (2007). Mode-seeking by medoidshifts. In *IEEE International Conference on Computer Vision (ICCV)*, pages 1–8. 10
- Shi, J. and Malik, J. (2000). Normalized cuts and image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)*, 22(8):888–905. 10
- Tochon, G. (2015). *Hierarchical analysis of multimodal images*. PhD thesis, Université Grenoble Alpes. 6
- Torabzadeh, H., Leiterer, R., Schaepman, M., and Morsdorf, F. (2015). Optimal structural and spectral features for tree species classification using combined airborne laser scanning and hyperspectral data. In *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pages 5399–5402. 4
- Torabzadeh, H., Morsdorf, F., and Schaepman, M. E. (2014). Fusion of imaging spectroscopy and airborne laser scanning data for characterization of forest ecosystems—a review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 97:25–35. 16
- Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote sensing of Environment*, 8(2):127–150. 5
- Vapnik, V. (2013). *The nature of statistical learning theory*. Springer Science & Business Media. 12
- Vauhkonen, J., Hakala, T., Suomalainen, J., Kaasalainen, S., Nevalainen, O., Vastaranta, M., Holopainen, M., and Hyyppä, J. (2013). Classification of spruce and pine trees using active hyperspectral lidar. *IEEE Geoscience and Remote Sensing Letters*, 10(5):1138–1141. 3
- Vauhkonen, J., Korpela, I., Maltamo, M., and Tokola, T. (2010). Imputation of single-tree attributes using airborne laser scanning-based height, intensity, and alpha shape metrics. *Remote Sensing of Environment*, 114(6):1263–1276. 6
- Vedaldi, A. and Soatto, S. (2008). Quick shift and kernel methods for mode seeking. *Computer vision—ECCV 2008*, pages 705–718. 10
- Véga, C., Hamrouni, A., El Mokhtari, S., Morel, J., Bock, J., Renaud, J.-P., Bouvier, M., and Durrieu, S. (2014). Ptrees: a point-based approach to forest tree extraction from lidar data. *International Journal of Applied Earth Observation and Geoinformation*, 33:98–108. 6

- Veksler, O., Boykov, Y., and Mehrani, P. (2010). Superpixels and supervoxels in an energy optimization framework. *Computer Vision–ECCV 2010*, pages 211–224. 10
- Vincent, L. and Soille, P. (1991). Watersheds in digital spaces: an efficient algorithm based on immersion simulations. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, (6):583–598. 8, 10
- Volpi, M. and Ferrari, V. (2015). Semantic segmentation of urban scenes by learning local class interactions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, pages 1–9. 20
- Wang, Y., Hyypä, J., Liang, X., Kaartinen, H., Yu, X., Lindberg, E., Holmgren, J., Qin, Y., Mallet, C., Ferraz, A., Torabzadeh, H., Morsdorf, F., Zhu, L., Liu, J., and Alho, P. (2016). International benchmarking of the individual tree detection methods for modeling 3d canopy structure for silviculture and forest ecology using airborne laser scanning. *IEEE Transactions on Geoscience and Remote Sensing*, 154(9):501–502. 6
- Wegner, J. D., Branson, S., Hall, D., Schindler, K., and Perona, P. (2016). Cataloging public objects using aerial and street-level images-urban trees. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 6014–6023. 20
- Wegner, J. D., Montoya-Zegarra, J. A., and Schindler, K. (2013). A higher-order crf model for road network extraction. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 1698–1705. 20
- Wegner, J. D., Montoya-Zegarra, J. A., and Schindler, K. (2015). Road networks as collections of minimum cost paths. *ISPRS Journal of Photogrammetry and Remote Sensing*, 108:128–137. 20
- Weinmann, M. (2016). Reconstruction and analysis of 3d scenes. *Springer International Publishing, Cham*. doi, 10:978–3. 4
- Weinmann, M., Jutzi, B., Hinz, S., and Mallet, C. (2015). Semantic point cloud interpretation based on optimal neighborhoods, relevant features and efficient classifiers. *ISPRS Journal of Photogrammetry and Remote Sensing*, 105:286 – 304. 4
- Workman, S., Zhai, M., Crandall, D. J., and Jacobs, N. (2017). A unified model for near and remote sensing. In *IEEE International Conference on Computer Vision (ICCV)*. 16, 20
- Zargar, A., Sadiq, R., Naser, B., and Khan, F. I. (2011). A review of drought indices. *Environmental Reviews*, 19:333–349. 5



Hyperspectral Imagery for Environmental urban Planning

Projet ANR 14-CE22-0016-01

<http://hyep.cnrs.fr/>

WP leader : BRIOTTET Xavier

Livable WP3

Mois Juillet **Année** 2018

Auteurs : Aguejdad R. (UMR LIVE- TETIS), E. Alvarez (COSTEL), J. Aval (ONERA), F. Z. Benhalouche (Centre des Techniques Spatiales, Arzew, Algérie), C. Brabant (M2 TELENVI, COSTEL), X. Briottet (ONERA), Le Bris A. (IGN), Y. Deville (IRAP, Université de Toulouse), J. Demuynck (ISAE), K. Djerriri (Centre des Techniques Spatiales, Arzew, Algérie), S. Fabre (ONERA), M. Fauvel (INRA), S. Gadal (UMR ESPACE), Houet Thomas (COSTEL), M. S. Karoui (Centre des Techniques Spatiales, Arzew, Algérie), LARIBI Achour (Mémoire M2, COSTEL), G. Morin (COSTEL), W. Ouerghemmi (UMR ESPACE), D. Shereen (INRA), E. Zenou (ISAE), C WEBER (UMR LIVE-TETIS)

OBJECTIFS

This work package aims at providing insights on the choice of remotely sensed images (based on spectral and spatial resolutions) regarding some specific urban applications. We assume that no unique solution (image and method) exists for various applications and, thus, we will propose a quality assessment regarding multiples objectives. Geometrical, statistical and combined reasoning will be tackled in order to provide a finer level of details in the proposed nomenclature and a first step towards land-use maps.

Tree topics will be considered according to local institutions interests:

- Impervious surfaces: a new income tax can be applied by local authorities based on impervious surfaces estimation. However, existing methods and remotely sensed images are not appropriate to do so: both impervious surfaces types (roofs, asphalts, etc.) and respective extents are required. If exhaustive in situ survey is the most convenient method, it has a huge cost and hyperspectral images show great potential.
- Urban vegetation mapping: characterizing urban vegetation (types, moisture, etc.) is essential to assess the efficiency of urban green infrastructures, as a tool to coping with urban climate warming (combined effect of urban heat island and climate change) and to preserving fauna corridors. Local authorities need exhaustive surveys in public / private areas in order to define objectives of urban planning for cooling the city.
- Building roofs characterization and Solar panels detection test: if cities aim at promoting renewable energy production (by means of incomes reduction for e.g.) as recommended by the Grenelle 2 law, they need an exhaustive inventory of the existing solar panel surface over public and private buildings.

WP3.1: Impervious surface estimation

Processing developed in WP2 will be applied depending on the type of considered sensors. The quality of the results will be estimated in different ways. First, discrepancies with existing data base (collaboration with Toulouse city) will be analyzed and if necessary confirmed from on ground checking.

WP3.2: Urban vegetation mapping

Processing developed in WP2 will be applied depending on the type of considered sensors. The quality of the results will be estimated in different ways. First, discrepancies with existing data base (collaboration with Toulouse city) will be analyzed and if necessary confirmed from on ground checking. Then, the results from each sensor will be evaluated taking into account its ability to extract the morpho-spectral parameters characterizing urban vegetation mapping. A specific topic will be considered taking into account images acquired over Toulouse at three different times in a year: June, September and end of October. This will enable us to evaluate the benefits of multitemporal observations for vegetation mapping

WP3.3: Building roofs characterization and Solar panels detection test

Processing developed in WP2 will be applied depending on the type of considered sensors. The quality of the results will be estimated in different ways. First, discrepancies with existing data base (collaboration with Toulouse city) will be analyzed and if necessary confirmed from on ground checking. Then, the results from each sensor will be evaluated taking into account its ability to extract the morpho-spectral parameters characterizing solar panel surfaces. Some specific attention will be paid on the discrimination of solar panel and windows on the roofs.

WP3.3: Building roofs characterization and Solar panels detection test

Table des matières

1. INTRODUCTION	4
2. WP3.1: ESTIMATION DES SURFACES IMPERMEABLES	4
2.1 Méthode orientée pixel :.....	4
2.1.1 Classification supervisée avec apprentissage à partir de la base de données morpho- spectrale LIVE	4
2.1.2 Classification supervisée.....	4
2.1.2.1 Introduction.....	4
2.1.2.2 Apprentissage à partir d'une base de données de spectres de réflectance	4
2.1.2.3 Impact des configurations spectrales et spatiales	9
2.1.2.4 Conclusions générales	17
2.2 Méthode orientée objet.....	18
3. WP3.2: CARTOGRAPHIE DE LA VEGETATION URBAINE.....	23
3.1 Classification supervisée de la végétation (haute et basse) à partir d'une librairie	23
3.2 Cartographie supervisée des espèces d'arbres	31
3.2.1 Cartographie supervisée des espèces d'arbres à partir de sources aéroportées multiples 31	
3.2.2 Cartographie supervisée des espèces d'arbres avec un ensemble de classifieurs (ONERA, ISAE, INRA).....	38
3.2.3 Détection d'arbres alignés en milieu urbain	43
3.3 Evaluation de l'influence des résolutions spatiale et spectrale sur la classification de la végétation arborée	48
3.4 Evaluation de l'influence de la réduction de dimension sur la classification de la végétation arborée	52
3.5 Evaluation de multiples techniques visant l'amélioration de la performance de classification de la végétation urbaine à partir de données hyperspectrales	56
4. WP3.3: CARACTERISATION DES TOITS DE BATIMENTS ET DETECTION DE PANNEAUX SOLAIRES	63
4.1 Classification supervisée des matériaux de toits	63
4.2 Panneaux solaires.....	63
5. CONCLUSION ET PERSPECTIVES	68

1. INTRODUCTION

Le WP3 a pour but d'évaluer le potentiel de l'imagerie hyperspectrale pour trois classes d'applications :

- WP3.1 - Estimation des surfaces imperméables (§2) selon deux approches orientées pixel (§2.1) et objet (§2.2),
- WP 3.2 - Cartographie de la végétation urbaine (§3),
- WP3.3 – cartographie des toits (§4) comprenant une classification supervisée des toits et la détection de panneaux photovoltaïques.

Enfin, une conclusion sur les travaux réalisés sera menée.

2. WP3.1: ESTIMATION DES SURFACES IMPERMEABLES

2.1 Méthode orientée pixel :

2.1.1 Classification supervisée avec apprentissage à partir de la base de données morpho-spectrale

Auteurs : R. Aguejdad (UMR LIVE-TETIS)

Des calculs de moyenne de spectre ont été effectués afin de constituer la base d'apprentissage pour la classification (SAM). Les premiers résultats sont plutôt décevants car les classes sont trop larges, d'où d'importantes ambiguïtés.

2.1.2 Classification supervisée

2.1.2.1 Introduction

Auteurs : A. Le Bris (IGN)

Les méthodes mises en œuvre dans ce travail sont des approches de classification supervisée.

Les algorithmes testés font partie des méthodes désormais classiques : SVM à noyau gaussien, SVM à noyau linéaire, Forêts Aléatoires, Arbres de Décision, Maximum de Vraisemblance (avec modèle gaussien), Angle spectral (SAM), Spectral Information Divergence (SID).

Différentes expériences ont été menées :

- Apprentissage à partir d'une base de données spectrales,
- Influence de la configuration spectrale pour une même configuration spatiale,
- Influence de la résolution spatiale pour une même configuration spectrale,
- Fusion de classifications issues de configurations spectrales et spatiales différentes.

2.1.2.2 Apprentissage à partir d'une base de données de spectres de réflectance

Données utilisées

Une base de données de spectres de réflectance de différents matériaux urbains a été constituée à partir de bibliothèques spectrales existantes : Aster [Baldrige *et al.*, 2009], SLUM Spectral Library of impervious Urban

Materials [Kotthaus *et al.*, 2014], MEMOIRES (Moyen d’Echange et de valorisation de Mesures de propriétés thermiques, Optiques et InfraRouges d’Echantillons et de Scènes) [Martin et Rosier, 2012], Santa Barbara [Herold *et al.*, 2004a ; Herold *et al.*, 2004b], Tel-Aviv Ben Dor [Ben-Dor *et al.*, 2001], DESIREX [Sobrino, 2008 (Figure1)].

Les spectres proposés par ces différentes librairies ont généralement été acquis au cours de campagnes de mesures sur le terrain ou en laboratoire.

Une fois ces spectres triés et remis en forme selon une nomenclature commune, il apparaît toutefois que les différentes classes sont très inégalement réparties, comme on peut le voir sur la figure suivante.

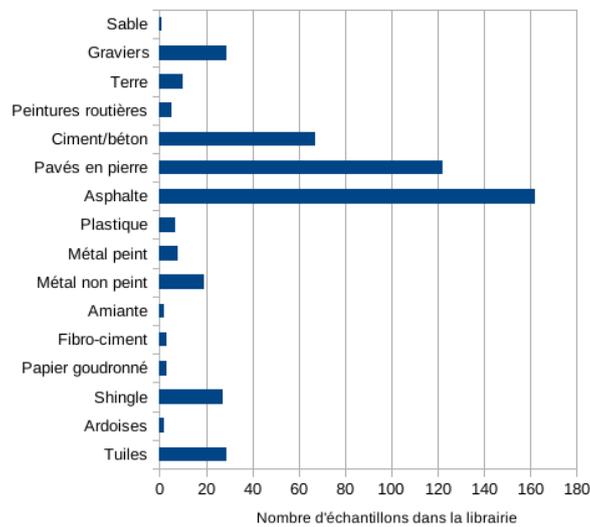


Figure 1 - Répartition des spectres collectés selon différentes classes de matériaux urbains.

Méthode

L'approche mise en œuvre pour utiliser ces données afin d'entraîner un classifieur a consisté à générer des spectres synthétiques à partir de ces références. Ainsi, pour générer n spectres pour une classe, on identifiait d'abord les spectres de la librairie correspondant, puis pour chacun des n spectres à créer, on sélectionnait aléatoirement l'une de ces signatures de référence, à laquelle on appliquait un facteur multiplicatif aléatoire, afin de simuler une certaine variabilité. Le spectre résultant était ensuite ré-échantillonné à la résolution spectrale de l'image à traiter.

Un classifieur était ensuite entraîné à partir de ces échantillons générés, puis appliqué à l'image hyperspectrale en réflectance. Les bandes situées dans les fenêtres d'absorption atmosphérique ou correspondant à des artefacts instrumentaux étaient, bien entendu, éliminées.

Les images sont issues de la caméra hyperspectrale Hypspx acquise en 2015 (initialement 408 bandes entre 414 et 2500 nm, pour un pixel sol de 2 m) corrigée de l'atmosphère par la méthode Cochise

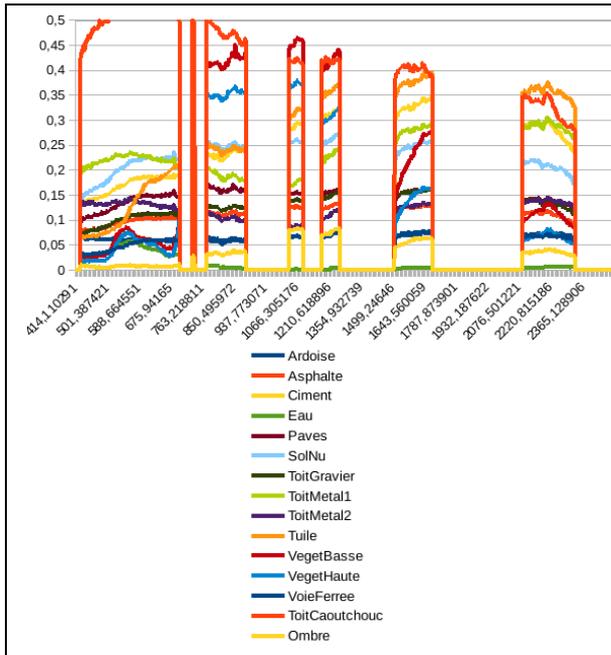
Résultats

Les résultats obtenus (présentés dans la figure suivante) ne se sont pas avérés probants, comme on peut le voir sur les exemples suivants. Les illustrations suivantes présentent les résultats obtenus pour les classifieurs Forêts Aléatoires et Angle Spectral. Les résultats obtenus par classification SVM sont encore moins bons (Figure 2).

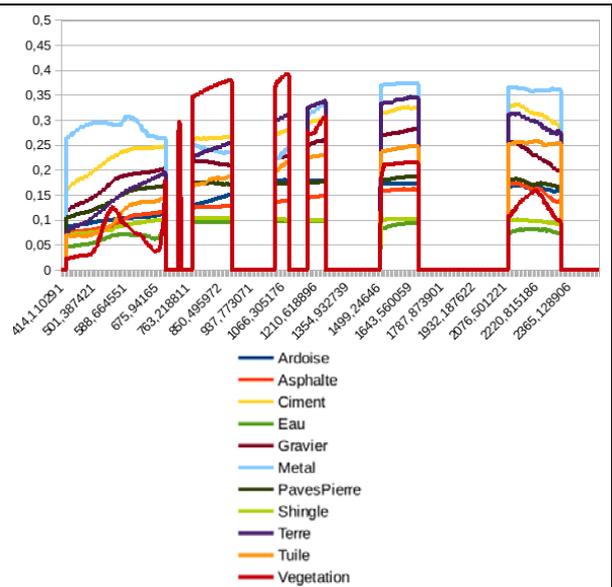


Figure 2 - Résultats obtenus par différents classifieurs pour un apprentissage à partir de la base de données spectrale.

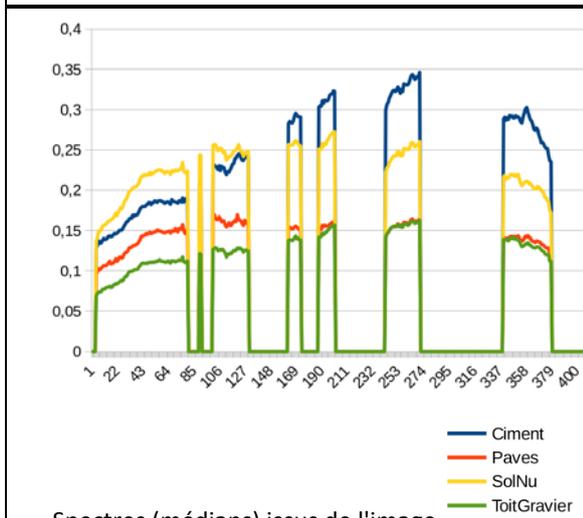
Si l'on observe, comme dans les figures qui suivent, les spectres issus de l'image et ceux de la base de données, on peut comprendre les raisons de cet échec (Figure 3).



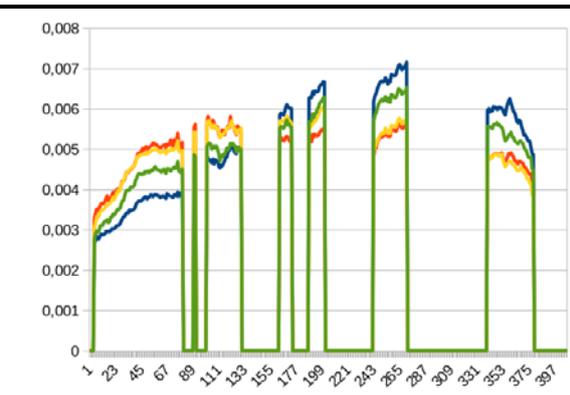
Spectres (médiens) issus de l'image



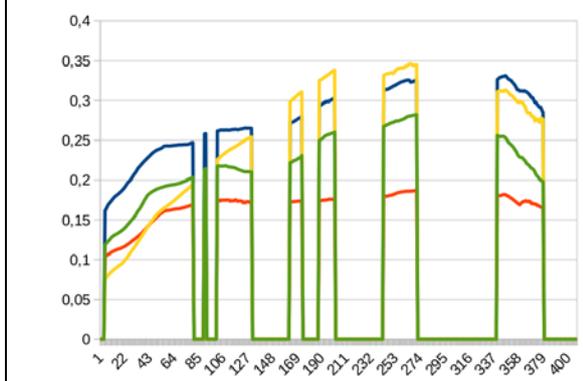
Spectres médians issus de la base de données



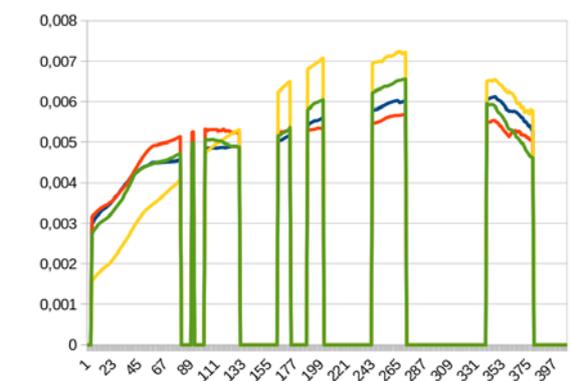
Spectres (médiens) issus de l'image



Spectres (médiens) issus de la base de données, après normalisation par l'aire sous la courbe



Spectres (médiens) issus de la base de données



Spectres (médiens) issus de la base de données, après normalisation par l'aire sous la courbe

Figure 3 - Exemples de spectres de réflectance issus de l'image et de la base de données (en abscisse sont indiqués les numéros de bande)

Le spectre d'un matériau peut se situer au-dessus de celui d'un autre dans le VNIR, et en dessous dans le SWIR dans la base de données. Tandis que le phénomène inverse peut être observé dans les spectres issus de l'image.

Conclusion

Les résultats de la classification supervisée montrent qu'une base de données construite à partir de spectres d'origines géographiques très différentes ne permettent pas d'obtenir de bons résultats quelle que soit la méthode de classification utilisée (meilleures performances obtenues avec SAM et Forêts Aléatoires).

Perspectives .

Références

[Baldrige *et al.*, 2009] A. M. Balbridge, S. Hook, C. Grove et G. Rivera. The ASTER spectral library Version 2.0. *Remote Sensing of Environment*, 113 : 711-715, 2009.

[Ben-Dor *et al.*, 2001] E. Ben-Dor, N. Levin et H. Saaroni. A spectral based recognition of the urban environment using the visible and near-infrared spectral region (0.4-1.1 μm). A case study over Tel-Aviv, Israel. *International Journal of Remote Sensing*, 22(11):2193-2218, 2001.

[Herold *et al.*, 2004a] M. Herold, D. Roberts, M. Gardner et P. Dennison. Spectrometry for urban area remote sensing – development and analysis of a spectral library from 350 to 2400 nm. *Remote Sensing of Environment*, 91(3-4):304-319, 2004.

[Herold *et al.*, 2004b] M. Herold, D. Roberts, O. Smadi et V. Noronha. Road condition mapping using hyperspectral remote sensing. In *Proceedings of the AVIRIS Workshop*, Pasadena, USA, 2004.

[Kotthaus *et al.*, 2014] S. Kotthaus, T. Smith, M.J. Wooster et C. Grimmond. Derivation of an urban materials spectral library through emittance and reflectance spectroscopy. *ISPRS Journal of Photogrammetry and Remote Sensing*, 94:194-212, 2014.

[Martin et Rosier, 2012] C. Martin et B. Rosier. Status of MEMOIRES - a thermal and optical data base. in *Fraunhofer IOSB*, Etlingen, Allemagne, 2012.

[Sobrino, 2008] J. Sobrino. DESIREX 2008 final report. ESA technical report, 2008.

Production scientifiques dans le cadre de l'ANR HYEP

2.1.2.3 Impact des configurations spectrales et spatiales

Méthode et données

Dans la suite, l'entraînement des classifieurs se fait donc à partir de données d'apprentissage directement issues de l'image. Une vérité a donc été saisie manuellement par photo-interprétation. On s'est alors aidé de toutes les données disponibles (composition RVBPIR calculée à partir de l'image hyperspectrale, ortho-images aériennes RVBPIR de résolution spatiale 12,5 cm, ortho-images diffusées sur le Géoportail, Google Earth et Bing Map, et données Street View). Les différentes classes sont toutefois présentes dans des proportions très variables sur cette zone d'étude. En effet, les toitures de la zone d'étude sont très majoritairement couvertes par des tuiles, les autres matériaux étant plus rares, et dans certains cas difficiles à identifier. En ce qui concerne les classes de matériaux de couverture du sol, un grand nombre de fonds de rues se trouvent à l'ombre ou masqués par des arbres, ce qui limite la quantité d'échantillons possibles.

A l'issue d'une première série d'expériences, il est apparu que les meilleurs résultats étaient généralement obtenus pour le classifieur SVM à noyau gaussien. Ce classifieur présente en effet une aptitude à séparer les classes pour un apprentissage restreint (quelques dizaines d'échantillons par classe).

On s'intéresse dans les expériences suivantes à l'impact de la configuration spectrale et de la résolution spatiale sur la classification. A l'issue de premières expériences, il est apparu que les polygones saisis n'étaient pas forcément compatibles avec le traitement des données les moins résolues et incluaient alors une proportion vraiment trop importante de pixels (trop) mixtes. Aussi, les a-t-on érodés afin de n'en conserver que les parties les plus pures. Cette référence érodée a ensuite été utilisée pour toutes les configurations testées afin de conserver un protocole identique : le même jeu de 50 échantillons d'apprentissage par classe a été utilisé à chaque fois. En revanche, les résultats obtenus ont été évalués par rapport à la référence originale (avant érosion).

L'évaluation quantitative a alors consisté à comparer (au niveau pixel) la classification obtenue à cette donnée de référence. (Tous les résultats ont été ré-échantillonnés à la résolution originale de 2m.) Des matrices de confusions ont été calculées et différentes métriques d'évaluation classiques en ont été déduites au niveau de chaque classe (Précision utilisateur, Précision producteur, F1-Score) et de manière plus globale (*Overall Accuracy*, *Average Accuracy*, F1-Score moyen). Dans la suite, on s'intéresse plutôt aux indicateurs fournis pour chacune des classes, et en particulier au F1-Score qui est une synthèse des précisions utilisateur et producteur (moyenne harmonique de ces 2 indicateurs). En effet, du fait de la représentation dans des proportions très variables des différentes classes dans la référence, les métriques globales ne sont pas très intéressantes.

Par ailleurs, on remarquera que pour les classes les moins représentées, il n'a pas été possible de trouver suffisamment d'échantillons pour entraîner et évaluer la classification sur des échantillons distincts. Même pour d'autres classes mieux représentées, certains échantillons utilisés pour l'apprentissage et pour l'évaluation appartiennent aux mêmes objets, d'où une évaluation un peu optimiste (Figure 4).

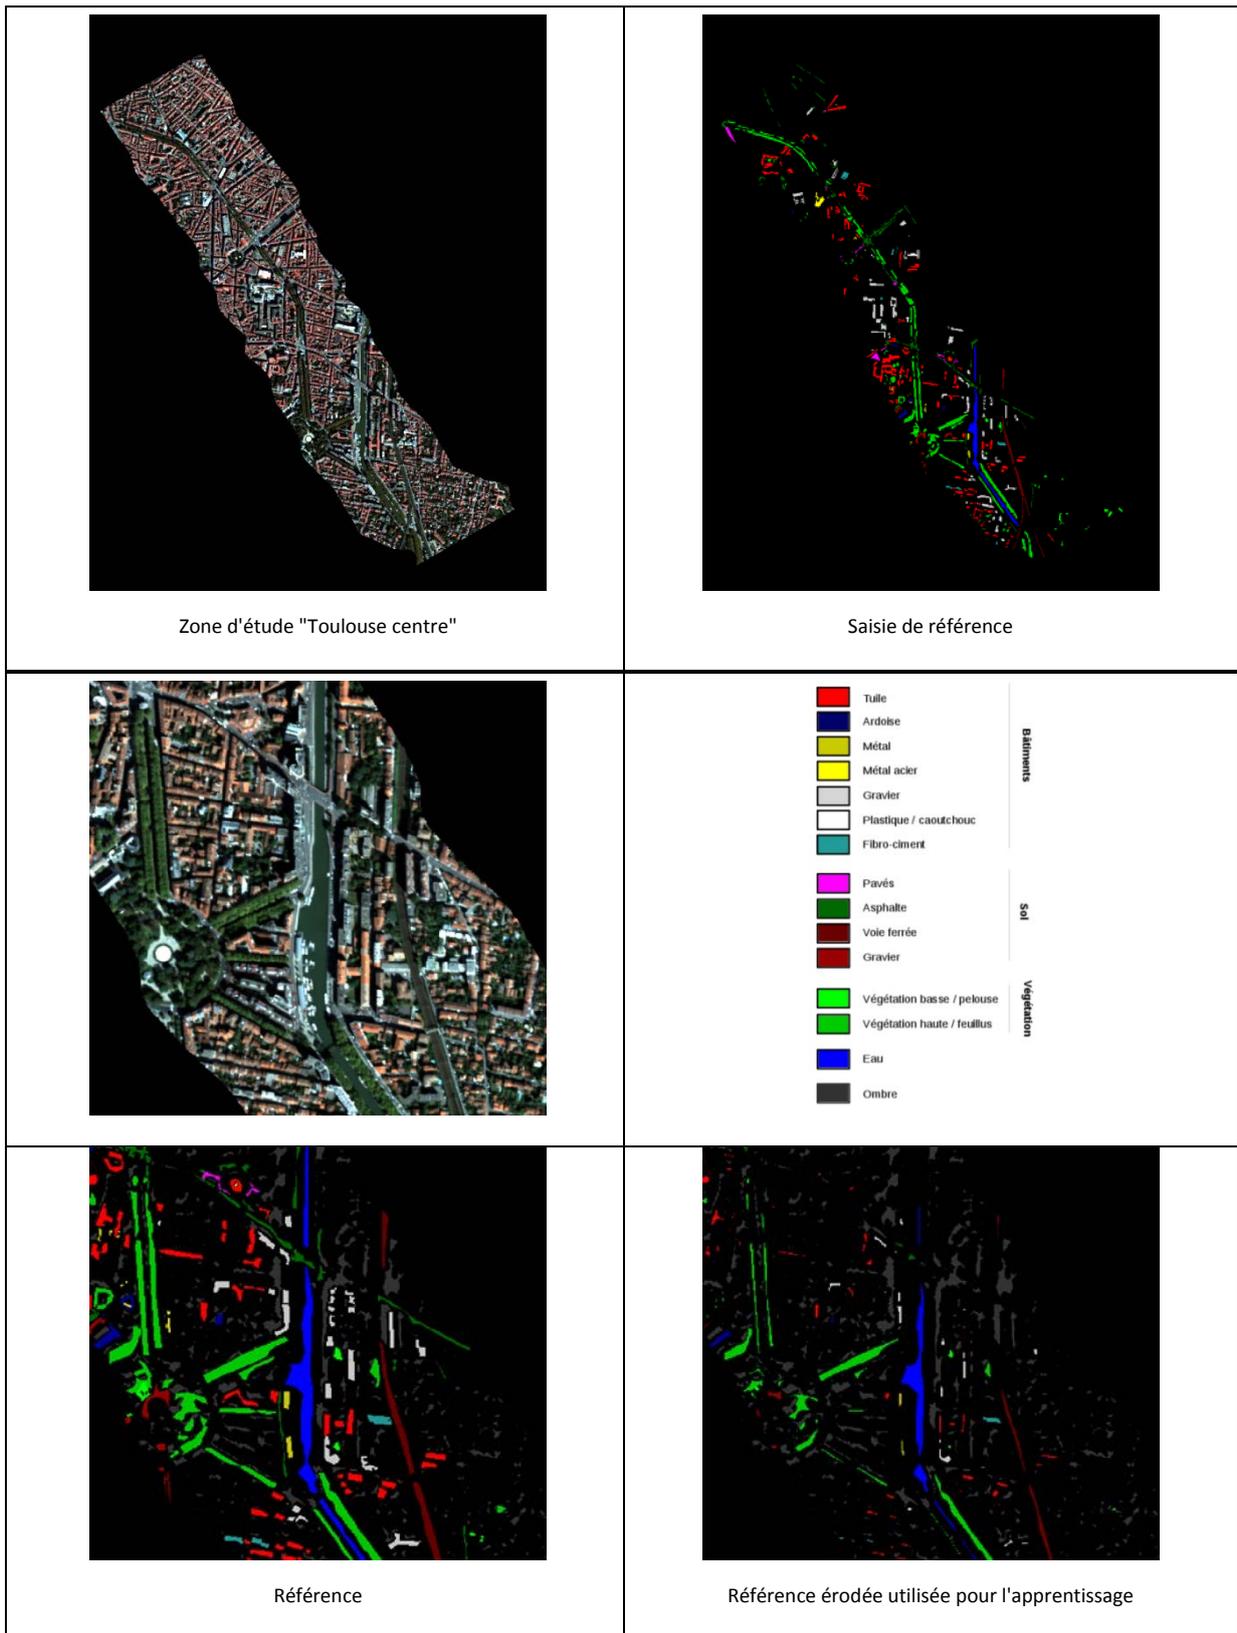


Figure 4 – Composition colorée de l'image acquise par les caméras HYSPEX sur Toulouse (en haut à gauche) et de la carte construite pour servir de référence à la classification. Composition colorée de l'image acquise par les caméras HYSPEX sur Toulouse sur une portion de l'hyper-centre de Toulouse (au milieu à gauche) – Légende des matériaux (au milieu à droite). Carte construite pour servir de référence à la classification (en bas à gauche) et carte de référence utilisée pour l'apprentissage (en bas à droite).

Les images utilisées pour les expériences sont des simulations de capteurs présentant différentes configurations spectrales et spatiales. Ces simulations ont été calculées à partir d'images hyperspectrales acquises en juin 2015 au-dessus de l'agglomération toulousaine par des capteurs Hypspx (408 bandes couvrant le domaine 400-2500 nm à une résolution spatiale de 2m).

➤ Impact de la configuration spectrale

Données

Différentes images ont été simulées à partir de l'acquisition hyperspectrale originale pour différentes caractéristiques. Les différentes configurations spectrales comparées sont les suivantes :

- la configuration spectrale du capteur Pléiades ;
- la configuration spectrale originale du capteur Hypspx limitée au domaine VNIR (400nm – 1000nm) et après suppression des bandes trop affectées par l'atmosphère ;
- la configuration spectrale originale du capteur Hypspx limitée au domaine VNIR et à la première partie du domaine SWIR (400nm – 1800nm) et après suppression des bandes trop affectées par l'atmosphère ;
- la configuration spectrale originale du capteur Hypspx sur l'ensemble du domaine VNIR+SWIR (400 nm – 2500 nm) et après une suppression moins stricte des bandes affectées par l'atmosphère ;
- une sélection de 10 bandes du capteur Hypspx. Ces 10 bandes ont été sélectionnées automatiquement à partir de la base de données spectrale décrite précédemment, c'est-à-dire indépendamment de l'image traitée, et pour une nomenclature légèrement différente.

Ces différentes simulations conservent la résolution spatiale de 2 m de l'acquisition originale. Excepté le cas de la simulation Pléiades, ces images ont fait l'objet d'une correction par la méthode Cochise.

Résultats

Comme on peut le constater d'après la figure 5 et le tableau 1, même si les différences ne sont pas spectaculaires, on observe que dans l'ensemble, de meilleurs résultats sont obtenus lorsque l'on améliore la configuration spectrale.

La configuration hyperspectrale limitée au domaine 400-1000 nm donne de meilleurs résultats que la configuration de Pléiades. Ajouter des bandes issues du domaine SWIR améliore ces résultats, les meilleurs résultats étant atteints pour la configuration couvrant le domaine 400-2500 nm. L'importance du SWIR peut aussi être notée par les améliorations observées sur certaines classes lorsque l'on compare les résultats obtenus pour un jeu de 10 bandes issues du domaine 400-2500 nm par rapport à la configuration de Pléiades, voire selon les classes à la configuration hyperspectrale 400-1000 nm.

D'un point de vue plus qualitatif, ces améliorations s'observent aussi visuellement par un résultat moins bruité lorsque la configuration est plus riche. On notera que les différents résultats présentés ici sont issus de classification pixellaire et n'ont pas fait l'objet d'une régularisation spatiale.

Les principales confusions qui demeurent concernent les classes suivantes :

- Les ardoises sont très mal classées. Ceci était prévisible, car cette classe est peu représentée, présente une spécularité importante, qui peut la faire ressembler à d'autres classes avec pour conséquence des confusions avec les ombres, l'eau, le métal.
- Végétations hautes et basses tendent à se confondre. Ceci peut s'expliquer par le fait que pour chacune de ces classes, on a une variabilité intra-classe (stress, espèces) qui peut être importante.
- Des confusions entre asphalte, pavés et graviers de toit se produisent aussi.

L'expérience reste toutefois limitée car la zone d'étude n'est pas très importante (risque de sur-ajustement du modèle), que certaines classes sont assez peu représentées (apprentissage et évaluations sur les mêmes zones).

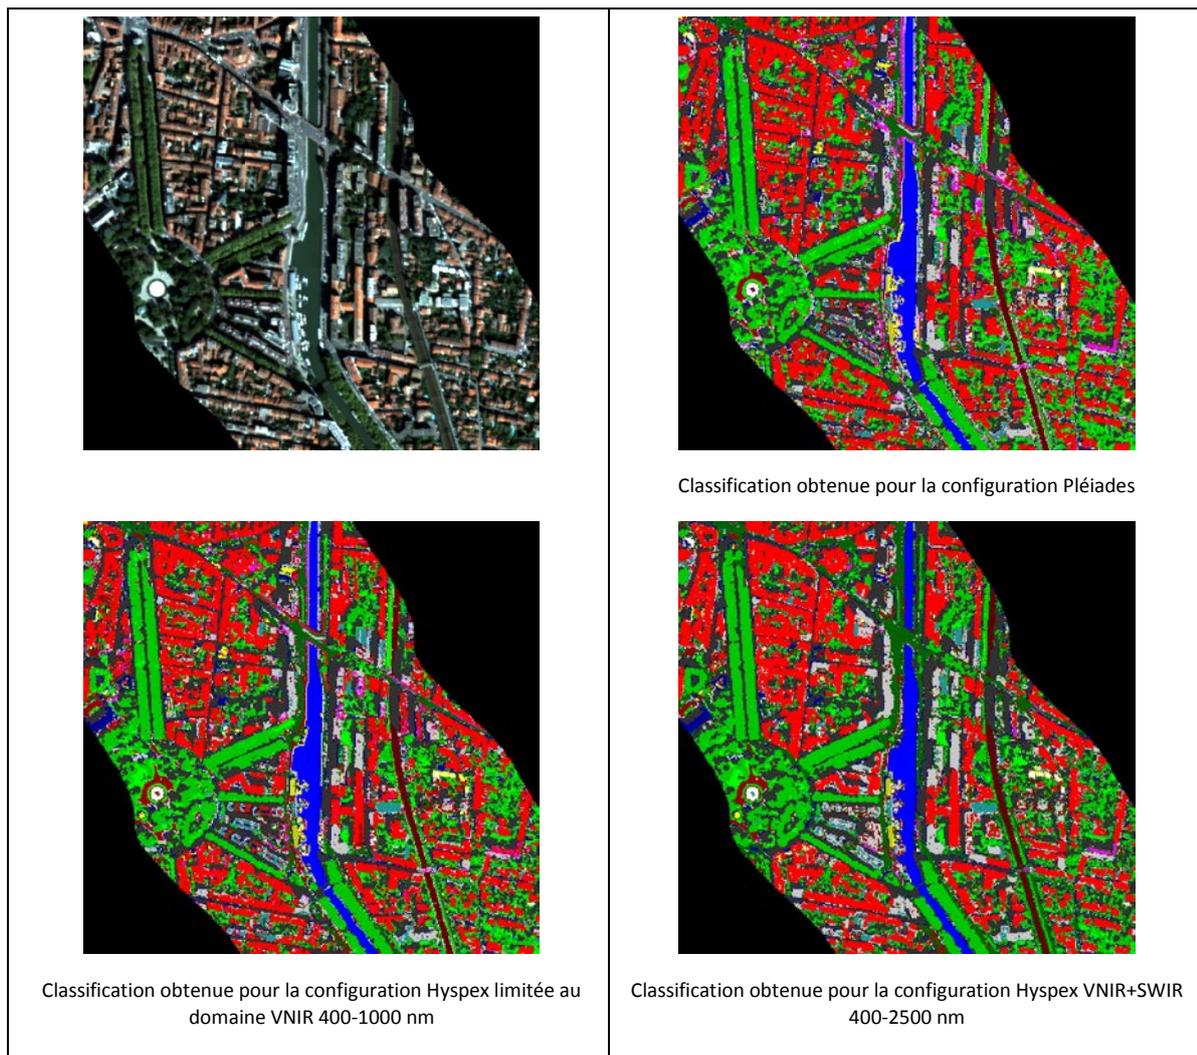


Figure 5 - Résultats de classification obtenus pour trois des configurations spectrales testées.

