K-NN crédibiliste pour la reconnaissance automatique des espèces d'arbres

Siwar Jendoubi, Didier Coquin, Reda Boukezzoula

▶ **To cite this version:**

Siwar Jendoubi, Didier Coquin, Reda Boukezzoula. K-NN crédibiliste pour la reconnaissance automatique des espèces d'arbres. LFA 2018 - Rencontres francophones sur la Logique Floue et ses Applications, Nov 2018, Arras, France. hal-01867783v2

HAL Id: hal-01867783
https://hal.science/hal-01867783v2

Submitted on 12 Dec 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.

K-NN crédibiliste pour la reconnaissance automatique des espèces d'arbres

Siwar Jendoubi[1,2] Didier Coquin[1] Reda Boukezzoula[1]

[1] LISTIC, Université Savoie Mont Blanc, BP 80439, Annecy-le-Vieux, 74944 Annecy Cedex, France
[2] LARODEC, Université de Tunis, ISG Tunis, 2000 Le Bardo, Tunis, Tunisie
{siwar.jendoubi, didier.coquin, reda.boukezzoula}@univ-smb.fr

Résumé :
La reconnaissance des espèces d'arbres est un problème d'identification des espèces d'arbres à partir des photos de feuilles et d'écorces. Dans cet article, nous proposons une règle de combinaison pour les *k*-plus proches voisins crédibilistes (Ek-NN). Cette règle est adaptée aux problèmes de classification pour lequel nous avons un grand nombre de classes avec une variabilité intra-classe et une similarité entre classes importantes. Enfin, nous comparons la performance de la solution proposée aux solutions existantes.
Mots-clés :
Reconnaissance des espèces d'arbres, théorie des fonctions de croyance, k-Plus Proches Voisins Crédibilistes.

Abstract:
The tree species recognition is the problem of identifying tree species from their photos of leaves and barks. In this paper, we introduce a combination rule for the evidential *k*-nearest neighbor (Ek-NN) classifier. The proposed rule is suitable for classification problems where we have many classes with intra-class variability and inter-class similarity. Finally, we compare the performance of the proposed solution to the existing solutions.
Keywords:
Tree species recognition, Theory of belief functions, Evidential *k*-Nearest Neighbor.

1 Introduction

La reconnaissance de l'espèce d'un arbre à partir de l'une de ses feuilles ou de l'écorce est une tâche accessible pour la plupart des botanistes, mais reste encore délicate pour un amateur même équipé d'ouvrages spécialisés comme *la Flore* [4]. L'objectif de ce travail[1] est de développer une application éducative embarquée sur un smartphone qui permette d'identifier l'espèce d'un arbre à partir des deux modalités que sont la feuille et l'écorce. Une telle application serait utile pour les novices en botanique et pour ceux qui souhaitent parfaire leurs connaissances sur les espèces d'arbres.

Au cours de ces dernières années, quelques travaux de recherche ont été menés pour automatiser cette tâche en proposant des applications fonctionnant sur smartphones comme LeafSnap [10], Pl@ntNet [8] et Folia [7]. L'automatisation de la reconnaissance des espèces d'arbres n'est pas une tâche simple car dans la nature il y a une grande variété d'espèces et le territoire français compte environ 126 espèces natives. Les difficultés de la reconnaissance des arbres à partir de leurs feuilles et écorces sont liées à de très fortes similarités inter-espèces et de fortes disparités pour une même espèce, comme en témoigne la Figure 1. La forme globale des feuilles (a) et (b) sont différentes alors qu'elles appartiennent à la même espèce (le houx). La forme globale des feuilles (b) et (c) sont très similaires, alors qu'elles appartiennent à deux espèces différentes (houx pour (b) et chêne pour (c)).

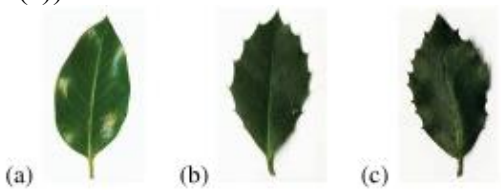

Figure 1 – La variabilité intra-espèces et la similarité inter-espèces.

