

# COUPLAGE DE DONNÉES GÉOGRAPHIQUES PARTICIPATIVES ET D'IMAGES AÉRIENNES PAR APPRENTISSAGE PROFOND

Nicolas Audebert<sup>1,2</sup>, Bertrand Le Saux<sup>1</sup>, Sébastien Lefèvre<sup>2</sup>

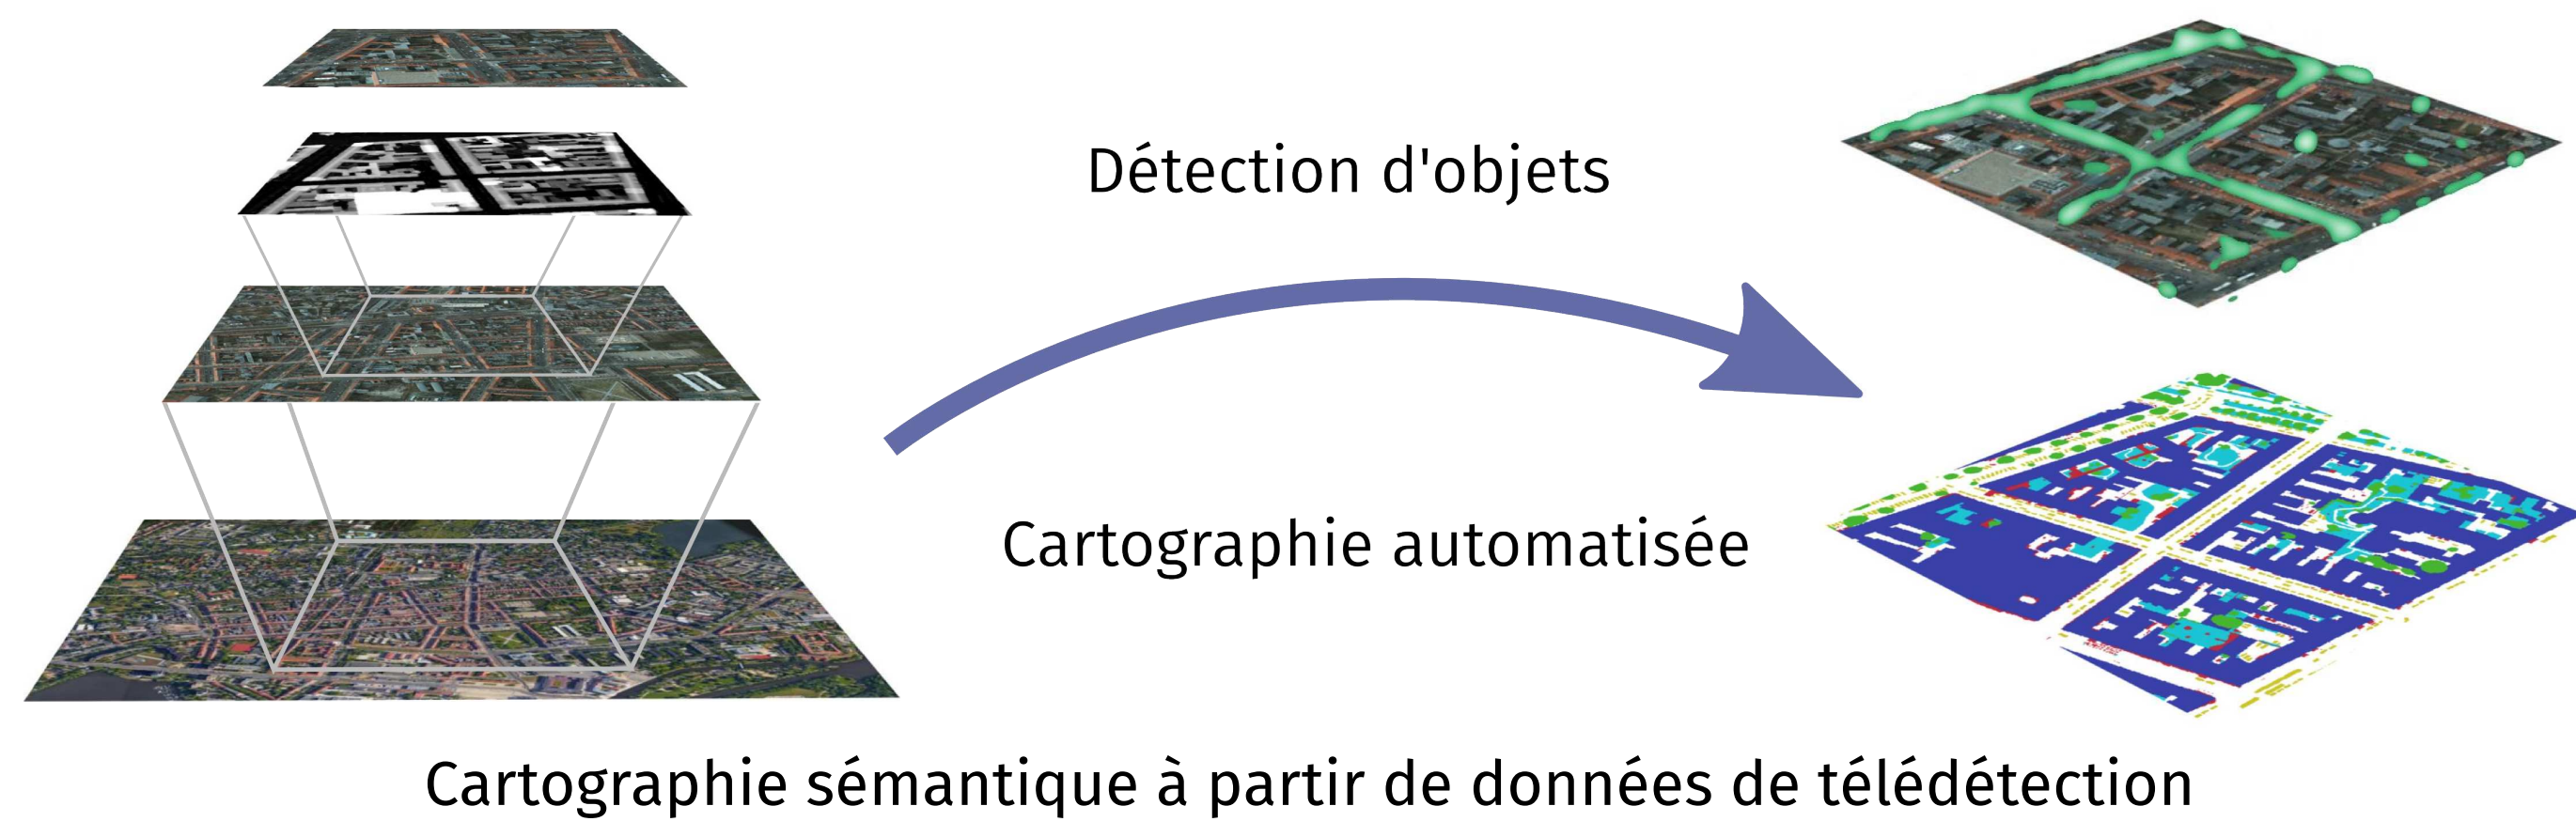
ONERA - The French Aerospace Lab<sup>1</sup>, Univ. Bretagne-Sud - IRISA<sup>2</sup>