Tableau 1 - F1-Score (en %) des différentes classes selon les différentes configurations spectrales testées.

Classe	Pléiades	400-1000 nm	400-1800 nm	400-2500 nm	400-2500 nm moins strict	10 bandes
Ardoise	49,6	50,7	51,8	54,6	55,3	48,2
Asphalte	68,4	72,6	71,8	75,1	76,8	69,1
Ciment	59,8	74,4	71,3	73,4	73,3	72,9
Eau	99,3	99,3	99,1	99,2	99,1	99,2
Pavés pierre	47,4	53,9	57,9	65,6	71,6	50,3
Sol nu / terre	51,0	54,8	59,5	62,1	61,8	61,8
Toit Gravier	70,2	71,6	75,0	82,3	84,1	76,6
Toit métal 1	62,8	63,1	68,8	70,9	71,1	69,6
Toit métal 2	43,4	44,9	56,3	61,7	59,7	60,0
Tuile	90,9	90,5	95,5	96,0	96,1	95,6
Végétation basse	43,3	57,7	70,3	71,4	73,5	71,6
Végétation haute	85,6	88,6	90,8	91,0	91,0	89,4
Voie ferrée	77,4	82,0	84,3	83,4	82,2	80,4
Toit plastique	76,9	76,7	83,2	84,4	84,7	82,1
Ombre	95,3	96,0	96,4	96,5	96,4	95,7

➤ Impact de la résolution spatiale

Données

On s'est ensuite intéressé à l'impact de la résolution spatiale sur les résultats, notamment dans la perspective d'une nouvelle mission satellite Hypxim. Des images ont été simulées pour 2 résolutions spatiales cibles (4m et 8m) et pour la configuration spectrale envisagée pour cette mission.

Résultats

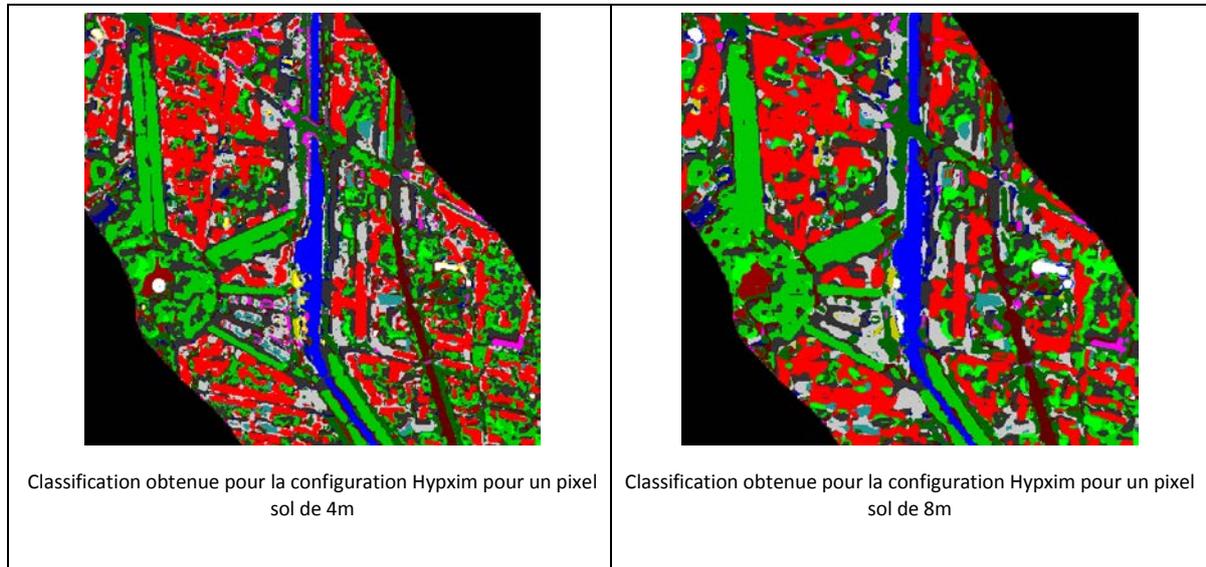


Figure 6 - Résultats de classification obtenus pour les deux configurations spatiales testées pour une même configuration spectrale Hypxim.

D'un point de vue visuel (Figure 6), on observe une dégradation des résultats lorsque l'on dégrade la résolution spatiale. A 4 m, la scène reste "interprétable" mais à 8 m seuls les objets les plus grands sont encore bien classés.

Les résultats quantitatifs (Tableau 2) sont plus nuancés. Des améliorations sont observées pour certaines classes lorsque la taille du pixel sol passe de 4 à 8 m. Mais il faut garder en mémoire que la donnée de référence ne constitue pas un partitionnement de l'image, et les polygones saisis ne l'ont souvent pas été sur les plus petits objets. Or les résultats pour la résolution spatiale de 8 m sont plus grossiers et plus lisses (moins de bruit), et les petits objets peuvent donc avoir tendance à disparaître au profit de leurs voisins plus grands mais de classe différente sans que cela ne transparaisse lors de l'évaluation.

Dans les 2 cas, les pixels mixtes ne sont pas forcément bien classés, mais dans ce cas de figure la classification n'est alors plus nécessairement pertinente et des approches alternatives comme le démixage mériteraient d'être testées.

Tableau 2 - F1-Score (en %) des différentes classes selon les différentes configurations testées.

Classe	Hypxim 4m	Hypxim 8m	Pléiades	Fusion
Ardoise	56,9	30,9	49,6	52,5
Asphalte	68,7	71,1	68,4	76,6
Ciment	71,8	79,0	59,8	78,3
Eau	97,9	96,9	99,3	98,7
Pavés pierre	53,1	68,8	47,4	70,5
Sol nu / terre	60,9	79,3	51,0	77,8
Toit Gravier	74,1	72,8	70,2	82,4
Toit métal 1	68,3	80,6	62,8	80,7
Toit métal 2	47,7	61,5	43,4	65,5
Tuile	93,5	79,8	90,9	94,6
Végétation basse	78,0	64,7	43,3	74,4
Végétation haute	89,6	84,7	85,6	90,2
Voie ferrée	82,3	66,1	77,4	87,0
Toit plastique	86,5	92,1	76,9	92,5
Ombre	95,2	77,5	95,3	94,6

➤ Fusion

Méthode

Une solution pour améliorer les résultats précédents peut consister à fusionner ces données hyperspectrales moins bien résolues spatialement avec une donnée multispectrale (voire panchromatique) mieux résolue spatialement. La fusion amont serait possible avec le pansharpening. La fusion aval est également possible en exploitant les mesures d'appartenance aux classes générées par les classifieurs pour chaque source, par exemple par la méthode de [Ouerghemmi *et al.*, 2016] développée dans le WP2 et rappelée Figure 7. Cette méthode a ici été appliquée aux résultats issus de la simulation Hypxim à 8m et ceux de la simulation Pléiades à 2m. Le résultat obtenu présente une amélioration par rapport aux résultats originaux. Du point de vue qualitatif et visuel (Figure 8), le résultat est plus interprétable : on y reconnaît mieux les différents objets que dans la classification issue de l'image hyperspectrale peu résolue spatialement. Ce résultat est également moins bruité que celui issu de la simulation Pléiades. Certaines confusions y sont par ailleurs corrigées. Du point de vue quantitatif (voir tableau ci-dessous), les résultats sont généralement améliorés par rapport aux classifications indépendantes des deux sources originales.

Production dans le cadre de l'ANR HYEP

[Ouerghemmi *et al.*, 2016] W. Ouerghemmi, A. Le Bris, N. Chehata et C. Mallet. A two-step decision fusion strategy: application to hyperspectral and multispectral images for urban classification. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII(1/W1):167-174, 2017.

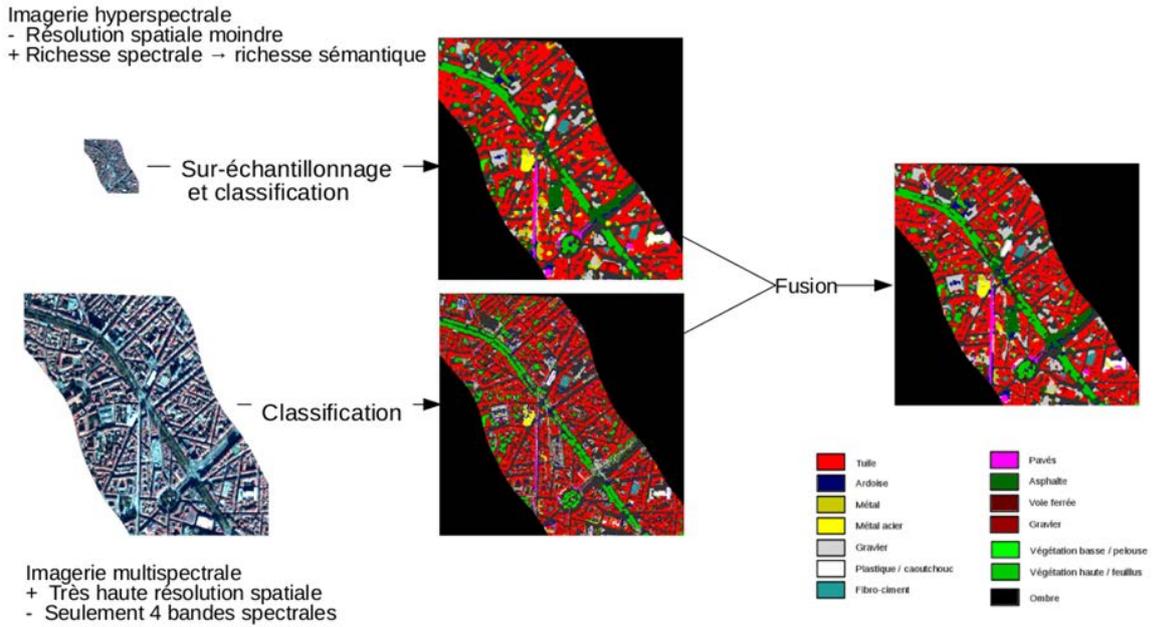


Figure 7 - Méthode de fusion aval mise en œuvre. [Querghemmi et al., 2016]

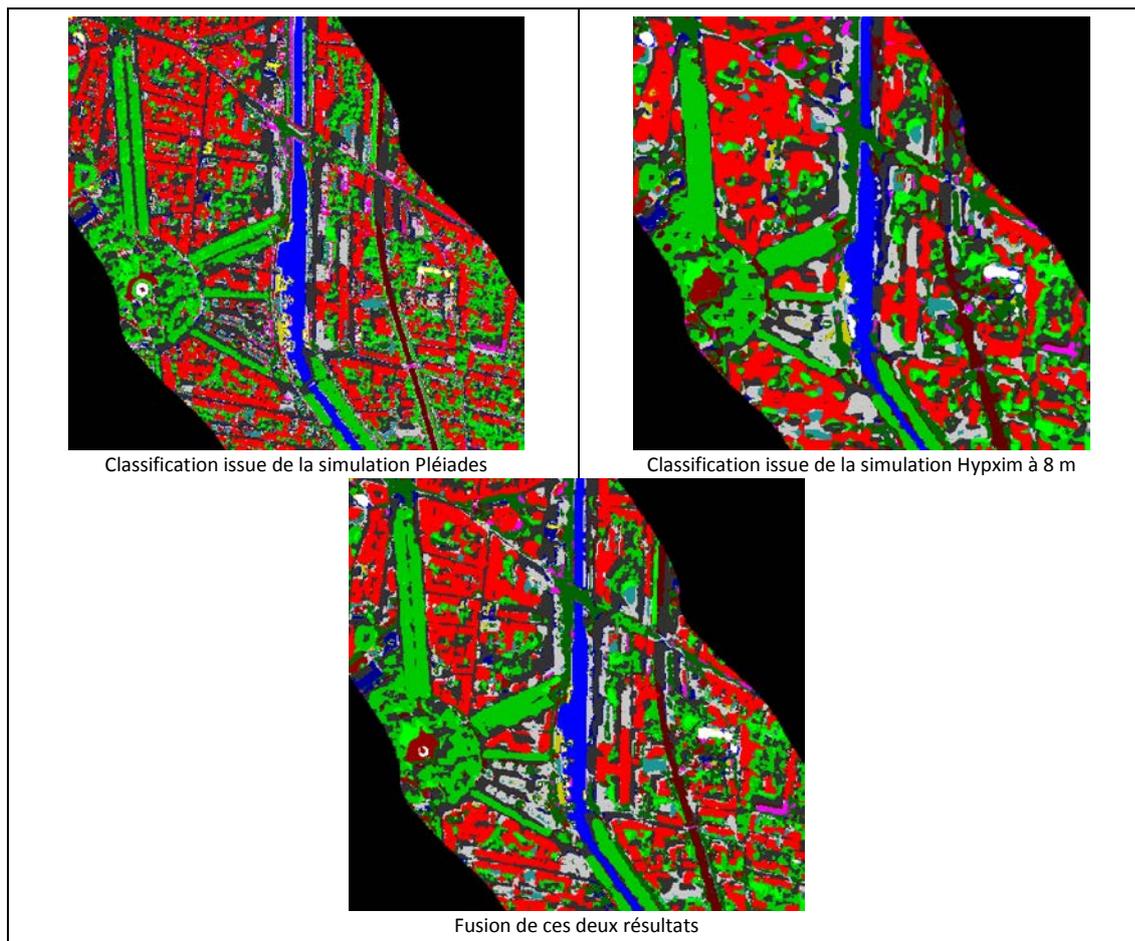


Figure 8 - Fusion de classifications issues de la simulation Pléiades et de la simulation Hypxim 8 m.

- **Qualité du modèle / passage à l'échelle : que se passe-t-il si l'on s'éloigne de la zone d'apprentissage ?**

Les expériences précédentes (apprentissage et classification) ont été effectuées sur une zone d'étude restreinte située sur le centre-ville de Toulouse. Il apparaissait donc intéressant d'étudier la capacité des modèles obtenus à traiter des zones plus conséquentes. Le modèle a donc été appliqué à une autre zone test située quelques kilomètres plus loin à Montaudran en périphérie de Toulouse. Cette seconde zone présente un paysage urbain différent (zone d'activité, présence plus importante de végétation, présence d'une autoroute ainsi que d'une ancienne piste d'aviation en cours de démantèlement). Les images utilisées proviennent de la même acquisition que pour les expériences précédentes. Les expériences ont porté uniquement sur les données hyperspectrales Hyspex (domaine 400-2500 nm ; pixel sol de 2 m). Le modèle (SVM à noyau gaussien) calculé sur la zone d'étude Toulouse Centre leur a été appliqué directement.

On constate différentes erreurs de classifications (Figure 9) qui laissent à penser que le modèle a pu être sur-ajusté par rapport aux échantillons d'apprentissage issus du centre-ville. Par exemple, une partie importante des routes (asphalte) sont classés comme du gravier (zones plus claires) ou des ardoises (zones plus sombres, peut-être récemment refaites). La distinction des deux types de végétation n'est en revanche pas aussi mauvaise que l'on aurait pu le craindre (dans le centre-ville, les zones de végétation basse étaient souvent peu étendues, avec le risque d'avoir des échantillons contaminés par la végétation haute voisine). Cette nouvelle zone d'étude présente aussi davantage de zones de sol nu, une classe peu présente dans le centre-ville, qui est souvent confondue avec d'autres classes comme les graviers de toits, voire le ciment. On peut donc penser que quelques échantillons complémentaires issus de cette nouvelle zone amélioreraient les résultats.

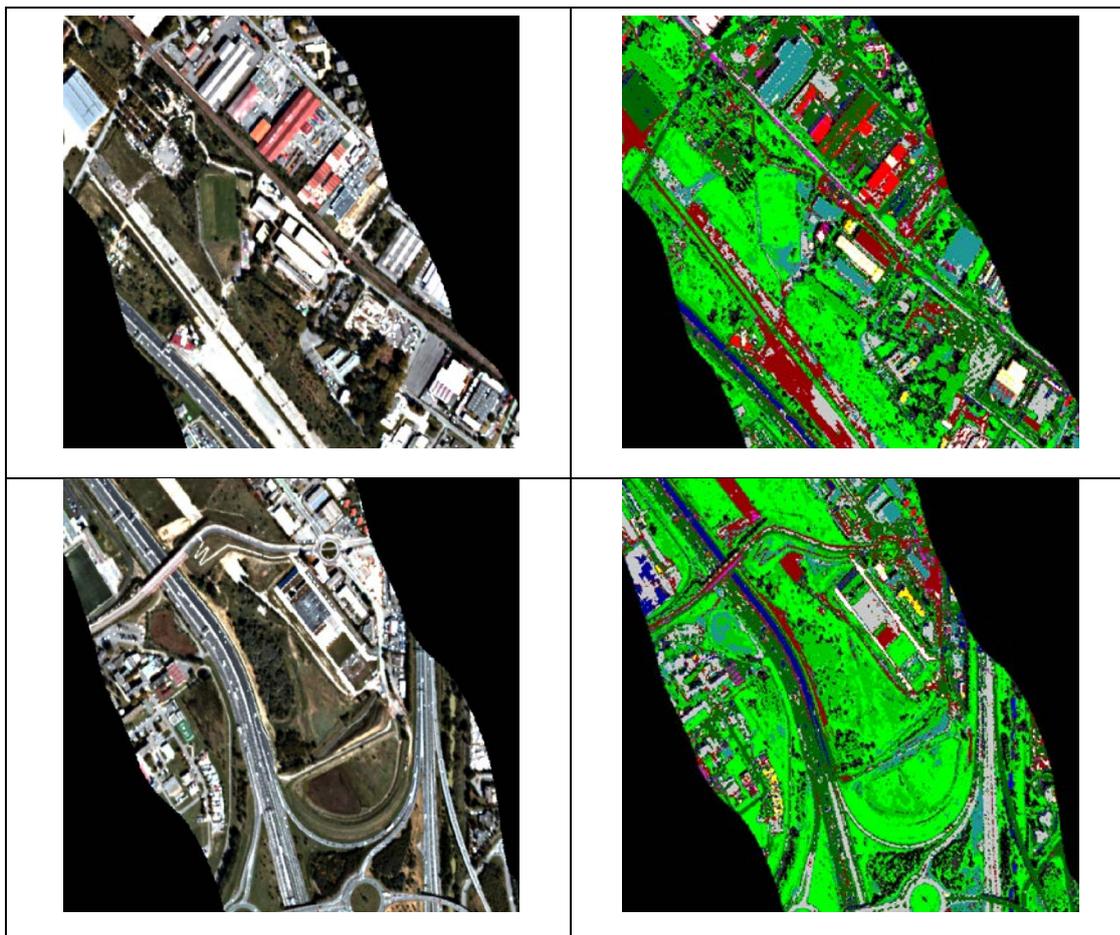


Figure 9 - Résultats de classification en appliquant à l'image Hyspex (domaine 400-2500 nm ; pixel sol de 2 m) sur la zone d'étude de Montaudran un modèle entraîné sur la zone "Toulouse Centre".

2.1.2.4 Conclusions

Différentes expériences ont été menées :

- Apprentissage à partir d'une base de données spectrales :
 - Une large base de données a été construite à partir de spectres issus de villes très différentes (Londres, Tel-Aviv, Toulouse, Madrid). Celle-ci reste néanmoins déséquilibrée car elle présente une très forte proportion d'asphalte, de pavés et de ciment et en revanche une très faible proportion de fibrociment, sable, terre, peintures, amiante, béton.
 - Cette base a été utilisée comme base d'apprentissage pour tester différents algorithmes de classification supervisée (SVM à noyau gaussien, SVM à noyau linéaire, Random Forest, arbre de décision, maximum de vraisemblance, angle spectral SAM).
 - Ces outils de classification sont appliqués sur une image Hypspx à 2m corrigée de l'atmosphère. Les résultats montrent les faibles performances (analyse visuelle) de ce type de méthode à partir d'une base de données externes, les meilleures méthodes étant le SAM (végétation et tuiles bien classées mais confusions importantes entre eau/métal, les autres classes), et le Random Forest (bonne classification de l'eau et de la végétation, tuile partiellement retrouvée, confusion Ombre/eau, pavés / asphalte).
 - Dans la suite, la base de données sera construite directement à partir de l'image et la méthode de classification retenue sera le SVM à noyau gaussien (adapté lorsque le nombre d'échantillons est faible)
- Influence de la configuration spectrale pour une même configuration spatiale :
 - Différentes configuration spectrales sont étudiées à la même résolution spatiale de 2 m : Pléiades, HYPXIM VNIR, HYPXIM 0.4-1.8 μ m, HYPXIM 0.4-2.5 μ m, HYPXIM 10 bandes (sélection automatique à partir d'une librairie spectrale différente de l'image)
 - Les résultats de la classification montrent que les performances augmentent avec le domaine spectral : le nombre de classes discriminées est plus important et les images résultat moins bruitées. Des confusions persistent entre ardoise / autres classes, végétation haute / végétation basse, asphalte / pavés/graviers.
- Influence de la résolution spatiale pour une même configuration spectrale :
 - Différentes configurations spatiales sont analysées (4 et 8m) pour un domaine spectral couvrant 0.4-2.5 μ m.
 - Une analyse visuelle des résultats montre une dégradation de l'image quand la résolution spatiale se dégrade. A 8m, seuls les gros objets sont bien classés. Mais, les performances de classification montrent que le F-score s'améliore en passant de 4 m à 8 m sans doute lié au lissage des hétérogénéités spatiales (bruit) lors de la réduction de la résolution.
- Fusion de classifications issues de configurations spectrales et spatiales différentes :
 - La méthode proposée par Ouerghemmi et al., 2016 (cf WP2) est appliquée en fusionnant une image HYPXIM 8m avec une image multispectrale Pléiades (2m). Les résultats montrent une amélioration notable des performances en fusion ces 2 images par rapport aux performances de chaque source traitée individuellement, c'est également le cas par rapport aux résultats de l'image HYPXIM 4m.
- Que se passe-t-il en s'éloignant de la zone d'apprentissage ?
 - L'image utilisée est l'image Hypspx 2m acquise sur la zone de Montaudran sur laquelle la méthode SVM à noyau gaussien a été appliquée
 - Une analyse visuelle des résultats montre que l'image est globalement bien classée (en particulier deux types de végétation sont discriminés) mais de nombreuses confusions sont présentes (route/graviers/ardoise, sol nu /graviers de toit, ciment).

Perspectives

2.2 Méthode orientée objet

Auteurs : Rahim AGUEJDAD (LIVE, UMR TETIS)

Objectifs :

Méthode

L'approche orientée-objet que nous avons appliquée en utilisant le logiciel eCognition comprend deux étapes successives. D'abord, l'image a été segmentée en objets ou segments selon des critères d'échelle (taille des objets segmentés), couleur (leur réponse spectrale), et de forme qui est la résultante de deux critères, le lissage qui relève de la texture et la compacité (Figure 10). La segmentation a été effectuée sur 116 bandes spectrales de l'image (76 bandes de mauvaise qualité ont été exclues) en utilisant un facteur échelle de 0,4. Le critère d'échelle détermine indirectement la taille des objets; il est déterminé par l'utilisateur par apprentissage empirique basé sur des itérations successives.

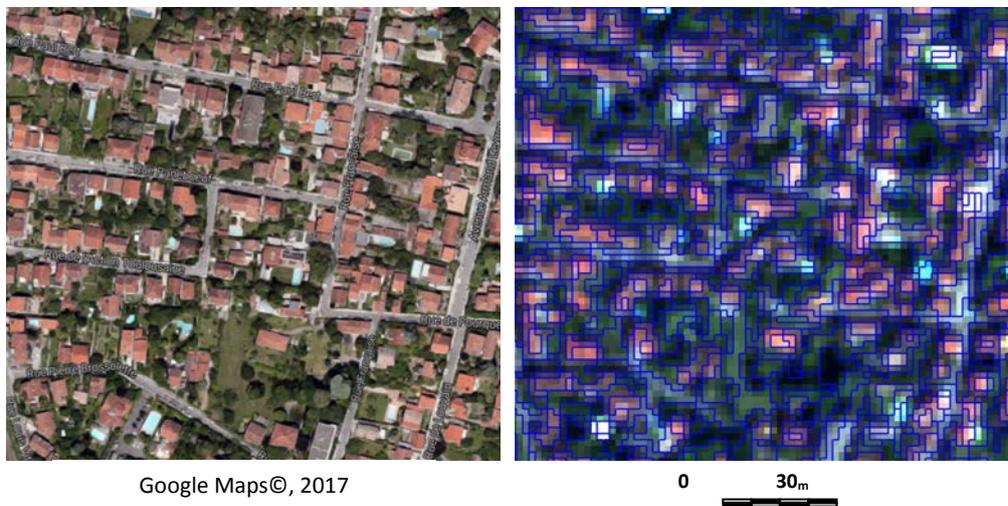


Figure 10 - Extrait centré sur une zone d'habitat pavillonnaire de l'image segmentée en utilisant un facteur échelle 0,4.

Ensuite, les objets ont été classés de façon supervisée selon une classification basée sur la logique floue utilisant des fonctions d'appartenance déterminées à partir d'une connaissance d'expert. Les objets sont affectés aux classes (Figure 11) selon des règles dépendant généralement des valeurs spectrales et de leur répartition au sein de l'objet, des paramètres de forme des objets ainsi que des relations de voisinage entre les objets. Dans notre cas, les critères, non discriminants, relevant de la texture, la taille et la forme des objets n'ont pas servi dans la classification. Seuls paramètres dérivés des valeurs spectrales ont donc permis de classer l'image.

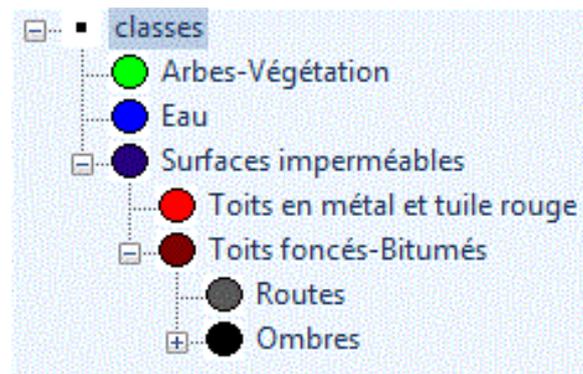


Figure 11 - Classification hiérarchique.

Données utilisées

Le jeu de données utilisé dans cette étude consiste en une image hyperspectrale HYPXIM couvrant le domaine spectral allant de 400 à 2500 nm (Visible, NIR et SWIR) avec une résolution spatiale de 4 m (Tableau 3). Cette image simulée est issue d'une image hyperspectrale de 2 m de résolution spatiale acquise à partir d'une mission aéroportée sur le centre-ville de Toulouse (Figure 12) en juillet 2015 par la caméra HYSPEX (Tableau 4).

Tableau 3 - Caractéristiques spectrales de l'image hyperspectrale HYPXIM à 4 m de résolution.

Domaine	Spectre (nm)	Largeur de la bande $\Delta\lambda$ (nm)	Liste des bandes
Visible (Vis)	418 - 691	10,9	1 - 26
Near-InfraRed (NIR)	702 - 1095	10,9	27 - 63
Short Wave InfraRed (SWIR)	1105 - 2502	10,9	64 - 192

Tableau 4 - Résolutions spatiales et spectrales des deux images HYSPEX et HYPXIM.

Images	Nombre de bandes	Résolution spectrale	Résolution spatiale
TC_2015_Hyspex	408	0,4 – 2,5 microns	2 m
TC_2015_Hypxim	192	0,4 – 2,5 microns	4 m

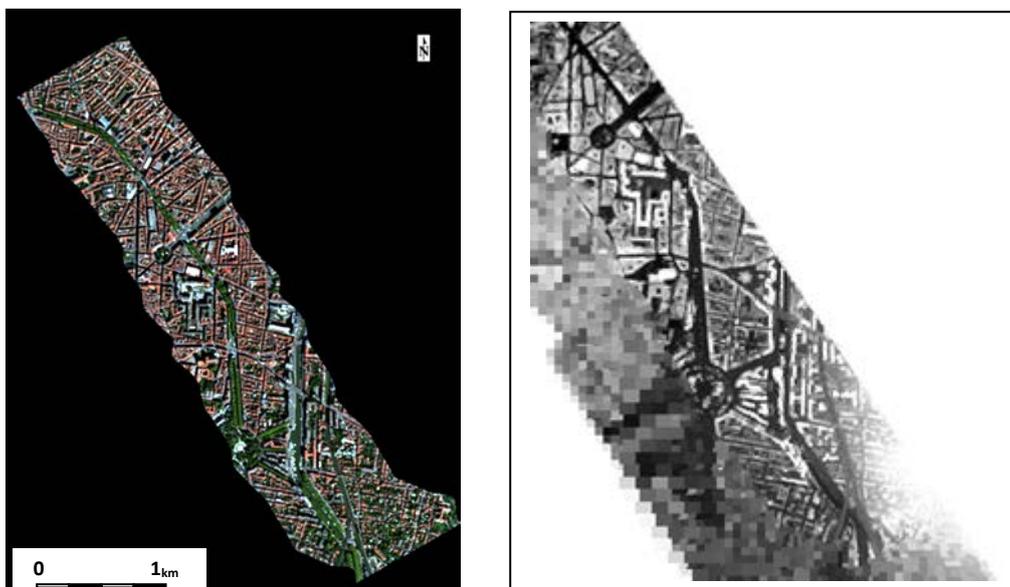


Figure 12 - Centre-ville de Toulouse : image hyperspectrale RGB et Modèle Digital d'Élévation (ONERA et IGN, 2015).

Des données issues de la transformation des images d'origines ont été utilisées dans le processus de classification. Il s'agit principalement des images issues de l'indice de végétation NDVI, de l'analyse en composantes principales (ACP) et de la transformation Minimum Noise Fraction (MNF) utilisée pour compenser le bruit capteur (Figure 13). Nous avons aussi utilisé un modèle digital d'élévation de 1,6 m de résolution (DEM) généré à partir des données LIDAR (Figure 12).

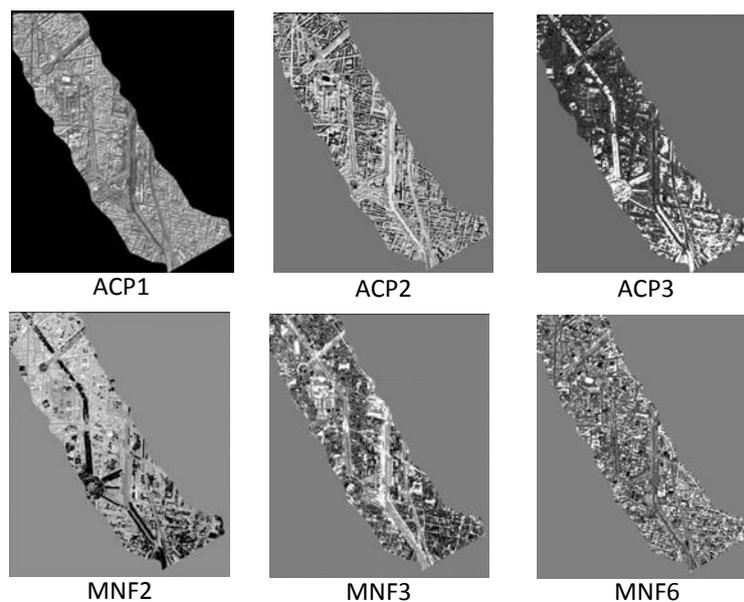


Figure 13 - Images issues de l'ACP et de la transformation MNF.

Résultats

La *Figure 14* montre les bâtiments extraits grâce à la classification des objets de l'image segmentée. Le résultat illustre que la cartographie des toits faits en matériaux de construction claires (Zinc, Wood, PVC, tuile rouge) donne de bons résultats. Cependant et malgré l'usage de l'imagerie hyperspectrale, des confusions persistent entre, d'un côté, le réseau routier et les structures associées tels que les parkings, et les bâtiments présentant des toits bitumés, de l'autre côté. En effet, la *Figure 15* illustre la ressemblance spectrale entre la voirie et les toits foncés le long des domaines VNIR et SWIR. Les tuiles rouges et les toits en métal sont facilement identifiés par rapport aux toits foncés qui sont souvent confondus avec la voirie (asphalte). Cependant, l'usage de l'information 3D et sa prise en compte dans le processus de classification permet de remédier à ce problème (*Figure 16*). Ainsi, la voirie a été différenciée des bâtiments après l'introduction d'une condition sur la hauteur des objets dans les règles de classification.

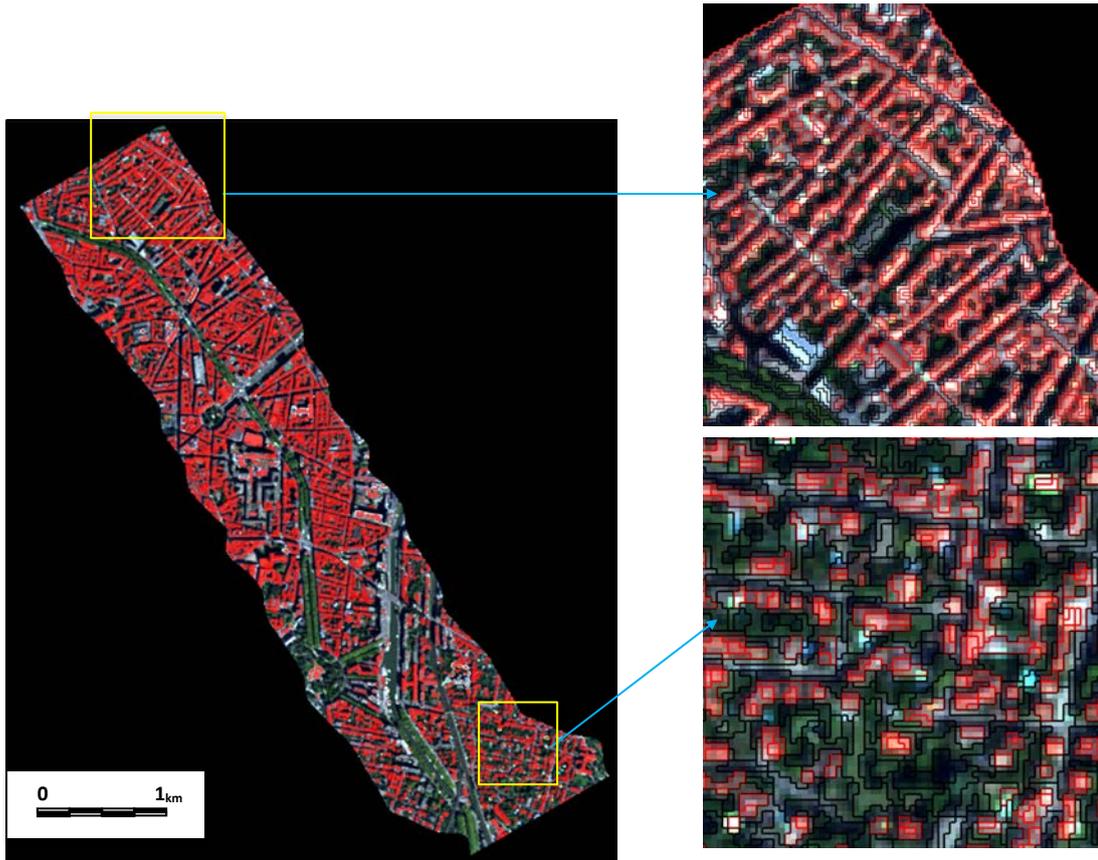


Figure 14 - Extraction des toits en tuile rouge et en métal sur deux zones résidentielles différentes (pavillonnaire et habitat collectif) sans prise en compte de la hauteur des bâtiments.

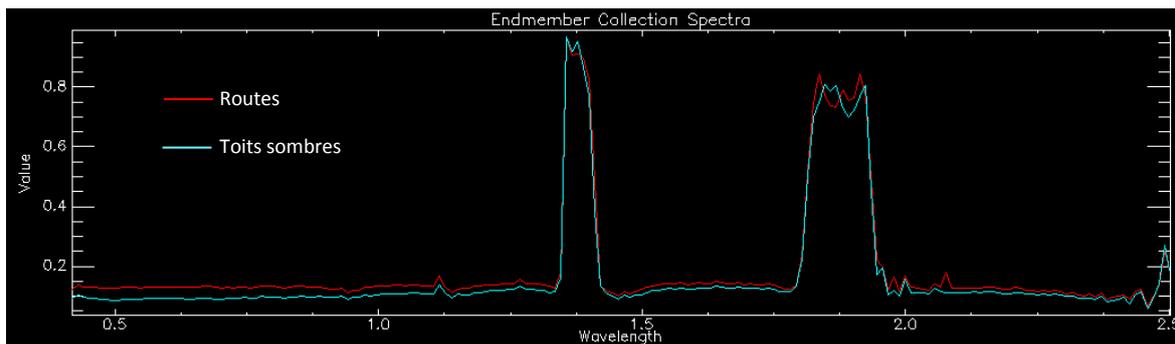


Figure 15 - Réponse spectrale des bâtiments foncés par rapport à la voirie sur l'ensemble du domaine étudié.

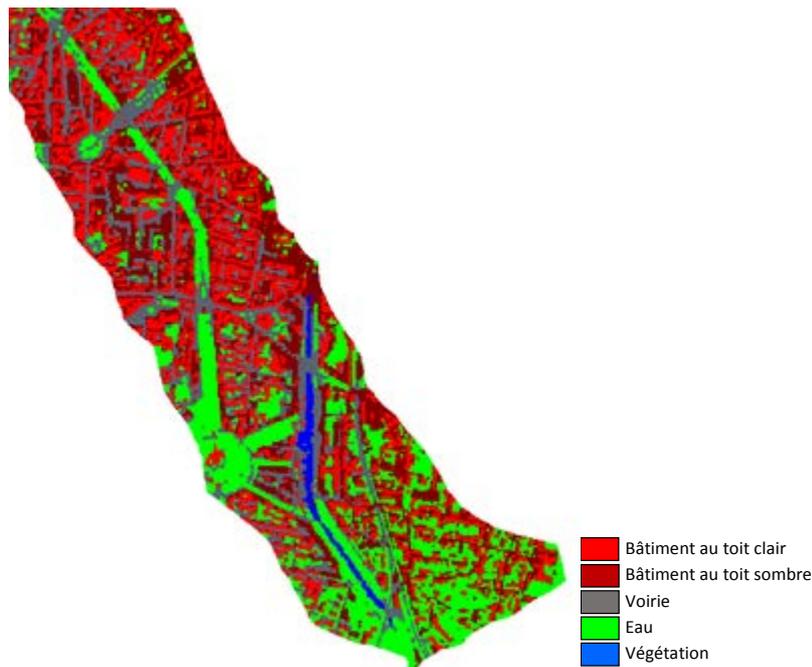


Figure 16 - Résultat de la classification après prise en compte de l'information 3D.

Conclusion

Cette étude montre que les images hyperspectrales HYPXIM utilisées conjointement avec des données LIDAR offre un grand potentiel pour la cartographie des surfaces imperméables en milieu urbain. Elle illustre aussi que la méthode orientée-objet permet d'obtenir des résultats prometteurs quant à l'extraction des toits en se basant uniquement sur l'information spectrale et la hauteur des bâtiments.

Références

- R.R. Rindfuss, P.C. Stern, *Linking remote sensing and social science*. In S. Liverman et al. (Eds.), *People and pixel-linking remote sensing and social science* (pp. 1–28). Washington, DC: National Academic Press (1998).
- M. Herold, H. Couclelis, K.C. Clarke, The Role of Spatial Metrics in the Analysis and Modeling of Urban Land Use Change. *Computers, Environment and Urban Systems* **29**, 369–399 (2005).
- F. Priem, F. Canter, Synergistic Use of LiDAR and APEX Hyperspectral Data for High-Resolution Urban Land Cover Mapping. *Remote sensing* **8**, 787 (2016).
- D.S. Lu, Q.H. Weng, Use of impervious surface in urban land-use classification. *Remote Sensing of Environment* **102**, 146–160 (2006).
- R. Welch, Spatial resolution requirements for urban studies. *International Journal of Remote Sensing* **3**(2), 139–146 (1982).
- R.R. Jensen, P.J. Hardin, A.J. Hardin, Classification of urban tree species using hyperspectral data. *Geocarto International* **27**, 443–458 (2012).
- E. Ben-Dor, *Imaging spectrometry for urban applications*. In *Imaging Spectrometry: Basic Principles and Prospective Applications*; Van Der Meer, F.D., De Jong, S.M., Eds.; Kluwer Academic Publishers: Dordrecht, The Netherlands; pp. 243–281 (2001).
- D.A. Roberts, M. Herold, *Imaging spectroscopy of urban materials*. In *Infrared Spectroscopy in Geochemistry, Exploration and Remote Sensing*; King, P., Ramsey, M.S., Swayze, G., Eds.; Mineral Association of Canada: Ottawa, ON, Canada; pp. 155–181 (2004).
- S. Gadai, W. Ouerghemmi, *Morpho-spectral objects classification by hyperspectral airborne imagery*, 8th Workshop in Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, Aug. 2016, Los Angeles, USA (2016).
- S. Pascucci, C. Bassani, R.M. Cavalli, L. Fusilli, A. Palombo, S. Pignatti, F. Santini, *Hyperspectral remote sensing capability for mapping near-surface asbestos deposits and pollutants dispersion in soils*. Proc. Hyperspectral 2010 Workshop, Frascati, Italy, 17–19 March (2010).