Dans ce travail, nous considérons le problème de la reconnaissance des espèces d'arbres à partir des photos des feuilles et des écorces

[1] Ce travail est financé par l'agence nationale de la recherche sous la référence ANR-15-CE38-0004 (ReVeRIES project)

prises par le smartphone de l'utilisateur. L'objectif principal est de lui apprendre à reconnaitre les espèces d'arbres à partir des caractéristiques liées à la feuille et à l'écorce. Pour lever le doute lors de la prise de décision, de nombreuses théories peuvent être utilisées comme les probabilités imprécises [5], la théorie des fonctions de croyances [14], la théorie des possibilités [17], *etc*. Les travaux de Ben Ameur ont montré que la théorie des fonctions de croyances permettait d'améliorer les résultats de bonne classification en combinant les sorties des classifieurs basés sur les forêts aléatoires [1]. Les forêts aléatoires demandent un temps de traitement que nous souhaitons réduire pour que l'application puisse fonctionner sur un smartphone. Dans ce papier nous allons nous orienter vers les k plus proches voisins crédibilistes (Ek-NN) qui ont ont montré leur performance dans de nombreux problèmes de classification. Cependant, lorsque le nombre de classes est important, cette performance peut diminuer. De plus, le problème devient délicat à traiter quand on a une variabilité intra-classe et une similarité inter-classe comme le montre l'exemple de la Figure 1, d'où un conflit important lors de la prise de décision.

Les principales contributions de cet article sont les suivantes : d'abord, nous avons modifié la règle de combinaison pour le Ek-NN pour l'adapter au problème de la classification des espèces d'arbres. La solution proposée permet de réduire le conflit entre les espèces. Pour ce faire, nous proposons d'utiliser une version modifiée de la règle de combinaison introduite par Zhou *et al.* [18]. Dans un deuxième temps, nous comparons notre approche aux méthodes existantes permettant d'évaluer la performance de la méthode proposée.

Cet article est organisé de la façon suivante : la section 2 présente un bref état de l'art sur la reconnaissance des espèces d'arbres. La section 3 introduit le k-NN crédibiliste et la solution que nous proposons pour résoudre le problème de la variabilité intra-espèces et de la similarité inter-espèces. Dans la section 4 nous étudions la performance de la méthode proposée sur un ensemble d'expérimentations.

2 La reconnaissance des espèces d'arbres

Dans ce travail, nous nous sommes intéressés à la reconnaissance des espèces d'arbres à partir des photos de feuilles et d'écorces. Dans la littérature, quelques solutions ont été proposées pour la reconnaissance automatique des espèces d'arbre [8][2][1][9].

La plupart des travaux existants cherchent à identifier l'espèce de l'arbre en utilisant des attributs extraits des feuilles. Harrison *et al*. [9] ont utilisé les longueurs d'onde dans l'infrarouge pour extraire des paramètres à partir des feuilles de vingt-six espèces. Ces attributs ont été utilisés comme entrées d'un classifieur de type forêt aléatoire. Les auteurs ont réussi à atteindre un taux de reconnaissance de 90%. Mzoughi *et al*. [12] ont utilisé un vocabulaire spécifique au domaine des botanistes pour la reconnaissance des feuilles. En effet, ils ont représenté chaque feuille avec un ensemble de concepts décrivant l'architecture de la feuille, par exemple une feuille peut être simplement lobée, non lobée ou composée. Après l'identification des caractéristiques de chaque espèce, ils ont utilisé un k-NN pour la classification. Ils ont testé cette approche sur le jeu de données du challenge ImageCLEF 2011 qui contient 70 espèces. Finalement, ils ont réussi à obtenir un taux de reconnaissance proche de 70% pour certaines caractéristiques.

Rares sont les travaux qui cherchent à reconnaitre les espèces d'arbre à partir des photos d'écorces. Nous trouvons par exemple le travail de Othmani *et al.* [13] qui permet d'identifier l'arbre à partir de son écorce. Ils ont utilisé une technique de balayage laser terrestre pour extraire une description 3D de la texture de l'écorce. Par la suite, ils ont appliqué un classificateur de type forêt aléatoire. Ils ont testé leur approche sur un jeu de données contenant des exemplaires provenant de cinq espèces. Ils ont réussi à avoir un taux de reconnaissance de 98%. Lee *et al.* [11] ont introduit un système de reconnaissance des plantes basé sur les réseaux de neurones convolutifs et récur-rents. De plus

leur système peut prendre en considération plusieurs organes de la plante. Toutefois leur solution ne peut pas faire l'objet d'une application ayant un objectif éducatif puisqu'il est difficile d'expliquer les résultats issus des diffé-rentes couches du réseau.