ONERA

THE FRENCH AEROSPACE LAB

UMR IRISA

## Cartographie sémantique automatisée



Des données d'observation de la Terre pour :

- ▶ Cartographie urbaine locale : bâtiments, routes, végétation...
- ▶ Cartographie macro : zones d'eau, terrains agricoles, aires urbaines...
- ▶ Détection d'objets : véhicules, végétation anormale...

Apprentissage automatisé :

- ▶ Sur des données aériennes/satellites optiques
- ▶ En utilisant les réseaux de neurones profonds (deep learning)
- ▶ Exploitant des données hétérogènes et l'information *a priori*

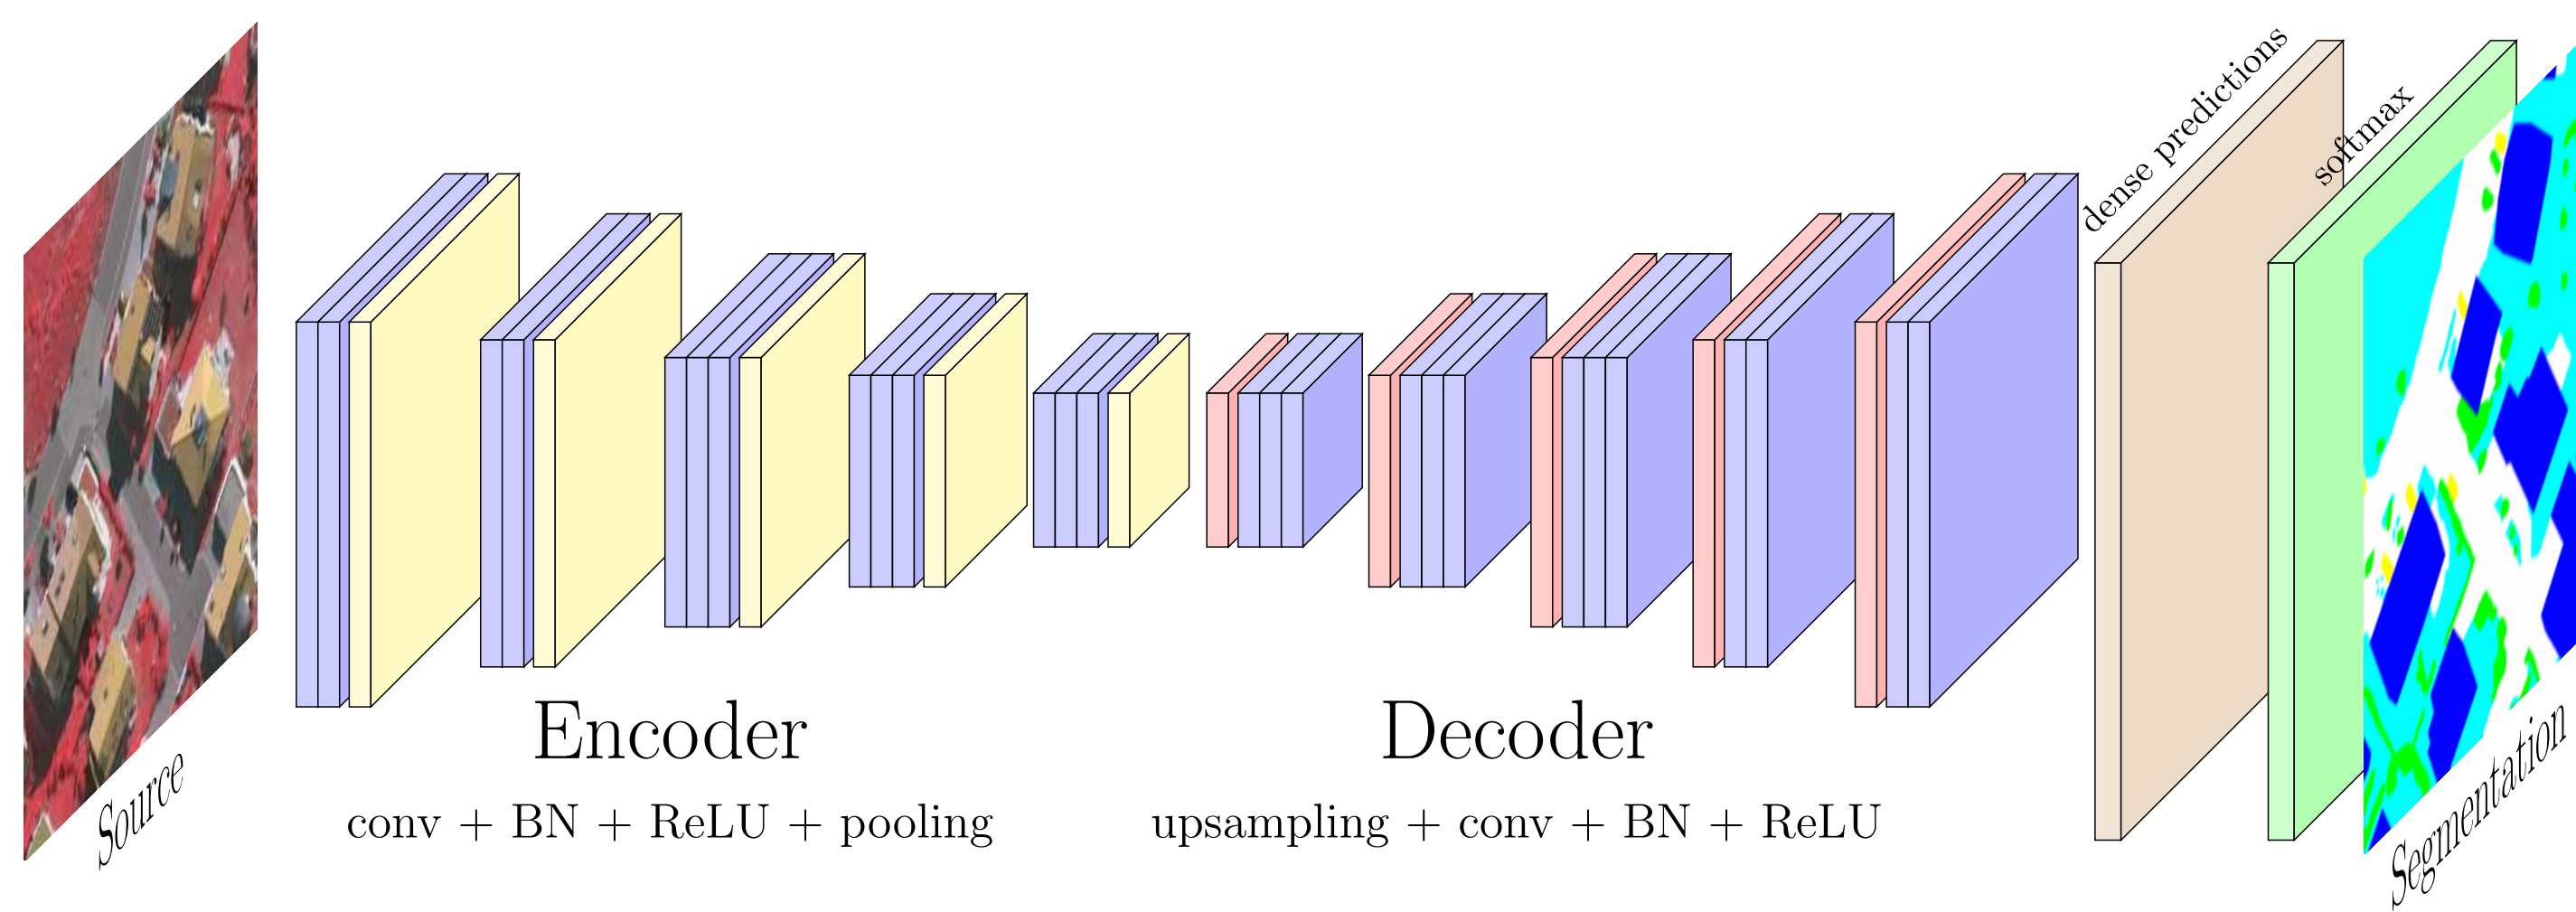
## Deep learning

Convolutional Neural Networks (CNN) :