C. Cilia, C. Panigada, M. Rossini, G. Candiani, M. Pepe, R. Colombo, Mapping of asbestos cement roofs and their weathering status using hyperspectral aerial images. *ISPRS International Journal of Geo-Information* **4**, 928–941(2015).

S. Michel, M.J. Lefevre-Fonollosa, S. Hosford, *HYPXIM – A hyperspectral satellite defined for science, security and defence users*. Proc. 'Hyperspectral 2010 Workshop', Frascati, Italy, 17–19 March (2010).

Y. Boucher, L. Poutier, V. Achard, X. Lenot, C. Miesch, *Validation and robustness of an atmospheric correction algorithm for hyperspectral images*. Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery VIII, N° 4725-54, SPIE AeroSense 2002, Orlando, FL., 1-5 April (2002).

Production dans la cadre de l'ANR HYPEP

Aguejdad R., Skupinski G., Weber C., Serradj A., 2018. Object-Oriented Classification of Urban LULC using Hyperspectral and LiDAR Remote Sensing Data. *The 9th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS 2018)*, September 23-26, Amsterdam (The Netherlands).

Weber C., **Aguejdad R.**, Briottet X., Avala J., Fabre S., Demuynck J., Zenou E., Deville Y., Karoui M., Benhalouche F., Gadal S., Ourghemmi W., Mallet C., Le Bris A., Chehata N., 2018. Hyperspectral Imagery for Environmental Urban Planning. *International Geoscience and Remote Sensing Symposium (IGARSS 2018)*, July 23-27, Valencia (Spain).

Aguejdad R., Serradj A., Weber C., 2017. Mapping urban impervious surfaces from an airborne hyperspectral imagery using the object-oriented classification approach. *Proceedings of the International Conference on Advances in Sustainable Construction Materials & Civil Engineering Systems (ASCMCES-17)*, April 18-20, Sharjah (United Arab Emirates).

Aguejdad R., Serradj A., Weber C., Briottet X., 2017. Extraction des surfaces imperméables à partir d'une image hyperspectrale en utilisant une méthode orientée-objet. *Colloque du Groupe Hyperspectral, Société Française de Photogrammétrie et de Télédétection*, Mai 9–11, 2017, Ifremer, Brest (France).

Perspective

L'une des perspectives futures consiste à appliquer cette méthode au domaine thermique et à différentes résolutions spatiales disponibles (2, 4, 8 et 10 m).

3. WP3.2: CARTOGRAPHIE DE LA VEGETATION URBAINE

3.1 Classification supervisée de la végétation (haute et basse) à partir d'une librairie

Auteurs : S. Gadal, W. Ouergemmi (UMR ESPACE)

Objectif : cartographie supervisée des espèces d'arbres sur la ville de Kaunas (Lituanie) à plusieurs échelles spatiales

Méthode

Nous avons mené une étude de faisabilité et de performance sur la **cartographie supervisée des espèces d'arbres** sur la ville de Kaunas (Lituanie) à plusieurs échelles d'étude et en utilisant différents jeux de données aéroportées et satellites et en testant diverses approches.

➤ **Performance de la classification et de la cartographie des espèces d'arbres**

Deux études ont été menées sur un nombre différent de bandes spectrales pour identifier celles qui sont les plus intéressantes et sur respectivement 11 et 8 espèces de végétation en utilisant le classifieur Spectral Angle Mapper (SAM) (soumission à la conférence IGARSS 2018) (Figure 10), (soumission à la conférence Whispers 2018) (Figure 11).

Parallèlement à ces deux études, une étude de Master 1 (à Aix-Marseille université) septembre 2017) a porté sur l'analyse critique de l'utilisation de l'imagerie aéroportée et satellite pour la cartographie de la végétation urbaine .

Concernant la première étude, nous avons testé deux jeux de données à 16 et 64 bandes acquis avec l'imageur hyperspectral Ricola. Comme prétraitements, nous avons converti les images corrigées atmosphériquement en utilisant le modèle Modtran 4, puis nous avons appliqué la méthode de débruitage Minimum Noise Fraction (MNF) afin de compenser le bruit capteur. Nous avons ensuite appliqué un masque de NDVI, afin de limiter les confusions potentielles avec des pixels de non-végétation. Ensuite, la classification a été appliquée en utilisant une librairie spectrale de laboratoire et une librairie spectrale image (acquisition des spectres d'entraînement depuis l'image en s'aidant de la vérité de terrain). Dans un deuxième temps, une sélection de bandes a été appliquée sur l'image à 64 bandes en utilisant la méthode BandMax, suivi d'une régularisation par optimisation pseudo-booléenne dans le but de compenser les effets sel et poivre en sortie du classifieur et d'améliorer le rendu final de classification (Figure 17).

Dans un deuxième temps, et après discussion avec des collègues Lituanais de l'Université Aleksandras Stulginskis de Kaunas, il s'est avéré qu'il fallait rectifier les espèces de végétation utilisées, en supprimant les espèces peu représentatives et peu présentes dans la ville de Kaunas. Nous avons donc restreint notre étude à 8 espèces de végétation, nous avons également fiabilisé la vérité de terrain à disposition, (l'inventaire d'arbres utilisée rédigé en lituanien, et sa traduction en anglais effectuée en 2015, ne correspondait pas forcément à la bonne espèce). Pour cette étude, nous avons utilisé le même jeu de données que pour l'étude précédente, et comparé deux classifieurs à savoir le SAM et le Support Vector Machine (SVM), et nous avons également fait une étude de sensibilité en faisant un test sur 3 classifications : une classification sans MNF, une classification avec MNF dans le domaine de transformation décorrélé (supprimant les bandes MNF à forte variance cumulative), et une classification avec MNF après suppression des bandes MNF à forte variance cumulative dans le domaine de transformation et restauration de l'image.. La classification est appliquée sur une image masquée des pixels de non-végétation par seuillage NDVI.

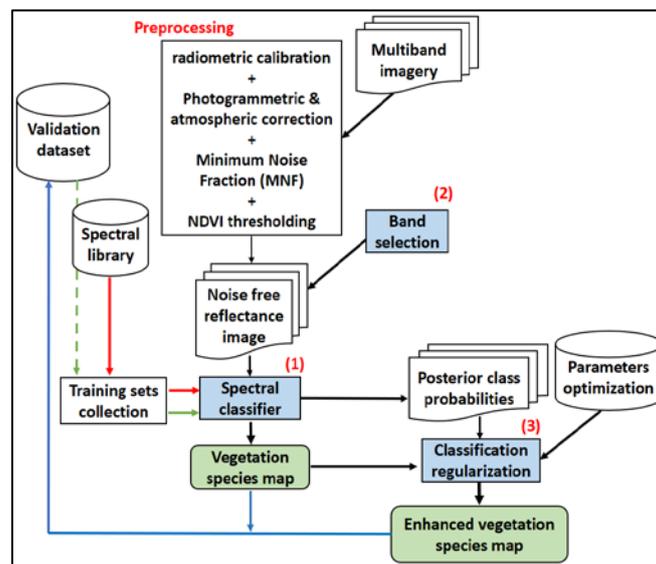


Figure 17 - Cartographie de la végétation urbaine 1) en utilisant tout l'intervalle spectral, 2) en appliquant une sélection de bandes, et 3) en utilisant une post-classification à base de régularisation.

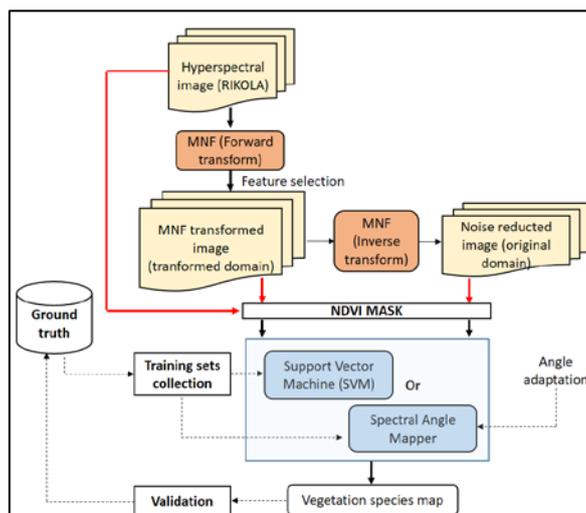


Figure 18 - Cartographie de la végétation urbaine par SAM et SVM, précédée d'un débruitage par MNF et seuillage sur NDVI.

➤ Cartographie des espèces d'arbres à partir de différentes sources

Le projet de Master 1 a porté sur la faisabilité de détection de la végétation urbaine en utilisant plusieurs jeux de données aéroportées et satellites dont les deux jeux de données à 16 et à 64 bandes cités ci haut¹. En plus des données aéroportées, des images Landsat-8 OLI et Sentinel-2 ont été utilisées pour i) déterminer la période optimale dans la saison de détection de la végétation urbaine, et ii) pour comparer les cartes du couvert végétal obtenues avec Landsat-8 et Sentinel-2 et iii) les images hyperspectrales ont servi à bien préciser les intervalles spectraux à prendre en compte pour le calcul d'indices de végétation. Les cartographies des espèces de végétation, ont été effectuées avec le classifieur SAM en considérant différents échantillons d'apprentissage : 10 et 50. L'évaluation des résultats s'est faite en utilisant deux indices de bonne classification qui sont la précision globale des cartes générées (i.e. Overall Accuracy) et l'indice Kappa.

Données utilisées

Deux jeux de données aéroportées acquis sur la ville de Kaunas (Lituanie) ont été utilisés. L'acquisition a été réalisé avec le capteur hyperspectral Vis-NIR RIKOLA, opérant dans l'intervalle spectral 500-900nm.

Le premier jeu de données a été acquis en **Juillet 2015**, en configuration 16 bandes spectrales, avec une résolution spatiale de 0.7m et une portion test de 3189×3292 pixels, avec une fenêtre horaire d'acquisition entre 11 :40 et 13 :23.

Le deuxième jeu de donnée a été acquis en **Septembre 2016**, en configuration 64 bandes, avec une résolution spatiale de 0.5m et une portion test de 4000×1900 pixels, avec une fenêtre horaire d'acquisition entre 9 :15 et 10 :40. Les images en luminance ont été converties en réflectance en utilisant le modèle de transfert radiatif MODTRAN.

Données Landsat dates bandes été

Données S2 dates bandes 3 dates

Ou sous forme de tableau !!!!

Points entrainement avec DGPS ?

Inventaire d arbres ????

¹ A noter qu'au moment du stage de Master, nous avons rencontré des difficultés relatives à une mauvaise qualité des prétraitements de l'image à 64 bandes, les résultats présentés dans le Master 1 en utilisant cette image sont donc moins fiables que ceux obtenus avec l'image à 16 bandes, cette image a été revue et optimisée pour les deux études cités ci haut.

La ville de Kaunas (*Figure 19*) est caractérisée par une diversité importante d'espèces végétales, 96 espèces d'arbres, 49 espèces d'arbustes et 2 espèces de vignes. Pour cette étude nous nous sommes concentrés sur le centre-ville, la cartographie a concerné la végétation urbaine se trouvant dans les jardins individuels et publics, et au sein de la ville.



Figure 19 - Zone d'étude, centre-ville de Kaunas (Lituanie).

Concernant la première étude, la définition des espèces s'est faite à deux niveaux : le premier sur la famille exemple végétation rase (i.e. gazon) et feuillus et conifères, et le second, plus fin, sur les espèces avec 6 espèces de feuillus, 4 espèces de conifères et une espèce de végétation rase. Nous avons comparé la classification par librairie spectrale, en entraînant le classifieur avec des spectres purs mesurés en laboratoire, et par librairie image, en prenant des spectres d'entraînement à l'aide de la vérité de terrain à disposition. Nous avons comparé plusieurs cas de figure en termes d'échantillons entraînement en prenant 10, 50 et 100 éléments : l'apprentissage avec 50 échantillons s'est avéré être un bon compromis et a été utilisé pour la stratégie de sélection de bandes avec l'image à 64 bandes.

Concernant la deuxième étude, seule l'étude par espèces a été réalisée, avec 4 espèces de feuillus, 3 espèces de conifères et une espèce de végétation rase. Pour cette étude, une librairie image a été utilisée pour entraîner les classifieurs SAM et SVM, en effet cette stratégie s'est avérée plus efficace que la stratégie par librairie spectrale. En termes d'entraînement, 100 échantillons d'entraînement sont sélectionnés.

Pour le Master 1, quatre jeux de données ont été utilisés, les deux jeux de données cités ci haut, 1 jeu de données LANDSAT 8 OLI (image d'été), 1 jeu de données Sentinel-2 comprenant 3 dates (automne, printemps et été) et correspondant à l'année 2016. Il n'y a pas eu d'image d'hiver pour l'année 2016, dû à des couvertures nuageuses trop importantes. Pour ces jeux de données, une librairie spectrale de 15 espèces de végétation a été utilisée dans la phase d'apprentissage du classifieur SAM, ainsi qu'un inventaire d'arbres sur la ville de Kaunas pour le processus de validation.

Résultats

Les meilleures performances obtenues avec la classification par librairie image étaient de 19.4% et de 21.1% respectivement pour les images à 16 et 64 bandes (*Tableau 4*). La plupart des espèces étant détectées, avec des performances faibles. L'augmentation du nombre d'échantillons a dégradé la performance pour l'image à 16 bandes, contrairement à l'image à 64 bandes qui a donné de meilleures performances après augmentation

du nombre d'échantillons, probablement du fait d'une meilleure caractérisation spectrale et donc d'une meilleure variabilité spectrale donnant une modélisation plus cohérente de la classe d'intérêt.

La classification utilisant des spectres d'entraînement issus de librairie spectrale s'est avérée peu performante avec des précisions de 3% et de 1.5% respectivement pour les images à 16 et 64 bandes (Tableau 3). Le degré de détection des espèces étant également faible, nous avons remarqué une importante dégradation de la performance par rapport au cas de la librairie image. Ces résultats s'expliquent par une non-concordance de l'échelle de mesure du laboratoire et de l'échelle de mesure aéroportée. Les arbres feuillus ont montré une meilleure détectabilité que les conifères, la détection de la végétation rase s'est révélée faible (Figure 20c).

La classification par groupe d'espèces en utilisant la librairie image s'est avérée meilleure que la classification par espèces individuelles, avec des précisions de 57% et de 49.8% respectivement pour les images à 16 et 64 bandes, et une meilleure détectabilité des arbres feuillus (Tableau 4). La classification par groupe d'espèces en utilisant la librairie spectrale s'est avérée encourageant en utilisant l'image à 16 bandes, avec une précision de 67%, la détectabilité des conifères et de la végétation rase étant toujours insuffisante. Les performances obtenues avec l'image à 64 bandes se sont avérées plus faibles.

Dans la suite de l'étude, nous avons appliqué une sélection de bandes sur l'image à 64 bandes en utilisant la méthode BandMax, afin de compenser la corrélation spectrale entre les espèces végétales et donc améliorer la performance de classification, le test a été effectué pour une classification avec la librairie spectrale (i.e. le cas le plus complexe). Le principe consiste à comparer des spectres cibles et des spectres de fond (i.e. sources de confusion), le but étant de déterminer les bandes qui permettent de mieux distinguer le premier groupe du second. Les spectres cibles choisis proviennent de la librairie spectrale d'arbres utilisée pour l'entraînement, les spectres de fond proviennent de 5 spectres de végétation rase acquis à partir de l'image. L'algorithme a détecté 15 bandes utiles pour distinguer les arbres de la végétation rase. Cette procédure a permis d'améliorer la précision globale de 15%, le degré de détectabilité des arbres feuillus passe ainsi de 20.7% à 47%, la détectabilité de la végétation rase passe 0% à 16%, la détection des arbres conifères demeure faible (Tableau 4, sélection de bandes et Figure 20d).

, Une méthode de régularisation a été appliquée sur le résultat pour compenser les effets grossiers de classification, cette étape a permis rendu visuel de classification plus clair (Figure 20.e). La détection par groupe d'espèces s'est renforcée, spécialement pour le groupe arbres feuillus, avec une faible amélioration des conifères est à noter. La procédure de régularisation a permis d'améliorer le rendu global de classification, cependant sans amélioration en termes de performance de classification (Tableau 4, sélection de bandes).

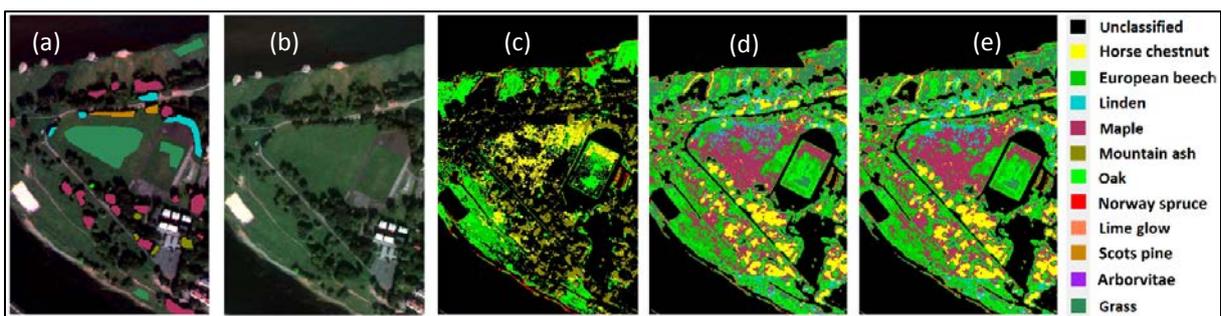


Figure 20 - a) Composition colorée RGB de l'image à 64 bandes avec vérité de terrain correspondante, b) Composition colorée RGB de l'image seule, c) classification par librairie spectrale en utilisant tout l'intervalle spectral, d) classification par librairie spectrale en appliquant une sélection de bandes, et e) classification par librairie spectrale en appliquant une sélection de bandes et une étape de régularisation.

Tableau 4 - Performance de classification par espèces de végétation, et par groupe d'espèces en utilisant une librairie image et une librairie spectrale.

Espèces	Précision de classification (16 bandes)		Précision de classification (64 bandes)	
	Librairie image	Librairie spectrale	Librairie image	Librairie spectrale
				Toutes les bandes
Classifieur				

Échantillons													Pas de reg.	Reg.
	10	50	100	10	50	100	10	50	100	10	50	100	50	50
Marronnier	0.0	3.7	5.4	20.1	6.4	4.3	2.3	8.3	8.7	20.0	3.2	1.1	3.3	3.2
Hêtre européen	21.0	7.9	7.9	2.6	10.0	11.1	20.2	38.7	33.1	0.2	4.0	5.2	20.0	19.9
Tilleul	4.3	17.5	9.2	0.7	0.0	0.0	3.7	2.4	11.6	0.0	0.0	0.0	8.5	8.8
Érable	30.4	14.8	12.4	0.3	0.0	0.1	13.3	12.9	11.0	0.0	0.0	0.0	29.5	28.9
Sorbier	10.2	11.8	22.5	0.0	59.8	59.6	15.2	21.0	15.7	0.0	26.2	20.7	0.0	0.0
Chêne	33.8	34.3	17.1	2.1	6.8	8.7	8.8	11.7	10.2	1.6	1.7	3.97	21.9	21.9
Épicéa	11.3	43.3	21.7	4.9	3.2	4.6	5.8	11.6	16.6	0.4	1.2	2.7	0.0	0.0
Genévrier	0.0	0.3	0.3	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
Pin sylvestre	21.5	24.0	22.8	0.0	0.0	0.1	63.8	51.5	30.1	0.0	0.0	0.0	0.4	0.4
Thuya	11.8	25.9	46.1	0.0	0.0	4.9	0.7	0.5	0.7	0.0	0.0	0.0	0.0	0.0
Gazon	30.4	56.9	60.8	0.0	0.0	0.4	34.1	31.3	36.0	0.0	0.0	0.0	16.6	16.5
O.A. (%)	19.4	18.2	15.6	2.7	3.0	2.9	19.7	19.1	21.1	1.5	1.1	0.9	16.8	16.7
Kappa × 10 ⁻¹	70	70	70	-4	-0.9	-0.4	50	100	110	-3	-0.6	-0.1	14	11
Feuillus	--	57.9	--	--	78.0	--	--	63.2	--	--	36.2	--	71.2	71.2
Conifères	--	45.6	--	--	5.4	--	--	35.0	--	--	1.0	--	3.7	3.7
Gazon	--	56.8	--	--	0.0	--	--	31.3	--	--	0.0	--	16.6	16.5
O.A. (%)	--	57.0	--	--	67.2	--	--	49.8	--	--	20.7	--	47.0	46.0
Kappa × 10 ⁻¹	--	170	--	--	-20	--	--	190	--	--	-7	--	-3	-7

➤ Influence du classifieur

Dans cette étude, nous avons comparé deux classifieurs, en utilisant un nombre limité et constant de spectres d'entraînement égal à 100, le contexte est toujours complexe avec une distribution hétérogène des espèces d'arbres dans la zone test et avec des zones d'ombres.

L'application de la MNF a permis globalement une amélioration de la précision de classification, que ce soit pour le SAM ou bien pour le SVM, en utilisant 16 bandes ou 64 bandes, l'opération reste tout de même délicate, car il y a risque de surestimer le bruit en supprimant trop de bandes MNF et donc de dégrader potentiellement la performance de classification. D'un autre côté, il y a risque de sous-estimer le bruit en supprimant un nombre insuffisant de bandes MNF et donc de ne pas pouvoir améliorer la performance de classification. Dans la bibliographie, il est généralement conseillé de supprimer les bandes MNF ayant une variabilité cumulative égale ou supérieure à 90%. De manière générale une inspection visuelle de ces bandes serait à recommander

Concernant le classifieur SAM, la performance en utilisant les images à 16 et 64 bandes sans MNF s'est révélée faible ; l'application de la MNF dans le domaine inverse (MNF 1) a permis une légère amélioration, l'application de la MNF dans le domaine de transformation s'est révélée plus intéressante avec une amélioration de la précision de 15% et de 12% respectivement pour les images à 16 et 64 bandes (Tableau 5).

Le classifieur SVM s'est révélé plus robuste indépendamment de l'entrée utilisée (e. g. image transformée ou pas), pour les images à 16 et 64 bandes. La meilleure précision de classification est obtenue en utilisant une image MNF dans le domaine de transformation (MNF 2), l'amélioration par rapport à une classification sans MNF étant moindre que pour le classifieur SAM, avec des améliorations allant de 1% à 3% approximativement (Tableau 5). Concernant l'image à 16 bandes, les meilleures détections ont concerné les chênes, pins, Thuya et végétation rase. Concernant l'image à 64 bandes, les meilleures détections sont effectuées avec les sorbiers, les chênes, sapins et végétation rase. Le passage de 16 à 64 bandes a permis globalement une meilleure détection des espèces spécialement les feuillus et la végétation rase (Tableau 5).

Tableau 5- Performance de classification en utilisant les classifieurs SAM et SVM, pour les données à 16 et 64 bandes.

Espèces	Precision de classification (16 bandes)						Precision de classification (64 bandes)					
	SAM			SVM			SAM			SVM		
Transform.	No NMF	MNF (1)	MNF (2)	No MNF	MNF (1)	MNF (2)	No NMF	MNF (1)	MNF (2)	No MNF	MNF (1)	MNF (2)
Marronnier	16.4	16.5	21.5	19.2	19.1	23.3	11.5	12.1	27.0	28.1	28.0	22.0
Tilleul	15.4	16.0	24.5	33.6	36.0	35.8	20.5	21.1	13.1	19.3	19.2	17.3
Sorbier	16.7	11.9	25.8	37.5	38.4	46.2	46.3	49.0	50.1	38.5	38.8	34.0
Chêne	41.0	40.2	49.7	36.2	36.5	45.8	62.3	61.1	72.9	69.9	72.5	62.2
Épicéa	10.0	9.8	21.1	16.4	15.0	19.2	26.8	26.9	16.0	50.7	51.6	40.3
Pin sylvestre	49.8	47.7	55.4	49.1	47.3	59.3	10.7	10.5	18.7	17.9	18.1	17.7
Thuya	35.7	31.9	33.7	52.7	50.1	48.3	10.4	10.9	6.7	28.5	27.6	26.8
Gazon	45.2	45.4	93.9	92.5	91.2	92.6	22.3	21.8	65.0	85.1	85.5	95.8
O.A. (%)	22.6	22.4	37.6	40.7	41.2	43.6	21.9	22.6	34.5	45.5	45.7	46.1
Kappa	10.7	10.2	28.9	29.8	30.3	33.7	11.4	11.6	24.7	34.7	34.9	34.3

Concernant les travaux de Master 1, le stagiaire a tenté de cartographier 15 espèces de végétation sur la ville de Kaunas. Les performances de classification obtenues pour l'image à 16 bandes pour 10 et 50 échantillons pour la détection par espèces, sont très faibles (<5%), une étude en 3 classes correspondants aux arbres feuillus, conifères et végétation rase a été réalisée, les performances obtenues sont respectivement de 12.3% et de 14.3% pour 10 et 50 échantillons, avec donc une légère augmentation de la précision, néanmoins, la performance reste faible. L'image à 64 bandes n'a pas permis de donner des résultats pertinents au moment du stage, dû à des problèmes de co-enregistrement de bandes et de correction atmosphérique. L'étude a mis en évidence qu'une augmentation du nombre d'échantillons d'entraînement de 10 à 50 améliorerait de façon peu significative la performance de classification des images aéroportées (Figure 21).

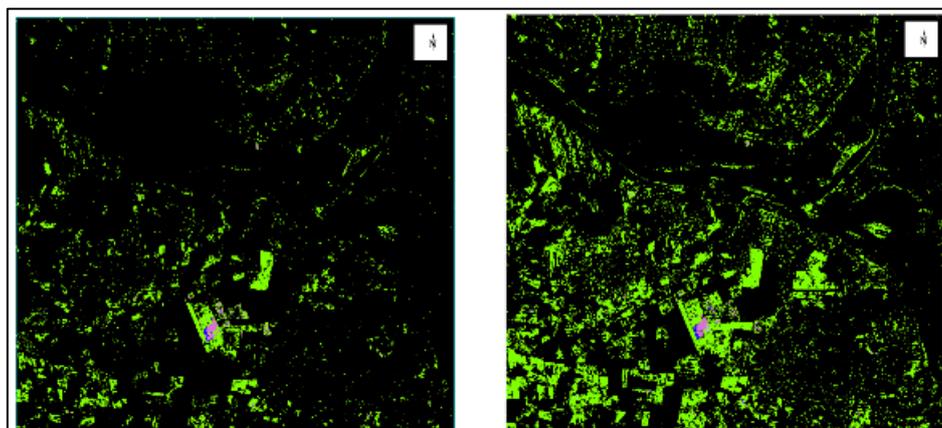


Figure 21- Comparaison des résultats obtenus avec Sentinel-2 pour le printemps, à gauche une classification à 50 échantillons, à droite une classification à 10 échantillons. (Source : Sentinel 2 : 12/05/2017)

Le stagiaire a aussi effectué une étude comparative entre une image LANDSAT-8 et une image Sentinel-2. Cette dernière montre de meilleures performances en cartographie de végétation dues à une résolution spatiale meilleure (10 m contre 30 m). Une étude de saisonnalité a été menée montrant que le printemps est l'optimum climatique pour la détection de la végétation urbaine, l'automne quant à lui obtient les moins bons résultats.

Conclusion :

Deux études de cartographie de la végétation urbaine par imagerie superspectrale/hyperspectrale dans l'intervalle Vis-NIR ont été évaluées. Malgré des résolutions spatiales assez hautes de 0.5m et de 0.7m, les

performances sont mitigées pour 3 raisons 1) l'intervalle spectral est limité au Vis-NIR (pas de SWIR), 2) l'hétérogénéité de la distribution des arbres dans la ville de Kaunas et 3) une vérité de terrain limitée pour certaines espèces sur la portion test.

- La première étude a montré que l'utilisation d'une librairie spectrale de laboratoire n'est pas adaptée pour la détection par espèces individuelles en utilisant l'imagerie aéroportée, les échelles de mesures étant différentes. La détection par espèces en utilisant une librairie image s'est révélée plus performante mais la précision globale n'étant toujours pas suffisante. La détection par groupe d'espèces s'est révélée par contre encourageante notamment pour la détection des arbres feuillus.
- Nous avons appliqué une sélection de bandes sur l'image à 64 bandes en utilisant la librairie spectrale pour l'apprentissage du classifieur SAM, cela a permis d'obtenir une amélioration de la précision globale de 15% pour la détection par espèces individuelles (c.f. Tableau 4) et d'une augmentation de 26% pour la détection par groupe d'espèces (c.f. Tableau 4). La détection des conifères et de la végétation rase reste faible, avec tout de même une augmentation de 16% en termes de détection de végétation rase. Une régularisation a permis par la suite de réduire les effets sel et poivre après classification. Concernant le choix des classifieurs : un classifieur à apprentissage (SVM), basé sur la génération d'hyper-plans entre les échantillons d'entraînement pour les séparer en classes distinctes dans un espace de caractéristiques multidimensionnel, a été introduit en plus du SAM qui est quant à lui basée sur la similarité spectrale en utilisant l'angle angulaire entre deux vecteurs, sans tenir en compte leur amplitudes. Nous avons pris un nombre de spectres d'apprentissage constant pour ne pas privilégier une classe par rapport à une autre. Nous avons également comparé la classification sans MNF et avec MNF, la MNF a été testée dans le domaine de transformation décorrélié et dans le domaine inverse d'origine après élimination des bandes MNF à forte variabilité cumulative. Cette étude a révélé que **le SVM est plus adapté à la cartographie de la végétation** que le SAM., L'utilisation du classifieur SVM, s'est révélée plus performante à partir des données à 64 bandes que celle utilisant des données à 16 bandes. La classification à partir de données transformées par MNF s'est révélée meilleure qu'à partir des données non transformées. La meilleure performance de classification a été obtenue en utilisant la MNF dans le domaine de transformation suivi du SVM, la précision de classification est égale à 46.1%. Finalement, les résultats de classification obtenus en utilisant une librairie image couplée au classifieur SVM sont encourageants et peuvent être améliorés en modifiant la stratégie d'apprentissage et en appliquant une sélection de bandes. En revanche, l'utilisation d'une librairie spectrale de type laboratoire ne semble pas adéquate en tant que telle, d'autres prétraitements doivent être considérés (e. g. passage de la feuille à l'arbre). L'utilisation de l'imagerie Sentinel-2 est une solution intéressante pour la cartographie de végétation à une échelle grossière (ex : feuillus, conifères et végétation rase). La période optimale pour la détection du couvert végétal est le printemps. La détection par espèces est quant à elle plus performante avec l'imagerie aéroportée de type superspectral/hyperspectral.

Références

Perspectives

Ces travaux ont mis l'accent sur l'intérêt de l'imagerie hyperspectrale dans la cartographie de la végétation urbaine à plusieurs échelles spatiales. Cependant, plusieurs problématiques ont été relevées vis-à-vis : (1) des prétraitements des images acquises avec l'imageur à trame, qui génèrent des problèmes de co-enregistrements entre bandes ; (2) de l'utilisation des librairies spectrales externes et de (3) la corrélation importantes entre certaines espèces végétales, qui rendent la distinction de ces dernières difficiles. Par rapport à ces questions, nous envisageons en premier temps (1) d'améliorer la qualité des données acquises, en testant d'autres méthodologies de prétraitements et de photogrammétrie, (2) d'augmenter le nombre de bandes spectrales à 100 en utilisant le même intervalle spectral, afin de mieux caractériser les limites des méthodes orientées pixels pour la distinction des espèces végétales et déterminer le bon compromis entre résolution spatiale et nombre de bandes adéquats, (3) d'explorer d'autres méthodologies de sélection/optimalisation de bandes spectrales, afin d'éliminer les redondances indésirables et de compenser les corrélations spectrales entre

espèces. Finalement, l'utilisation des bibliothèques spectrales dans le processus d'apprentissage peut être une solution intéressante à condition de prétraiter ces spectres (i.e. utiliser des modèles de mélange) et de les adapter à la résolution spatiale d'entrée.

Production scientifique dans le cadre de l'ANR HYEP

Sébastien Gadal, Walid Ouerghemmi, Gintautas Mozgeris, Romain Barlatier. Recognition of urban vegetation by hyperspectral airborne high-resolution VNIR imager (Kaunas, Lithuania). 6ème édition : colloque groupe hyperspectral SFTP-GH, May 2018, Montpellier, France. pp.47, 2018.

Sébastien Gadal, Walid Ouerghemmi. Cartographie de la végétation urbaine par imagerie aéroportée hyperspectrale sur la ville de Kaunas (Lituanie). TEMU 2018 : Atelier Télédétection pour l'Etude des Milieux Urbains, Mar 2018, Strasbourg, France.

Gintautas Mozgeris, Sébastien Gadal, Donatas Jonikavičius, Lina Straigyte, Walid Ouerghemmi, et al.. The Potential of Imaging from Ultra-Light Aircraft for Urban Tree Inventories: Case Study in Kaunas, Lithuania. IUFRO - 125th Anniversary Congress 2017, Sep 2017, Freiburg, Germany. IUFRO, pp.430, 2017, Interconnecting Forest, Science, and People.

Gintautas Mozgeris, Sébastien Gadal, Donatas Jonikavičius, Lina Straigyte, Walid Ouerghemmi, et al.. Hyperspectral and color-infrared imaging from ultra-light aircraft: Potential to recognize tree species in urban environments. University of California Los Angeles. 8th Workshop in Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, Aug 2016, Los Angeles, United States. pp.542-546, 2016.

Walid Ouerghemmi, Sébastien Gadal, Gintautas Mozgeris. Urban vegetation mapping using hyperspectral imagery and spectral library. IGARSS 2018, Jul. 2018, Valence, Spain.

Walid Ouerghemmi, Sébastien Gadal, Gintautas Mozgeris. Urban vegetation mapping by airborne hyperspectral imagery: Feasibility and limitations. 9th Workshop in Hyperspectral Image and Signal Processing, Sept. 2018, Amsterdam, Nederland.

3.2 Cartographie supervisée des espèces d'arbres

3.2.1 Cartographie supervisée des espèces d'arbres à partir de sources aéroportées multiples

Auteurs : J. Aval (ONERA), S. Fabre (ONERA), E. Zenou (ISAE), D. Shereen (INRA), M. Fauvel (INRA), X. Briottet (ONERA),

Objectif de l'étude : Evaluer l'apport de la **fusion de données hétérogènes** (Imagerie hyperspectrale VNIR et SWIR, imagerie panchromatique, MNS) acquises sur Toulouse pour l'identification de 15 espèces d'arbre.

Méthode

La méthode comprend plusieurs étapes synthétisées dans la Figure 22.

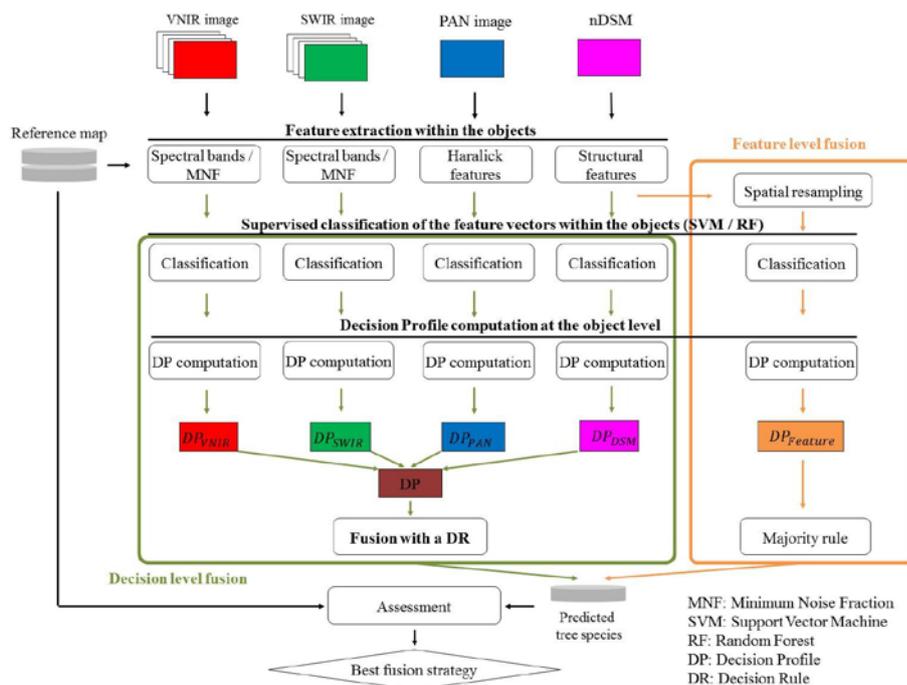


Figure 21 – Organigramme générale de la méthode

Une première étape consiste à extraire des caractéristiques des objets dans chaque type d'images. Pour les images hyperspectrales (VNIR et SWIR, indépendamment les résolutions spatiales étant différentes), les vecteurs de caractéristiques sont constitués soit de la réflectance spectrale, soit des composantes de la MNF (30 composantes pour le VNIR et 15 pour le SWIR). Pour l'image panchromatique, les paramètres d'Haralick (moyenne, écart type, homogénéité, dissimilarité, entropie, moment d'inertie d'ordre 2, contraste et corrélation) sont utilisés pour représenter la texture des espèces d'arbres. Enfin, pour le modèle numérique de surface, le vecteur de caractéristiques est constitué de paramètres caractéristiques de la forme 3D de l'arbre. Si h est la hauteur et A l'aire de l'objet, les paramètres de structure sont : h_{\max} , A/h_{\max} , $A * h_{\max}$, h_{\min} , h_{mean} , $h_{\max} - h_{\min}$, $h_{\max} - h_{\text{mean}}$, h_{std} , $(h_{\max} - h_{\min})/h_{\max}$, $(h_{\max} - h_{\text{mean}})/h_{\max}$, h_{std}/h_{\max} .

Ces 4 vecteurs de caractéristiques (VNIR, SWIR, PAN et MNS) sont utilisés ensuite dans l'étape de classification en utilisant les algorithmes de classification supervisée : Support Vector Machine (SVM) et Random Forest (RF). Une probabilité d'appartenance est calculée pour chaque vecteur de caractéristiques et chaque espèce. Une classification mono-source est alors effectuée via un vote par la majorité au sein des couronnes.

Concernant la fusion, une première alternative est proposée reposant sur une approche de fusion au niveau de la décision. En effet, une règle de décision est alors mise en place en combinant les différentes probabilités d'appartenance afin de produire un profil de décision (DP) regroupant les sources (VNIR, SWIR, PAN ou MNS) représenté par une matrice 4 lignes (nombre de sources) et 15 colonnes (nombre d'espèces) où chaque valeur (s, p) de la matrice représente la confiance que l'on a de trouver l'espèce p avec la source s . La fusion de ces informations pour sélectionner l'espèce est ensuite effectuée en testant 3 règles de décision décrites dans le 6.

Tableau 6 – Règles de décision pour 4 sources et 15 espèces. L'indice p est la source (VNIR, SWIR, PAN ou MNS).

Le facteur de pondération w permet de pondérer l'importance de chaque source en fonction de leurs performances. Ainsi si une source a une très faible précision pour une espèce donnée, la contribution de la source pour l'estimation de cette espèce sera pondérée par sa précision dans la règle de décision afin de prévenir d'éventuelles confusions

DR	Type	Rule
1	Nontrainable	$s = \arg \max_s \sum_{p=1}^4 DP(s, p)$
2	Trainable	$s = \arg \max_s \sum_{p=1}^4 w(s, p) * DP(s, p)$
3	Trainable	$s = \arg \max_s \sum_{p=1}^4 \sum_{s'=1}^{15} w(s, s', p) * DP(s', p)$

*nécessitant un apprentissage

Une seconde alternative est une approche de fusion de caractéristiques, méthode plus classique utilisée comme base de comparaison. Les vecteurs de caractéristiques des différentes sources sont regroupés en un seul vecteur avant l'étape de classification supervisée (SVM ou RF). La règle du vote par la majorité est appliquée pour sélectionner l'espèce la plus probable, de manière analogue à ce qui est effectué pour la classification mono-source.

Données utilisées

Le site d'étude est le centre de Toulouse où deux zones d'études sont retenues : zone de référence afin de sélectionner la meilleure stratégie de fusion et une zone de test pour évaluer le potentiel de l'approche sélectionnée (figure 22).



Figure 22 – Gauche : vue du centre-ville de Toulouse (Google Earth). Les rectangles jaunes délimitent les deux zones d'études : référence et test. En haut à droite : site de référence avec des arbres alignés et un parc (Images VNIR Hypsex), les polygones colorés indiquent la délimitation des arbres et les espèces inventoriées dans le site de référence. En bas à droite : image Hypsex VNIR en composition colorée avec des arbres alignés composés de 2 espèces majoritaires (*Tilia tomentosa*, *Platanus x hispanica*), les polygones blancs correspondant au résultat de la délimitation automatique des couronnes d'arbre.