Quelques applications embarquées sur smartphones sont désormais disponibles comme Pl@ntNet et Folia. Pl@ntNet [8] est une application puissante qui donne de bons taux de reconnaissance. Cependant, elle fournit les résultats sans aucune explication, et nécessite une connexion à internet pour envoyer la requête à un serveur. Citons également Folia [2], une application qui imite le processus suivi par les botanistes pour décrire une feuille et permettant d'identifier l'espèce recherchée. Cette méthode exploite les caractéristiques de la feuille à partir d'un nombre limité d'attributs extraits des photos de feuilles. Ces caractéristiques sont utilisées comme entrées d'un classifieur (k-NN) de la feuille. L'avantage de cette application réside dans sa manière d'expliquer les résultats à l'utilisateur comme le ferait un botaniste.

Ben Ameur *et. al.* [1] ont proposé une solution basée sur un modèle qui reconnait les arbres à partir des feuilles et des écorces. La méthode utilise des forêts aléatoires comme classifieurs à partir des attributs extraits des feuilles et des écorces. Dans ce cadre, les sorties des classifieurs sont transformées en une distribution de masse consonante en utilisant l'opérateur introduit dans [16]. Puis une combinaison des masses consonantes (de la feuille et de l'écorce) est réalisée d'une manière hiérarchique afin d'obtenir une distribution de masse, qui est utilisée pour reconnaitre l'espèce de l'arbre. Dans cet article, notre objectif est de proposer une solution qui évite l'étape de classification basée sur les forêts aléatoires, qui est relativement gourmande en temps de calculs.

3 K-NN crédibiliste pour la reconnaissance des espèces d'arbres

Pour reconnaître les espèces d'arbres à partir des feuilles et des écorces, nous suivons la stratégie des botanistes. En effet, ils identifient les différentes caractéristiques morphologiques des feuilles (forme globale, contour, base et sommet) et des écorces (couleur, texture, etc.). Par la suite, nous extrayons de chaque caractéristique un vecteur d'attributs. A partir de chaque photo de feuille, trois vecteurs sont extraits. Le premier caractérise le sommet et la base de la feuille (*9 attributs*), le second représente le contour (*13 attributs*) et le dernier caractérise la forme globale (*9 attributs*). A partir de chaque photo d'écorce, quatre vecteurs attributs sont extraits. Ces derniers caractérisent respectivement : i) la couleur extraite de la teinte H (*256 attributs*) de l'espace HSV, ii) la texture par les ondelettes de Gabor (*3 attributs)*, iii) & iv) le type d'écorce à partir des structures verticales (*70 attributs*) et horizontales (*50 attributs*) respectivement. Chaque caractéristique est considérée comme une source d'information indépendante.

Nous définissons un système de classification tel que décrit dans la Figure 2. Ensuite, pour classifier une nouvelle photo feuille / écorce, nous extrayons les mêmes caractéristiques présentées ci-dessus. Puis, nous appliquons un k-NN crédibiliste (Ek-NN) sur chaque caractéristique comme présenté dans la Figure 2. La sortie de chaque Ek-NN est une distribution de masse (BBA) définie sur l'ensemble de toutes les espèces possibles. Ensuite, nous combinons les BBA obtenues à partir des caractéristiques pour prendre une décision en fonction de la feuille, d'une écorce et d'un couple (feuille, écorce). Le choix de l'architecture présentée dans la Figure 2 est justifié par l'aspect éducatif de l'application cible. En effet, l'identification de l'espèce à partir de chaque caractéristique séparé-ment permet d'expliquer à l'utilisateur final les résultats qu'il obtient.

3.1 K-NN crédibiliste

Soit $\Omega = \{c_1, c_2, ..., c_n\}$ l'ensemble de toutes les classes possibles. Dans son fonction-nement, l'Ek-NN [6] reste semblable au k-NN probabiliste. En effet, pour estimer la sortie associée à une nouvelle entrée *x* non étiquetée,

la méthode consiste à prendre en compte les k échantillons d'apprentissage dont l'entrée est la plus proche de la nouvelle entrée x, selon une distance. A ce stade, le k-NN probabiliste choisit la classe de x selon le principe du vote majoritaire. L'Ek-NN estime une distribution de masse, m_i^{Ω}, pour chaque plus proche voisin, i, en utilisant sa distance à x comme suit :

$$\begin{aligned} m_i^{\Omega}(c_i) &= \alpha_0 e^{-\gamma_i d_i^{\beta}} \\ m_i^{\Omega}(\Omega) &= 1 - m_i^{\Omega}(c_i) \end{aligned} \qquad (1)$$

telle que $i = 1, \ldots, k$, c_i est la classe du voisin i, d_i est la distance entre x et i, $\alpha_0 \in [0,1]$, $\gamma_i > 0$ et $\beta \in [0,1]$. L'Ek-NN combine alors les masses résultantes afin d'obtenir une distribution de masse permettant de prendre une décision. Cette combinaison est réalisée en utilisant la règle de Dempster [5] :

$$m^{\Omega} = \bigoplus_{i}^{k} m_i^{\Omega} \qquad (2)$$

Finalement, la décision est prise en utilisant le maximum de la probabilité pignistique.