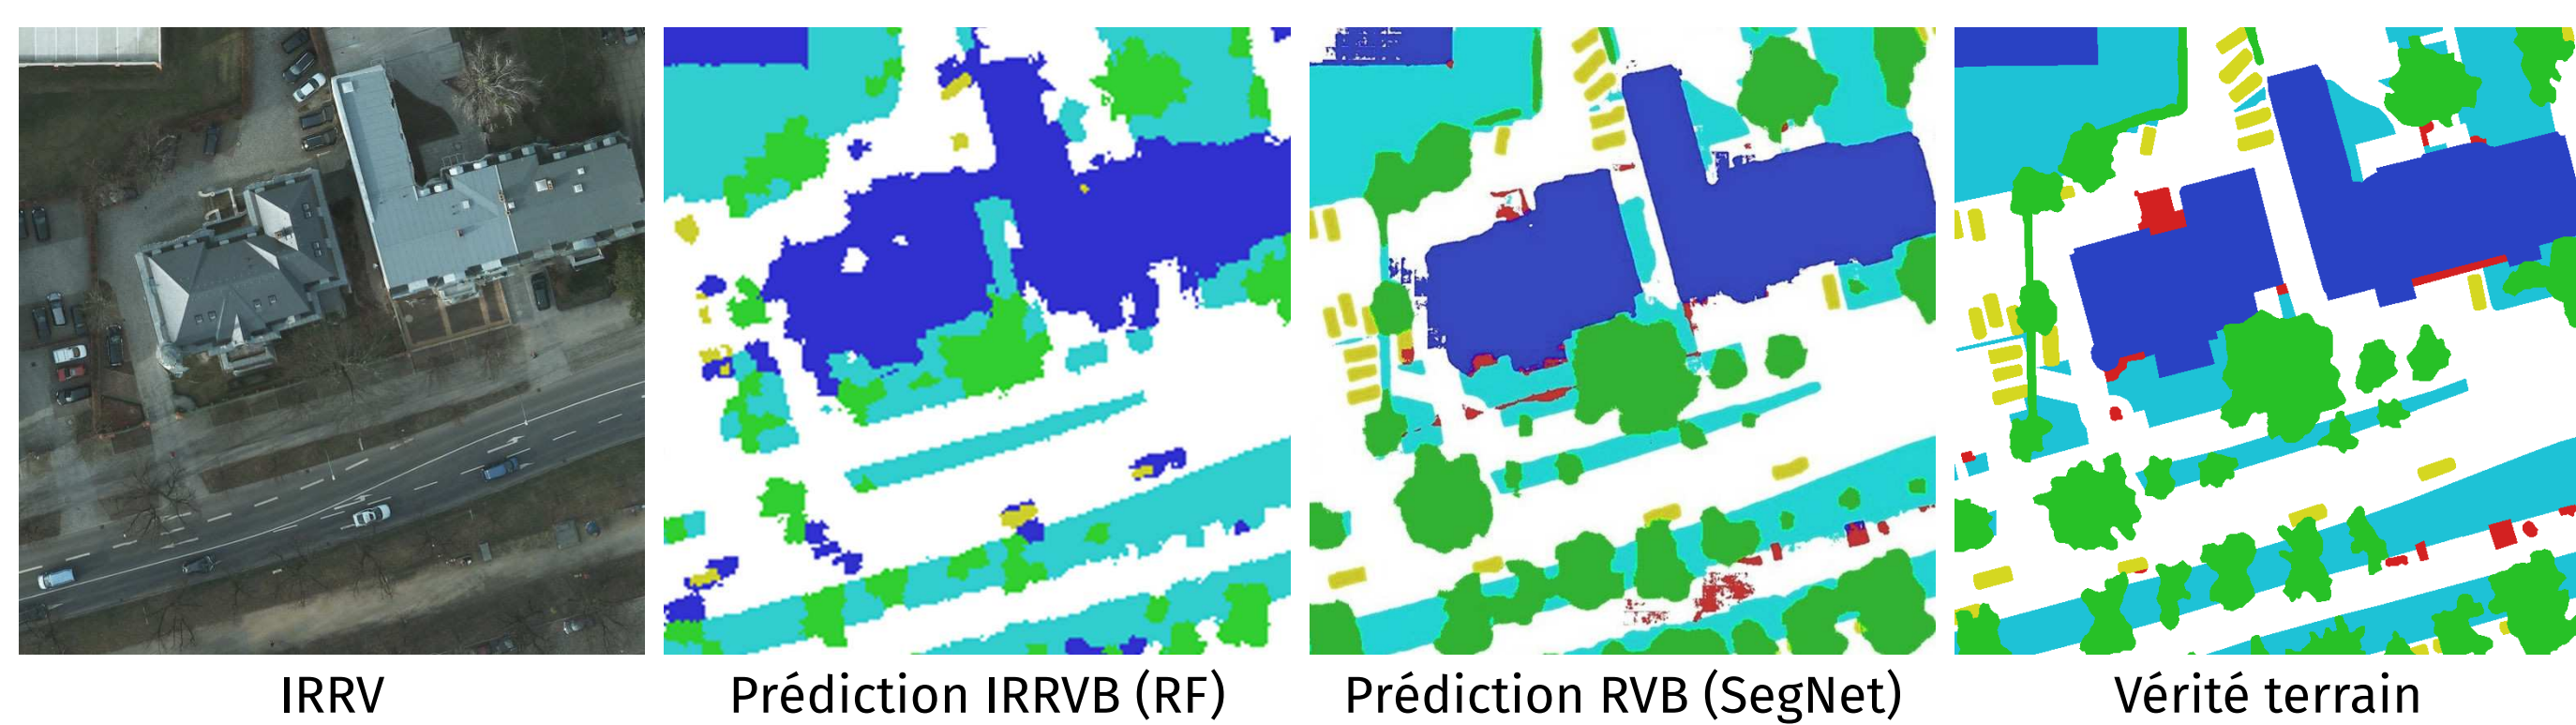
- ▶ État-de-l'art en vision par ordinateur (segmentation sémantique, détection d'objet, reconnaissance faciale...)
- ▶ Succession de convolutions et de fonctions de transfert non linéaires inspirées des neurones biologiques
- ▶ Optimisation des noyaux de convolution par entraînement sur une banque d'images d'apprentissage
- ▶ Excellents résultats en télédétection pour la cartographie de routes [1]