Les 194 arbres répertoriés sur le site de référence sont donnés dans le Tableau 7.

Tableau 7 – Principales caractéristiques des arbres de la zone de référence

Species scientific name (species code)	Tree type	Stem count	Canopy area (m ²)	VNIR pixel count	SWIR pixel count	PAN pixel count	DSM pixel count
<i>Acer negundo</i> (A.n.)	Broadleaf	6	202	1077	41	9929	12325
<i>Acer platanoides</i> (A.p.)	Broadleaf	6	204	1084	39	10035	12458
<i>Aesculus hippocastanum</i> (A.h.)	Broadleaf	23	1433	7936	335	71237	88367
<i>Cedrus atlantica</i> (C.a.)	Coniferous	6	1036	5954	283	52119	64584
<i>Celtis australis</i> (C.au.)	Broadleaf	10	1032	5856	264	51721	64082
<i>Celtis occidentalis</i> (C.o.)	Broadleaf	9	1340	7750	382	67656	83792
<i>Fagus sylvatica</i> (F.s.)	Broadleaf	10	529	2897	118	26229	32559
<i>Juglans nigra</i> (J.n.)	Broadleaf	12	904	5021	220	45011	55867
<i>Liquidambar styraciflua</i> (L.s.)	Broadleaf	6	334	1836	75	16565	20562
<i>Liriodendron tulipifera</i> (L.t.)	Broadleaf	11	436	2510	94	22983	28534
<i>Platanus x hispanica</i> (P.h.)	Broadleaf	26	2082	11730	521	104134	129107
<i>Taxus baccata</i> (T.b.)	Coniferous	7	226	1185	39	11024	13732
<i>Tilia platyphyllos</i> (T.p.)	Broadleaf	14	570	3075	106	28064	34380
<i>Tilia tomentosa</i> (T.t.)	Broadleaf	41	1424	7650	292	70082	86980
<i>Ulmus glabra</i> (U.g.)	Broadleaf	7	1169	6736	323	58918	72962

Les images ont été acquises le 24 octobre 2012 à 11:00 TU (angle zénithal solaire de 60°) au cours de la campagne UMBRA [Adeline et al., 2013] organisée par l'ONERA et l'IGN à partir de caméras embarquées sur avion volant à une altitude d'environ 2000 m :

- Une caméra hyperspectrale Hypspec VNIR (0.4-1.0 µm), de résolution spatiale 0.4x0.8m²,
- Une caméra hyperspectrale Hypspec SWIR (1.0-2.5 µm), de résolution spatiale 1.6 m,
- Une caméra panchromatique CamV2 de résolution spatiale 14 cm.

Le modèle numérique de surface orthorectifié et géoréférencé a été produit par l'IGN avec une résolution de 0.125 m. Les images hyperspectrales et panchromatiques ont été enregistrées sur le MNS et des amers au sol à l'aide des outils QGIS et GDAL (module gdalwarp). Le rééchantillonnage a été fait au plus proche voisin. La qualité de cette registration est estimée qualitativement à moins d'un pixel.

Les images hyperspectrales sont ensuite corrigées de l'atmosphère avec une hypothèse sol plat avec l'outil de l'ONERA COCHISE.

Résultats

- Les données hyperspectrales sont les sources contribuant le plus aux performances de classification (OA de 75 % pour le VNIR et de 69% pour le SWIR) sur le site de référence. Les arbres d'alignement composés de deux espèces majoritaires (*Tilia tomentosa* and *Platanus x hispanica*) sont bien identifiés.
- La méthode MNF de réduction de dimension améliore les performances de classification.
- L'apport de la source PAN reste marginal pour la classification (OA = 43%).
- L'apport du DSM reste faible pour l'amélioration des performances de discrimination des espèces (OA=35%) mais son intérêt réside dans la discrimination de la végétation haute de la végétation basse. Cette étude a montré également que la complémentarité des données est faible. La raison principale est liée aux hautes performances du VNIR par rapport aux autres sources. En particulier, la première alternative de fusion (au niveau des caractéristiques) baisse les performances de la classification de 75 à 73%, alors que la fusion au niveau de la décision améliore les performances (77%). (Figure 24 et tableau 8)

Afin d'évaluer la robustesse de notre méthode, elle a été appliquée sur le site de test ; les résultats obtenus sont cohérents avec ceux obtenus sur le site de référence (utilisé comme base d'apprentissage). En effet, la fusion par règle de décision améliore la précision globale de 8% (AO=63% contre 55%) et permet une bonne identification de l'espèce *Platanus hispanica*. Mais, il faut noter que la source VNIR seule donne déjà de bons résultats. L'espèce *Tilia tomentosa* n'est pas bien identifiée à cause de la différence de phénologie entre les arbres du site de référence et ceux du site test (figure 25 tableau 9).

Figure 23 – Cartes de performances après fusion. Pour chaque arbre et chaque source, la performance est estimée comme le nombre de bonne prédiction d'espèce divisé par le nombre de fois où cet arbre est classé dans la stratégie de validation. La couleur d'un polygone correspond à un arbre qui n'a jamais été bien classé (rouge), bien classé une fois sur 2 (blanc) et toujours bien classé (bleu). Les termes suivants, respectivement VNIR, SWIR, PAN et DSM, indiqués dans l'image font référence aux traitements de classification suivants, respectivement : VNIR MNF + SVM, SWIR MNF + SVM, PAN + RF et DSM + RF.

Tableau 8- OA (%) and k (%) issus de la classification avec la source VNIR, de la fusion associant un vecteur de caractéristiques construit à partir de toutes les sources et de la fusion en utilisant les 3 règles de décision sur les classifications effectuées par chacune des sources au préalable

	Source				
	VNIR	Feature	Decision		
			DR1	DR2	DR3
OA	75	73	76	77	76
κ	72	69	73	74	72



Figure 24 – Cartes de performances après fusion. Pour chaque arbre et chaque source, la performance est estimée comme le nombre de bonne prédiction d'espèce divisé par le nombre de fois où cet arbre est bien classé dans la stratégie de validation. Par exemple, un polygone rouge, blanc ou bleu indique un arbre qui n'a respectivement jamais, une fois sur 2, systématiquement été bien classé. Les termes suivants, respectivement VNIR, SWIR, PAN et DSM, indiqués dans l'image font référence aux traitements de classification suivants, respectivement : VNIR MNF + SVM, SWIR MNF + SVM, PAN + RF et DSM + RF.

Tableau 9 – Matrices de confusion avec la source VNIR (à gauche) et après fusion (à droite) sur le site de test pour les 2 principales espèces (*Tilia tomentosa* and *Platanus x hispanica*). Le terme "other" fait référence aux autres espèces pour lesquelles la vérité terrain n'est pas disponible.

		VNIR					Fusion		
		Predicted					Predicted		
		T.t	P.h	Other			T.t	P.h	Other
True	T.t	27	0	56	True	T.t	35	8	40
	P.h	0	45	3		P.h	0	48	0
OA (%)	55				OA (%)	63			

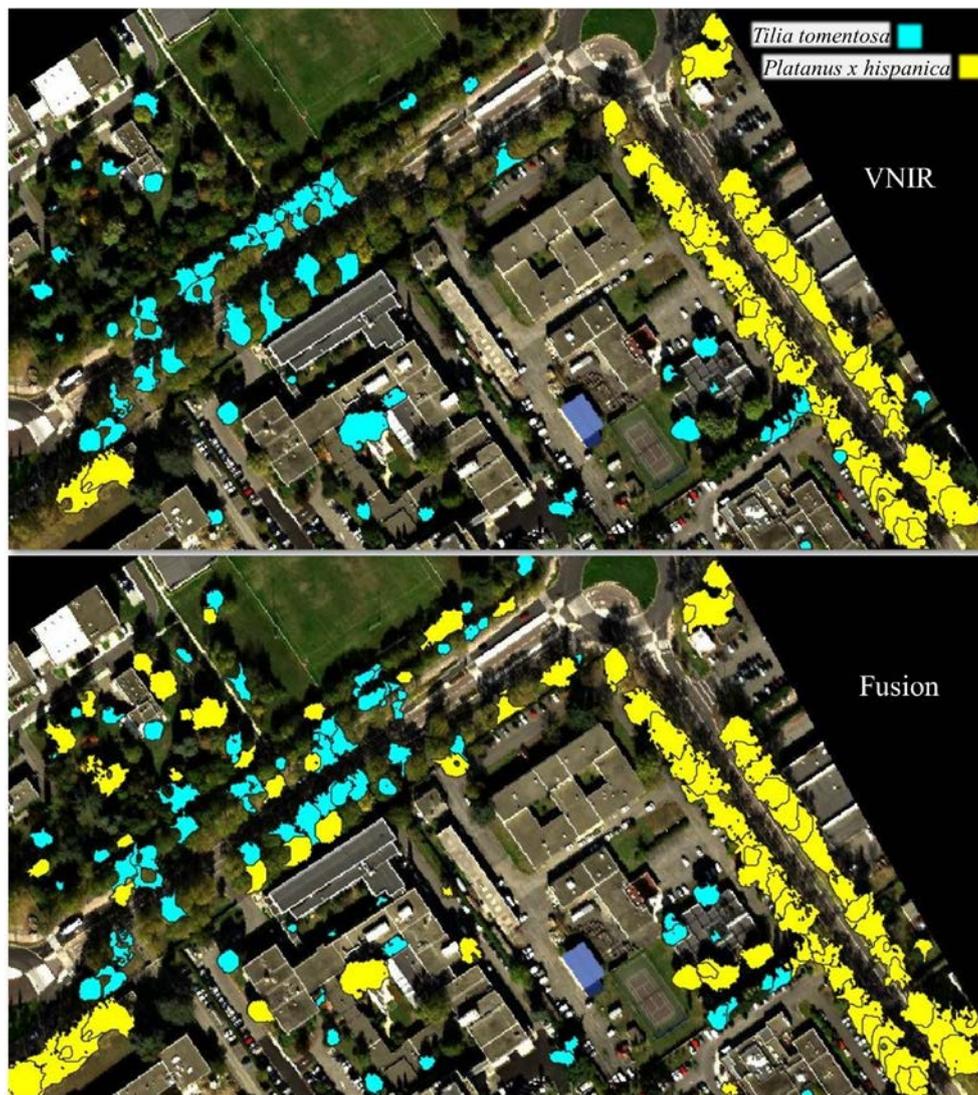


Figure 25 - Carte de classification des espèces sur le site de test obtenu à partir de la source VNIR (en haut) et la fusion (en bas) pour les 2 espèces majoritaires (*Tilia tomentosa* and *Platanus x hispanica*)

Perspectives

Des voies d'amélioration sont envisagées.

- Tout d'abord, il est nécessaire d'optimiser la complémentarité des sources en définissant par exemple une source spécifique par espèce en adoptant une approche hiérarchique.
- Ensuite, les travaux présentés mettent en évidence les **différents comportements de la classification** entre les parcs et les arbres d'alignement, il semblerait intéressant de distinguer ces différentes structures comme une première étape avant la classification.
- Enfin, la phase d'apprentissage construite directement sur l'image ne permet pas d'identifier correctement l'espèce *Tilia tomentosa*. Des mesures spectrales au sol pourraient permettre d'améliorer la qualité de la base d'apprentissage

Production scientifique dans la cadre de l'ANR HYEP

SFPT (2016, Grenoble), poster : Étude du potentiel des données hyperspectrales en vue de développer une méthode de cartographie automatique du patrimoine arboré en milieu urbain

TEMU (2017, Toulouse), oral : Classification des espèces d'arbres en milieu urbain par fusion de données aéroportées hyperspectrales, panchromatiques et d'un MNS

EARSel (2017, Zurich), oral: Urban tree species classification with airborne hyperspectral VNIR and SWIR, PAN and DSM data

IAC (2017, Adelaïde), poster (présenté par Emmanuel Zenou): Urban tree species classification with airborne hyperspectral VNIR and SWIR, PAN and DSM data by fusion at the object level

J. Aval (ONERA), S. Fabre (ONERA), E. Zenou (ISAE), D. Sheeren (INRA), M. Fauvel (INRA), X. Briottet (ONERA), Object-based fusion for urban tree species classification from heterogeneous data: hyperspectral, panchromatic and DSM. Accepté avec révisions majeures dans IJRS (révision soumise en Juillet 2018)

3.2.2 Cartographie supervisée des espèces d'arbres avec un ensemble de classifieurs

Auteurs : J. Aval (ONERA), S. Fabre (ONERA), E. Zenou (ISAE), D. Sheeren (INRA), M. Fauvel (INRA), X. Briottet (ONERA)

Objectif de l'étude : Evaluer l'apport de la richesse de l'imagerie hyperspectrale afin de classer, de façon supervisée à l'aide de mesures de références acquises au sol, 5 espèces d'arbre avec une approche basée sur un ensemble de classifieurs.

Méthode

Le principe général repose sur le constat que chaque espèce peut être identifiée par un triplet d'indices spectraux de végétation spécifique associé à une classification supervisée SVM, noté classifieur C_{ij} , i étant l'espèce et j un des triplets sélectionné pour l'espèce i .

L'organigramme général de cette nouvelle méthode « ensemble » est donné Figure 27.

La première étape a pour but de sélectionner (par méthode SVM) les meilleurs triplets (de nombre N_i) d'indices de végétation (parmi une centaine défini à partir d'Erudel et al . 2017) pour chaque espèce à partir de trois jeux différents de données de référence: réflectances spectrales mesurées au niveau de la feuille, réflectances spectrales mesurées au niveau de la canopée et réflectances spectrales prises directement sur l'image aéroportée après correction atmosphérique. En particulier, un apprentissage des modèles SVM est effectué à partir des données de référence, tandis que le test est effectué sur les données de l'image relatives à un sous-échantillon d'arbres, afin d'optimiser la performance au niveau de l'image. Les meilleurs triplets sont ainsi identifiés. Cette étape permet de constituer l'ensemble de classifieurs C_{ij} Figure 27.

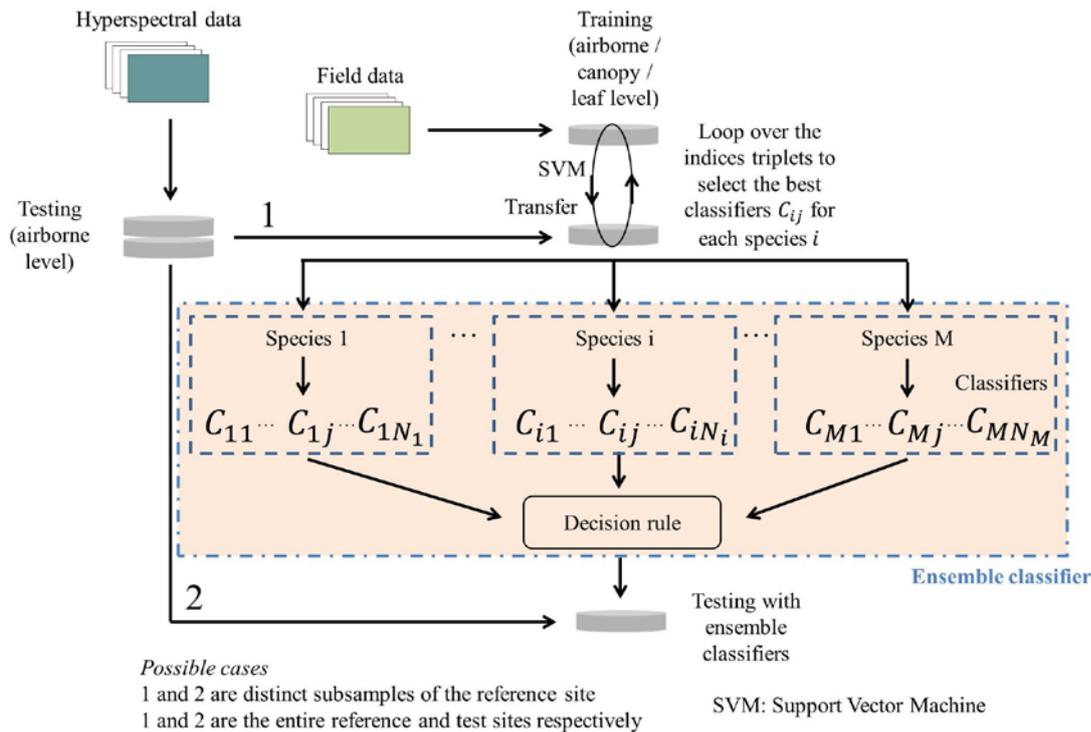


Figure 26 – Organigramme de traitement de la classification supervisée à partir d'un ensemble de classifieurs

« L'ensemble de classifieurs » est alors utilisé pour classer les données de l'image relatives à un sous-échantillon d'arbres indépendant. Une règle de décision est appliquée afin de combiner les prédictions de chaque classifieur de l'ensemble. F_i est calculé pour chaque espèce : $F_i = \frac{\sum_{j=1}^{N_i} F-score_{i,j} \cdot w_j}{N_i}$ avec $F-score_{i,j}$ le F-score du classifieur C_{ij} et w_j un opérateur booléen égal à 1 si le classifieur vote pour l'espèce i , 0 sinon. Suivant la valeur de F_i , la règle de décision suivante s'applique :

- Si le meilleur $F_i > 0.5$ AND $|F_i - F_{i'}| < 0.2$ où i' correspond au deuxième meilleur F_i , l'espèce i est sélectionnée, sinon l'espèce est rejetée.

Afin d'évaluer l'apport de cette approche à partir d'un ensemble de classifieurs, les résultats seront comparés à deux autres approches. La première utilise directement la réflectance spectrale (méthode « réflectance ») et la seconde consiste à regrouper tous les triplets dans un seul vecteur caractéristique (méthode « stacked »).

Données utilisées

Les données hyperspectrales aéroportées utilisées sont identiques à celles décrites dans le §3.2.1 à ceci près que seul le domaine 0.4-1.0 μm est couvert avec la caméra Hypspx VNIR-1600 –résolution spatiale au sol de 0.4 m). Comme dans le § précédent, les données acquises ont été enregistrées avec les données du DSM et corrigées de l'atmosphère avec COCHISE.



Figure 27 – (a) Vue générale de Toulouse avec les sites de référence et le site test (Google Earth) (b) Composition colorée du site de référence à partir de l’image Hypspx. Les polygones en couleur indiquent les délimitations des arbres. En gris, les espèces inventoriées sur le terrain. (c) Le site test, en blanc, le résultat de la délimitation automatique des arbres.

Des mesures terrain sur le site de référence ont été réalisées avec un spectroradiomètre ASD sur 7 arbres (1 par espèce, au nombre de 5, et une supplémentaire sur les 2 espèces majoritaires *Aesculus hippocastanum* et *Tilia tomentosa* au niveau de la feuille (le même jour que l’acquisition aéroportée) et au niveau de la canopée (6 jours après en sachant que la météo était restée stable, sans pluie, durant cet intervalle de 6 jours). Les principales caractéristiques des arbres étudiés dans la carte de référence sont rappelées dans le Tableau 10. Dans la 29, sont montrés les spectres de réflectance moyenne de chaque base d’apprentissage.

Tableau 10 – Principales caractéristiques des arbres de la carte de référence. Les 3 dernières colonnes correspondent aux 3 jeux de données utilisés pour l'apprentissage.

Species scientific name (species code)	Stem count	Canopy area (m ²)	VNIR pixel count	Airborne training pixels	Canopy training samples	Leaf training samples
<i>Aesculus hippocastanum</i> (A.h.)	23	1433	7936	267	7	9
<i>Celtis australis</i> (C.au.)	10	1032	5856	66	5	4
<i>Fagus sylvatica</i> (F.s.)	10	529	2897	52	4	4
<i>Juglans nigra</i> (J.n.)	12	904	5021	213	5	4
<i>Tilia tomentosa</i> (T.t.)	39	1547	8397	219	10	4

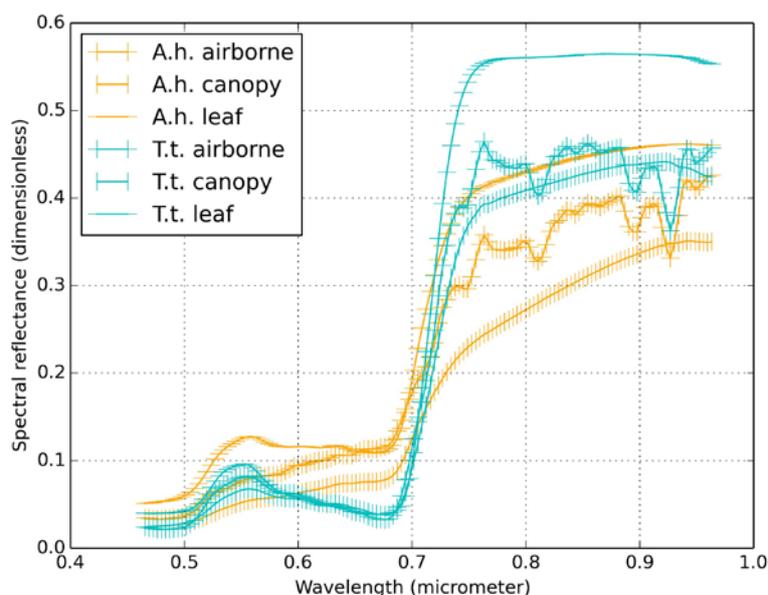


Figure 28 – Réflectances spectrales moyennes des espèces *Aesculus hippocastanum* (A. h.) and *Tilia tomentosa* (T. t.) des 3 bases d'apprentissage : feuille, canopée, image.

Résultats

Les résultats sont synthétisés dans le Tableau 10 et une illustration est donnée Figure 30.

Tableau 11 – Précision globale (OA en %) et κ (%) des 3 méthodes de classification en fonction des 3 bases d'apprentissage.

	Reflectance	Stacked	Ensemble
Airborne	53	62*	56
	40	52*	46
Canopy	41	68*	66
	27	53	55*
Leaf	15	45	58*
	2	27	46*
Average	36	58	60*
	23	44	49*

- Meilleurs résultats



Figure 30– Comparaison des cartes d'espèces sur le site de test dans le cas d'un apprentissage à partir des données feuille. Gauche : méthode « stacked ». Droite : méthode « ensemble ». La classe « rejected » ne concerne que la classification par méthode « ensemble ».

Une première comparaison des 3 méthodes avec un apprentissage basée sur la bases de réflectances spectrales mesurées au niveau des feuilles, montre que notre nouvelle méthode « ensemble » fournit des performances significativement supérieures aux deux autres méthodes pour classer l'espèce *Tilia tomentosa* : gain de +19% (respectivement +4%) par rapport à la méthode « stacked » (respect. « reflectance »).

En utilisant la base de réflectance spectrale au niveau de la canopée, les performances des méthodes « stacked » et « ensemble » sont similaires OA~66-68% et κ ~53-55%.

En utilisant la base de données construite directement sur l'image, les méthodes présentent des performances similaires mais avec un avantage pour la méthode « ensemble » qui réduit les confusions entre espèces.

Les 3 méthodes ont été construites à des échelles spatiales très différentes. Les résultats montrent que la méthode « ensemble » est la moins sensible aux changements d'échelle spatiale des bases d'apprentissage, la plus sensible étant l'approche « reflectance ». Enfin, la méthode « reflectance » n'est pas recommandée pour classer les espèces d'arbres si les bases d'apprentissage sont construites à partir de mesures terrain à l'échelle de la canopée ou de la feuille.

Références

Thierry Erudel, Sophie Fabre, Thomas Houet, Florence Mazier, Xavier Briottet, Criteria comparison for classifying peatland vegetation types using in situ hyperspectral measurements, *Remote Sens.* 2017, 9, 748; doi:10.3390/rs9070748

Perspectives

Afin de mieux évaluer les performances de notre nouvelle méthode « ensemble », celle-ci doit être appliquée à d'autres jeux d'images et une base de données d'apprentissage plus complète.

Production scientifique

ForestSAT (2018, Washington), abstract accepté pour un poster : Field to airborne transfer based on vegetation indices for tree species classification with hyperspectral data: an ensemble classifiers approach

J. Aval (ONERA), S. Fabre (ONERA), X. Briottet (ONERA), E. Zenou (ISAE), D. Sheeren (INRA), M. Fauvel (INRA), An ensemble classifier approach for urban tree species classification from ground-based spectral references (en cours de rédaction pour soumission dans une revue à comité de lecture)

3.2.3 Détection d'arbres alignés en milieu urbain

Auteurs : J. Aval (ONERA), J. Demuynck (ISAE), E. Zenou (ISAE), S. Fabre (ONERA), D. Sheeren (INRA), M. Fauvel (INRA), X. Briottet (ONERA)

Objectif de l'étude : cartographier les arbres d'alignement en milieu urbain à partir de données hyperspectrales aéroportées, d'un MNS et du réseau de routes.

Méthode

La méthode générale est synthétisée dans la *Figure 31*

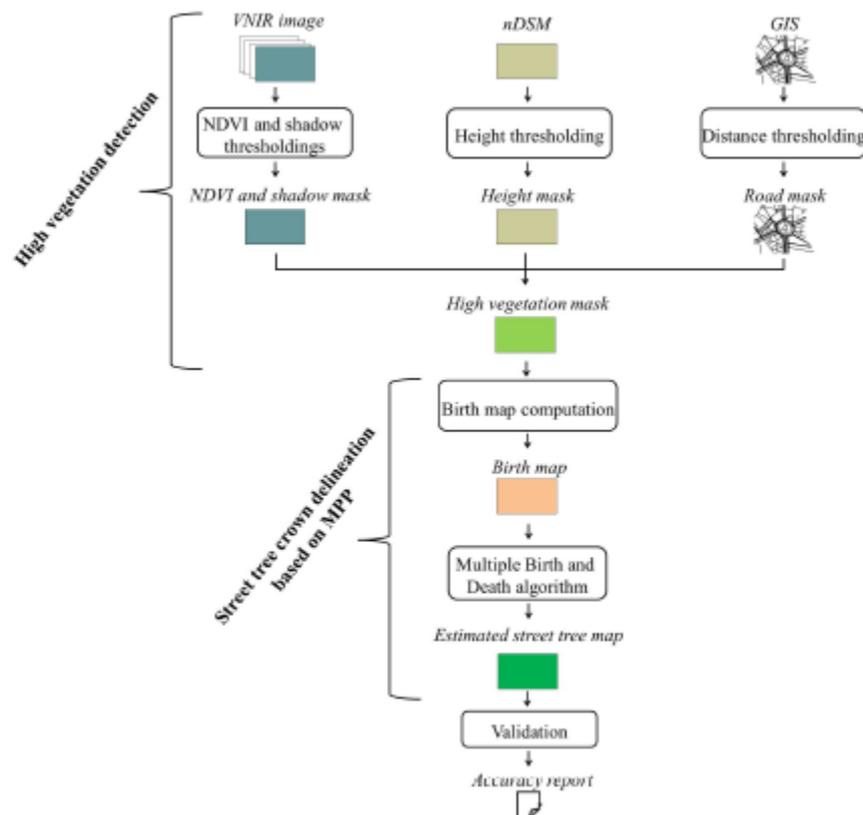


Figure 29 – Organigramme général de la méthode de détection d'arbres d'alignement.

Une première étape orientée pixel a pour objectif de détecter les **pixels de végétation haute** à proximité des routes, en fusionnant 4 masques : détection de la végétation à partir de l'indice NDVI, détection des ombres à l'aide de l'indice proposé par Nagao, détection des pixels hauts à l'aide du modèle numérique de surface normalisé nDSM (seuil à 5 m de hauteur), sélection des pixels se trouvant à moins de 20 m d'une route (information accessible via des données SIG).

La deuxième étape (orientée objet) a pour objectif **de détecter les arbres d'alignement de manière individuelle**, en utilisant le cadre des MPP (Marked Point Process) à partir du masque construit. La considération de ce masque à la place des données d'origine réduit les temps de traitement. La carte des arbres d'alignement est ici considérée comme un ensemble de disques (de rayons compris entre 2 et 8 m), assimilable à une réalisation d'un MPP (Figure 32). Une réalisation est sélectionnée en minimisant deux énergies, une sur chaque individu et l'autre sur leur interaction (critère d'alignement incluant une contrainte sur chaque arbre et ses proches voisins : angle faible entre les arbres et hauteurs similaires dues à la taille). La minimisation de l'énergie est assurée par la méthode MBD (Multiple Births and Deaths process).

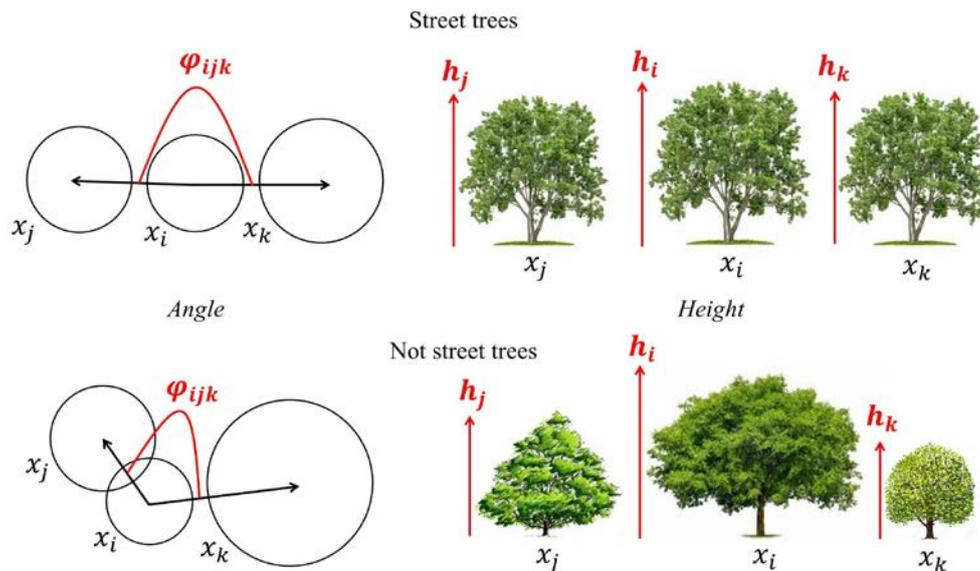


Figure 30– Illustration des attributs utilisés pour le calcul de l'énergie d'interaction. En haut : cas d'arbres alignés (même hauteur, même espèce et alignement). En bas : cas d'arbres non alignés (hauteurs différentes, espèces différentes sans alignement).

Les résultats sont comparés à une méthode de délimitation d'arbre développée par Adeline et al., 2014, inspirés des travaux de Iovan et al., 2008) avec et sans utilisation du SIG, c'est-à-dire du réseau de routes (respectivement nommée par la suite méthode « standard » / « standard avec SIG »). La quantification des performances est estimée par une matrice de confusion construite par interprétation visuelle. De cette matrice de confusion, en sont déduites les précisions utilisateur et producteur permettant de calculer l'indicateur F-score.

En vue d'évaluer le potentiel de la méthode, elle est ensuite introduite dans un contexte de classification des espèces. Le principe est d'utiliser les arbres détectés par l'approche proposée pour régulariser l'estimation des espèces au sein des alignements, effectuée au préalable à partir d'une méthode standard (classification mono-source VNIR du §3.2.1). En particulier, l'approche MPP permet de chaîner les triplets d'arbres d'alignement les uns aux autres. Pour chaque arbre d'une chaîne, l'espèce est mise à jour selon l'espèce majoritaire de la chaîne. On fait l'hypothèse que les alignements sont mono-spécifiques.

Données utilisées

Les images et leurs prétraitements sont identiques à ceux décrits dans le §3.2.1. Sur cette image, trois zones comprenant des types différents d'alignement sont sélectionnées (Figure 33).

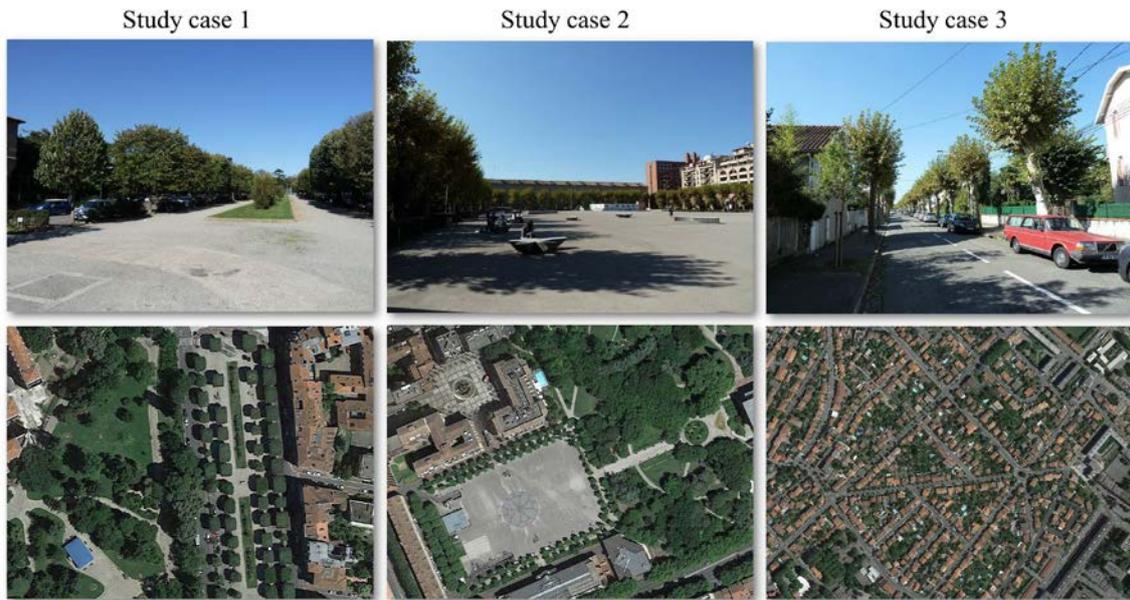


Figure 31 – Illustrations des 3 types d'alignement considérés. Ligne du bas : images Google Earth.

A cela, s'ajoute un modèle numérique de surface fourni par l'IGN et un système d'information géographique (dérivé de la base de données OSM) est également utilisé décrivant le type de route. Dans cette étude, seules les routes primaires, secondaires, tertiaires, résidentielles et de service sont utilisées (Figure 34).

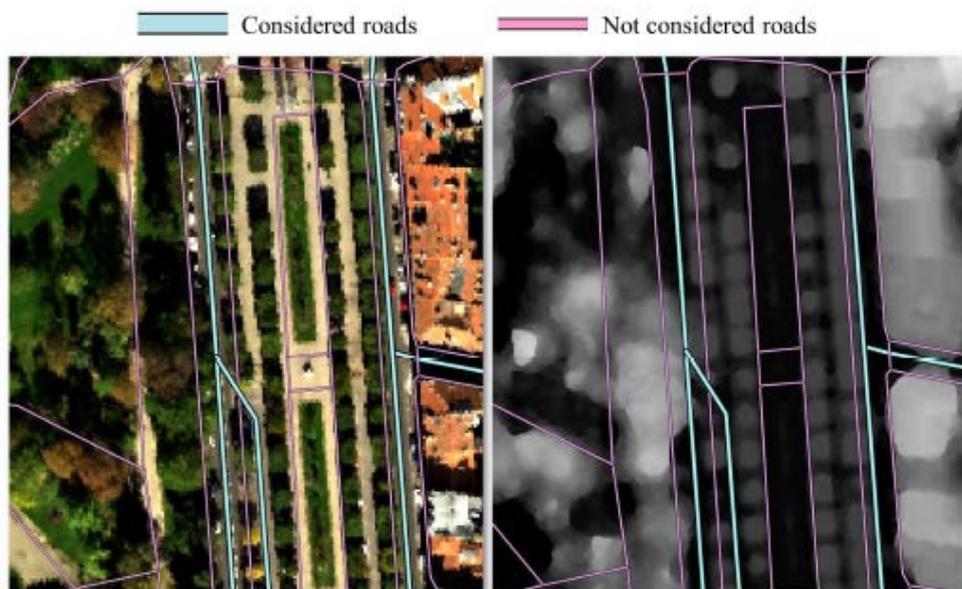


Figure 32 – Gauche : composition colorée de l'image hyperspectrale Hypsrex avec l'information de type route du système d'informations géographiques (SIG). Droite : superposition de l'image de hauteur (en niveaux de gris) avec l'information de type route du SIG.

Résultats

La comparaison des résultats sur les 3 types d'alignement montre que notre nouvelle méthode améliore de façon significative les performances de détection : la valeur du F-score varie entre 91 à 75 % alors que pour les méthodes traditionnelles sans SIG, celles-ci varient entre 70 et 20% (Tableau 14, Figure 35).

Tableau 5 – Comparaison des performances de détection en terme de F-score entre notre méthode et les 2 méthodes traditionnelles avec et sans SIG.

Framework		Case 1	Case 2	Case 3
Baseline	Without GIS	70	41	20
	With GIS	83	82*	28
Proposed		91*	75	85*

Alors que le réseau de routes seul permet d’obtenir de bonnes performances pour les deux premiers cas, cela ne suffit pas dans le dernier (le plus complexe). **Les résultats montrent en effet que les meilleurs résultats sont obtenus en utilisant conjointement l’angle, la hauteur et le SIG.** De bons résultats sont obtenus avec uniquement une contrainte sur l’angle et la hauteur (Figure 36).

Concernant l’application de la méthode dans un contexte de classification des espèces, les résultats obtenus (Figure 35, droite) montrent que 100% des arbres de type *Platanus x hispanica* sont détectés grâce à la régularisation proposée (69 arbres), contre 51 arbres avec la méthode standard.

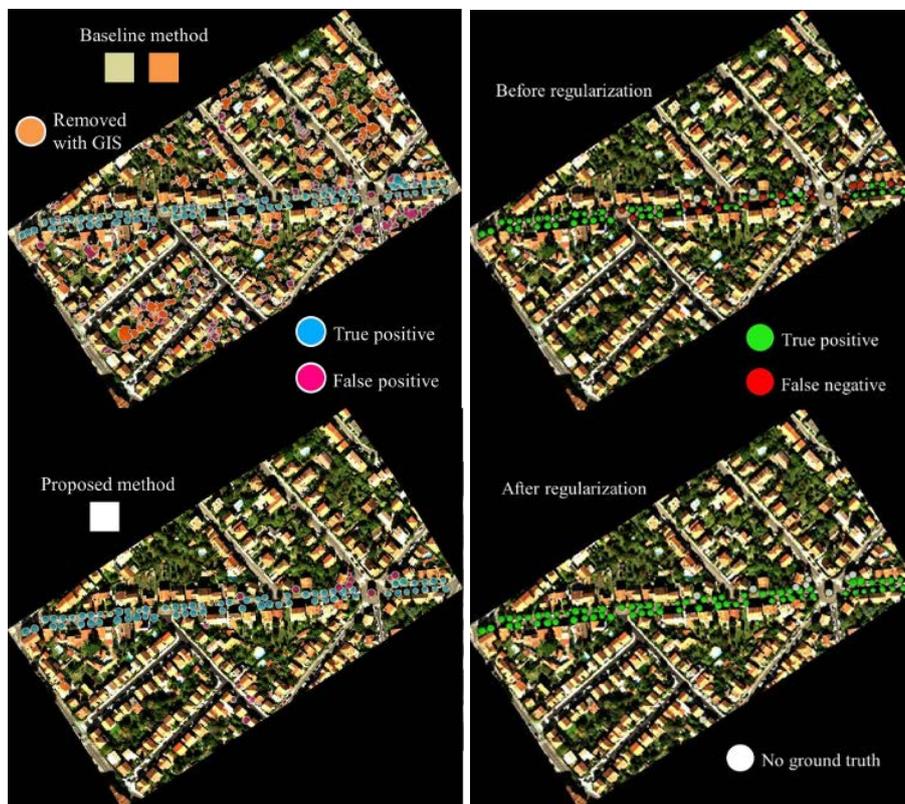


Figure 33 – Gauche : Détection des arbres d’alignement. Comparaison des cartes produites par la méthode “standard” (en haut) et notre méthode (en bas). Droite : Classification des espèces. Comparaison des cartes produites par notre méthode avant et après régularisation (en posant par hypothèse qu’une seule espèce d’arbres est présente par alignement).

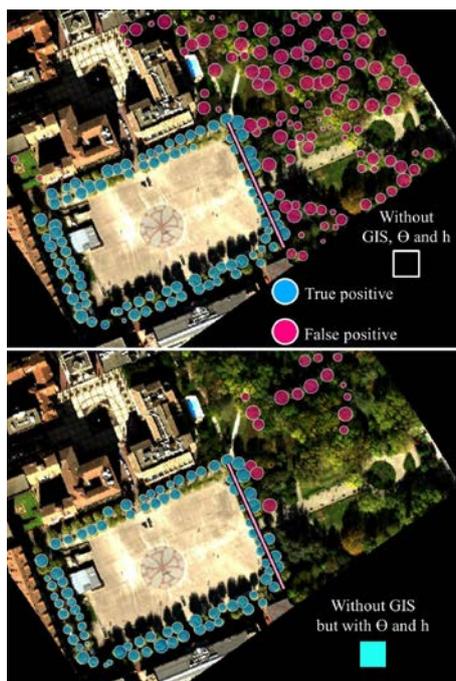


Figure 36 – Détection des arbres d’alignement. Comparaison des cartes produites avec (en bas) et sans (en haut) tenir compte de l’angle (contrainte d’alignement) et de hauteur. Dans les deux cas, le SIG n’est pas utilisé.