La similitude entre les espèces et la variabilité au sein de la même espèce complique la tâche de reconnaissance. Ces deux faits génèrent un conflit important entre les espèces.

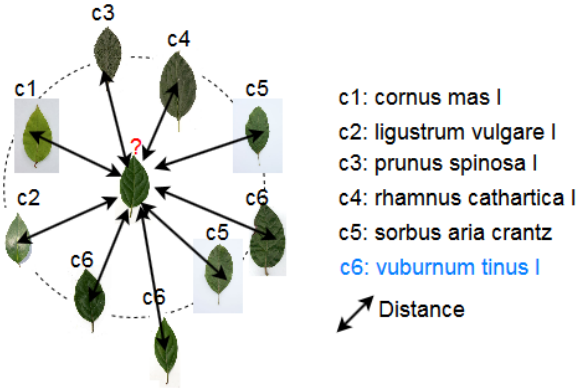

Figure 3 – Effets des similitudes inter-espèces et de la variabilité intra-espèces.

Afin d'illustrer ces propos, considérons l'exemple de la Figure 3 pour lequel nous avons la feuille centrale à identifier. L'Ek-NN sélectionne les k voisins les plus similaires à la feuille donnée. Dans la Figure 3, nous avons plusieurs feuilles qui ressemblent à la feuille inconnue. Par conséquent, si nous prenons une petite valeur de k ($k = 3$ par exemple), la vraie classe (c_6 dans ce cas) n'apparaîtra pas dans l'ensemble des voisins sélectionnés (c_1, c_4, c_5). Donc, pour augmenter la probabilité pour que la vraie classe apparaisse, il faut choisir un k plus grand. Dans nos expérimentations, nous avons fixé k à 20.

Après la sélection de l'ensemble des voisins, l'Ek-NN estime une BBA à support simple (c'est-à-dire une BBA avec deux éléments focaux dont l'un est l'univers Ω) pour chaque voisin sélectionné. Nous remarquons sur l'exemple de la Figure 3 que les feuilles sélectionnées sont très similaires à la feuille inconnue. Par conséquent, les distances entre la feuille inconnue et ses voisins les plus proches sont petites et presque égales, ce qui a un impact sur les BBA estimées. En effet, nous obtenons des BBA avec une grande valeur de masse sur la classe du voisin (c_i). La combinaison de ces BBA engendre une valeur de conflit élevée (masse de l'ensemble vide) qui tend vers 1. En conséquence, les décisions de l'Ek-NN seront dans la plupart des cas erronés. D'où la nécessité d'une règle de combinaison adaptée à ce type de problème de fusion.

3.2 Règle de combinaison pour l'Ek-NN

Pour mieux répartir le conflit et résoudre le problème de combinaison introduit dans la section précédente, nous proposons de combiner les BBA en utilisant la règle de combinaison des grands nombres de sources (LNS) proposée par Zhou *et al.* [18]. Comme cette règle de combinaison est non associative, l'ordre des sources est important et respecte celui de la Figure 2. LNS s'applique à des BBA séparables. Par définition, une BBA est dite séparable si on peut l'obtenir comme résultat de la combinaison par la règle de Dempster d'un ensemble de BBA simples. On note qu'une BBA simple est par défaut séparable. LNS prend en entrée un ensemble de BBA séparables. Dans un premier temps, LNS transforme les BBA d'entrée en des BBA simples. Dans le cas de notre application, on cherche à combiner les BBA obtenus à partir

des voisins de l'espèce recherchée qui sont déjà des BBA simples. L'étape suivante du LNS consiste à regrouper les BBA simples en θ clusters en fonction de leurs éléments focaux $A \neq \Omega$. Ensuite, les BBA de chaque cluster sont combinées en utilisant la règle de combinaison conjonctive (CRC [15]) comme indiquée dans [18]. Après avoir combiné les BBA de chaque cluster, nous obtenons θ BBA, une par cluster.