### Fully Convolutional Networks pour la cartographie

- ▶ Conservent la structure 2D de l'image
- ▶ Infèrent une classe d'appartenance pour chaque pixel
- ▶ Capturent les relations de dépendance spatiales




Architecture SegNet, conçue pour la vision embarquée en conduite autonome [2]



Exemple de carte prédite sur le jeu de données ISPRS Potsdam.

## Représentation des données OpenStreetMap



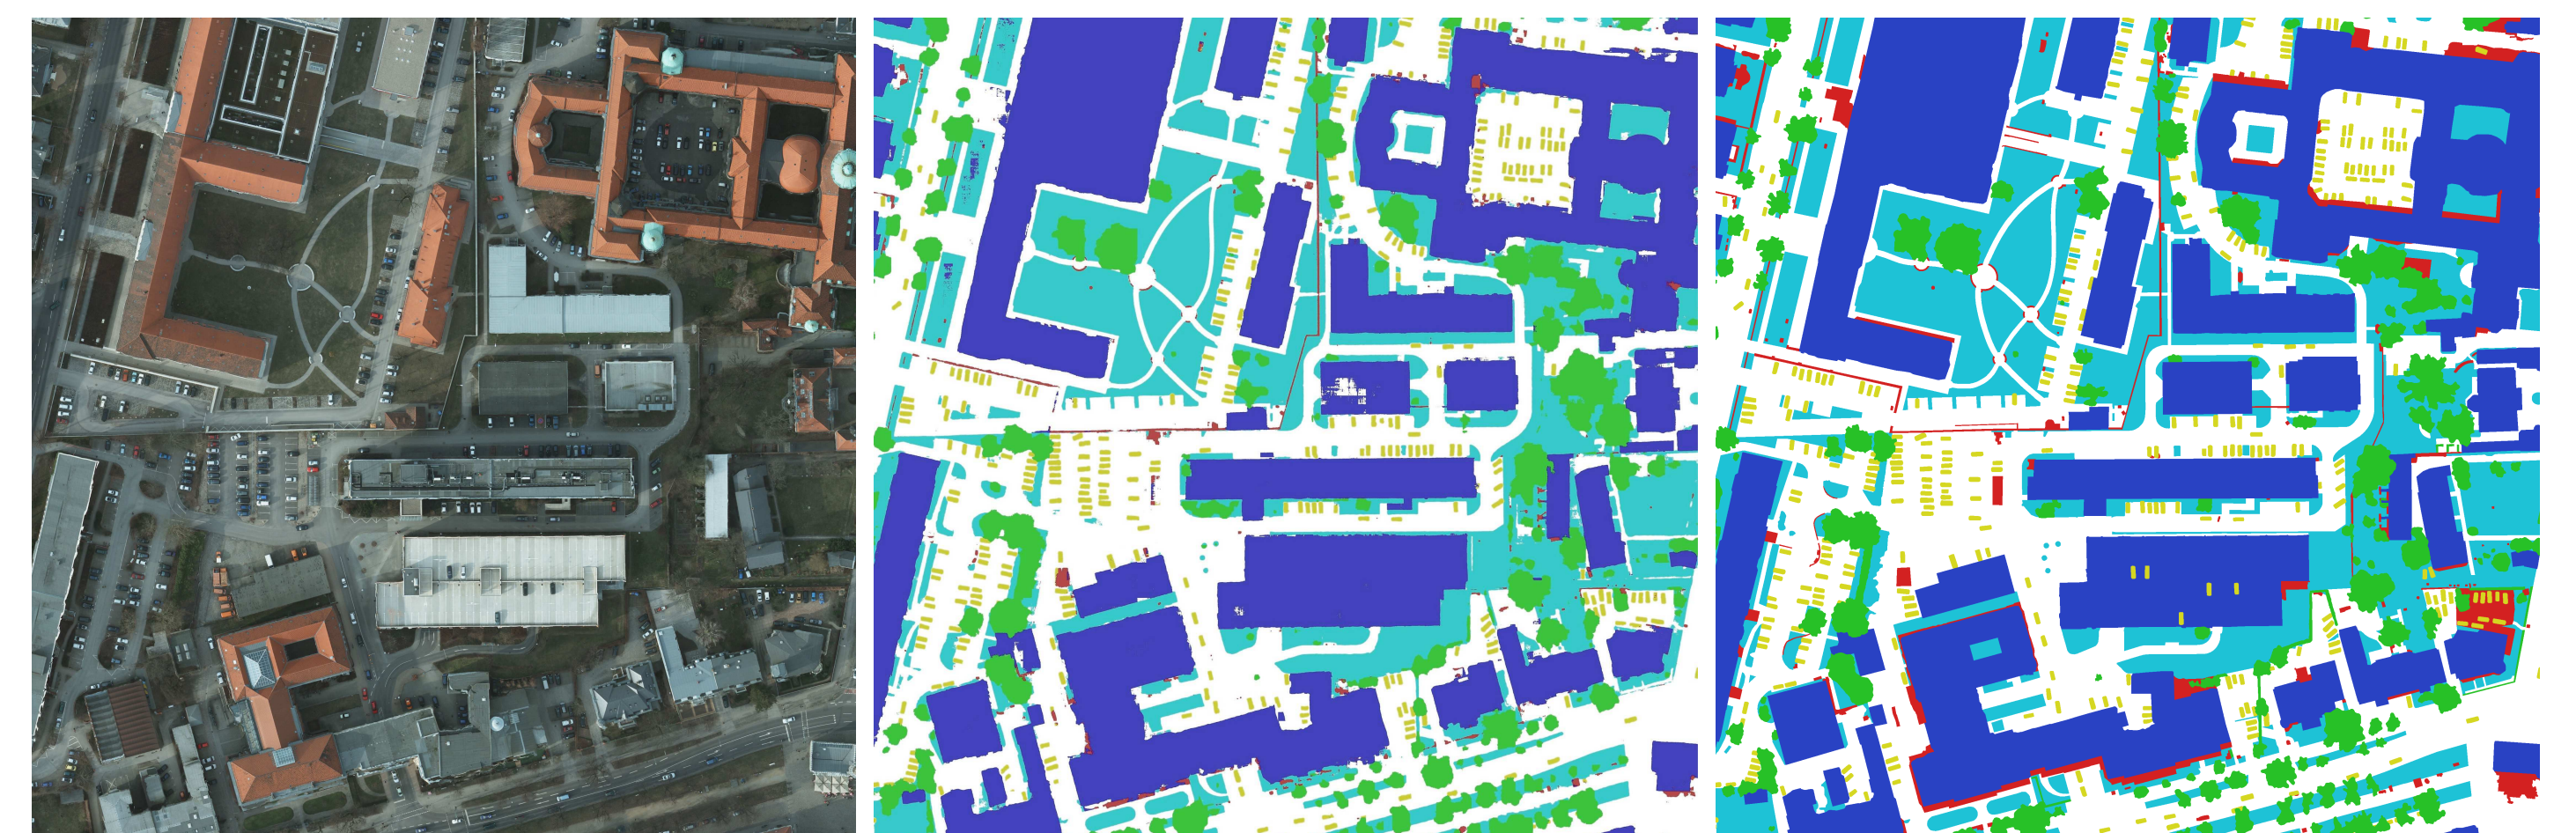
Chaque couche d'information géographique peut être considérée comme une carte binaire parcimonieuse, mais aussi comme une carte de distance dense. En pratique, la carte binaire suffit car les réseaux convolutifs généreront automatiquement des cartes d'activation denses.