Références

Karine Adeline. Classification des matériaux urbains en présence de végétation éparse par télédétection hyperspectrale à haute résolution spatiale. PhD thesis, Toulouse, ISAE, 2014.

Corina Iovan, Didier Boldo, and Matthieu Cord. Modélisation de la végétation en milieu urbain: Détection et caractérisation à partir d’images aériennes haute résolution couleur et infrarouge. *Revue française de photogrammétrie et de télédétection*, (189):17–27, 2008.

Perspectives

Cette méthode ne prend pas en compte des superpositions éventuelles entre arbres voisins qui nécessiteraient des travaux supplémentaires. De plus, son application à un plus grand nombre de cas permettrait d’affiner ses performances. Le cas d’application étudié repose sur la classification d’arbres d’alignement mono-espèces, des travaux supplémentaires sont nécessaires pour traiter le cas d’alignements multi espèces.

Production scientifique

GEOBIA (2018, Montpellier), oral : Individual street tree detection from airborne data and contextual information

J. Aval (ONERA), J. Demuyck (ISAE), E. Zenou (ISAE), S. Fabre (ONERA), D. Sheeren (INRA), M. Fauvel (INRA), Xavier Briottet (ONERA), Detection of individual trees in urban alignment from airborne data and contextual information: a marked point process approach, accepté avec révisions majeures dans ISPRS (révision soumise en Avril 2018).

3.3 Evaluation de l'influence des résolutions spatiale et spectrale sur la classification de la végétation arborée

Auteurs : LARIBI Achour (Mémoire M2, COSTEL), HOUET Thomas (COSTEL)

Objectif : Evaluer l'impact des résolutions spectrales et spatiales sur la classification de la végétation arborée urbaine.

Méthode

Hypothèse : pour pouvoir évaluer et comparer les résultats issus de données présentant des résolutions spatiales et spectrale différentes, il est nécessaire de ne pas réduire la dimension spectrale des images. Les signatures spectrales sont utilisées pour classer les images. Trois étapes constituent ce travail.

- La première étape consiste à appliquer différents algorithmes de classification (SVM, RF, NN, SAM, SID) sur l'image entière puis sur un masque de végétation, réalisé à partir d'un simple seuillage de NDVI. L'hypothèse est que limiter l'emprise géographique peut permettre d'améliorer les résultats de classification.
- La deuxième étape consiste à comparer les résultats pour évaluer l'influence des résolutions spatiale et spectrale sur les différentes méthodes de classification, avec une nomenclature hiérarchique à trois niveaux de complexité selon une approche systématique écologique par type (5 classes), famille (24 classes) et espèce (38 classes).
- La troisième étape consiste, une fois l'image et l'algorithme de classification présentant les meilleurs résultats identifiés, à optimiser le processus de classification (taille du jeu de données d'apprentissage, réduction de dimension, etc.) afin d'obtenir les meilleurs scores de classification possibles. En effet, si le respect du protocole de classification présenté en étape 2 requiert d'être strictement comparable, il est assumé ici qu'il ne permet pas d'obtenir des scores optimaux.

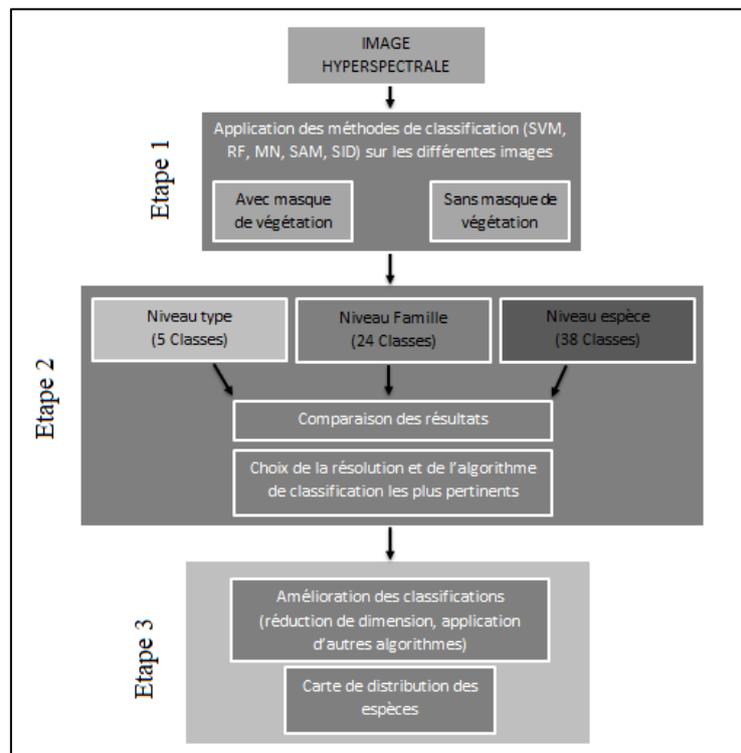


Figure 37 – Organigramme de la méthode développée

Données utilisées

Les données sont présentées tableau 15 figure 38.

Tableau 6 – Résolutions spatiales et spectrales des différentes images utilisées dans l'étude (acquises en 07/2015)

image	Nombre de bandes	Domaine spectral	Résolution spatiale
TC_2015_Hypspec	408 bandes	0.4 – 2.5 microns	2m
TC_2015_Hypxim	192 bandes	0.4 – 2.5 microns	4m
TC_2015_Hypxim	192 bandes	0.4 – 2.5 microns	8m
TC_2015_Sentinel2	13 bandes	0.4 – 2.5 microns	10m



Figure 34 – De gauche à droite : composition colorée de l'image Hypspec (résolution spatiale 2 m), de l'image synthétisant HYPXIM à 4m, de l'image synthétisant HYPXIM à 8m, et de l'image synthétisant sentinel-2 à 10m.

Les données d'apprentissage et de validation ont été créées sur la base d'un recensement géolocalisé au DGPS de la plus grande diversité d'espèces d'arbres suivant l'hypothèse que la végétation arborée n'a pas changé entre 2015 et 2017 (campagne réalisée entre le 31 mai et le 02 juin 2017). Après les post traitements, la précision en XY des arbres recensés est d'ordre centimétrique (2 à 5 cm).

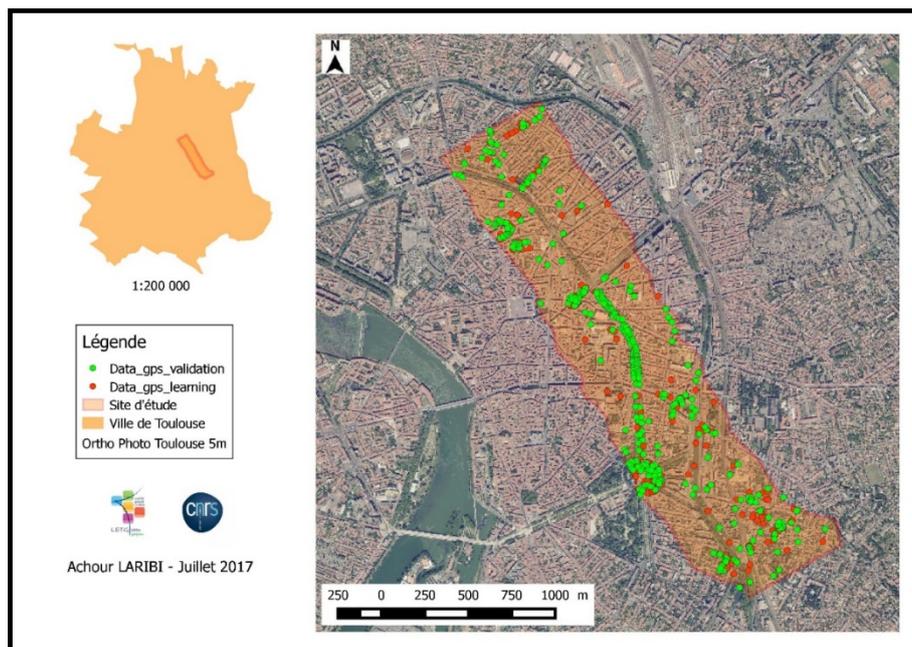


Figure 39– Image de Toulouse, en vert les arbres inventoriés

Résultats

Les résultats de la première étape sont résumés sur la *Figure 40*.

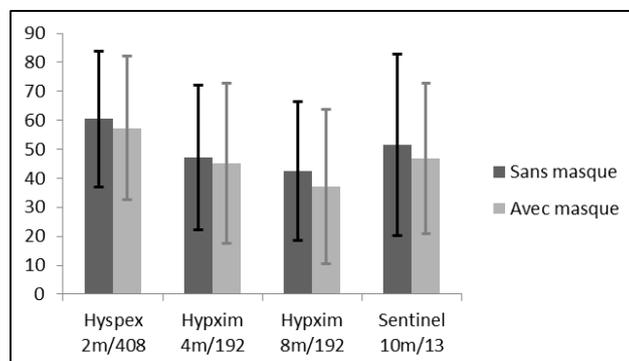


Figure 40 – Précision globale (OA en %) de la classification appliquée sur les images acquises à différentes résolutions spatiales mais avec la même richesse spectrale avec ou sans masque sur la végétation.

En ne travaillant que sur un masque de végétation, la réduction de la dimension n'améliore pas la qualité des classifications.

L'image aéroportée **Hypspx à 2m** de résolution spatiale et **408 bandes spectrales** donne les meilleurs résultats de classification par l'algorithme SVM quelle que soit la classification de la végétation (type, famille ou espèce). Pour une classification par type, les résultats sont satisfaisants (OA= 90.24%, kappa= 0.72) (*Tableau 13*), mais les résultats décroissent pour une classification par famille (OA=62.23%, kappa= 0.54) (*Tableau 14*) ou par espèce d'arbre (OA= 54.63%, kappa= 0.45) (*Tableau 16*).

L'image Sentinel-2 à 10m de résolution spatiale et 13 bandes spectrales permet d'obtenir des résultats de classification meilleurs qu'avec des images Hypxim à 4m et 8m de résolution spatiale et 192 bandes spectrales. D'une façon générale, l'algorithme SVM fournit les meilleurs résultats de classification de la végétation pour ses trois niveaux de nomenclature (type, famille et espèce) et quelle que soit la résolution choisie.

Tableau 7 – Influence de la résolution sur la pertinence des différents algorithmes pour une classification par type de végétation (5 classes) exprimée en précision globale (OA) et en Kappa

Résolution	Précision	SVM	RF	NN	MD	SAM	SID
Hypspx 2m/408 b	OA	90.24	86.02	75.53	35.06	34.2	42.04
	Kappa	0.72	0.58	0	0.20	0.16	0.23
Hypxim 4m/192 b	OA	85.84	83.13	1.47	39.62	43.24	29.23
	Kappa	0.59	0.49	0	0.20	0.20	0.49
Hypxim 8m/192 b	OA	77.21	79.30	15.19	32.40	28.35	22.27
	Kappa	0.46	0.38	0	0.13	0.12	0.11
Sentinel2 10m/13 b	OA	85.63	77.3	85.1	28.45	17.28	14.62
	Kappa	0.59	0.35	0.58	0.12	0.03	0.05

Tableau 17 – Influence de la résolution sur la pertinence des différents algorithmes pour une classification par famille de végétation (24 classes) exprimée en précision globale (OA) et en Kappa

Résolution	Précision	SVM	RF	NN	MD	SAM	SID
Hypspx 2m/408 b	OA	62.23	49.39	0.70	21.85	23.27	28.74
	Kappa	0.54	0.40	0	0.15	0.17	0.22
Hypxim 4m/192 b	OA	31.62	45.16	0.24	18.38	19.60	11.27
	Kappa	0.19	0.35	-0.02	0.11	0.12	0.08

Hypxim 8m/192 b	OA	28.21	42.61	0.5	14.10	17.12	7.05
	Kappa	0.16	0.31	0	0.08	0.10	0.04
Sentinel2 10m/13 b	OA	48.04	38.13	38.64	8.61	8.87	17.49
	Kappa	0.36	0.28	0.30	0.05	0.05	0.13

Tableau 18 – Influence de la résolution sur la pertinence des différents algorithmes pour une classification par espèce de végétation (38 classes) exprimée en précision globale (OA) et en Kappa

Résolution	Précision	SVM	RF	NN	MD	SAM	SID
Hypex 2m/408 b	OA	54.63	50.56	31.11	16.38	21.85	26.36
	Kappa	0.45	0.44	0.01	0.12	0.17	0.21
Hypxim 4m/192 b	OA	42.89	29.35	0.73	11.27	14.46	8.57
	Kappa	0.24	0.22	0	0.06	0.08	0.06
Hypxim 8m/192 b	OA	38.53	30	3.02	8.31	12.09	6.80
	Kappa	0.21	0.22	0.01	0.05	0.08	0.04
Sentinel2 10m/13b	OA	49.21	42.90	36.19	6.25	4.16	8.33
	Kappa	0.37	0.36	0.28	0.04	0.02	0.05

L'application d'une réduction de la dimension (MNF) permet d'améliorer sensiblement la performance des classifications (SVM sur les 30 premières composantes) pour les données HYPXIM, qui deviennent meilleurs que les résultats issus de Sentinel-2.

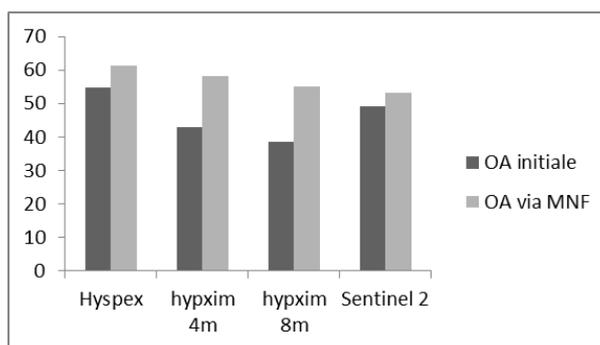


Figure 41 – Précision globale (OA en %) de la classification appliquée sur les images acquises à différentes résolutions spatiales mais avec la même richesse spectrale avec masque sur la végétation, après une réduction de dimension par méthode MNF.

Dans le détail de la classification par espèce après transformation MNF, les espèces qui sont représentées par un nombre significatif de pixels d'entraînement tel que le platane ressort bien dans les résultats de classification alors que des espèces telles que le tilleul commun, le micocoulier de province sont surestimés. D'autres espèces telles que le tilleul argenté, le marronnier commun, magnolia, les chênes, les cèdres, les pins et les sapins etc. sont sous-estimés. Il apparaît clairement que **le jeu de données d'apprentissage / validation influe fortement sur la performance des algorithmes de classification.**

Discussion & Conclusion

L'approche méthodologique adoptée est pertinente pour comparer les résultats obtenus, mais ne permet pas d'obtenir des scores optimaux. La précision des résultats est corrélée avec la finesse de la résolution spatiale et spectrale. Cependant, le bruit induit par une fine résolution spectrale peut limiter l'apport de la résolution spatiale dans les classifications. Ceci est vrai pour les images HYPXIM où la résolution spatiale ne compense pas suffisamment cet effet de seuil pour une approche de classification fondée sur l'usage de signatures spectrales couvrant tout le spectre. Néanmoins, les analyses et résultats préliminaires obtenus à partir des données réduites sont prometteurs et confèrent aux images hyperspectrales HYPXIM un potentiel substantiel, sous réserve que l'approche méthodologique soit bien réfléchi en amont (choix des indicateurs, des méthodes de classifications selon les données terrain disponibles).

Perspective

Références

Production scientifique dans le cadre de HYP

3.4 Evaluation de l'influence de la réduction de dimension sur la classification de la végétation arborée

Auteurs : C. Brabant (M2 TELENVI, COSTEL), E. Alvarez, G. Morin, T. Houet (COSTEL)

Objectif : Etudier l'influence de la réduction de dimension sur la classification de la végétation arborée urbaine

Méthode

La problématique est axée sur la comparaison de différentes méthodes de réduction de dimensions (extraction de caractéristiques et la sélection de caractéristiques par indices de végétation) afin de savoir laquelle est la plus adaptée à la détection de la végétation urbaine via de l'imagerie hyperspectrale à différentes résolutions spatiales (2, 4 et 8m). La réduction de dimensions va permettre de s'affranchir du phénomène de Hughes (Hughes.G.F, 1968). Ce phénomène en imagerie hyperspectrale, se traduit par du bruit dans le signal dont la cause est notamment l'autocorrélation spectrale qui amène de fortes redondances de l'information.

Hypothèse : L'identification des caractéristiques biophysiques peut permettre une meilleure discrimination de la végétation urbaine. Les objectifs de ce travail se résument comme suit : classer les arbres en milieu urbain par famille d'arbres (19 familles répertoriées), comparer les méthodes de réductions de dimensions via extraction et sélection de caractéristiques et enfin connaître les caractéristiques biophysiques qui sont les plus influentes dans la classification.

L'organigramme général pour effectuer cette comparaison est donné *Figure 42*.

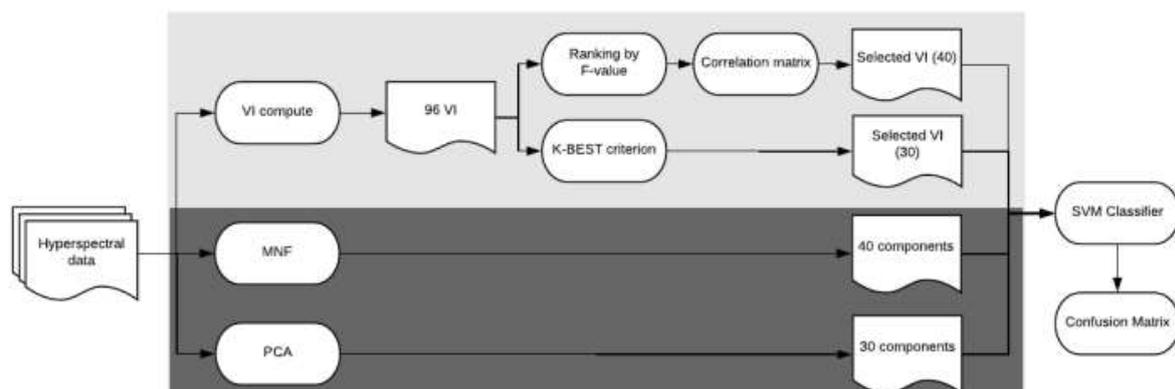


Figure 42– Organigramme générale de la comparaison de méthodes de réduction de données

1^{ère} étape : Les approches de réduction de dimensions (Vegetation Indices Compute)

Première approche : Sélection de caractéristiques, à partir d'indices de végétation (96 indices calculés) sur lesquels une ANOVA a été appliquée. Ces indices ont été ordonnés par décroissance selon la valeur F (test de Fisher) de l'ANOVA qui traduit la variance entre les moyennes de chaque famille d'arbres. En parallèle, une matrice de corrélation est appliquée sur l'ensemble des indices. Si 2 indices présentaient une corrélation supérieure à 85% ($r > 0,85$) alors ils étaient évalués selon leur valeur F de l'ANOVA, celui présentant une valeur plus basse était éliminé.

Deuxième approche : Par extraction de caractéristiques, à partir des algorithmes Minimum Noise Fraction (MNF) et l'Analyse en Composantes Principales (PCA).

2^{ème} étape : La classification par Support Vector Machine (SVM)

Cette étape consiste à comparer les différentes réductions de dimensions en appliquant l'algorithme de classification SVM aux images ayant subi ces réductions et selon les trois résolutions spatiales avec une nomenclature écologique par familles d'arbres (19). Afin de mieux comprendre chaque résultat des méthodes de réduction, une analyse des matrices de confusion de chaque résultat du SVM a été faite par famille d'arbres (19 familles répertoriées), pour comparer les méthodes de réductions de dimensions via extraction et sélection de caractéristiques et enfin connaître les caractéristiques biophysiques qui sont les plus influentes dans la classification.

Données utilisées

Une image Hypsax et 2 images HYPXIM à 2 résolutions spatiales différentes sont utilisées (Figure 43) dont les caractéristiques sont précisées dans le Tableau 19.

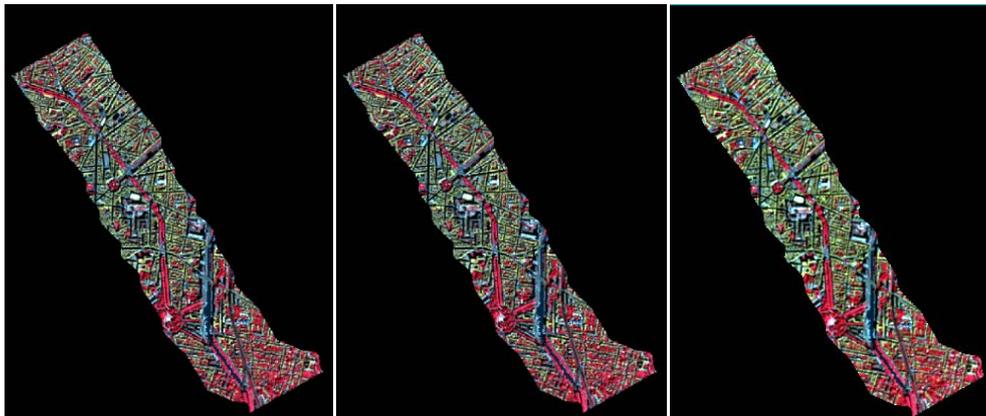


Figure 35 – De gauche à droite : composition colorée de l'image Hypsax (résolution spatiale 2 m), de l'image synthétisant HYPXIM à 4m, de l'image synthétisant HYPXIM à 8m.

Tableau 19 – Résolutions spatiales et spectrales des différentes images utilisées dans l'étude (acquises en 07/2015)

Images	Nombre de bandes	Résolution spectrale	Résolution spatiale
TC_2015_Hypsax	408 bandes	0.4 – 2.5 microns	2m
TC_2015_Hypxim	192 bandes	0.4 – 2.5 microns	4m
TC_2015_Hypxim	192 bandes	0.4 – 2.5 microns	8m

Les données d'apprentissage et de validation (50-50%) ont été créées sur la base d'un inventaire géolocalisé au DGPS de la plus grande diversité d'espèces d'arbres suivant l'hypothèse que la végétation arborée n'a pas changé entre 2015 et 2017 (campagne réalisée entre le 31 mai et le 02 juin 2017). Après les post-traitements, la précision en XY des arbres recensés est d'ordre centimétrique (2 à 5 cm). Plus de 500 échantillons ont été effectués en prenant en compte le type, la famille et l'espèce. Seulement les familles ont été utilisées dans ce travail.

Résultats (Tableaux 10 et 11)

Analyse exploratoire : 2 classifications non-supervisées par K-means ont été réalisées afin de rendre compte du potentiel discriminant du jeu de données. La première avec autant de classes que de familles soit 19 classes et la deuxième avec 4 classes. Ces classifications confrontées à la "réalité terrain" (tableau de contingence) avaient pour objectif de mettre en évidence une identification plus ou moins aisée de certaines classes ou bien le regroupement de certaines classes d'arbres. Pourtant le résultat n'indique aucun regroupement qui isole clairement une ou plusieurs familles.

Sélection d'indices : Selon la résolution spatiale, le nombre d'indices sélectionnés n'est pas le même. Plus la résolution spatiale augmente plus il y a d'indices corrélés (à 2m : 45 ; à 4m : 39 ; à 8m : 38). Les indices séparant au mieux le jeu de données (10 sont principalement des indicateurs liés à la chlorophylle (à 2m: les 11 premiers ; à 4m: les 12 premiers ; à 8m: 7 premiers). L'ordre d'importance des indices change également, même si ce sont généralement les mêmes qui reviennent dans le haut du classement (*Tableau 10*).

Tableau 8 – Classement par valeur F de l'ANOVA des différents indices selon les trois résolutions spatiales (les 10 premiers)

<u>Résolution spatiale à 2m</u>		<u>Résolution spatiale à 4m</u>		<u>Résolution spatiale à 8m</u>	
Anova	indices	Anova	indices	Anova	indices
34,26	Datt_780	38,26	Datt_850	27,96	Datt_850
34,26	Maccioni	38,20	Datt_780	22,50	Mcari_700_670
33,25	Datt_850	38,20	Maccioni	19,52	Cari
23,10	MTCI	36,62	Mcari_700/Osavi_800	18,06	DD
20,98	Datt_850_710	27,42	Cari	16,20	Tcari_700_670
19,31	REMI	23,63	Tcari_700_670	15,06	Mcari_700_Osavi_800
19,13	Cari	22,36	Tcari_700/Osavi_800	13,69	Carter_695_670
19,11	Vogelmann	18,36	DD	13,03	SR_675_700
18,95	Vogelmann 2	16,99	Vogelmann 2	11,09	NDVI_682_553
17,98	CCCI	16,01	Vogelmann	10,21	REMI

Classification SVM :

En premier lieu, la réduction de dimension avant classification a un intérêt par rapport à la classification sans réduction de dimension préalable. En effet, la réduction par MNF permet d'obtenir les meilleurs résultats de classifications, notamment pour l'image aéroportée Hypspec à 2m de résolution spatiale avec un Overall Accuracy de plus 59% et un Kappa de 0.51 (*Tableau 18*). La précision est décroissante selon la résolution sauf pour la réduction via les indices de végétation où l'image à 4 m donne une OA de plus de 45% avec un kappa de 0.33 suivi du 8m (OA : 43,46%, kappa de 0,29) puis du 2m (OA : 41,15%, Kappa de 0,25) (*Tableau 18*). La réduction par extraction (MNF) est donc meilleure que la réduction par sélection d'indices. L'ACP ne donne pas de résultats extrêmement intéressants, elle est de moins bonne qualité que la classification sans réduction de dimensions préalable.

Tableau 9 – Résultats des différentes réductions de dimensions ACP, MNF et Indices de végétation suivi d'une classification SVM

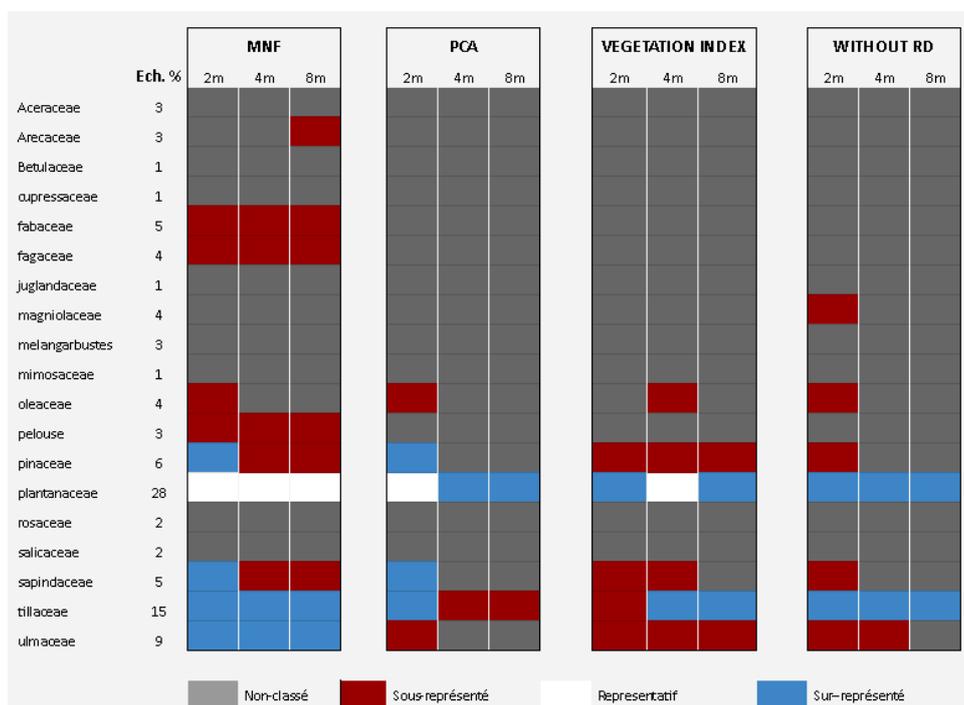
	Datasets	Spatial resolution	Overall Accuracy (OA)	KIA
Without RD	Hypex (408 bands)	2m	48.84%	0.37
	Hypxim (192 spectral bands)	4m	35.38%	0.15
		8m	35 %	0.16
Reduced	PCA	2m	47.69 %	0.36
		4m	28.08 %	0.01
		8m	27.70 %	0.04
	MNF	2m	59.23 %	0.51
		4m	51.92%	0.41
		8m	46.92 %	0.35
	VI (correlation matrix)	2m	41.15%	0.25
		4m	45.77 %	0.33
		8m	43.46%	0.29

Without RD sans réduction, Reduced : avec

Analyse des matrices de confusion :

La MNF est la réduction de dimensions la plus efficace afin de représenter les différentes familles (Tableau 12). En effet c'est la seule réduction qui réussit à discriminer les Platanaceae correctement dans les différentes résolutions spatiales. La MNF sous et sur représente d'autres familles telles que les Fabaceae, les Fagaceae ou encore la pelouse, qui ne sont pas représentés dans les autres réductions de dimensions. Les Platanaceae sont bien représentés avec l'ACP à 2m et avec la méthode de sélection d'indices de végétation à 4m.

Tableau 10 – Synthèse des erreurs de commissions et d'omissions par représentation des familles dans la classification selon les différentes réductions de dimensions ainsi que la résolution spatiale



Discussion & Conclusion

L'hypothèse « l'identification des caractéristiques biophysiques peut permettre une meilleure discrimination de la végétation urbaine » est rejetée même si la réduction de dimensions par sélection de caractéristiques a du potentiel puisque ses résultats se rapprochent de ceux de la MNF (Tableau 12). De plus cette approche permet de connaître les facteurs biophysiques les plus influents, les plus représentatifs du jeu de données. Ces résultats amènent à remettre en question la méthodologie employée, et notamment l'échantillonnage effectué sur le terrain. En effet, le jeu de données est fortement déséquilibré. Mais c'est une caractéristique de la végétation urbaine sur lequel il est difficile d'agir. En revanche il a pu être mis en évidence qu'il y a une **variabilité intra-classe importante** (orientation arbre, différentes espèces, ombrages,...) et une variabilité interclasse faible avec notamment une confusion entre les familles.

References

Perspectives

Il serait intéressant de travailler à partir d'un **échantillonnage équilibré**. Il est possible d'utiliser une nomenclature floristique adaptée à la donnée de télédétection et ayant une pertinence écologique (regroupement de familles ayant une signature spectrale similaire). L'utilisation de la méthode par sélection d'indice peut toutefois être intéressante dans le cadre d'un suivi temporel, à l'aide d'images hyperspectrales satellitaires, par différenciation des propriétés biophysiques liées à la phénologie entre les classes.

Sur la méthodologie, pour la sélection d'indices, des méthodes simples ont été utilisées. En effet, elles comparent le niveau de corrélation des indices un à un. Mais la **combinaison d'indices** donne parfois une meilleure séparabilité des classes, comme par exemple en utilisant la méthode de Kurskal Wallis (algorithme itératif teste toutes les combinaisons possibles d'indices – voir Erudel et al 2017). Une autre méthode intéressante serait le calcul de la dérivée première comme information complémentaire à intégrer dans une méthode par extraction des caractéristiques. De plus lors du calcul des indices, seule une bande était choisie pour sa proximité avec la longueur d'onde nécessaire dans le calcul. L'utilisation de quelques bandes spectrales autour de la valeur identifiée par l'indice, en moyennant les valeurs, pourrait permettre de lisser l'indice et ainsi améliorer le rapport Signal / Bruit et donc d'améliorer le résultat.

Enfin la méthode d'apprentissage / validation par "Leave-one-out" peut être intéressante pour ce type de jeu de données déséquilibré.

Production dans le cadre de l'ANR HYEP

3.5 Evaluation de multiples techniques visant l'amélioration de la performance de classification de la végétation urbaine à partir de données hyperspectrales

Auteurs : Charlotte BRABANT (Mémoire M2, COSTEL), Thomas HOUET (COSTEL)

Objectif : L'objectif de ce travail consiste à déterminer le niveau de **performance attendu** des données hyperspectrales THRS satellitaires pour détecter la diversité de la végétation urbaine arborée

Méthode

La méthode est basée sur la comparaison de techniques intervenant à différentes étapes clés de la classification afin d'évaluer l'influence de ces étapes sur les résultats obtenus. La démarche est identique quelle que soit la résolution spatiale considérée afin de rendre comparables les résultats (*Figure 44*). Au regard de la littérature, plusieurs méthodes de réduction de dimensions (ACP, MNF et sélection d'indices de végétation) et

de classification (SVM, Random Forest) sont testées en combinaison pour connaître quelles méthodes offrent les meilleures performances selon les images considérées. Chaque classification est appliquée sur deux niveaux de nomenclature (Espèce et Famille), eux-mêmes subdivisés en 2 sous-niveaux.

Les hypothèses :

1. Le nombre d'individus minimum présents dans le jeu de données de chaque Espèce ou Famille pour l'apprentissage de la classification influence les résultats obtenus,
2. La réduction de dimension permet une meilleure séparabilité de classes plutôt que l'utilisation des données hyperspectrales complètes (réduction du rapport signal/bruit) ;
3. Les caractéristiques biophysiques de la végétation, s'exprimant au travers d'indices de végétation, peuvent permettre une meilleure discrimination de la végétation urbaine notamment lors de la réduction de dimension. Une sélection des indices les plus décorrélés favorisent la discrimination de la végétation arborée ;
4. L'image HySpex à 2m, par sa fine résolution spatiale ne permet pas de discriminer les arbres possédant une couronne de diamètre supérieur.

1ère étape : Réductions de dimension (RD). La première approche, la sélection de caractéristiques (96 indices de végétation ont été calculés) et sur lesquels deux sous méthodes ont été appliquées : une ANOVA et une ACP. Pour la première, les indices ont été ordonnés par décroissance selon la valeur F de l'ANOVA qui traduit la variance entre les moyennes de chaque famille d'arbres. En parallèle, une matrice de corrélation est appliquée sur l'ensemble des indices. Si 2 indices présentaient une corrélation à plus de 85% ($r > 0,85$) alors ils étaient évalués selon leur valeur F de l'ANOVA : celui présentant une valeur plus basse, était éliminé. Pour l'ACP, le critère de Kaiser a déterminé le nombre de composantes ayant des valeurs propres au moins supérieures à 1.

La deuxième approche : Par extraction de caractéristiques, à partir des algorithmes Minimum Noise Fraction (MNF) et l'Analyse en Composantes Principales (ACP).

2^{ème} étape : Jeu de données. En parallèle, un travail sur le jeu de données a été fait dû notamment au fait qu'il est fortement déséquilibré. Deux nomenclatures, familles et espèces ont été évaluées avec au moins 4 individus par classes puis un deuxième jeu de données a été créé avec au moins 10 individus par classes. Dans un premier temps, pour la méthode d'entraînement-validation, le choix s'est porté sur une méthode en 50-50% dû au nombre réduit d'individus présent dans certaines classes.

3^{ème} étape : Classifications. A partir de cela, les classifications Support Vector Machine (SVM) et Random Forest (RF) ont été appliquées sur les images réduites et non-réduites issues des images hyperspectrales HYPXIM et multispectrales Sentinel 2 simulées. Le SVM est capable de gérer les espaces de grandes dimensions efficacement en étant peu sensible au phénomène de Hughes, tandis que le RF a tendance à réaliser une sélection de caractéristiques ou une pondération de celles-ci lors de l'apprentissage.

4^{ème} étape : Amélioration des résultats. Par la suite, une méthode en KFold Stratifiés a été appliquée sur la réduction de dimension ayant obtenue les meilleurs résultats de classification et avec les sous-niveaux de nomenclature ayant au moins 10 individus/classe. Le but est ici de séparer en autant de K qu'il y a d'individus minimum par jeu de données (Kfolds = 10) et d'entraîner la classification sur Kfolds = 9 et de le valider sur le dernier sous-ensemble. L'opération est répétée dix fois sur les dix échantillons les uns après les autres.

La méthode mise en œuvre doit ainsi permettre d'estimer les différentes influences de chaque étape de traitement des images hyperspectrales (Nomenclatures, nombre d'individus, Réductions de dimension, classifications mais aussi de la méthode d'entraînement-validation) sur les résultats de classification.

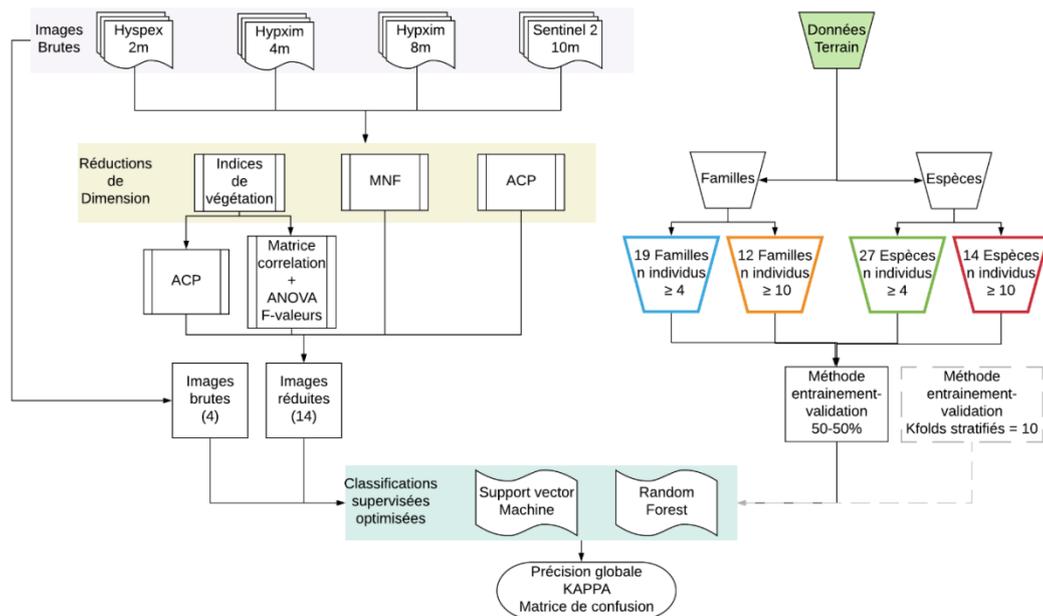


Figure 44 - Méthodologie générale appliquée sur les images

Données utilisées

Les caractéristiques des données utilisées sont décrites dans le *Tableau 13* et illustrées sur la *Figure 45*

Tableau13 – Caractéristiques spectrales et spatiales des différentes images utilisées

Capteur	Bandes	Plage dynamique	Résolution Spatiale
HySpex	408	0.4-2.5µm	2m
Hypxim	192		4m
Hypxim	192		8m
Sentinel 2	13	Annexe 1	10m



Figure 36 - Composition colorée vraies couleurs des images HS et Sentinel 2. A : Image HySpex à 2m de résolution spatiale ; B : image Hypxim à 4m ; C : image Hypxim à 8m ; D : image Sentinel 2

Les données d'apprentissage et de validation ont été créées sur la base d'un inventaire géolocalisé au DGPS de la plus grande diversité d'espèces d'arbres possible suivant l'hypothèse que la végétation arborée n'a pas changé entre 2015 (acquisition des images – *Tableau 13* et *Figure 44*) et 2017 (campagne réalisée entre le 31 mai et le 02 juin 2017). Après les post-traitements, la précision en XY des arbres recensés est d'ordre centimétrique (2 à 5 cm). Plus de 500 échantillons ont été effectués en prenant en compte le type, la famille et l'espèce. Seules les familles et les espèces ont été utilisées dans ce travail. Cependant il est à noter que ces données sont fortement déséquilibrées avec un nombre d'individus important d'individus dans certaines

classes, telles que le Platane commun (Platanacée pour les familles) ou le Tilleul (Tiliacées) avec respectivement 144 et 80 individus, alors que certaines espèces n'en comptent qu'un ou deux individus.

Résultats

Influence de la réduction de dimension (RD). La RD par MNF offre les meilleurs résultats de classification quels que soient la Nomenclature, l'algorithme de classification ou encore l'image utilisée. Les indices de végétation présentent des résultats proches de ceux du MNF mais jamais égalés ou dépassés. Ces deux RD ont en permanence des résultats supérieurs aux autres méthodes (Tableau 14). Les ACP, appliquées que ce soit sur les indices de végétation ou sur les images entières, présentent des résultats plus faibles que les images entières elles-mêmes.

Influence de la Classification. Les deux algorithmes offrent dans l'ensemble, des résultats similaires de classification. La nomenclature Famille semble mieux discriminée par le SVM et les espèces par le Random Forest (Figure 47).