A l'étape suivante, LNS affaiblit les BBA. En effet, les clusters sont considérés comme des sources d'information et le but principal est de considérer la fiabilité de chaque source à travers l'hypothèse suivante : plus la cardinalité du cluster est élevée, plus le cluster est fiable. Donc, nous proposons d'estimer le coefficient de fiabilité, ε_j, du cluster θ_j comme suit :

$$\varepsilon_j = \frac{Card\left(\theta_j\right)}{k} \qquad (3)$$

Ensuite, chaque cluster est affaibli en utilisant son coefficient de fiabilité. La dernière étape de l'algorithme LNS consiste à combiner toutes les BBA des clusters affaiblis en utilisant une règle de combinaison conjonctive ([18] a utilisé la règle de combinaison conjonctive.

L'avantage de l'algorithme LNS est qu'il offre la possibilité d'utiliser deux règles de combinaisons différentes car il combine les BBA sur deux niveaux, c'est-à-dire intra et inter-clusters. Donc, nous proposons la règle de combinaison disjonctive (DRC[15]) pour combiner les BBA intra-clusters et la règle de combinaison conjonctive pour combiner les BBA inter-clusters.

Dans la section suivante, nous présentons un ensemble d'expérimentations liées au problème de la reconnaissance des espèces d'arbres et nous montrons la contribution de la règle de combinaison disjonctive dans l'algorithme LNS.

4 Expérimentations et résultats

Pour évaluer la solution proposée, nous utilisons un jeu de données issu du challenge ImageClef 2015. L'ensemble de données contient des photos d'arbres de France métropolitaine. Ces photos sont prises dans la nature par des non-professionnels. Le jeu de données contient 2572 photos de feuilles et 895 photos d'écorces pour l'apprentissage et 820 couples de photos de feuilles et d'écorces pour le test. Nous avons 72 espèces d'arbres à reconnaître.

Dans les expérimentations, nous avons fixé le paramètre *k* à 20 en minimisant le critère AIC [3] (critère d'information d'Akaike), $\alpha_0 = 0.944$, $\gamma_i = 0.76$, et $\beta = 3.6$.

Dans la suite, une comparaison de la solution proposée (LNS Ek-NN) avec l'Ek-NN et le modèle de Ben Ameur *et al.* [1] basé sur les forêts aléatoires (FA).

Dans une première expérimentation, nous étudions l'impact de la règle de combinaison sur le taux de classification correcte des classifieurs. La Figure 4 présente les résultats obtenus. En effet, nous avons testé l'Ek-NN avec la règle de Dempster, le CRC et le DRC. Nous remarquons que la règle de combinaison utilisée a un impact important sur le taux de classification correcte de l'Ek-NN. La règle de combinaison conjonctive a réussi à améliorer le taux de classification correcte de l'Ek-NN.

Nous avons évoqué dans la section précédente que l'algorithme LNS permet l'utilisation de deux règles de combinaison différentes pour combiner les BBA intra et inter-clusters.

Dans la Figure 4, nous avons utilisé le LNS Ek-NN en combinant les BBA intra-cluster avec le DRC et les BBA inter-clusters avec le CRC (*courbe rouge*). Puis avons testé la combinaison des BBA inter et intra-cluster avec le CRC (*courbe bleue*) comme proposé par [18]. L'expérimentation montre que le DRC a un impact positif sur le taux de bonne classification du classificateur LNS Ek-NN proposé. En effet, nous avons obtenu 49,87% de taux de classification correcte pour la première espèce reconnue avec le DRC/CRC (*courbe rouge*) contre 45,48% lorsque nous utilisons que le CRC (*courbe bleue*). En outre, nous avons 89,14% de taux de classification correcte pour dix espèces avec le DRC/CRC (*courbe rouge*) contre 88,65% lorsque nous utilisons uniquement le CRC (*courbe bleue*).

De plus, nous remarquons que l'effet du DRC est plus important pour les huit premières espèces détectées. En effet, lorsque nous utilisons le DRC pour combiner des BBA intra-clusters, la valeur de masse sur l'ignorance globale, Ω, dans la BBA résultante est plus importante que sa valeur lorsque nous utilisons le CRC. Ainsi, avec le DRC on ne considère plus l'ignorance globale ce qui améliore les résultats comme le montre la Figure 4.