## Résultats de cartographie

Comparaison sur les images aériennes ISPRS Potsdam

Méthode	Routes	Bâtiments	Vég. basse	Arbres	Véhicules	Global
RF IRRVB	77,0 %	79,7 %	73,1 %	59,4 %	58,8 %	74,2 %
SegNet RVB	93,0 %	92,9 %	85,0 %	85,1 %	95,1 %	89,7 %
RF IRRVB+OSM	85,6 %	92,4 %	73,8 %	59,5 %	67,6 %	80,9 %
CR RVB+OSM	93,9 %	92,8 %	85,1 %	<b>85,2 %</b>	95,8 %	90,6 %
FuseNet	<b>95,3 %</b>	<b>95,9 %</b>	<b>86,3 %</b>	85,1 %	<b>96,8 %</b>	<b>92,3 %</b>


→ le gain est le plus significatif sur les classes identifiées dans OSM (bâtiments et routes), mais les autres classes bénéficient également de la levée de certaines ambiguïtés (végétation et véhicules)



(blanc : routes, bleu : bâtiments, cyan : végétation basse, vert : arbres, jaune : voitures)

## Fusion de données optiques et géographiques

Des données hétérogènes peuvent être traitées en parallèle puis fusionnées pour améliorer la cartographie [3], [4]. L'architecture FuseNet [5] est ici utilisée pour apprendre conjointement à partir des images RVB et des données OSM.



## Conclusion

- ▶ Le deep learning permet l'apprentissage de modèles pour la cartographie de larges zones à de multiples niveaux de granularité.
- ▶ La fusion de données permet d'intégrer de l'information *a priori* structurée comme celle venant d'OpenStreetMap.
- ▶ Code source et modèles pré-entraînés :



<https://github.com/nshaud/DeepNetsForEO>

## Références

- [1] V. MNIH et G. E. HINTON, "Learning to Detect Roads in High-Resolution Aerial Images", in *Computer Vision – ECCV 2010*, sér. Lecture Notes in Computer Science 6316, Springer Berlin Heidelberg, sept. 2010, p. 210–223.
- [2] V. BADRINARAYANAN, A. KENDALL et R. CIPOLLA, "SegNet : A Deep Convolutional Encoder-Decoder Architecture for Scene Segmentation", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, t. PP, n° 99, p. 1–1, 2017.
- [3] N. AUDEBERT, B. LE SAUX et S. LEFÈVRE, "Semantic Segmentation of Earth Observation Data Using Multimodal and Multi-scale Deep Networks", in *Computer Vision – ACCV 2016*, Springer, Cham, nov. 2016, p. 180–196.
- [4] N. AUDEBERT, B. LE SAUX et S. LEFÈVRE, "Fusion of heterogeneous data in convolutional networks for urban semantic labeling", in *2017 Joint Urban Remote Sensing Event (JURSE)*, mar. 2017, p. 1–4.
- [5] C. HAZIRBAS, L. MA, C. DOMOKOS et D. CREMERS, "FuseNet : Incorporating Depth into Semantic Segmentation via Fusion-Based CNN Architecture", in *Computer Vision – ACCV 2016*, Springer, Cham, nov. 2016, p. 213–228.



Les travaux de Nicolas Audebert sont financés par le projet de recherche NAOMI, une collaboration entre l'ONERA et Total. Les auteurs remercient l'Agence Nationale de la Recherche (ANR) pour leur support du projet Astérix (ANR-13-JS02-0005-01).