Tableau 11 – Résultats de classifications SVM et RF des différentes résolutions et réductions de dimensions. Méthode en 50-50%, Sous-niveau 14 espèces

			14 Espèces (n>10)					
			SVM			Random Forest		
		Résolution spatiale	OA	Ecart type	KAPPA	OA	Ecart type	KAPPA
Images Brutes	HySpex	2m	56,16% ± 4,0	0,46		47,55% ± 4,0	0,34	
	Hypxim	4m	33,98% ± 2,0	0,03		43,30% ± 7,0	0,28	
		8m	35,42% ± 2,0	0,05		38,51% ± 4,5	0,21	
	Sentinel 2	10m	40,57% ± 4,0	0,24		37,60% ± 3,5	0,23	
Images Réduites	MNF	2m	63,20% ± 5,5	0,55		62,29% ± 5,0	0,53	
		4m	63,88% ± 4,0	0,56		61,07% ± 3,0	0,52	
		8m	60,85% ± 4,0	0,53		58,27% ± 4,5	0,48	
		S2 -10m	46,95% ± 3,5	0,30		52,56% ± 5,0	0,42	
	IV (ANOVA/matrice de corrélation)	2m	48,52% ± 5,5	0,37		57,04% ± 2,5	0,48	
		4m	48,69% ± 4,0	0,37		51,10% ± 2,5	0,41	
		8m	35,89% ± 3,5	0,14		50,89% ± 3,5	0,40	

Influence du nombre d'individus.

L'influence est visible dans les deux nomenclatures avec une amélioration des résultats lorsque le nombre minimum d'individus par famille ou espèce est plus grand. Par exemple les résultats pour les images s HySpex et Hypxim à 4m par MNF (pour les sous-niveaux 19 Familles et 12 Familles), sont intéressants avec une augmentation de plus de 5 points par rapport aux autres résolutions (Tableau 15).

Tableau 15 – Comparaison des résultats de classification des 2 sous-niveaux de la nomenclature Famille pour La RD par MNF

		19 Familles (n>4)						12 Familles (n>10)					
		SVM			Random Forest			SVM			Random Forest		
		OA	Ecart type	KAPPA	OA	Ecart type	KAPPA	OA	Ecart type	KAPPA	OA	Ecart type	KAPPA
MNF	HySpex	59,81% ± 8,0	0,53		58,26% ± 8,5	0,51		65,13% ± 8,5	0,58		64,08% ± 8,0	0,57	
	Hypxim 4m	55,68% ± 6,5	0,48		56,50% ± 6,0	0,48		61,96% ± 4,5	0,55		60,71% ± 6,5	0,53	
	Hypxim 8m	54,73% ± 4,5	0,47		51,99% ± 5,0	0,42		59,21% ± 5,5	0,51		56,07% ± 5,0	0,46	
	Sentinel 2	46,49% ± 5,0	0,36		45,33% ± 3,5	0,35		49,70% ± 5,0	0,39		48,86% ± 4,0	0,38	

Influence de la nomenclature.

Les familles et les espèces ne présentent pas de différences significatives dans les résultats de classification. Par exemple, la classification avec l'image Hypxim à 4m de résolution réduite par MNF, obtient une précision globale de 63,9% (kappa = 0,56) pour le sous-niveau « 14 Espèces » et 62,0% (kappa = 0,55) pour le sous-niveau « 12 Familles ».

Influence de la méthode d'entraînement - validation en 50-50% contre Kfolds = 10.

Réalisée sur la RD par MNF, la méthode d'entraînement/validation croisé par échantillonnage stratifié (KFolds) permet une augmentation des résultats que ce soit pour le sous-niveau « 12 Familles » ou pour le sous-niveau « 14 Espèces » avec pour cette dernière une amélioration de plus de 15 points pour l'image HySpex, 14 points pour Hypxim à 4m, 4 points pour Hypxim à 8m et plus de 9 points pour Sentinel 2 par rapport à la méthode en 50-50% (Figure 46). Les images HySpex et Hypxim à 4m présentent des résultats similaires, avec une précision globale de 78,38% et un Kappa de 0,73 mais un écart-type réduit pour Hypxim ($\pm 1,5$) par rapport à l'HySpex ($\pm 2,5$). Les matrices de confusion confirment ces observations avec une similarité entre HySpex et Hypxim à 4m mais aussi entre Hypxim à 8m et Sentinel 2. Néanmoins, une forte influence des classes sur-représentées est visible, surtout avec la classe Tilleul et peu importe le niveau de nomenclature (famille, genre, espèce).

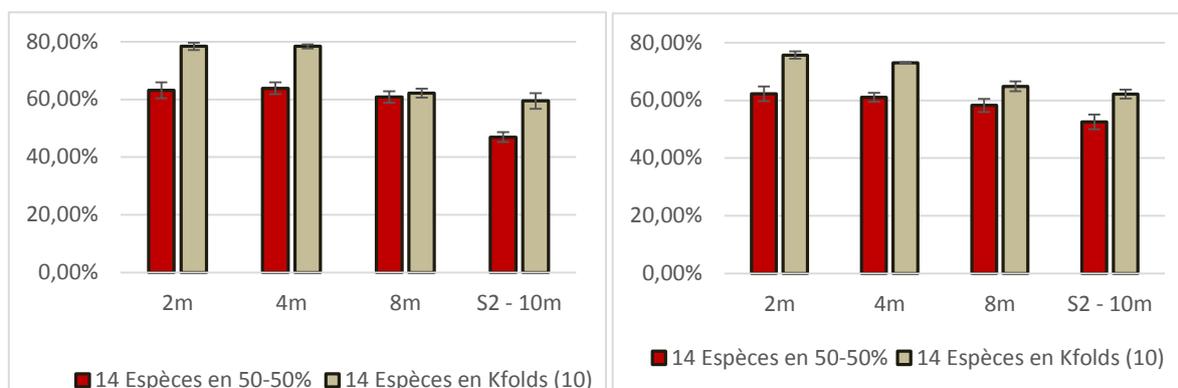


Figure 37 - Comparaison des résultats de la précision globale de la classification SVM (gauche) et RF (droite) entre la méthode en 50-50% et Kfolds sur le sous-niveau « 14 Espèces »

Discussions

Influence de la méthode d'échantillonnage. La nomenclature « Famille versus Espèces » révèle que lorsque le nombre de classes est plus important alors les classifications deviennent moins performantes. Le choix de cartographier un certain nombre d'espèces dépend des objectifs fixés : veut-on avoir une cartographie fine de toutes les espèces en présence ou souhaite-t-on obtenir les espèces dominantes ?

- La première hypothèse est vérifiée avec un nombre d'individus par classe qui influence les résultats de classification. Cela peut être dû au jeu de données déséquilibrées ainsi qu'au nombre de classes important. Cependant les variabilités semblent plus marquées dans la nomenclature *Famille* et la cause pourrait être les espèces au sein d'une famille ayant une ressemblance spectrale forte avec des espèces d'une autre famille (variabilité interclasse) mais ayant une ressemblance faible au sein de leur propre famille (variabilité intra-classe).
- La méthode en Kfolds a souligné cela pour toutes les images, notamment pour les Platanacées et les Tiliacées dont les faux positifs sont importants. Cette variabilité doit son origine notamment à **l'orientation de la rue, aux effets d'ombrages des espèces en présence mais aussi à la taille et la position du pixel en fonction de la taille de la houpe d'un individu, l'âge de l'arbre ainsi qu'aux différences spectrales des espèces elles-mêmes.** Mais l'effet peut surtout provenir de la présence d'une seule espèce au sein de la famille Platanacées (Platanes communs) qui est sur-représentée dans le jeu. Ceci est renforcé par la nomenclature Espèces puisque les Tilleuls argentés sont largement sous-estimés et mal classés dans la classe Tilleuls Sp. En effet, cette classe représente les individus identifiés jusqu'au genre mais dont l'espèce reste inconnue. Il serait intéressant de **raffiner les**

définitions de classe pour réduire l'ambiguïté en supprimant ces classes de *genre* (Tilleuls, Sapins, Chênes et Erables). De plus, il serait intéressant de diminuer le nombre d'individus dans les classes surreprésentées comme les Platanes communs (ou Platanacées pour les familles) afin de posséder un jeu plus équilibré.

Les réductions de dimension.

- La deuxième hypothèse est vérifiée, **la réduction de dimension permet une meilleure séparabilité de classes** plutôt que l'utilisation de données hyperspectrales complètes. Les images brutes sont soumises à l'effet de Hughes.. La MNF fournit les meilleurs résultats en permettant de ne sélectionner que l'information pertinente avec peu de perte de signal, ce que ne fait pas l'ACP. Le choix du nombre de composantes (ici, trop importantes) des ACP peut également expliquer ces résultats médiocres de classifications. La sélection d'une autre méthode de choix de composantes comme par exemple : garder 80% de l'inertie ou avec une inertie supérieure à l'inertie moyenne, permettrait peut-être une meilleure discrimination.
- La troisième hypothèse supposant que les caractéristiques biophysiques de la végétation, s'exprimant au travers d'indices de végétation, permettent une meilleure discrimination n'est pas vérifiée. Ce constat peut être dû à la prise d'une seule bande lors de l'implémentation dans le logiciel Python au lieu de prendre une moyenne des 2-3 bandes concernées par la longueur d'onde demandée. De plus, concernant la RD par Indices à partir de l'Anova, le choix du seuil de corrélation sélectionné était relativement arbitraire (> 0.85). Ceci peut entraîner un biais lors du calcul de classification empêchant une bonne séparation des classes. Il serait intéressant de faire une sélection par méthode non-linéaire par le biais du Deep Learning avec les Auto-encodeurs Empilés (SAE : Stacked Auto-encoders) même si elle n'a pour le moment été utilisée que pour des bandes et non pas pour des indices de végétation en milieu urbain.

Les résolutions (spectrales & spatiales).

- La méthode d'entraînement validation en 50-50% met en évidence l'impact de différentes **résolutions spatiales** sur les erreurs de classification : lorsque la résolution spatiale est grossière alors la distinction de certaines classes d'occupation du sol ne s'effectue pas correctement en raison de pixels mixtes. Ces différences tendent à se dissiper lors de la méthode en Kfolds, ce qui peut se traduire par une bonne capacité de généralisation de cette méthode. A de fines résolutions spatiales, la quatrième hypothèse n'est qu'en partie vérifiée il est nécessaire pour la valider de connaître le diamètre du houppier des individus compris dans l'échantillon d'entraînement pour en être certain.

La résolution spectrale

- Elle influence la capacité à distinguer des essences dont les signatures spectrales sont similaires, d'où les résultats médiocres de Sentinel-2 comparativement aux images Hypxim à 4 et 8m (sur la méthode en 50-50%). Cependant, une résolution trop fine peut entraîner d'autres problèmes étant donné que la réflectance spectrale peut varier au sein d'un seul arbre, en fonction de la biochimie et de sa teneur en eau. Cette variabilité se manifeste potentiellement par une classification d'un arbre ayant des pixels voisins étiquetés dans d'autres classes que celle à laquelle il appartient.

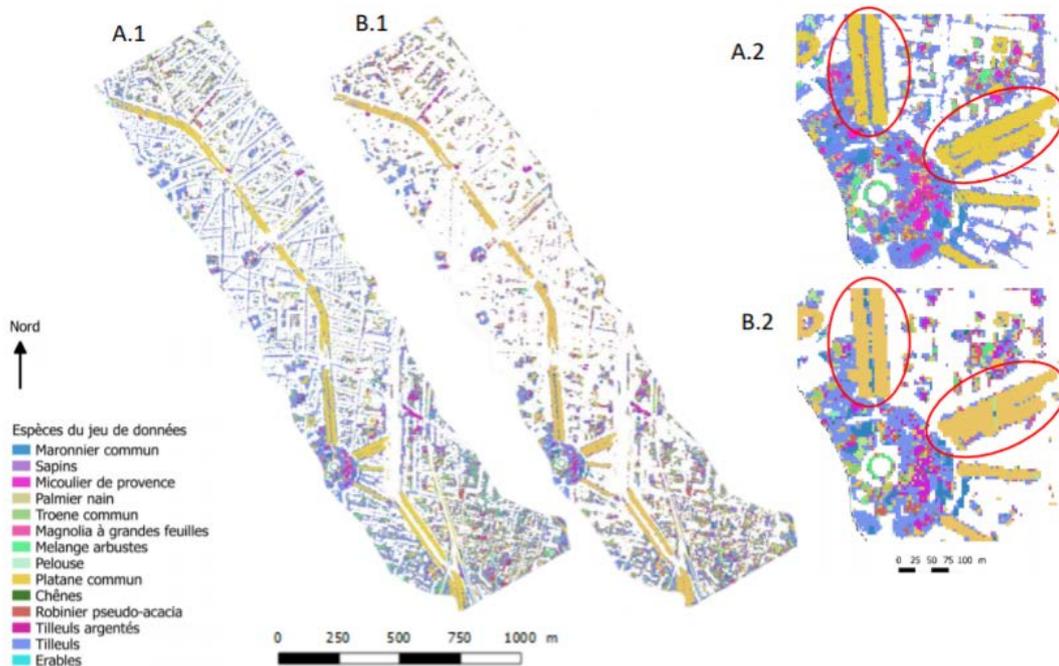


Figure 47 - Cartographie de la végétation à partir de la classification SVM généralisée sur les images réduites par MNF (méthode d'apprentissage en LOO) pour l'HySpex à 2m : A.1 & A.2 (Zoom sur le Rond-point Boulingrin) et l'Hyxim à 4m : B.1 & B.2. (Masque de végétation réalisé à partir d'un indice NDVI)

Conclusion

Ce travail avait comme but de connaître le niveau de performances possibles de données hyperspectrales pour détecter la diversité de la végétation urbaine arborée. Pour cela, de nombreuses questions ont été émises notamment au niveau de l'influence des données d'échantillonnages, des données hyperspectrales, des réductions de dimension ainsi que des classifications et des méthodes d'entraînement-validation. Ces questions ont conditionné la recherche et l'implémentation d'une approche robuste notamment par le choix des méthodes d'apprentissage, les niveaux de nomenclature ainsi que les comparaisons entre RD et classifications.

Les analyses effectuées, attestent des bons résultats de l'image Hypxim à 4m par MNF avec la méthode en Leave-One-Out sur la classification SVM et avec un niveau de nomenclature par espèces possédant au moins 10 individus par classe (OA = 78.4% \pm 1.5, Kappa = 0.73). L'approche démontre également l'intérêt de l'hyperspectrale en comparaison à la haute résolution spatiale multispectrale (Sentinel-2). Après réduction de dimension par MNF, les résultats des images HySpex à 2m et Hypxim à 4m sont considérablement supérieurs à ceux obtenus par Sentinel 2. Cependant, les résultats bien que satisfaisants pour la procédure multi-classe employée, pourraient être améliorés. Cette étude s'intègre dans le projet de lancement d'un capteur hyperspectral sur un vecteur satellitaire qui devrait avoir une revisite régulière. **Le suivi temporel en THRS peut améliorer considérablement les résultats par différenciation phénologique entre les classes.**

RéférencesPapiers publiés par HYEP :

C. Brabant, E. Alvarez-Vanhard, G. Morin, K. Thanh Nguyen, A. Laribi, T. Houet (2018) "Evaluation of dimensional reduction methods on urban vegetation classification performance using hyperspectral data", Proceedings of the 2018 IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2018), July 23-28 2018, Valencia, Spain

4. WP3.3: CARACTERISATION DES TOITS DE BATIMENTS ET DETECTION DE PANNEAUX SOLAIRES

4.1 Classification supervisée des matériaux de toits

Voir le §2.2.

4.2 Panneaux solaires

Auteurs : Moussa Sofiane Karoui, Fatima Zohra Benhalouche (Centre des Techniques Spatiales, Arzew, Algérie - IRAP, Université de Toulouse - LSI, Université des Sciences et de la Technologie d'Oran Mohamed Boudiaf, Oran, Algérie), Yannick Deville (IRAP, Université de Toulouse), Khelifa Djerriri (Centre des Techniques Spatiales, Arzew, Algérie), Xavier Briottet (ONERA), Thomas Houet (LETG, Université Rennes 2), Arnaud Le Bris (IGN).

Objectif : Détection et estimation des superficies des panneaux solaires en milieux urbains à partir des données hyperspectrales par une méthode basée sur la factorisation linéaire en matrices non-négatives

Résumé :

Les données hyperspectrales de télédétection spatiale offrent des opportunités uniques pour la caractérisation de la surface terrestre dans les zones urbaines. Les panneaux photovoltaïques représentent l'un des composants importants des systèmes énergétiques dans ces zones. Dans ce travail, une méthode basée sur le démixage linéaire et utilisant la factorisation en matrices non-négatives est proposée pour détecter les panneaux photovoltaïques et estimer leurs superficies. Cette approche est basée sur un algorithme original multiplicatif avec connaissance a priori de certains spectres de panneaux photovoltaïques. La méthode proposée peut être considérée comme une approche de factorisation partielle en matrices non-négatives.

Introduction :

Le nombre de systèmes d'énergie renouvelable en fonctionnement a augmenté rapidement ces dernières années, en particulier dans les zones urbaines des pays développés.

Les panneaux photovoltaïques constituent une partie importante de ces systèmes. En effet, ces installations solaires peuvent générer une énergie verte à partir de ressources non polluantes.

Ceci a conduit les agences gouvernementales, les gestionnaires de réseaux électriques et les décideurs à les encourager par des financements et des réductions d'impôts. Par conséquent, et pour éviter les fraudes malveillantes avec ces énergies alternatives, de nombreuses organisations sont de plus en plus intéressées par des informations détaillées sur ces installations solaires, y compris leur localisation et leur production d'énergie.

Une des méthodes pour obtenir ces informations détaillées, au moins pour la localisation, sur les panneaux photovoltaïques consiste à réaliser des études de terrain. Cependant, cette approche est coûteuse et prend beaucoup de temps, ce qui conduit à l'utilisation d'autres méthodes plus rapides et moins coûteuses telles que l'intégration des données de télédétection.

Récemment, des approches utilisant des données de télédétection ont été proposées pour la détection automatique des installations photovoltaïques et leur localisation. Ces méthodes utilisent des images RVB aéroportées/spatiales à haute résolution spatiale, donc avec un nombre limité de bandes spectrales. De telles données ne permettent pas une détection efficace des panneaux photovoltaïques, principalement en raison de leurs propriétés matérielles. En effet, selon les configurations d'irradiation, des réflexions spéculaires peuvent modifier les propriétés visuelles de ces panneaux, ce qui rend leur détection difficile.

Méthode :

Pour surmonter les limitations ci-dessus, les données hyperspectrales à haute résolution spectrale peuvent être considérées. En effet, les capteurs hyperspectraux recueillent simultanément des centaines ou des milliers de canaux spectraux dans le domaine du visible et de l'infrarouge, ce qui permet une reconnaissance précise des matériaux. Cependant, et principalement en raison de la faible résolution spatiale de ces capteurs, des pixels mélangés, caractérisés par des mélanges de spectres purs, peuvent apparaître dans les images acquises et

empêcher une détection directe des matériaux sans traitement avancé pour démêler ces spectres. Le démêlage spectral linéaire est l'une des techniques les plus utilisées pour le traitement des données hyperspectrales. Il vise à démêler linéairement tous les spectres observés en un ensemble de spectres purs et leurs fractions d'abondance correspondantes.

Dans l'étude que nous avons réalisée dans le cadre du projet HYPEP, une méthode de démêlage linéaire des données hyperspectrales est proposée pour détecter automatiquement les panneaux photovoltaïques et estimer leurs superficies. Cette méthode est basée sur un algorithme original multiplicatif avec connaissance a priori des spectres des panneaux photovoltaïques. La méthode proposée est une méthode utilisant le concept de factorisation en matrice non-négatives et peut être considérée comme une technique de factorisation partielle.

L'algorithme développé minimise une fonction de coût originale par de nouvelles règles de mise à jour itératives et multiplicatives issues de règles standard basées sur l'algorithme de descente en gradient. Ces nouvelles règles garantissent la contrainte de non-négativité des données manipulées. Ces mêmes règles mettent en jeu les données observées, l'information a priori sur les spectres des panneaux photovoltaïques, les spectres inconnus des autres matériaux présents dans la scène observée, ainsi que les fractions d'abondance de l'ensemble des matériaux (y compris celles des panneaux solaires permettant leur détection et l'estimation de leur superficie).

Données utilisées :

La méthode proposée est testée sur des données hyperspectrales synthétiques et sur des données réelles.

Les données synthétiques sont issues d'un mélange, selon le modèle considéré, de spectres réels (*Figure 48*) et de fractions d'abondance obtenues par moyennage, sur de petites fenêtres spatiales, des résultats d'une classification réelle d'une scène en milieu urbain. Les spectres purs utilisés (avec variabilité spectrale) sont ceux de matériaux présents en milieu urbain : panneau solaire (seul connu de la méthode), tuile, arbre et végétation.

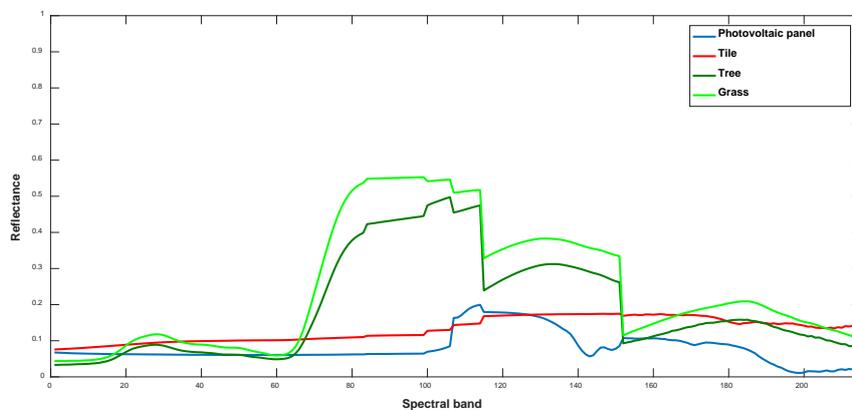


Figure 38 - Spectres purs utilisés pour la création des données synthétiques.

Deux imageries issues de données réelles sont aussi utilisées (voir *Figure 49*, partie droite). Ces données réelles sont constituées d'une image hyperspectrale issue d'une campagne aéroportée couvrant la zone urbaine de Toulouse (voir *Figure 49*, partie gauche).




Figure 39 - Composition colorée en vraies couleurs des données réelles et deux imageries extraites

Résultats :

Les résultats obtenus par l'approche proposée (appelée Multi-Part-NMF) sont comparés à ceux obtenus par la technique standard de factorisation en matrices non-négatives (Multi-NMF).

Pour les données synthétiques, l'erreur quadratique moyenne normalisée (NMSE), entre les fractions d'abondance originales des panneaux photovoltaïques et leurs estimées, est utilisée comme critère de performances (voir *Tableau 25*).

Tableau 12 – valeurs des NMSE (en %) des fractions d'abondance des panneaux photovoltaïques.

Multi-Part-NMF	Multi-NMF
16.62	81.76

Pour le cas des données réelles, des ortho-images de très haute résolution spatiale de la zone imagée (voir *Figure 50 (a)*) sont utilisées pour la validation de la détection des panneaux photovoltaïques (voir *Figure 50 (b)* et (c)) et aussi pour la validation des superficies obtenues, pour ces derniers, par les méthodes testées (*Tableau 17*).

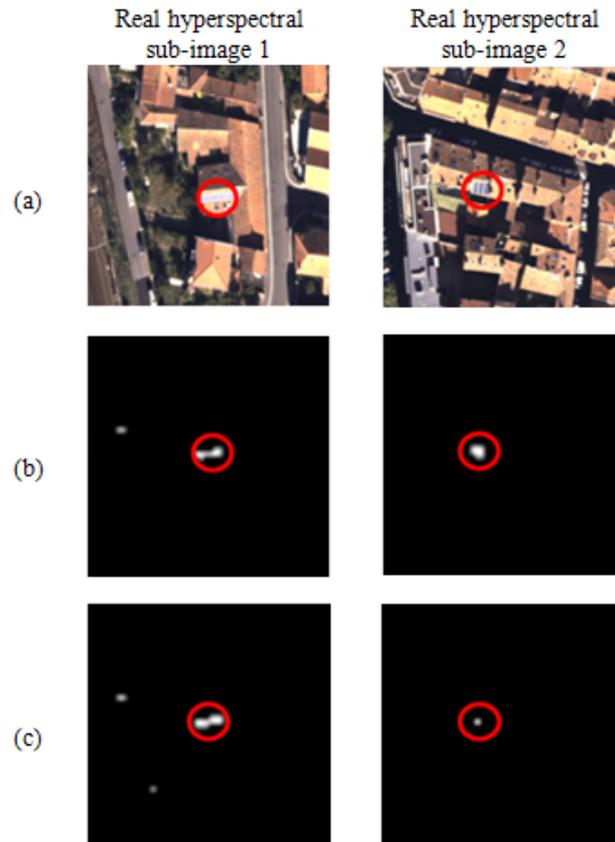


Figure 40 - (a) Ortho-image. Cartes des fractions d'abondance des panneaux photovoltaïques : (b) Multi-Part-NMF, (c) Multi-NMF. Les cercles en rouge englobent les panneaux photovoltaïques.

Tableau 17– superficies (m²) des panneaux photovoltaïques.

	Digitalisation manuelle	Multi-Part-NMF	Multi-NMF
Sub-image 1	15	15.27	21.26
Sub-image 2	12	13.06	1.10

Discussion et conclusion

Les performances de la méthode proposée sont nettement meilleures que celles de la méthode standard testée, (figures et tableaux ci-dessus), et détaillé dans nos articles cités ci-dessous). Ces premiers résultats sont très encourageants. L'algorithme proposé est très attractif pour la détection et l'estimation des superficies des panneaux photovoltaïques en milieux urbains, par l'utilisation de l'imagerie hyperspectrale de télédétection spatiale, et beaucoup plus précis qu'une méthode classique de la littérature. De plus, la méthode proposée peut être d'une grande utilité pour les opérateurs des réseaux électriques et pour les pouvoirs publics.

Perspectives

Les travaux futurs concernent, en premier lieu, l'application de la méthode proposée à des jeux de données nettement plus importants. En deuxième lieu, le développement d'une méthode similaire pour un modèle de mélange bilinéaire/linéaire-quadratique, plus adapté aux milieux urbains, représente une piste potentielle comme extension du présent travail.

Références

Papiers publiés hors HYEP par la communauté pendant la période 2014-2018 :

1. J.M. Malof, K. Bradbury, L.M. Collins and R.G. Newell, "Automatic detection of solar photovoltaic arrays in high resolution aerial imagery," *Applied Energy*, vol. 183, pp. 229-240, 2016.
2. S. Puttemans, W.V. Ranst and T. Goedemé, "Detection of photovoltaic installations in RGB aerial imaging: A comparative study," *Proc. GEOBIA 2016*, Enschede, The Netherlands, 2016.

Papiers publiés par HYEP :

1. M. S. Karoui, F. Z. Benhalouche, Y. Deville, K. Djerriri, X. Briottet and A. Le Bris, "Detection and Area Estimation for Photovoltaic Panels in Urban Hyperspectral Remote Sensing Data by an Original NMF-Based Unmixing Method," in *Proc. IEEE IGARSS 2018*, Valencia, Spain, 2018.
2. M. S. Karoui, F. Z. Benhalouche, Y. Deville, K. Djerriri, X. Briottet, T. Houet and A. Le Bris, "An NMF-Based Unmixing Method with Known Spectra of Photovoltaic Panels for their Detection and Area Estimation from Urban Hyperspectral Remote Sensing Data," in *Proc. SFPT-GH 2018*, Montpellier, France, 2018.

5. CONCLUSION ET PERSPECTIVES

Trois applications ont été évaluées.

La première avait pour objectif la **détection de surfaces imperméables** par classification supervisée à l'échelle du pixel.

Dans un premier temps, nous avons analysé l'apport d'une base de données de réflectance construites à partir de spectres issues de plusieurs villes de structures très différentes : Toulouse, Madrid, Londres, Tel Aviv. Les résultats montrent qu'une telle base globale ne permet pas d'obtenir une bonne qualité de classification pour plusieurs raisons : nombre d'échantillons trop faible pour certaines classes, déséquilibre important du nombre d'échantillons entre classe. Sur l'image de Toulouse acquise par la caméra Hypex à 2m, les meilleurs résultats sont obtenus avec les classifieurs Forêts Aléatoires et Angle Spectral. Les meilleurs résultats sont obtenus avec la base de données construite directement à partir de l'image.

L'analyse s'est poursuivie en évaluant l'apport de la résolution spatiale et spectrale en classification avec une méthode SVM. Meilleure est le domaine spectral couvert pour une résolution spectrale de 10 nm, meilleures sont les performances de classification. Pour la même configuration spectrale de l'instrument HYPXIM, bien que l'image de classification obtenue avec une image à 4 m soit plus interprétable visuellement par rapport à l'image à 8 m, les performances quantifiées en précision globale (AO) sont similaires.

Ensuite, la fusion de données de type HYPXIM 8m avec une image simulée multispectrale Pléiades 2m montre un gain significatif de performances.

Enfin, une classification SVM à noyau gaussien a été appliquée sur une zone péri-urbaine différente de la zone d'apprentissage (zone hyper centre). Une analyse visuelle montre que la zone est bien classée mais des confusions entre matériaux sont présentes.

A l'échelle objet, la classification supervisée des images après segmentation par méthode de logique floue en utilisant conjointement des données hyperspectrales et 3D améliore la détection des surfaces imperméables.

La deuxième application traitée à portée sur la **cartographie de la végétation urbaine**.

- Une première analyse (§3.1) a confirmé que la classification de la végétation haute et basse au niveau des espèces à partir d'une librairie par **approche pixel** n'était pas adaptée. Néanmoins, des résultats honorables sont obtenus lors de la classification par groupe d'espèces. Cette analyse a également déterminé qu'un nombre optimal de bandes (15 choisies sur le domaine 0.4-0.9 μm) augmentait de façon significative la précision globale (gain de 15 %) pour la classification des feuillus.

Ensuite, plusieurs méthodes de classification ont été testées montrant que la **méthode SVM** est plus adaptée que le SAM mais aussi la classification dans le plan de la transformée de la MNF améliore les résultats. Enfin, la classification des espèces d'arbres avec des données Sentinel-2 à plusieurs périodes de l'année a montré que la meilleure période pour la classification est le printemps.

- Une deuxième analyse a été entreprise sur la classification supervisée des espèces d'arbres par **approche objet** (§3.2) à partir d'une base de données construite sur l'image. Un premier travail avait pour objectif d'évaluer **l'apport et la complémentarité de sources différentes** (lidar 3D, panchromatique et hyperspectrales) pour la classification supervisée en testant plusieurs règles de décision pour la fusion. Les résultats montrent que l'imagerie hyperspectrale dans le domaine 0.4-0.9 μm la source a un impact majeur, plus vient l'imagerie hyperspectrale 1.0-2.5 μm . Les 2 autres sources ont une influence très marginale sur les performances de classification. L'apprentissage réalisé sur une zone de référence, a ensuite été appliqué sur une autre zone, avec des performances équivalentes pour la détection de deux espèces particulières, majoritaires. Une deuxième étude a été réalisée en **utilisant un ensemble de classifieur composé pour chaque espèce d'un triplet d'indices spectraux de végétation**. Cette nouvelle méthode (nommée « ensemble ») est comparée à une méthode utilisant

soit tous les indices (environ une centaine) ensemble soit en utilisant directement la réflectance spectrale. Trois bases d'apprentissage, d'échelles spatiales différentes, sont construites à partir de spectres de feuille mesurées au niveau de la feuille, de la canopée et de l'image. Les résultats obtenus montrent que la **méthode « ensemble » est la plus performante** et la moins sensible au changement d'échelle des bases de données. Ils confirment également les faibles performances de classification utilisant directement la réflectance spectrale avec une base de données construite à partir d'une librairie sol (échelle de la feuille ou de la canopée). Une dernière étude a été réalisée pour la détection d'arbres d'alignement, avec pour hypothèses ces arbres sont d'une même espèce et de hauteurs similaires. La nouvelle méthode développée basée sur une approche MPP en utilisant conjointement des informations sur leur signature spectrale, la hauteur des arbres, l'angle caractérisant l'alignement et un SIG afin des détecter les arbres proches des routes. Appliquée sur une zone de la ville de Toulouse, 100% des 69 arbres de type *Platanus x hispanica* sont détectés alors que les méthodes traditionnelles n'en détectent que 51.

- Une troisième analyse a été menée afin d'évaluer les performances de classification supervisée de la végétation arborée sur **l'influence des résolutions spatiale et spectrale (§3.3), de la réduction de dimension (§3.4) et des méthodes de classification (§3.5). Le premier point compare les performances de classification sur des images acquises par différents instruments** : Hypspx 2m / 408 bandes, HYPXIM 4m / 192 bandes, HYPXIM 8 m / 192 bandes et Sentinel-2 / 13 bandes. Meilleures sont les résolutions spatiale et spectrale, meilleurs sont les performances de classification. De plus, la classification a été testée sur l'image entière sans masque et avec un masque de végétation ; les résultats montrent que l'apport d'un tel masque dégrade légèrement les performances. Enfin, la méthode de classification la plus performante est le SVM, suivi par le Random Forest, couplée à une réduction de dimension de type MNF. L'apport de cette réduction de dimension améliore les performances de classification sur les images HYPXIM 4 m et 8 m et sont supérieures à celles de Sentinel-2 10 m (attention ici la bande SWIR de Sentinel – 2 a conservé une résolution de 10 m au lieu de 20 m, ce qui peut dégrader les performances de cette étude). **La partie réduction de dimension compare les méthodes PCA, MNF et indices de végétation (96).** Appliqués sur des images hyperspectrales à différentes résolutions spatiales (2, 4 et 8 m). Tout d'abord, le nombre d'indices sélectionnés et leur ordre d'importance dépendent de la résolution spatiale. Les meilleurs résultats de classification sont obtenus par MNF suivi du SVM, ces résultats décroissent avec la résolution. Bien que plus faibles par rapport à la MNF, la variation des performances en OA aux différentes échelles sont plus stables avec une réduction de dimension par indices que par les autres méthodes. La dernière partie de ce travail compare les **techniques intervenant à différentes étapes clés de la classification** pour détecter la diversité de la végétation urbaine arborée. Dans un premier temps, une comparaison des méthodes de réduction de dimension est faite confirmant les résultats précédents, la MNF puis les indices ont les meilleures performances. Les méthodes de classification SVM puis Random Forest ont les meilleurs résultats en termes de précision globale (OA%) mais plus précisément la nomenclature Famille semble mieux discriminée par le SVM et les espèces par le Random Forest. Plus le nombre d'individu par classe est grand meilleurs sont les performances. Enfin, la méthode d'apprentissage de type K-folds stratifié améliore les résultats par rapport à la méthode classique de d'entraînement – validation 50/50%.

La dernière application traitée a pour objectif de la **caractérisation des toits de bâtiments et la détection de panneaux solaires**. La **classification supervisée des toits** est réalisée par une approche objet et appliquée sur une image Hypspx 2 m et une image de la même zone simulant HYPXIM 4 m, couplées à un modèle numérique de surface (MNS). Les résultats montrent que la cartographie des toits faits en matériaux de construction claires (Zinc, Wood, PVC, tuile rouge) donne de bons résultats. Les principales sources de confusion sont les toits sombres avec les le réseau routier. L'apport du MNS en ajoutant une condition sur la hauteur permet de réduire cette source de confusion. Enfin, du fait de la surface réduite des **panneaux solaires en zone urbaine** par rapport à la résolution spatiale des caméras, une méthode basée sur le démélange linéaire a été mise en

œuvre afin de détecter les panneaux photovoltaïques, à partir de la connaissance à priori de leur réflectance spectrale, puis d'évaluer leurs superficies. Appliquée sur des images Hypspx 2m, les résultats démontrent le potentiel de la méthode pour atteindre ces objectifs avec une précision estimée meilleure que 10%.

Les principales conclusions que nous pouvons tirer de ces travaux portent sur plusieurs points :

- Base de données : importance de disposer d'une base de données représentative constituée d'un nombre suffisant d'échantillons par classe et d'importance comparable.
- Méthodes de détection
 - Le démélange est une technique d'imagerie hyperspectrale efficace pour détecter des objets à fort niveau de réflectance
- Méthodes de classification :
 - Au niveau pixel :
 - Les méthodes de types SVM ou RF ont des performances équivalentes
 - Ces méthodes ont de meilleures performances lorsque que l'image traitée a préalablement subi une réduction de dimension de type MNF ou à partir d'indices de végétation
 - A niveau objet :
 - Les méthodes utilisées montrent de meilleures performances que l'approche pixel
- Domaine spectral
 - Le domaine spectral recommandé pour couvrir l'ensemble des applications est le domaine 0.4-2.5 μm
 - Meilleure est la résolution spectrale, meilleure est la classification. Néanmoins, une résolution de l'ordre de 10 nm semble adaptée même si aucune étude n'a été faite pour évaluer ce point spécifiquement
- Résolution spatiale
 - Une résolution de 2 m est adaptée pour toutes les applications. Néanmoins, pour la classification de la végétation, une résolution de 4 m et même 8 m donne de bonnes performances.
- Fusion de données
 - L'apport d'une voie panchromatique pour améliorer les résultats de la classification obtenus par imagerie hyperspectrale est faible. En revanche, la fusion de données de type Pansharpening est une voie intéressante à mettre en perspective.
 - L'apport de la fusion de données de type MNS ou de SIG avec une image hyperspectrale améliore la discrimination des matériaux tout en réduisant la confusion entre classes.

Hyperspectral Imagery for Environmental urban Planning

Projet ANR 14-CE22-0016-01

<http://hyep.cnrs.fr/>

Recommandations techniques et des aux utilisateurs finaux

WP leader: Weber Christiane

Livrable WP4

Mois Juillet **Année** 2018

Auteurs : Aguejdad R. (UMR LIVE- TETIS), E. Alvarez (COSTEL), J. Aval (ONERA), F. Z. Benhalouche (Centre des Techniques Spatiales, Arzew, Algérie), C. Brabant (M2 TELENVI, COSTEL), X. Briottet (ONERA), Le Bris A. (IGN), Y. Deville (IRAP, Université de Toulouse), , K. Djerriri (Centre des Techniques Spatiales, Arzew, Algérie), S. Fabre (ONERA), S. Gadal (UMR ESPACE), Houet Thomas (COSTEL), M. S. Karoui (Centre des Techniques Spatiales, Arzew, Algérie), LARIBI Achour (Mémoire M2, COSTEL), G. Morin (COSTEL), W. Ouergemmi (UMR ESPACE), C WEBER (UMR LIVE-TETIS)

Dissémination : public

Interne au consortium

Remerciements

ANR "HYperspectral imagery for Environmental urban Planning" (HYEP), no. ANR 14-CE22-0016-01).

Le projet HYPE concentre ses travaux sur quatre applications : la quantification et la description de l'imperméabilité des sols urbains, l'identification et la cartographie de la végétation urbaine, des bâtiments avec si possible, la détection de panneaux solaires, et les zones humides urbaines.

Ces quatre applications sont intégrées dans différentes questions urbaines et les observables qui en résultant pourront être intégrés à différentes échelles : pour la planification urbaine (des blocs de construction aux districts), pour l'observation de la biodiversité et sa conservation, pour la conception de la "Trame verte et bleue", ainsi que pour le suivi de la stratégie de transition énergétique ou les défis de l'eau en milieu urbain (quantité et qualité de la ressource, les processus de traitement de l'eau, etc.) souvent associés à la biodiversité des zones humides.

L'intérêt des images hyperspectrales réside dans la gamme d'informations fournies sur des longueurs d'onde de 0.4 à 4 μ m ; ces images permettent d'avoir accès aux quantités spectrales d'intérêt et aux paramètres chimiques ou biophysiques de la surface. A ce stade, les images sont exprimées en unité de flux énergétique, la luminance spectrale, dans laquelle se trouve l'information optique caractéristique de l'objet d'étude perturbée par la présence de l'atmosphère.

Une étape de correction atmosphérique est nécessaire afin de s'affranchir des phénomènes de perturbation atmosphérique. Le processus d'exploitation est complexe, et une maturation des algorithmes et des outils est nécessaire pour une utilisation fiable et robuste par des non spécialistes, notamment sur des milieux complexes (urbains ou zones avec relief). Ceci passe aussi par la disponibilité de bases de données des propriétés optiques spectrales complètes d'éléments de la réalité (tuile, asphalte etc.) et statistiquement représentatives. Leur acquisition repose sur l'utilisation de moyens spectrométriques tant de laboratoire que de terrain dont les performances doivent être améliorées et adaptées au type de milieu.

Des efforts importants sont donc à entreprendre 1) pour développer des outils d'interprétation et d'analyse faciles d'utilisation et 2) pour accompagner des nouveaux utilisateurs par la proposition de documents ou de produits adaptés aux enjeux urbains.