Dans une deuxième expérimentation, nous comparons le LNS Ek-NN et l'Ek-NN avec le modèle basé sur les forêts aléatoires donné dans [1]. Nous avons fixé le nombre d'arbres dans chaque forêt à 200. La Figure 5 présente les résultats de cette expérimentation. Nous remarquons que le modèle de [1] basé sur les forêts aléatoires est plus performant en termes de taux de classification correcte que le LNS Ek-NN et l'Ek-NN. En effet, nous avons 58.65% de précision pour la première espèce reconnue avec les forêts aléatoires contre 49,87% pour le LNS Ek-NN et 40,85% avec l'Ek-NN. De la même manière, nous obtenons 89,75% de taux de classification correcte pour la dixième espèce reconnue avec les forêts aléatoires contre 89.14% avec le LNS Ek-NN et 83,41% avec l'Ek-NN.

Dans une troisième expérimentation, nous comparons le temps de réponse des forêts aléatoires avec celui du LNS Ek-NN pour la classification d'une seule espèce. Le Tableau 1 présente les résultats des forêts aléatoires et du LNS Ek-NN, sur un PC Inetl® core™ i7-6600U CPU @2.60GHz 2.70GHz.

Tableau 1 – Temps de traitement pour la reconnaissance d'une espèce en millisecondes

Nombre d'arbres (FA)	100	**200**	
Temps de traitement pour une espèce (ms)	123,1	**275,4**	
k : nombre de voisins	10	**20**	30
Temps de traitement pour une espèce (ms)	98,6	**127,8**	153,9

Selon le Tableau 1, nous remarquons que le temps de réponse des forêts aléatoires augmente en fonctions du nombre d'arbres dans la forêt. La même observation est constatée dans le cas du Ek-NN. En effet, le temps d'exécution du LNS Ek-NN augmente en fonction du paramètre *k*. Nous constatons aussi que le LNS Ek-NN est en moyenne plus rapide que les forêts aléatoires. Dans les expérimentations de la Figure 5, on a fixé le nombre d'arbre à 200 et *k* à 20. Avec cette configuration, les forêts aléatoires prennent 275,4 millisecondes pour reconnaitre une espèce et le LNS Ek-NN prend 127,8 millisecondes pour le même objectif.

A partir de la Figure 5 et du Tableau 1 nous pouvons conclure que le modèle donné dans [1] basé sur les forêts aléatoires est plus performant en termes de taux de classification correcte que le LNS Ek-NN. Cependant, le LNS Ek-NN est plus performant en termes de temps de calculs que les forêts aléatoires.

5 Conclusion

Dans cet article, nous traitons le problème de la reconnaissance des espèces d'arbres. En effet, nous proposons l'algorithme LNS Ek-NN qui est une version du Ek-NN adaptée à la classification des espèces d'arbres. En fait, nous avons adapté la règle de combinaison LNS avec le k-NN crédibiliste pour mieux combiner les informations provenant des voisins et pour mieux traiter le conflit provenant de la variabilité intra-espèces et la similarité inter-espèces.

Dans les travaux futurs, nous allons chercher à améliorer les résultats obtenus en termes de taux de classification correcte. Une solution consisterait à utiliser un classificateur adapté pour chaque caractéristique extraite des feuilles et des écorces, puis à combiner les sorties de ces classifieurs.

Références

[1] R. Ben Ameur, D. Coquin, and L. Valet. Influence of the basic belief assignments construction on the behavior of a fusion system for tree species recognition. In *Proceedings of 20th International Conference on Information Fusion, IEEE FUSION*, *Xi'an, China,* July 2017.

[2] G. Cerutti, L. Tougne, J. Mille, A. Vacavant, and D. Coquin. Understanding leaves in natural images a

model-based approach for tree species identification. *Computer Vision and Image Understanding*, 117(10), pp. 1482–1501, 2013.

[3] M.C. Cetin, A. Erar, A. Variable selection with akaike information criteria: a comparative study. *Hacettepe Journal of Mathematics and Statistics,* 31, pp. 89-97 (2002)

[4] H. Coste, *Flore descriptive et illustrée de la France, de la Corse, et des contrées limitrophes*. Paris, 1906.

[5] A. P. Dempster. Upper and Lower probabilities induced by a multivalued mapping. *Annals of Mathematical Statistics*, 38, pp. 325–339, 1967.

[6] T. Denoeux. A k-Nearest Neighbor Classification Rule Based on Dempster-Shafer Theory. *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, 25(5), pp. 804–813, mai 1995.