Table des matières

Introduction.....	5
1 Synthèse technique et indicateurs accessibles	6
2 Démarche	9
2.1 Prise en compte des besoins des utilisateurs.....	9
2.2 Les utilisateurs.....	10
2.3 Besoins exprimés.....	10
2.4 Informations collectées.....	13
2.5 Sélection des éléments d'intérêt.....	15
2.6 Résultats	17
2.7 Discussion et Perspectives.....	31
Références bibliographiques.....	33

Introduction

La représentation des surfaces urbaines fournit aux aménageurs et aux urbanistes, ainsi qu'aux scientifiques une information essentielle à la gestion du système urbain. La cartographie à partir de diverses approches doit être la plus à jour possible. C'est pourquoi l'information aérienne ou satellite est utilisée. L'occupation des sols voire l'utilisation des sols est une entrée habituelle de ces applications. La gestion du système urbain, surtout dans des villes où la croissance est importante et où l'extension au détriment des terres agricoles ou des espaces naturels est rapide.

De longue date l'image satellite, notamment à très haute résolution spatiale est utilisée seule ou en intégrant des données autres (cartographiques, cadastrales etc.). L'usage des données hyperspectrales reste cependant très restreint du fait de la rareté des survols ou de la difficulté à obtenir des images provenant de capteurs étrangers adaptées aux besoins. Certains aspects doivent cependant être gardés à l'esprit. Les surfaces urbaines sont caractérisées par de multiples matériaux et objets variant de manière très rapide sur de courtes distances, ceci entraîne une hétérogénéité très forte tant en formes 2D et 3D, qu'en densité et en matériaux. Si l'on compare à des milieux naturels ou agricoles les limites entre les divers éléments sont étroites et resserrées. L'utilisation de capteurs optiques conduit donc invariablement à séparer les spectres et les objets détectés.

En milieu urbain cette situation est souvent délicate en fonction des résolutions spatiales des capteurs. Les basses ou moyennes résolutions entraînent l'obtention de pixel mixtes parce que plusieurs objets sont contenus dans un pixel, ceci entraînant la disparition de éléments eux même réduisant la variabilité des signatures spectrale de chaque objet détecté. A très haute résolution spatiale, au contraire la variabilité des objets correspond souvent à plusieurs pixels qu'il s'agit alors d'agréger (exemple un toit peut avoir plusieurs types de tuiles, anciennes ou non ou encore à des éléments comme les cheminée ou les lucarnes, qui déconstruisent l'unité de l'objet. C'est pourquoi dans beaucoup de travaux plusieurs approches sont développées de manière complémentaires conjuguant résolutions spatiale et spectrale.

L'objectif principal du WP4 est démontrer l'intérêt de l'imagerie hyperspectrale pour le milieu urbain notamment au travers de la mission Hypxim. Il comporte deux volets

- La synthèse des aspects techniques et des indicateurs accessibles permettant de définir la mission Hypxim au niveau de sa résolution radiométrique et spectrale dans le NIR et le SWIR pour le domaine du visible au proche infrarouge (400 à 1100 nm) et SWIR dans l'infrarouge proche (800 à 2500 nm).
- La synthèse des produits et applications intéressantes pour le milieu urbain.

Ce document fait la synthèse des travaux du WP4.1 (aspect technique) et du WP4.2 2 dont l'objectif a été découpé en 3 parties.

- Premièrement nous avons accompagnés les acteurs de terrain (décideurs ou interlocuteurs) dans une démarche de co-construction de la définition des besoins et des informations d'intérêt à fournir. Cette approche est importante car elle facilite éventuellement la modification de l'usage de sources numériques dans des activités de planification ou de soutien.

- Deuxièmement, la fourniture d'informations techniques et d'indicateurs compréhensibles en accord avec les besoins envisagés.
- Enfin la **production d'informations innovantes** utilisables en planification urbaine, par exemple la détection de panneaux photovoltaïques.

1 Synthèse technique et indicateurs accessibles

Résolution spectrale

- Le domaine recommandé pour couvrir l'ensemble des applications en milieu urbain est le domaine 0.4-2.5µm
- La sélection de bandes adaptée aux éléments à détecter peut être intéressante

Résolution spatiale

- La résolution Hypex (2m) est très intéressante ; la résolution de Hypxim (8m) ne le sera que s'il y a des possibilités de fusion ou de pansharpning.
- Il est nécessaire de définir les éléments observables notamment pour la végétation. Selon la nomenclature : feuille – canopée- paysage ou espèce – genre – famille les résultats peuvent être différents à la fois pour la détection et la caractérisation.
- Les bâtiments sont en générale bien identifiés à une résolution de 4m sans nécessité de fusion ou pansharpning, au-delà ces traitements semblent nécessaires.

Matériaux

- Certains matériaux urbains sont délicats à différenciés exemple : asphalte, pavé et graviers ou sols nus, gravier de toit et ciment ; cela s'explique par la composition des matériaux mais aussi les difficultés potentielles de discrimination liées à l'ombre, aux pentes et orientations de toits ... nécessité de travaux ultérieurs portant sur les moyens de discrimination et de caractérisation.
- La détermination des réseaux de voirie et de l'imperméabilisation¹ repose la question de la « définition » et des observables pris en considération
- L'approche orientée objet, est plus opérationnelle que l'approche pixel et fournit des résultats prometteurs
- L'utilisation de la 3D permet de différencier par la hauteur les éléments (toits, arbres, structures) et donc de séparer les observables du sol des autres.
- Par l'utilisation d'indices de formes et de caractéristiques de bâti il est possible de fournir des indications typo morphologiques de zones urbaines (voir résultats Kaunas)

¹ Considérée comme couverture plus ou moins étanche de surfaces naturelles ou agricoles par des bâtiments et des infrastructures associées

Végétation

- Les résultats sont satisfaisants et peuvent être améliorés. Le problème majeur vient de la difficulté d'avoir des spectres de végétaux cohérents (entre laboratoire, terrain et image) qui permettent la discrimination d'espèces. Les BD sont déséquilibrées au regard de la variété présente dans les villes. L'homogénéisation voire la sur-représentation de certaines essences plantées biaise le choix des éléments servant à l'entraînement de méthodes et à leur validation. Les variations d'échelles entre le paysage et la feuille induisent aussi des biais dans la prise en compte des signatures spectrales mesurées en laboratoire, sur sol ou sur l'image. Les structures foliaires des houppiers, leur densité induisent des résultats différents selon les espèces. Il faudrait donc simuler ces essences en tenant compte de leurs caractéristiques physico-chimiques et géométriques pour obtenir une plus grande efficacité statistique et de modélisation.
- Les résultats ont fournis des démarches opérationnelles pour distinguer des éléments du paysage urbain comme les alignements ; ils ont confirmé la possibilité de distinguer des espèces présentes sur les sites même si certaines ne se distinguent pas facilement.

Indicateurs

- Caractérisation des toits selon la couleur et certains matériaux
- Selon les observables retenus, le taux d'imperméabilisation² est susceptible d'être fourni selon des unités de surfaces définies (carroyage, quartiers, districts...)
 - Extraction des m² de zones de végétation pleine terre, des zones sablées
 - Extraction des m² de zones bétonnées (piscine, terrasse) des enrobés, des toitures (ardoise, tuile zinc, ciment...) des toits en terrasse, des noues et bassins tampon (rôle de réservoir)
 - Le cas des toitures végétalisées : selon le type de substrat et de hauteur de terre végétale il est très délicat de les classer en imperméables ou non à partir des images
- Suivi de l'artificialisation³
- Densité de bâti
- Typomorphologie de zones urbaines

² L'imperméabilisation des sols, c'est-à-dire leur recouvrement par un matériau imperméable tel que le béton ou l'asphalte, est une des principales causes de la dégradation des sols dans l'Union européenne. L'imperméabilisation des sols augmente le risque d'inondation et de pénurie d'eau, contribue au réchauffement de la planète, menace la diversité biologique et est particulièrement préoccupante lorsqu'elle affecte des terres agricoles fertiles. Lignes directrices concernant les meilleures pratiques pour limiter, atténuer ou compenser l'imperméabilisation des sols. http://ec.europa.eu/environment/soil/sealing_guidelines.htm.

³ Processus de transformation lié à l'activité humaine autre qu'agricole et forestière. Il recouvre plus que le seul processus d'urbanisation même si les sites urbains en sont le plus souvent le facteur dominant. ESCO Artificialisation des sols 2017

- Indices de fragmentation de la matrice bâtie
- Tâche urbaine

- Localisation des Panneaux solaires
- Surfaces de panneaux solaires

- Taux de végétation selon des unités de surfaces définies (carroyage, quartiers, districts...)
- Densité de végétation
- Longueur de linéaire d'arbres
- Surface de végétation et type d'espace
- Indices de fragmentation paysagère
- Espèces et biodiversité

2 Démarche

Pour mener à bien ce WP nous avons contacté la métropole de Toulouse (MT) en premier lieu, et ensuite celle de Montpellier (Toulouse ne suivant plus le dossier). Grâce à cette possibilité, nous avons pu néanmoins avancer sur ce WP et discuter d'indicateurs et de produits innovants correspondant à certaines attentes de nos partenaires

La prise en compte des besoins a été élaborée à partir de discussions, de propositions, de questions posées aux divers services. L'objectif étant de sérier les observables et le type de représentation intéressantes pour une prise en compte dans des pratiques de gestion du territoire.

Nous avons aussi élaborée une démarche pour identifier ces observables à partir de sources différentes et les classer selon une typologie reconnue par les services, en y associant les caractéristiques du signal correspondant. Un rapprochement entre ces informations et les spectres présents dans les bases de données spectrales (BDS) de la littérature et celles constituées pour cette ANR, a permis d'associer les spectres et les observables concernés.

Une poursuite des divers indicateurs est envisagée avec Montpellier Métropole pour définir des indicateurs moins classiques.

2.1 Prise en compte des besoins des utilisateurs

Cette prise en compte a été faite par des réunions (pas aussi nombreuses que souhaitées) avec en premier lieu les personnels de la Métropole de Toulouse (MT) et ensuite celle de la Métropole Montpellier Méditerranée (3M).

Dates

Toulouse : 30/10/2015 ; 26/01/2016 ; 30/03/2016

Montpellier : 18/10/2017 ; 11/01/2018 ; 18/05/18

La démarche pour cet objectif a été d'établir avec les acteurs de terrain une liste des éléments importants actuellement pour les collectivités locales sans qu'il n'y ait une nécessité de développement méthodologique spécifique. Ceci a été abordé à partir : (1) des besoins exprimés, (2) la présentation de résultats potentiels en cohérence avec les catégories classiques de l'occupation du sol, (3) l'explicitation des résultats.

L'identification de « catégories test » d'intérêt pour un certain nombre d'applications urbaines concrètes a été développée avec la MT et présenté et renforcé avec les partenaires de 3M malgré l'absence de survol propre. L'identification de résultats innovants a été présentée aux partenaires de 3M.

2.2 Les utilisateurs

Contacts à la Métropole de Toulouse

Mme Edouart Valérie, Chargée de la mise en place du Plan d'adaptation au changement Climatique, impacts climatiques, détermination d'indicateurs

Intérêts : végétation sur toit et stress hydrique/îlot de chaleur et de fraîcheur/trame verte et bleue/états des sols/bilan hydrologique de la Garonne

Mme Lise Debrye, PLUi environnement climat énergie, évaluation des documents PLU PADD PLH

Intérêts : diagnostic environnemental, végétation, zones humides, pentes des toits et PV ; Agence d'urbanisme de Toulouse (Pléiades cartographie de la végétation)

Mme Cordier Marjolaine : urbanisme

Intérêts : bâtiments et toits/ secteur sauvegardé/ /risque d'inondation et mise en place du PAPI, Plan de sauvegarde et de mise en valeur/

M Richard Reclus : Développement économique filière systèmes spatiaux et systèmes embarqués, Toulouse centre spatiale, valorisation des projets

Contacts : Métropole de Montpellier Méditerranée

Isabelle Roussel, Mission Cité intelligente ;

Intérêts : les challenges du numériques

Marc Aparicio, Responsable SIG

Intérêts : les produits issus de l'imagerie satellitaire et de l'hyperspectrale notamment

Franck Perdrizet : chargé de mission satellite

Intérêts : dans le cadre de sa mission de veille

2.3 Besoins exprimés

Pour réaliser cette étape deux approches ont été arrêtées :

- L'une en se basant sur des questions posées aux personnes contact de la MT,
- L'autre définie à partir d'un questionnaire établi suite à une réunion par un membre de la Métropole de Montpellier et adressé à l'ensemble des services.

-

En références : Les questions posées : encadré 1 ; le questionnaire encadré 2



Questions aux services de la métropole de Toulouse

L'objectif du programme de recherche ANR HYEP est de **caractériser le milieu urbain** au travers des formes urbaines et des dynamiques socio-environnementales qui l'anime. Pour cela il est nécessaire d'identifier les éléments qui le composent notamment à partir de certaines caractéristiques : la forme, la taille, les matériaux et les usages de ces composants (résidentiel, loisirs, activités ...).

Pour atteindre cet objectif il est nécessaire de mobiliser diverses sources d'information notamment des images satellites. Les images satellites actuellement disponibles fournissent une gamme de plus en plus large de produits qui peuvent être utilisées pour caractériser, identifier, suivre les espaces et les éléments urbains.

Dans cette gamme de produits des informations plus précises (résolution spatiale inférieure à 1m), plus riches (résolution spectrale et domaine radiométrique étendus), plus fréquentes (résolution temporelle permettant des revisites hebdomadaires) sont accessibles.

Dans la perspective d'une réunion de travail dans le cadre de l'ANR HYEP et afin de mieux cerner les objectifs de notre rencontre nous aimerions vous poser quelques questions :

Par rapport aux informations fournies par les images satellites

- Quels sont les éléments du milieu urbain qui vous semblent actuellement le plus à enjeu ? (les surfaces imperméables par exemple pour la gestion des eaux pluviales, les îlots de chaleur ou les risques d'inondation ; donnez 3 éléments à enjeu
- Quelles sont les informations spatiales associées à ces enjeux qui vous semblent absolument nécessaires, importantes ou seulement potentiellement intéressantes ?
- Sous quelles formes ces informations devraient être disponibles ? cartes, tableaux ou Base de données de statistiques, couches SIG etc. ?

Merci de votre attention

Ces réponses sont à envoyer à

Christiane.weber@live-cnrs.unistra.fr

**ENQUETE : QUEL EST L'INTERET POTENTIEL
DES IMAGES SATELLITES POUR VOS MISSIONS ?**

1 Contact MMM : à préciser

Pour toute question à ce sujet vous pouvez contacter : M Aparicio

2 Objectif de ce questionnaire

A l'heure où les images satellites sont de plus en plus accessibles, fréquentes et précises, nous vous sollicitons pour détecter et prioriser les usages potentiels dans vos services des images satellites à travers les outils du SIG métropolitain ou autres supports prêts à l'emploi (ex. : plan papier). Cela nous permettra d'affiner notre offre de service et de produits notamment au travers de nos partenariats avec différents organismes nationaux et locaux (INSPACE, CNES, Maison de la Télédétection à Montpellier : UMR TETIS).

Merci d'y consacrer un peu de votre temps (10 ' max) !

A mettre dans le mail

3 Quelques définitions simples:

L'imagerie satellite ou satellitaire désigne la prise et le traitement d'images d'une partie de la surface de la Terre ou d'autres planètes à l'aide de mesures effectuées par un engin spatial (satellite). La **télédétection spatiale** ... est l'ensemble des connaissances et des techniques utilisées pour déterminer les caractéristiques de la surface terrestre... Ce type de méthode d'acquisition utilise normalement la mesure des rayonnements électromagnétiques émis ou réfléchis par des objets étudiés dans un certain domaine de fréquences (infrarouge, visible, micro-ondes). Ceci est rendu possible par le fait que les objets étudiés (plantes, maisons, surfaces d'eau ou masses d'air) émettent ou réfléchissent du rayonnement à différentes longueurs d'onde et intensités selon leur état. *(D'après extraits de Wikipédia)* Le phénomène observé étant ainsi situé dans l'espace (x,y,y) et le temps (t), de nombreuses **utilisations en sont faites sous forme de cartographie (SIG notamment) dans les domaines nous concernant tels que:**

- environnement (évaluation et surveillance de phénomènes tels que déforestation, pollutions, pollution lumineuse, artificialisation, imperméabilisation, biodiversité, fragmentation écologique, érosion,...),
- aménagement du territoire (urbanisation, périurbanisation, réinvestissement urbain, cabanisation, construction neuve, conformité...)
- suivi de l'usage des sols,
- agriculture,
- gestion de certains risques (incendie, inondation, submersion...)
- gestion de l'énergie (solaire, éolien)
- autres ...

4 Votre identité

NOM – Prénom

Mission :

Service / Direction

5 QUESTION GENERALE

Présentez-vous un intérêt à l'usage des images satellites ? oui / non

Si oui merci de remplir le formulaire suivant décrivant l'usage potentiel

Si non, pourquoi pensez-vous que l'image satellite ne peut rien vous apporter : -----

Souhaitez-vous une réunion d'information/formation traitant de ce sujet ? : oui/non

Souhaitez-vous un support d'information traitant de ce sujet ? : oui/non

Quelles questions souhaitez-vous aborder relatif à ce sujet :-----

Ces deux approches (questionnaire et enquête) ont fourni des informations complémentaires sur les nomenclatures importantes mais aussi sur les pratiques des services concernés liées à l'information spatiale. *A noter que la trace des images Hypex fournies ne couvre pas l'ensemble de la MT. Certains éléments urbains comme par exemple les zones humides n'ont pas pu être prises en compte.*

2.4 Informations collectées

Tableau 1 : Nomenclature par classes-test identifiées par la MT :

Éléments urbains	Caractéristiques	Indicateurs
Toits	Classés par couleur : foncé ou clair ? Type de matériaux	Faire des tests de séparation
Panneaux photovoltaïques	Existence ou non	Spectres ?
Sols nus	Types de sols nus par rapport à un % de couverture végétale	Indices de sols
Végétation	Strates (3)	Indice végétation + Extraction des formes paysagères
Zones humides		Indice eau /indice végétation
Infrastructures, asphalte	Couleur (usure et type de matériau)	Pragmatique ? faire des tests

Les catégories d'occupation du sol ont été sélectionnées (WP1) afin d'harmoniser la démarche entre le terrain, les bibliothèques de signatures spectrales (existantes ou acquises) et les résultats issus de classification (WP3) pour obtenir des catégories d'occupation du sol utiles dans les documents de planification.

Tableau 2 : Synthèse des résultats de l'enquête de 3M

PROJET DE SYNTHESE D'APPLICATIONS AVEREES DU TRAITEMENT D'IMAGES SATELLITES / BESOINS DE LA METROPOLE (3M)			
THEMATIQUE	phénomène	indicateurs	Illustrations possibles
AMENAGEMENT DU TERRITOIRE	Artificialisation	mesure et suivi de la densité	cf bilan SCOT
	Densification	mesure et suivi de la densité	cf bilan SCOT
		suivi des volumes + et -	ex. ville de Montpellier
	Typomorphologie urbaine	identification et suivi des zones	cf. diag PLU
	Conformité au droit du sol	construction illégale	
GESTION DE L'ESPACE PUBLIC	Suivi de l'occupation du domaine public		
	Suivi de chantier		
DEVELOPPEMENT DURABLE	Photovoltaïque	potentiel des toitures	ex. ville de Montpellier
		état des lieux	
ENVIRONNEMENT	Biodiversité	naturalité, compacité, connectivité, hétérogénéité	
	trame verte et bleue	connectivité,	cf. E. SALLES

	mitage	fragmentation, quantification	
	pollution et dépôt illégal	identification, suivi	
AGRICULTURE	suivi saisonnier		TERRANIS
	mutation		TERRANIS
	stress hydrique		TERRANIS
	capacité de production		TERRANIS
RISQUE	inondation	identification et suivi des zones	
	submersion	identification et suivi des zones	
		suivi du trait de côte	Villeneuve les Maguelone
	Incendie*	identification des zones incendiées	image sur incendie cet été à Grabels ?
	imperméabilisation du sol		
MARKETING TERRITORIAL*	présentation du territoire		image dynamique
DEVELOPPEMENT ECONOMIQUE	mise à disposition de donnée	copie d'écran application Lkspatialist	LKSPATIALIST

Les points d'intérêts se recoupent dans les 2 cas ...

L'extension du tissu urbain au détriment des zones agricoles (artificialisation), l'imperméabilisation des sols et les besoins d'évaluation environnementale correspondent à des préoccupations de plus en plus importantes surtout depuis la loi Alur (24/03/14) et l'ordonnance du 3 août 2016 avec son décret d'application du 11 août⁴. En contrepoint le suivi de la végétation et les informations sur la fragmentation du paysage et des habitats sont des éléments favorisant une appréhension de la gestion de la biodiversité au sein et dans les périphéries des métropoles. Enfin, l'intérêt pour les actions favorisant les mesures de lutte contre le changement climatique et la gestion de l'énergie, notamment au travers des équipements comme les panneaux photovoltaïques est très présent pour l'ensemble des villes.

Sans entrer dans la définition de l'artificialisation des sols (voir ESCO, Inra IFSTTAR, 2017⁵) l'apport de l'image permet d'obtenir une information fine des sols couverts et du degré d'imperméabilisation selon le type d'occupation des sols. Cette information est de plus en plus nécessaire dans la gestion des risques liée au ruissellement des eaux de pluie et aux inondations. Des études approfondies sont nécessaires toutefois pour quantifier le degré d'imperméabilisation notamment pour les couverts poreux.

La végétation est un volet essentiel des *Objectifs du Développement Durable (ODD)* à la fois en termes d'habitat et de biodiversité mais aussi en termes d'éléments urbains entrant dans les modèles d'urbanisme actuel (toits et murs végétalisés, utilisation optimum de parcelles, gestion raisonnée des espaces verts, verdissement des quartiers etc.). L'image facilite la prise en compte des espaces urbains mais aussi des corridors écologiques ou des liaisons intra urbaines. Les zones péri-urbaines (jardins,

⁴ La réforme de l'évaluation environnementale ; transposition de la directive 2011/92/UE du Parlement européen et du Conseil du 13 décembre 2011, modifiée par la directive 2014/52/UE du Parlement européen et du Conseil du 16 avril 2014.

⁵ <http://institut.inra.fr/Missions/Eclairer-les-decisions/Expertises/Toutes-les-actualites/Sols-artificialises-et-processus-d-artificialisation-des-sols#>

champs, friches ou autres espaces naturels) font tampons avec les espaces agricoles mais favorisent aussi les échanges d'espèces végétales ou animales. Les approches de conservation ou l'application des principes de compensation (Eviter, Réduire, Compenser) nécessitent une bonne information sur l'état de ces espaces, leur qualité et leurs dynamiques sur des étendues souvent plus importantes que la seule zone à évaluer.

Les panneaux solaires correspondent à objectif de stratégie énergétique territoriale. Il s'avère que le suivi des installations en ville est souvent lacunaire, une caractérisation et une localisation de ses surfaces permettraient de suivre le potentiel des toitures en complément des informations obtenues par cartographie et possiblement à une validation des permis d'installation ; permis peu validés pour le moment par les collectivités. Les seuls ayant une information exhaustive et fine sont les fournisseurs d'énergie.

2.5 Sélection des éléments d'intérêt

La figure 1 positionne les éléments observables à la fois dans l'image HYPEx de Toulouse, l'orthophoto IGN de la zone ainsi que dans Googlemap afin de bien localiser nos éléments, y sont associés les coordonnées ainsi que les valeurs spectrales. La dernière colonne sert à identifier les catégories de la nomenclature.

Site	Image HYPEx	Orthophoto IGN	Googlemap	Coordonnées	Valeurs spectrales	Catégorie
1						Building
2						Building
3						Building
4						Building
5						Building
6						Building

Figure 1 : Constitution des sites test WP1 ANR HYEP

A partir de ce premier positionnement une relation avec les catégories d'occupation du sol ont été vérifiées. Les références et les caractéristiques des éléments ont été ventilées dans les différents niveaux correspondant aux produits cartographiques (N1 à N4).

Dans nombre de travaux une classification hiérarchique est utilisée (Herold et al. 2004; Roessner et al. 2001⁶). La plus connue est celle d'Anderson et al., 1976. Elle consiste en 4 niveaux de profondeur. Le

⁶ Herold, M., Roberts, D.A., Gardner, M.E., & Dennison, P.E. (2004). Spectrometry for urban area remote sensing - Development and analysis of a spectral library from 350 to 2400 nm. *Remote Sensing of Environment*, 91, 304-319
 Roessner, S., Segl, K., Heiden, U., & Kaufmann, H. (2001). Automated Differentiation of Urban Surfaces Based on Airborne Hyperspectral Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 39, 1525-1532

niveau 1 regroupe les principales classes d’occupation du sol comme la végétation, l’eau, le bâti ou les surfaces artificielles et les sols nus. Le niveau 2 regroupe les mêmes classes subdivisées selon leur fonction ou des caractéristiques génériques. Les niveaux 3 et 4 sont développés par rapport à des usages du sol. Par exemple, les catégories de bâti se réfèrent aux éléments urbains selon les matériaux utilisés et leurs propriétés spectrales (Figure 2).

Level 1	Level 2	Level 3	Level 4
Built up	Buildings/Roofs	Composite shingle roof	Black shingle
			Blue shingle
			Brown shingle
			(...)
		Plastic roofs	
		Glass	
		Gravel roof	Gray gravel
			Red gravel
		Metal roof	Brown metal
			Light grey metal
			Green Metal
		Asphalt roof	Light grey asphalt
	Tile roof	Red tile	
		Grey tile	
	Tar roof	Black tar	
		Brown tar	
	Wood shingle roof	Dark wood shingle	
	Transportation areas	Asphalt roads	Light asphalt (old)
Dark asphalt (new)			
Concrete roads		Light concrete	
	(...)		
Sport infrastructure	Tennis courts		
	Red tartan		
	Basketball court		

Figure 2 : Exemple des niveaux pour le bâti d’après Anderson et al., 1976

La figure 3 reprend la ventilation des niveaux d’Anderson en y ajoutant les catégories de matériaux et les valeurs spectrales associées.

Level 1	Level 2: Material types	Level 3: Surface materials	Spectra	Article	Position		
Materials/Artificial surfaces	Built-up/Roofs	Asbestos	Amlante	580, 800, 2321, (2320, 844)	(20)	Labov.	
		Bitumen roof sheeting	Toit bitume	1700, 2350, 11300			
		Clay tiles (red)	Tuiles en argile rouge	A 520, 670, 870, iron oxide absorption			
		Mineral materials	Concrete tiles	Tuiles en béton	A 2300-2370 (quartz and dolomite), A 2170 (carbon clay), 1413 and 2323 (perlite, muscovite)	(20)	Labov.
			Gravel	Gravier	A silicates at 2300, hydro-carbonates above 2300, iron oxides near 520, 870, 870	(9)	Santa Barb.
			Plate window glass	Plaque de verre à vitre	R 372, 400 A 2280	(23)	Labov.
			Slate	Slate (ardoise)	R 792, A 940, 2200, 2280, 2340	(23)	Labov.
		Metallic materials	Aluminium	Aluminium	A 840	(19), (5)	
			Copper	Cuivre	R 540-850, A 2240, 2340	(23)	Labov.
			Zinc	Zinc	A (strong) 150	(4)	
					A 1020	(19), (5)	
		Business materials	Polyvinylchloride (PVC)	Polychlorure de vinyle	Deep absorption at 1200, 1700, 2170, 2300	(1), (2), (3), (4)	London
	PV		Micro crystalline silicon (Si)	752, 1300	(21)	Labov.	
			Gallium arsenide (GaAs)	381, 887	(21)	Labov.	
			Indium phosphide (InP)	732-1067 (The optimal PV window is between)	(22)	Labov.	
	Tar black paper		Ruberoïde	R 1660, A 2160, 2360, 2440	(22)	Labov.	
	Business materials		Green roof	Toit végétal	R 550, 750, A 450, 680, 980, 1200, 1400, 2900	(9)	Santa Barb.
		Tatched roof	Toit de chaume	Large-cellulose vibration A 2100, 2300	(9)	Santa Barb.	
Wood shingles		Tuile de bois	Large-cellulose vibration A 2100, 2300	(9)	Santa Barb.		
Asphalt		Asphalte	Minor absorption 1850, 2315, 2350	(9)	Labov.		
Cement brick	Brique de ciment	1700, 2350, 11300	(1), (2), (3), (4)	London			
		R 600-700, iron oxides A1418, A1940-1970, gray cement	(5), (6), (7), (8), (9)	London			

Figure 3 : WP1 ANR HYEP Ventilation niveaux cartographique et valeurs spectrales. (d’après Anderson et al., 1976)

2.6 Résultats

Espace extrêmement anthropisé, la ville est caractérisée par une forte hétérogénéité spatio-temporelle formant une mosaïque de matériaux de nature différente et d'objets de tailles variées mais souvent petites. Cette variabilité des surfaces résulte de la superposition d'une variabilité naturelle et d'une variabilité anthropique qui influencent la réponse du milieu. En effet, on y trouve des surfaces minérales, des surfaces métalliques, des surfaces chlorophylliennes et des surfaces hydriques. Cette mosaïque urbaine est aussi caractérisée par une grande fréquence spatiale d'éléments de tous types (bâtiments, rues, structures, espaces verts, friches etc.), une large variété de surfaces pouvant être rencontrées sur de faibles distances. Dans un contexte d'extension des villes sur le territoire environnant, il apparaît qu'une connaissance approfondie des territoires urbains est essentielle : (1) pour répondre à des questionnements scientifiques (caractérisation des milieux selon un gradient ville-espace rural, identification des dynamiques de changement, fragmentation des paysages etc.) (2) pour répondre aux attentes sociétales sur la qualité du milieu au sein desquels vit une part de plus en plus importante de la population ; (3) pour fournir des éléments de réflexion et de décision aux collectivités (PLU environnementaux, Trames vertes et bleues, mode d'occupations du sol écologiques, évaluation environnementale etc.).

2.6.1 Rappels

Quelques rappels concernant l'imagerie hyperspectrale : la réflectance spectrale des sols est une propriété cumulative dérivée du comportement spectral de combinaisons hétérogènes de minéraux, de matières organiques, d'eau et de couverts végétaux. (Irons et al., 1989⁷). Une excellente revue des applications peut être trouvée dans Ben Dor et al., 2008⁸.

L'image Hyperspectrale fournit la possibilité de caractériser plus finement les matériaux et éléments urbains par le nombre de canaux utilisables. Un problème récurrent reste lié à la structure morphologique de la ville en 3D. Les ombres portées cachent en effet l'occupation du sol par projection.

Les résultats présentés démontrent à la fois les verrous qui sont encore à approfondir concernant les méthodes d'extraction et d'identification des éléments mais aussi la variété des représentations possibles des éléments observables utilisables par des aménageurs ou des gestionnaires urbains.

2.6.2 Observables

Les résultats qui suivent se concentrent sur les éléments identifiés par les acteurs :

- (1) L'aménagement des territoires, la typomorphologie de l'espace et la gestion des espaces publics sont abordés par la représentation de l'occupation du sol et la caractérisation du bâti ;
- (2) L'environnement notamment la biodiversité, trame verte et bleue et le mitage ou la fragmentation des habitats sont abordés par l'analyse de la végétation et des espaces naturels ;
- (3) Le développement durable au travers de l'identification et localisation des panneaux solaires.

⁷ Irons, J.R., Weismiller, R.A., & Petersen, G.W. (1989). Soil reflectance. In G. Asrar (Ed.), *Theory and Application of Optical Remote Sensing* (p. 66–106): Willey Series in Remote Sensing, John Wiley & Sons, New York

⁸ Ben-Dor, E., Taylor, G.R., Hill, J., Dematte, J.A.M., Whiting, M.L., Chabrilat, S., & Sommer, S. (2008). Imaging spectrometry for soil applications. *Advances in Agronomy Journal*, 97, 321-392

- (4) L'imperméabilisation se définit par la réflectance des observables urbains mais aussi par agrégation de classes d'occupation du sol.

2.6.3 Représentation de l'occupation du sol et cartographie des observables

La cartographie de l'occupation et de l'usage du sol peut être réalisée à différentes échelles. Avec les images satellites seule **l'occupation du sol** peut être fournie, mais il est possible d'y adjoindre des usages indirectement en y joignant des classes d'usage (ex. une zone bâtie littorale caractérisée par de grandes formes aux matériaux synthétiques peut être classée zone portuaire grâce à des renseignements annexes).

Le choix des catégories d'occupation du sol dépend des objectifs de l'étude. Des bases de données cartographiques d'un territoire ou d'un continent fournissent des informations similaires mais non identiques sur un même territoire. Ainsi les deux bases de données couramment utilisées : Corine Land cover et Urban Atlas (Corine Land Cover (44 classes Minimum Mapping Unit (MMU) de 25 hectares); Urban Atlas (villes plus 10 000 habitants) <http://www.eea.europa.eu/data-and-maps/explore-interactive-maps/urban-atlas-for-europe>) bien que se référant aux mêmes espaces ne fournissent pas les mêmes informations d'occupation du sol.

- ⇒ *C'est pourquoi réaliser une représentation de l'occupation du sol reste un enjeu important d'autant plus que les métropoles et les régions se dotent actuellement de base de données ad hoc propres à leur territoire à partir de données satellitaires, photographiques voire participatives.*

La cartographie d'observables c'est-à-dire d'éléments particuliers des surfaces urbaines se situe dans une perspective différente. Là il s'agit de **relever, d'identifier voire de caractériser** de manière physico-chimique les matériaux ou éléments naturels. Les signatures spectrales sont définies par la composition chimique des matériaux. Par exemple les toits ou les routes peuvent receler des chaînes d'hydrocarbures repérables spectralement.

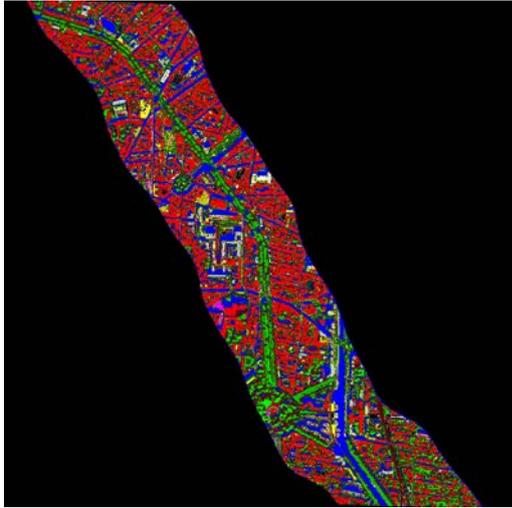
2.7 Les Applications

2.7.1 Aménagement des territoires, typomorphologie et gestion des espaces publics

L'aménagement des territoires est la plupart du temps représenté à partir de classification permettant une représentation selon des catégories prédéterminées et des échelles définies par les objectifs ou les pratiques. Les espaces publics ne se déterminent que par des informations ancillaires comme les plans des propriétés publiques (bâtiments) des espaces gérés par les collectivités comme les espaces verts (etc.) à ce titre ils ne peuvent pas être déduits directement par l'image.

Les méthodes de classification sont nombreuses (WP2) qu'elles soient supervisées ou non. Elles sont utilisées quelles que soient les catégories d'occupation du sol étudiées (agriculture, urbain etc.). Les approches de « démélange » et d'apprentissage (SVM par exemple) sont souvent appliquées.

La fusion d'images à différentes résolutions spatiales permet de tirer parti des informations différentes (spectrale et spatiale) de manière complémentaire. Enfin pour des objectifs particuliers le développement de méthodes innovantes cherchant précisément à isoler un spectre spécifique, des méthodes plus sophistiquées de démélange sont parfois nécessaires.



Les résultats des classifications peuvent varier selon les méthodes et les objectifs.

Figure 4 : Classification non supervisée



● Avec ombres

Classification dans les ombres. Les ombres en milieu urbain constituent un verrou important lié à l'hétérogénéité des hauteurs. Réussir à s'en affranchir peu ou prou est un enjeu important permettant de fournir des supports d'étude plus précis spatialement.

Figure 5 : Classification dans les ombres – ONERA

- Toits
- Végétation
- Eau
- Asphalté
- Gravier

L'approche Orientée Objet permet de délimiter et d'isoler les éléments de la matrice urbaine

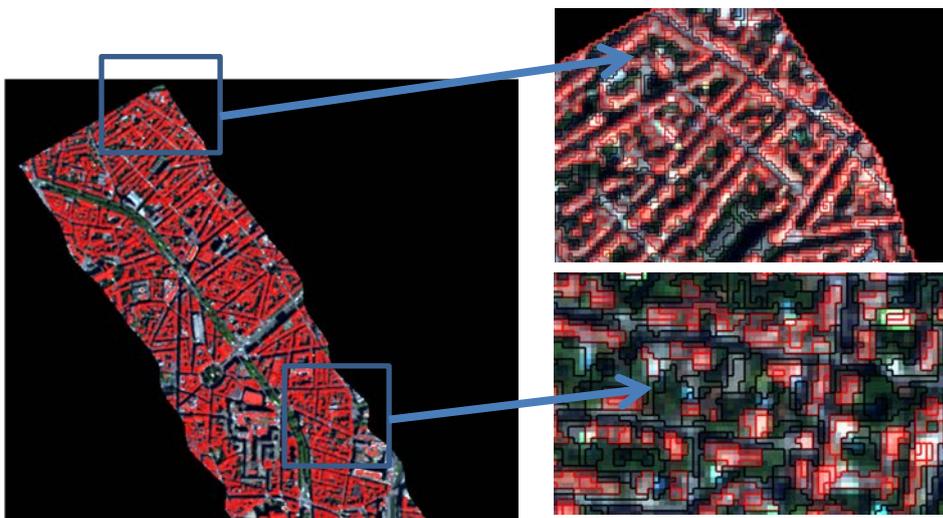


Figure 6 Extraction des formes bâties

La fusion de plusieurs images à différentes résolutions spatiales semble permettre de meilleurs résultats. (Ref WP2 - IGN).

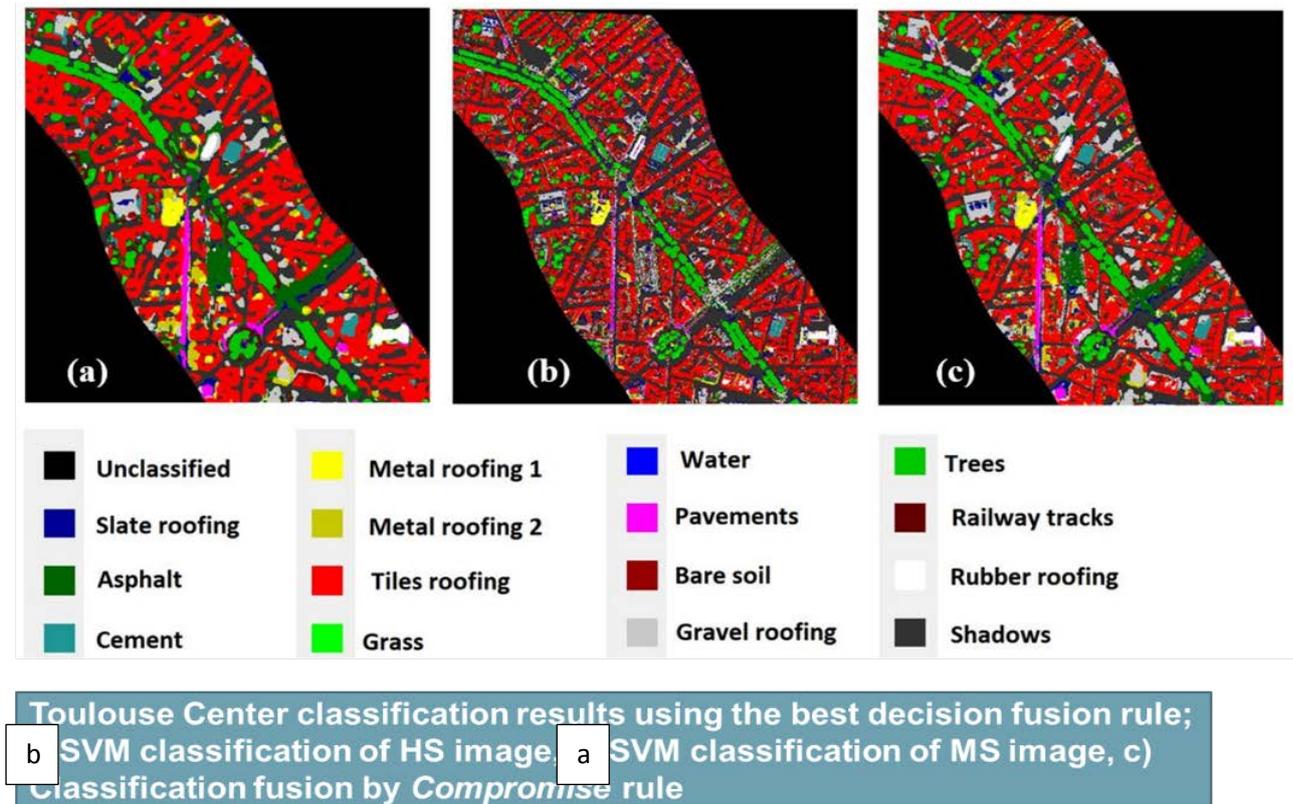


Figure 7 : Classification par fusion IGN – Détermination de l'occupation du sol

Pour améliorer les résultats l'utilisation de méthodes SVM (Support Vector Machine - ensemble de techniques d'apprentissage supervisé) permettent elles d'obtenir des résultats satisfaisant par fusion d'images à haute(MS image) et très haute résolution spatiale (HS image).

D'autres méthodes ont été abordées dans le WP2 et WP3.

2.7.2 Typomorphologie du bâti

Deux études typo-morphologiques ont été menées au sein de l'UMR ESPACE. Elles ont concerné les villes de Toulouse (France) et Kaunas (Lituanie). Elles sont basées sur une approche multi-capteurs (imageurs hyperspectraux ONERA et RICOLA), multi-résolution spectrale (RICOLA : 16 et 64 bandes spectrales) et multi-résolution spatiale (multi-scalaire) a été développée et testé dans ce contexte. Dans les deux cas il s'agit d'une reconnaissance et une caractérisation morpho-spectrale des structures urbaines à partir de caractéristiques des objets bâtis (BDS) des matériaux de toitures ou du sol (par exemple asphalt, tuiles, bitume, etc.) collectées en laboratoire, sur le terrain ou sur l'image. Concernant la ville de Kaunas (Lituanie) des règles morpho-métriques ont été utilisés en plus pour modéliser les objets urbains par leur forme géométrique. Elles sont construites à partir de différents attributs géomatiques décrivant la morphologie des bâtiments.

Les attributs morpho-métriques (géométriques) peuvent être considérés comme un outil performant de caractérisation des objets bâtis, à partir de l'imagerie à haute/très haute résolution spatiale (idéalement centimétrique). En effet, plusieurs attributs morphologiques sont disponibles (par exemple région,

élongation, convexité, circularité, etc.) et ces derniers peuvent être utilisés séparément ou d'une manière groupée dans le but de caractériser une forme géométrique particulière. La résolution spatiale de départ est à prendre en considération dans tout traitement morphologique, car elle influe sur la performance de caractérisation finale des objets ; en effet une opération de segmentation sur l'image d'intérêt précède généralement la procédure de détection morphologique. Plus la résolution spatiale est importante, meilleure sera la précision de segmentation des différents objets et meilleure sera ensuite l'estimation des attributs morphologiques des différents objets segmentés.

L'exemple de la figure 8 illustre une caractérisation morphologique en utilisant différents attributs morphologiques et texturaux sur la ville de Toulouse. Les attributs de type texturaux peuvent présenter une solution intéressante pour la caractérisation urbaine, en effet, le milieu urbain est hautement hétérogène, avec différents objets ayant des caractéristiques de forme et de texture différentes. En définissant des seuillages texturaux adaptés, on peut détecter des objets urbains spécifiques comme les grandes structures commerciales/culturelles (par exemple des parkings, des centres commerciaux, etc.) (Fig. 8.c.), la végétation urbaine (Fig.8.a) et les routes/pavés (Fig. 8.d.). En plus d'attributs texturaux, les attributs morphologiques ont permis la détection de structures bâties urbaines selon leur taille et leur forme. Par exemple d'étude, l'attribut « élongation » a été appliqué pour détecter des bâtiments allongés (Fig.8.b).

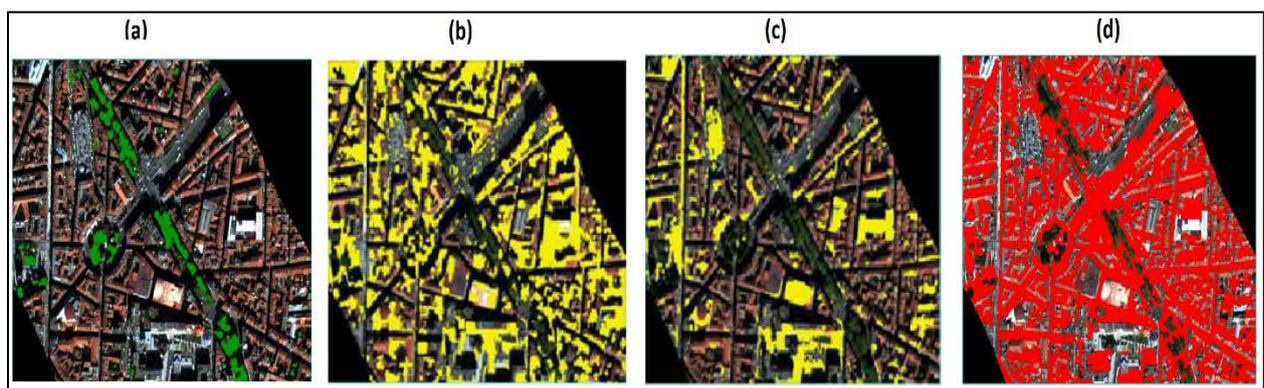


Figure 8 : exemple de caractérisation des principaux objets urbains sur la ville de Toulouse centre (France) (objet bâti « tuiles »), CNRS ESPACE UMR7300, S. Gadal, W. Ouerghemmi (2015)

L'exemple de la figure 8 illustre une caractérisation d'objets bâtis en utilisant les attributs morphologiques ou des combinaisons d'attributs morphologiques. L'objet urbain en question concerne les toitures en « tuiles ». Plusieurs classes ont été extraites : ici, les structures de grande dimension (les bâtiments culturels, les résidences groupées, les sites industriels, etc.) et de petite dimension (les maisons individuelles, les commerces, etc.) ont été détectées en utilisant l'attribut « région ». Les structures allongées (par exemple les bâtiments administratifs/résidentiels, etc.) ont été détectées en utilisant les attributs [élongation + MBR.FILL.RATIO⁹]; les structures cubiques (par exemple les grandes maisons, les structures culturelles, etc.) ont été détectées en utilisant l'attribut "MBR.FILL.RATIO", et finalement les structures circulaires/semi circulaires, ont été détectées en utilisant les attributs [circularité + convexité].

⁹ pour taux de remplissage du rectangle à limite minimum



Figure 8 : Exemple de caractérisation socio-économique sur la ville de Kaunas (Lituanie) (objet bâti « tuiles »), CNRS ESPACE UMR7300, S. Gadal, W. Ouerghemmi (2016)

En plus de la caractérisation des objets urbains, les attributs morphologiques peuvent être utilisés pour rectifier les artefacts de classification, qui suivant la méthode de classification peuvent varier. Dans l'exemple illustré par la figure 9, les artefacts de petite taille et des portions de routes en été éliminés en utilisant les attributs « région » et « élongation ».

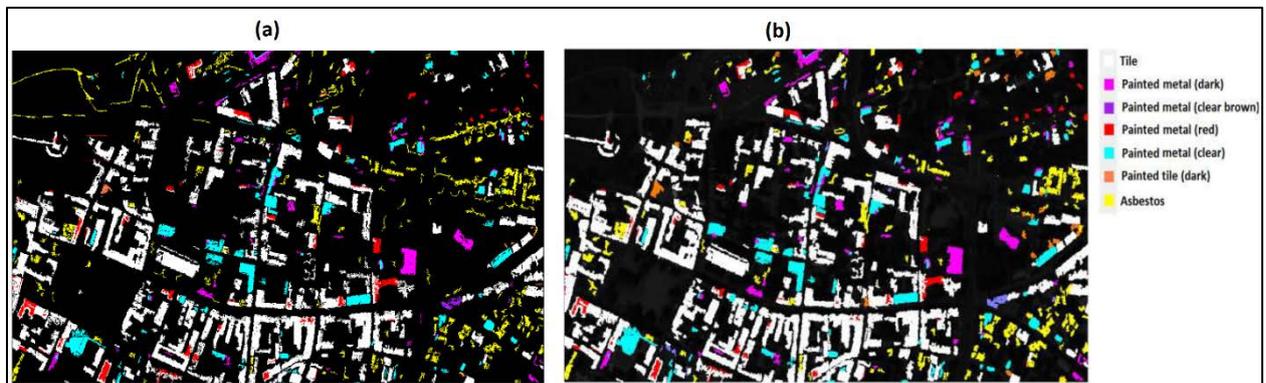


Figure 9 : Rectification de classification par attributs morphologiques, (a) centre-ville de Kaunas avant rectification, (b) même zone après rectification morphologique, CNRS ESPACE UMR7300, S. Gadal, W. Ouerghemmi (2016)

Le deuxième exemple (Figure 10) illustre une rectification morphologique sur une portion test sur zone industrielle, dans cette zone il y avait une corrélation importante entre les toitures de bâtiment qui étaient pour la plupart à base de bitume ou de ciment et les routes/pavés, il a fallu créer plusieurs combinaisons d'attributs géométriques pour éliminer ces artefacts de classification : région, élongation, [circularité + élongation] et [région + convexité].

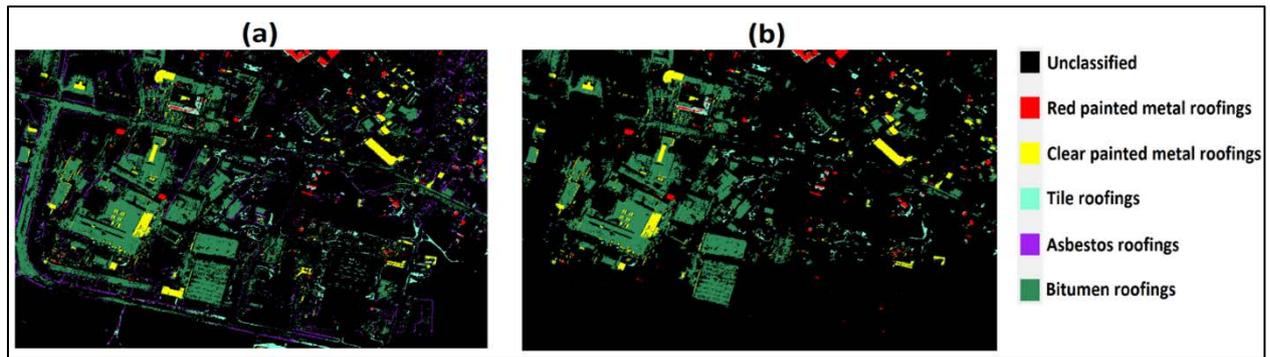


Figure 10 : Rectification de classification par attributs morphologiques, a) zone industrielle sur la ville de Kaunas avant rectification, b) même zone après rectification morphologique, CNRS ESPACE UMR7300, S. Gadal, W. Ouerghemmi (2017).

Dans le cadre d'un stage de Master 2 en 2017 (Aix-Marseille Université, CNRS ESPACE UMR 7300), qui s'est déroulé dans le cadre du programme HYEP, une étude sur la ville de Kaunas (Lituanie) a mis en évidence, qu'un nombre limité d'attributs morphologiques était suffisant pour détecter la plupart des structures urbaines bâties. Ils confirment les travaux menés par S. Gadal sur les images panchromatiques et multi-spectrales hautes résolutions spatiales (Gadal, 2001) (Gadal, 2011).

Ces attributs sont les suivant : élongation, compacité, région, taux de remplissage du rectangle à limite minimum, convexité et fraction de surface. En effet, ces attributs peuvent être utilisés individuellement ou combinés pour détecter/caractériser des objets urbains en particulier. La figure 11 illustre quelques exemples d'application de plusieurs attributs ou groupes d'attributs pour détecter des structures urbaines sur la ville de Kaunas (Lituanie). Détection de petites structures dont les petites maisons individuelles en utilisant l'attribut « compacité » (Fig.11.a), détection des structures allongées dont bâtiments et routes en utilisant les attributs [élongation + région] (Fig.11.b), détection des structures résidentielles et commerciales en utilisant l'attribut « région » (Fig.11.c), détection de structures religieuses/vieux édifices en utilisant les attributs [région + taux de remplissage du rectangle à limite minimum].

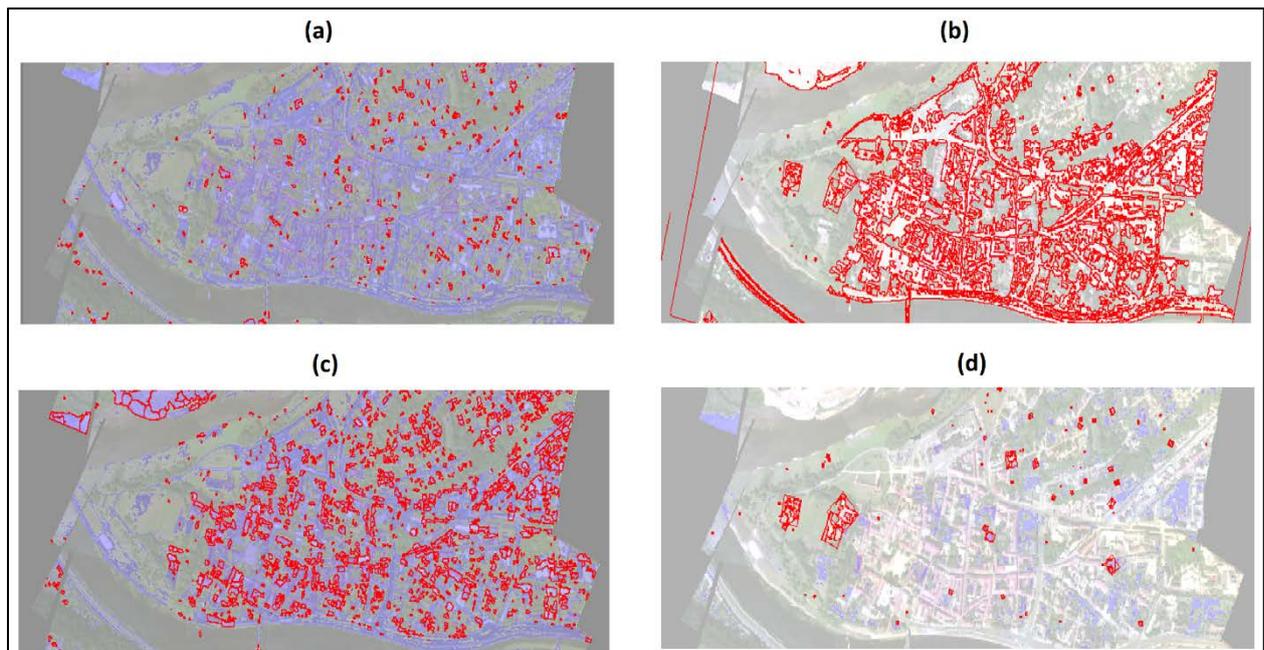


Figure 11 : détection de différentes structures urbaines sur la ville de Kaunas, en utilisant différents attributs morphologiques, CNRS ESPACE UMR7300, S. Gadal, M. Khelifa (2017).

2.7.2 Environnement

La Végétation

Les approches les plus courantes pour estimer les paramètres de végétation peuvent être soit explicites ou implicites. Les méthodes explicites sont fondées sur des approches physiques du signal impliquant le transfert radiatif ou des modèles de réflectance de canopée. En utilisant des lois physiques ces derniers permettent une description du transfert et des interactions à la surface du sol, la couronne et l'intérieur du houppier (Kimes et al.1998)¹⁰. Les méthodes explicites comme les approches statistiques ou empiriques tentent d'obtenir la relation entre les paramètres de végétation comme le LAI mesuré *in situ* et la feuille ou la réflectance du houppier ou encore des indices de végétation (NDVI par exemple) (Sims and Gamon 2002¹¹).

Pour une utilisation par les collectivités territoriales en planification ou en gestion, divers types de documents sont potentiellement utilisables : la densité de végétation par unités de surface, la détection des alignements ou encore l'identification de strates (arbres, buissons ou haies, parterres) ou d'espèces; figures 12, 13, 14 et 15). La localisation, le dimensionnement, l'extraction de caractéristiques de composition sont autant d'éléments de plus en plus importants pour améliorer les conditions de vie en milieu urbain. L'abattement de polluants atmosphériques particulaires, la filtration des eaux, l'aménagement de la connectivité des trames vertes sont des enjeux importants de la gestion et du développement des villes.

¹⁰Kimes, D., Nelson, R., Manry, M.& Fung, A. (1998). Attributes of neural networks for extracting continuous vegetation variables from optical and radar measurements. *International Journal of Remote Sensing*, 19(14), 2639–2663.

¹¹ Sims, D.& Gamon, J. (2002). Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sensing of Environment*, 81, 337–354.

L'imagerie hyperspectrale devrait également servir à l'étude de l'état des sols, le niveau de stress hydrique/des taux d'humidité, la détection des phénomènes d'îlot de chaleur (et de fraîcheur) ainsi que le suivi des éléments de la trame verte et bleue.

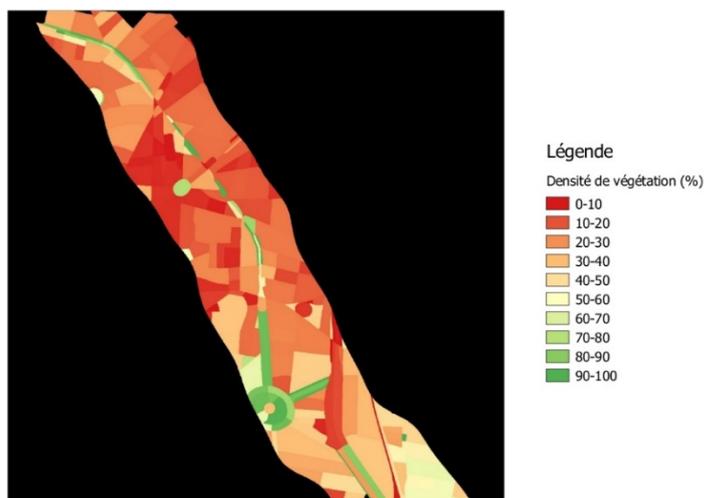


Figure 12 : Caractérisation de la densité de végétation par structure de bâti - ONERA

Couplé à la proximité des espaces de végétation, cette détermination de densité permet de qualifier les quartiers urbains.

Les informations collectées peuvent être différentes aussi selon le grain de résolution choisi pour représenter l'observable. La finalité du document ou du support numérique est donc essentiel pour délivrer un résultat adapté. La détermination des espèces ou des familles peuvent avoir des finalités différentes : détection d'une anomalie sanitaire ou gestion de la taille des arbres par exemple.

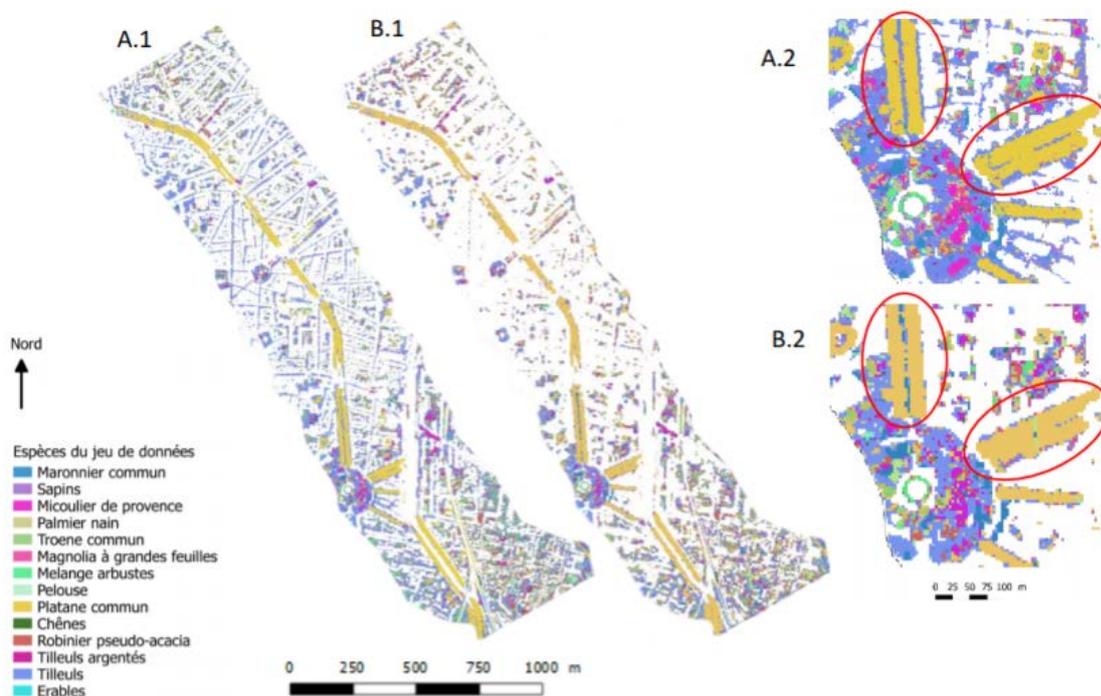


Figure 13 : Cartographie de la végétation à partir de la classification SVM généralisée sur les images réduites par MNF (méthode d'apprentissage en LOO) pour HySpex à 2m : A.1 & A.2 Zoom sur le Rond-point Boulingrin ; et Hypxim à 4m : B.1 & B.2. Masque de végétation réalisé à partir d'un indice NDVI LETG – 2017

Parmi les observables importants les alignements d'arbres sont tout aussi importants que les parcs ou les jardins dans la gestion des réseaux, de la biodiversité, de la lutte contre la pollution atmosphérique ou encore la détermination d'îlots de fraîcheur le long des voies. De plus d'un point de vue sanitaire il est nécessaire de les caractériser soigneusement car les alignements mono-espèces sont plus sensibles aux maladies que la variété arborée.

La détection des alignements et la détermination des espèces est à ce titre un observable intéressant pour les collectivités. Des travaux supplémentaires devraient permettre en utilisant des séries d'images d'identifier les cycles végétatifs mais aussi les anomalies potentiellement associées à des affections ou déficits.




Figure 14 : Détection des alignements d'arbres à Toulouse. IGARSS 2018 - ONERA

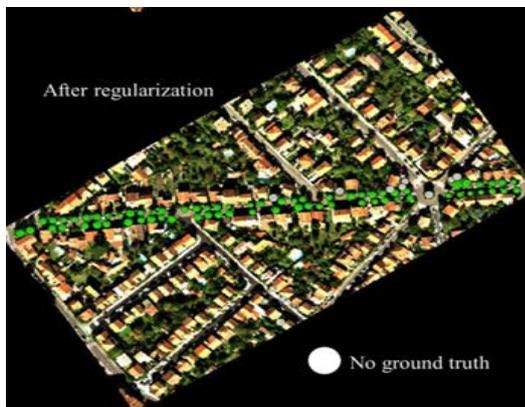


Figure 15 : Classification de l'espèce d'arbre d'alignement : *Platanus x hispanica* (100% des arbres sont détectés) - ONERA.

Différentes études ont été réalisées sur la végétation pour définir les caractéristiques optimales d'acquisition de telles représentations :

- Le domaine spectral [0.4 ; 0.9 μm] est essentiel pour discriminer les espèces néanmoins, l'extension du domaine jusqu'à 2.5 μm améliore les performances de discrimination. Ces conclusions ont été réalisées à partir d'un jeu d'images acquis en automne.
- Meilleure est la résolution spectrale, meilleures sont les performances de classification. Néanmoins une résolution spectrale de 10 nm n'affecte pas de façon significative ces performances.
- Différentes résolutions spatiales ont été étudiées : 2, 4 et 8 m. Les meilleures performances sont obtenues avec une résolution de 2 m. Bien que légèrement plus faible, la qualité de la classification sur des images de 4 m et 8 m sont similaires en partie due au fait que l'image à 8 m est moins sensible aux hétérogénéités locales.
- Des acquisitions Sentinel-2 effectuées sur la ville de Kaunas (Lituanie) à 3 périodes dans l'année ont montré que la période la plus favorable pour la classification des espèces est le printemps. Néanmoins, l'exploitation conjointe d'images acquises à différentes périodes de l'année n'a pas été évaluée (faute de données hyperspectrales disponibles) alors que la littérature montre que la fusion de données à haute résolution spectrale et temporelles améliore la discrimination des espèces.
- La fusion de données hyperspectrales avec des mesures Lidar 3D ou un SIG permet de mieux détecter la végétation haute et de prendre en compte le contexte (exemple les arbres d'alignement le long de route)
- La fusion de données hyperspectrales avec une image à plus haute résolution spatiale avec un nombre réduit de bandes spectrales améliore la classification.

Des règles de traitement en classification supervisée émergent également pour obtenir de telles cartes :

- La base de données doit être **représentative des espèces présentes tant en termes de nombre d'espèces que de nombres d'échantillons par espèce**. Différentes bases ont été testées correspondant à 3 échelles spatiales (feuille, canopée, image). L'échelle au niveau image donne les meilleures performances, mais il a également été montré que pour des arbres à fortes densités de feuilles, des performances de classification similaires sont obtenues avec les bases construites au niveau de la feuille ou de la canopée.
- Les méthodes de classification par approche pixel directement à partir de la réflectance spectrale sont peu performantes, il est préférable d'avoir une approche orientée-objet, ce qui est confirmé par les travaux existants dans la littérature. De plus, le **couplage des méthodes MNF et SVM** est le plus performant. Enfin, une approche de classification à partir de triplets d'indices de végétation spécifiques à chaque espèce est une voie nouvelle de classification à fort potentiel.

2.7.3 Développement durable

Les panneaux solaires

Les panneaux solaires sont des éléments particuliers du paysage urbain offrant des spectres spécifiques. A partir de spectres mesurés *in situ* et en laboratoire, il a été possible de les isoler et de valider les surfaces obtenues. Cette approche méthodologique mise au point durant l'ANR fournit une information intéressante pour les collectivités. En effet il est difficile de connaître non seulement le potentiel global des toits pour soutenir un plan d'installation d'appareils dans le cadre de la mise en place d'une stratégie énergétique à l'échelle des territoires, mais de plus le suivi de ces installations n'est pas toujours facile pour plusieurs raisons :

- La demande d'autorisation obligatoire n'est pas toujours déclarée auprès des services et n'est pas toujours suivie d'une mise en place. Si bien que les informations recueillies sont souvent lacunaires et difficiles à mettre à jour.
- De plus les données collectées par les fournisseurs d'énergie sont souvent difficiles à obtenir même pour les collectivités.

Une localisation et une quantification des installations sont donc des informations très intéressantes pour les communes même si le type de panneaux n'est pas observable. En effet un panneau solaire est un dispositif technologique à base de capteurs solaires thermiques ou photovoltaïques, destiné à convertir le rayonnement solaire en énergie thermique ou électrique.

Les **superficies** (m²) obtenues à partir des abondances estimées sont comparées à celles obtenue par digitalisation manuelle sur des ortho-images (0.1m) des mêmes zones (tableau 3) :

	Digitalisation manuelle	Méthode proposée HYEP	Méthode classique
Image 1	15	15.27	21.26
Image 2	12	13.06	1.10

Tableau 3 : validation manuelle des surfaces obtenues avec la méthode proposée.

Une validation sur plusieurs images devrait permettre d'estimer la robustesse de la méthode et confirmer l'intérêt de la détection des PV.

L'ANR a permis de développer une méthode qui permet d'obtenir une localisation et une estimation de *la surface concernée de manière satisfaisante (voir WP2 et WP3)*

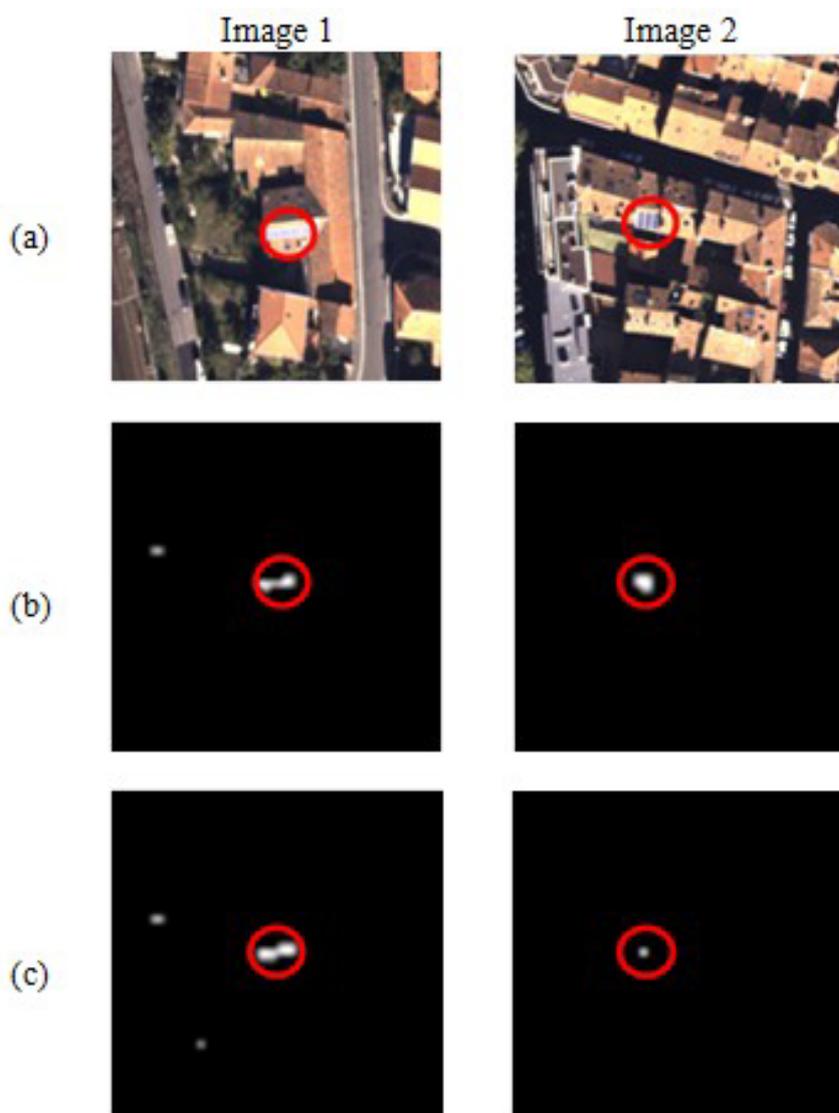


Figure 16 : Détection et quantification des surfaces de panneaux - IRAP

(a) Ortho-images. Abondances estimées des panneaux solaires : (b) Méthode proposée, (c) Méthode classique

2.5.7 Risques

L'Imperméabilisation

L'état de couverture des sols varie d'entièrement recouvert (réseau routier) à partiellement recouvert (parking drainant). Il est donc difficile de fournir une information de l'imperméabilisation des sols à partir du signal uniquement. La finalité des espaces peut être un ajout intéressant fournissant des renseignements supplémentaires à la caractérisation des surfaces.

Selon les matériaux utilisés cette information peut être intégrée dans des réflexions sur la stratégie énergétique territoriale par identification des îlots de fraîcheur ou de prévention des risques d'inondation ou de maintien ou développement de la qualité du milieu urbain.

L'imperméabilisation est en effet un élément perturbateur des cycles naturels d'évapotranspiration, les capacités d'émissivité des matériaux augmentant le réchauffement des basses couches l'air (voir annexe). Ce processus est essentiel dans la détermination des modèles microclimatiques urbains et d'écoulement de l'air en complémentarité des analyses d'émission de gaz à effet de serre (GES).

Cette identification des surfaces imperméabilisées entre aussi en résonance avec la gestion des risques dus à des pluies torrentielles ou des inondations, puisqu'elles empêchent plus ou moins les processus d'infiltration. De plus, elles dirigent les flux vers les exutoires et accentuent les vitesses d'écoulement.

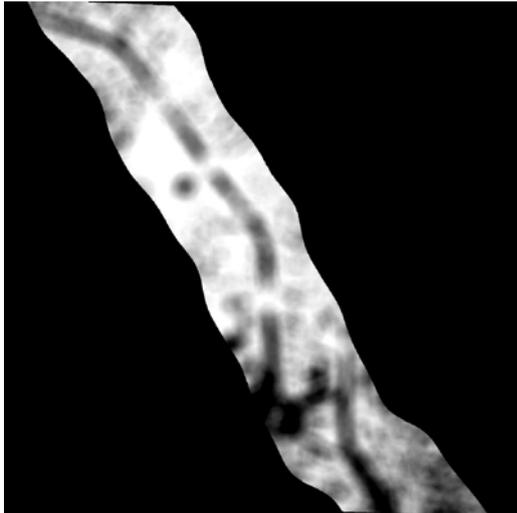


Figure 17 Intensité d'imperméabilisation selon les réflectances des matériaux – ONERA

La gradation de la valeur peut être un élément intéressant dans la détermination du degré d'imperméabilisation.

Cette mesure peut aussi être représentée en fonction d'un seuillage en % .

Les 2 types de représentation ne fournissent pas tout à fait la même information



Légende

Niveau d'imperméabilité (%)

- 0-10
- 10-20
- 20-30
- 30-40
- 40-50
- 50-60
- 60-70
- 70-80
- 80-90
- 90-100

Figure 18 Niveau d'imperméabilisation (% par zone)

L'imperméabilisation peut aussi se présenter en pourcentages selon des unités spatiales. ONERA

2.6 Discussion et Perspectives

Il était prévu de ne pas développer de méthodologies spécifiques, mais plutôt de les adapter aux images hyperspectrales. Cependant l'application des méthodes de démixage notamment sur les panneaux solaires a conduit à des développements ad hoc. De la même manière la nécessité de corriger les images des effets de l'atmosphère ou de diminuer le bruit par un traitement de MNF a conduit à développer des améliorations au fil des traitements.

2.6.1 Base de données spectrales (BDS)

Pour une bonne identification des types de sols, de toits ou d'espèces de végétation, une base de données représentative est nécessaire. Plusieurs contraintes pour une bonne constitution et utilisation de celle-ci ont été établies : être construite sur la ville analysée (ou pour le moins être constituée de matériaux similaires), disposer de types de matériau (vivants ou inertes) suffisamment représentatifs et avec un nombre d'échantillons suffisant pour que ce soit statistiquement cohérent. L'équilibrage des types de matériau doit être un objectif méthodologique dans la constitution de ces BDS. La compréhension de leur comportement au cours du temps est une perspective nécessaire pour un suivi temporel de leur évolution et une meilleure compréhension du comportement radiométrique urbain.

2.6.2 Résolutions spatiales et spectrales

Plusieurs points ont été abordés au cours de ce projet.

Tout d'abord, plus le domaine spectral est large meilleure étaient les performances de classification ; le domaine recommandé est [0.4-2.5 μm]. Ainsi à iso-résolution spatiale (2m), les performances de classification sont meilleures avec les instruments Sentinel-2 et HYPXIM qu'avec Pléiades. La richesse spectrale (nombre de bandes et résolution spectrale) sur un tel domaine peut améliorer les performances de classification.

De plus, compte tenu de la forte hétérogénéité à petite échelle du milieu urbain, une haute résolution spatiale est requise. **Le projet HYEP a pu montrer que les performances de classification étaient comparables entre Pléiades 2m et HYPXIM 8 m pour une classification des sols.** En revanche, une richesse spectrale fine est requise pour une meilleure discrimination des surfaces imperméables ou des espèces végétales. Les confusions étant différentes, il y a une réelle opportunité à fusionner des images à haute résolution spatiale mais à faible richesse spectrale avec des images à haute résolution spectrale mais avec une résolution spatiale moindre. Plusieurs travaux ont été développés dans ce sens montrant la difficulté méthodologique d'une telle fusion mais également démontrant le bénéfice que peut apporter une telle méthode de type Pansharpening.

La confusion entre certains types de matériaux peut être en partie levée par l'utilisation de l'élévation (Modèle Numérique d'Élévation) permettant de discriminer la hauteur du bâti et des arbres. Ceci diminue la confusion entre des toits de gravier et les réseaux routiers ou entre la végétation haute et basse.

2.6.3 Représentation

Comme l'ont illustré les paragraphes ci-dessus, la représentation est une question qu'il faut travailler avec les destinataires de l'information. Une information utilisable et utilisée est seule garante d'un usage qui s'inscrit dans les pratiques. Les choix d'échelle, de contenu, de support doivent être mieux définis avec les partenaires des différents services comme cela a été présenté dans le tableau 2. L'activité associée à ces échanges est de l'ordre de l'explicitation et d'accompagnement des personnes au sein des services ceci afin de favoriser un usage à long terme de ce type de ressource.

2.6.4 Perspectives

Les résultats obtenus ouvrent plusieurs perspectives pour l'amélioration de tels résultats :

- Evaluer l'apport d'acquisitions multitemporelles hyperspectrales ;;
- Evaluer l'apport de la fusion d'images hyperspectrales et panchromatiques ;
- Construire une base de données représentative et équilibrées des observables présents (vivants et inertes), en tenant compte de leur variabilité temporelle ;
- Utiliser ces résultats pour la production de résultats de plus haut niveau : carte de biodiversité, carte de densité de feuilles pouvant afin de mieux évaluer la qualité de l'environnement urbain au travers de ces observables : les îlots de fraîcheur, carte de stress hydrique et de propagation de maladie... mais aussi carte de ruissellement, cartes de coûts d'entretien, parcours de déambulation en cas d'alerte canicule etc...

Références bibliographiques

Sébastien Gadal. Identification des formes spatiales de métropolisation par télédétection. Exemple de l'axe Rabat-Casablanca au Maroc. Géographie Théorique et Quantitative. Université de Provence (Aix-Marseille 1), 2001.

Sébastien Gadal. Métropolisations, Territoires émergents et Systèmes géographiques d'information et de modélisation territoriale. Géographie. Université Paris Diderot Paris 7; Institut d'études doctorales, 2011.

Sébastien Gadal, Walid Ouerghemmi. Morpho-Spectral Recognition of Dense Urban Objects by Hyperspectral Imagery. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Copernicus GmbH (Copernicus Publications), 2015, XL-3/W3, pp.433-438. <<http://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XL-3-W3/433/2015/isprsarchives-XL-3-W3-433-2015.pdf>>

Sébastien Gadal, Walid Ouerghemmi. Morpho-spectral objects classification by hyperspectral airborne imagery. University of California Los Angeles. 8th Workshop in Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, Aug 2016, Los Angeles, United States. pp. 349-353, 2016.

Walid Ouerghemmi, Sébastien Gadal, Gintautas Mozgeris, Donatas Jonikavičius, Christiane Weber. Urban objects classification by spectral library: feasibility and applications. JURSE 2017, Mar 2017, Dubai, United Arab Emirates. 2017.

Annexes

Extrait de « Lignes directrices concernant les meilleures pratiques pour limiter, atténuer ou compenser l'imperméabilisation des sols » EC EU ISBN 978-92-79-26214-2 doi: 10.2779/79012

Imperméabilisation et surfaces observables

L'imperméabilisation des sols ayant une forte capacité de rétention de l'eau entraîne une diminution significative de l'évapotranspiration, et donc la perte de l'effet de refroidissement naturel par absorption d'une partie de la chaleur de l'air, de sorte que la température continue d'augmenter dans nos villes.

A partir de cette figure il est aisé de voir les liens existants entre l'imperméabilisation due à l'artificialisation et la végétation. L'évapotranspiration et le ruissellement sont deux mesures clés dans réchauffement des villes, la gestion de la ressource, du ruissellement et des risques.

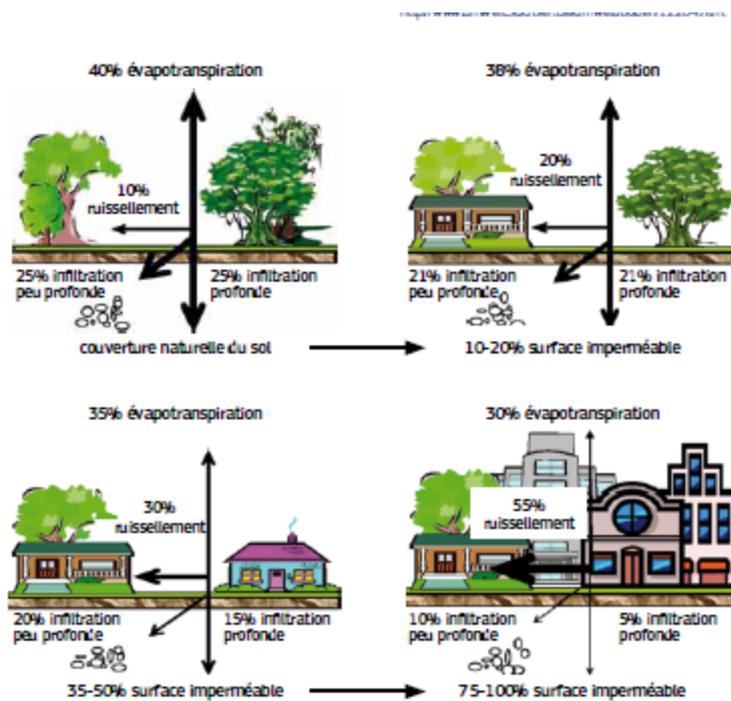


Illustration de l'influence de l'occupation des sols sur le cycle hydrologique

(source <http://www.coastal.ca.gov/nps/watercyclefacts.pdf>)