[7] Folia: http://liris.univ-lyon2.fr/reves

[8] H. Goeau, P. Bonnet, A. Joly, V. Bakic, J. Barbe, I. Yahiaoui, S. Selmi, J. Carré, D. Barthélémy, N. Boujemaa, J.-F. Molino, G. Duché, and A. Péronnet. Pl@ntnet mobile app. In *Proceedings of the 21st ACM Int. Conf. on Multimedia*, pp. 423–424, 2013.

[9] D. Harrison, B. Rivard, A. Sanchez-Azofeifa. Classification of tree species based on longwave hyperspectral data from leaves, a case study for a tropical dry forest. *Int. J. Appl. Earth Obs Geoinformation*, 66, pp. 93-105, 2018.

[10] N. Kumar, P.N. Belhumeur, A. Biswas et al. LeafSnap : a computer vision system for automatic plant species identification. *In Proceedings of Computer Vision – ECCV*, *Springer* , pp. 502-516, 2012.

[11] S. H. Lee and C. S. Chan and P. Remagnino. Multi-Organ Plant Classification Based on Convolutional and Recurrent Neural Networks. *IEEE Transactions on Image Processing*, 27(09), pp. 4287-4301, 2018.

[12] O. Mzoughi, I. Yahiaoui, N. Boujemaa, E. Zagrouba. Semantic-based automatic structuring of leaf images for advanced plant species identification. *Multimed Tools Appl*, 75, pp. 1615-1645, 2016.

[13] A. Othmani, A. Piboule, O. Dalmau, N. Lomenie, S. Mokrani, and L. F. C. L. Y. Voon. Tree species classification based on 3D bark texture analysis. In *Pacific-Rim Symposium on Image and Video Technology,* pp. 279-289. 2013.

[14] G. Shafer. A mathematical theory of evidence. *Princeton University Press*, 1976.

[15] P. Smets. Belief Functions: the Disjunctive Rule of Combination and the Generalized Bayesian Theorem. *Int. J. of Approximate Reasoning*, 9, pp. 1–35, 1993.

[16] J. J. Sudano. Inverse pignistic probability transforms. In *Proceedings of FUSION*, pp. 763–768, 2002.

[17] L.A. Zadeh. Fuzzy sets as a basis for a theory of possibility. *Fuzzy Sets ans Systems*, 1, pp. 3-28, 1978.

[18] K. Zhou, A. Martin, and Q. Pan. Evidence combination for a large number of sources. In *Proceedings of 20th International Conference on Information Fusion, IEEE FUSION*, *Xi'an, China*, July 2017.

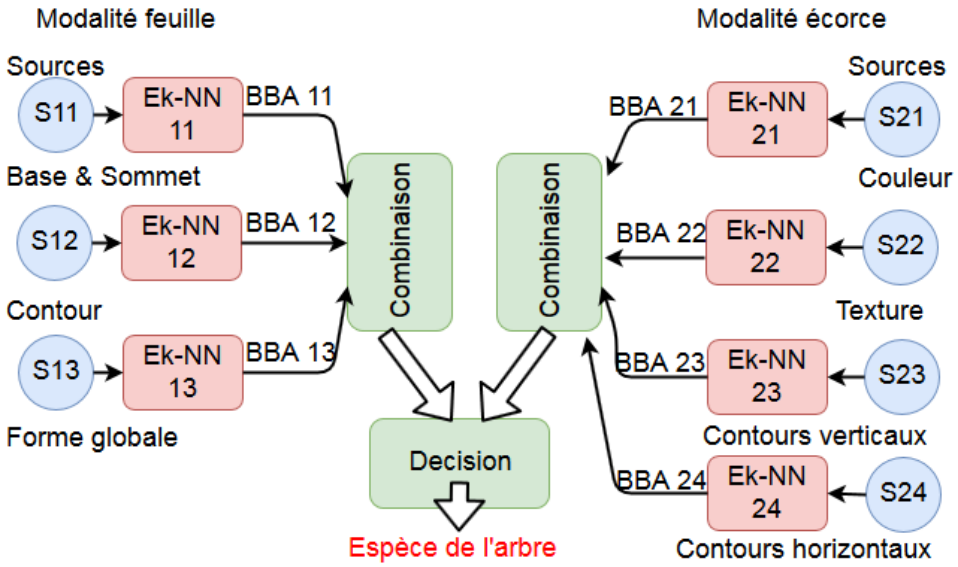

Figure 2 – Reconnaissance des espèces d'arbres avec les k-NN crédibilistes

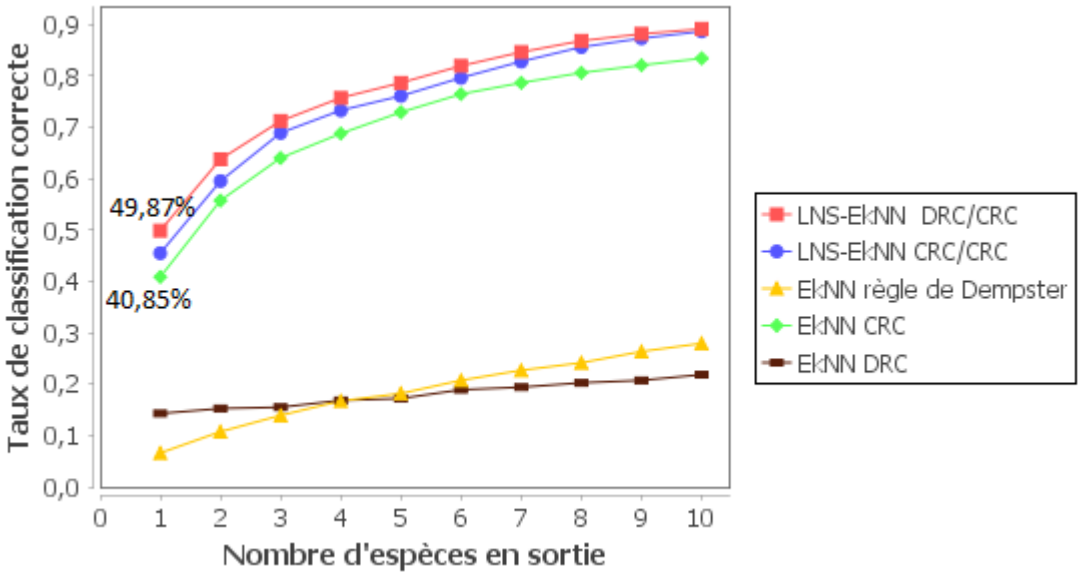

Figure 4 – Impact de la règle de combinaison sur les taux de classification correcte issus des classifieurs LNS Ek-NN et Ek-NN [6]

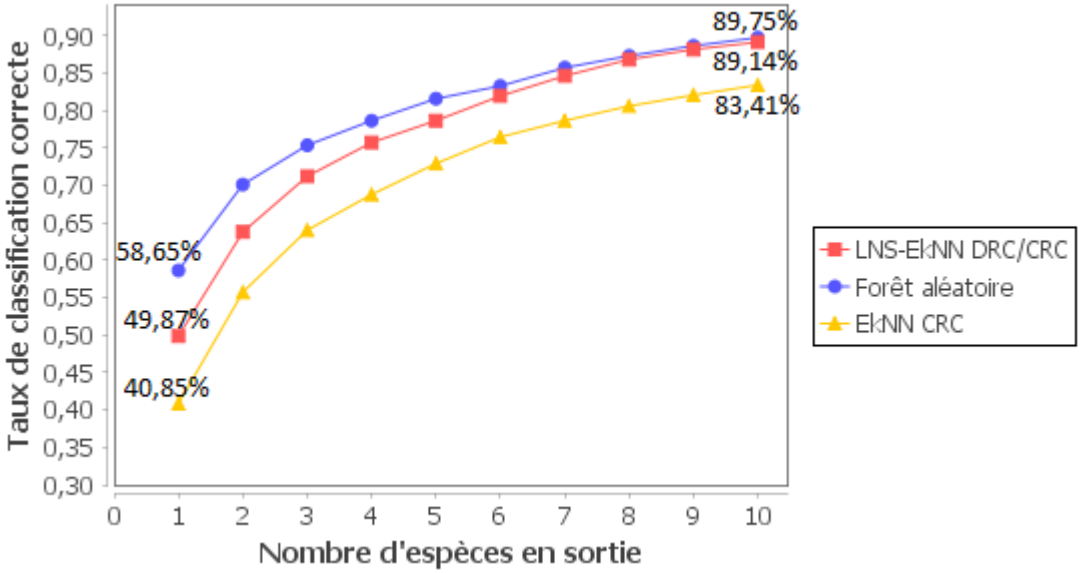

Figure 5 – Comparaison des taux de classification correcte issus des forêts aléatoires [1] avec ceux issus du LNS Ek-NN et Ek-NN [6]