

Reconnaissance de feuilles d'arbres par fusion de décisions partielles

HONGHUI LIU¹, DIDIER COQUIN¹, LIONEL VALET¹

¹ Laboratoire d'Informatique, Système et Traitement de l'Information et de la Connaissance
5 chemin de Bellevue, BP 8065, 74942 Annecy le vieux Cedex, France

¹Honghui.LIU@univ-savoie.fr, Didier.Coquin@univ-savoie.fr, Lionel.Valet@univ-savoie.fr

Résumé - Dans le cadre du développement d'une application Smartphone destinée à la reconnaissance des espèces d'arbres, une stratégie basée sur des sous-classifieurs a été mise en place pour reconnaître les feuilles à partir des caractéristiques liées à la base, au sommet et au contour. La théorie des fonctions de croyance est appliquée sur la sortie de chaque sous-classifieur afin de raffiner les résultats en diminuant l'effet de l'incertitude qui existe sur les caractéristiques des feuilles. La décision finale sur l'espèce de feuille est prise en transformant la croyance en probabilité pignistique et en accumulant les probabilités issues de chaque sous-classifieur pour chaque espèce. Les résultats démontrent que notre méthode de sous-classification et de décision obtient de bonnes performances.

Abstract - Within the framework of developing a Smartphone-based application for helping people to recognize plant species in the wild, a sub-classifier strategy has been introduced for recognizing leaf's properties, such as the contour, as well as the tip and base outlines. Belief function theory is applied on the output of each sub-classifier in order to revise the results by removing the uncertainty we have on leaf's property. A decision can be made by accumulating the pignistic probability we pose on each revised property. In this paper, we first describe the sub-classification strategy and its advantage. The method for treating the uncertainty of leaf property identification and the method for leading the obtained properties to a decision on leaf classification are described. The results demonstrate that our sub-classification and decision methods can offer good performance in leaf classification.

1 Introduction

Reconnaître l'espèce d'un arbre à partir de l'une de ses feuilles et comprendre ses caractéristiques est une tâche accessible pour la plupart des botanistes, mais reste encore délicate pour un amateur même équipé d'ouvrages spécialisés. Les difficultés de ce travail sont doubles : premièrement la photo de la feuille est prise en milieu naturel, nécessitant une étape de segmentation efficace, et deuxièmement le territoire français compte 126 espèces, chaque espèce ayant une grande variabilité morphologique ce qui ajoute de la confusion et de l'ambiguïté dans l'étape de reconnaissance. Quelques applications de reconnaissance de feuilles ont été développées sur des Smartphones, la plupart utilisent un jeu de questions et de réponses en introduisant des connaissances botaniques de manière interactive. De nos jours, l'identification des espèces végétales sur un fond blanc avec l'appareil photo d'un Smartphone a permis de donner des performances satisfaisantes [1]. Le projet ANR ReVes* consiste à développer une application sur Smartphone pour reconnaître une espèce d'arbre à partir d'une image de feuilles. L'application exploite l'image d'une feuille d'arbre prise en milieu naturel, puis extrait les caractéristiques morphologiques utiles pour reconnaître l'espèce la plus probable. Cette application permet également, de fournir un moyen éducatif et interactif de formation aux amateurs de botanique. La méthode de reconnaissance développée dans ce papier est basée sur une stratégie de sous classification et l'utilisation de la théorie des fonctions

de croyance permet de raffiner les sorties des sous-classifieurs avant de les combiner pour améliorer la décision.

La section 2 expose la problématique et montre les difficultés du problème de classification. Une stratégie basée sur des sous-classifieurs est décrite dans la section 3. Un raffinement des sorties permet de pallier en partie à la confusion et l'ambiguïté associés aux propriétés des feuilles. Enfin une étape de décision combinant ces sorties permet de proposer aux utilisateurs les espèces les plus probables. Des tests sur une base de données de feuilles sont présentés dans la section 4.

2 Problématique de la classification de feuilles

2.1 La base de données des feuilles

Le problème de la reconnaissance de feuilles est un problème de classification multiple. Les 7338 images de feuille utilisées pour les tests proviennent de la base de données Pl@ntLeaves II [2] qui est composée d'un mélange de scan (feuille scannée sur fond unis), pseudo-scan (photo sur fond unis avec des ombres autour de feuille) et photos prises en milieu naturel. Les tests sur scan et pseudo-scan permettent de valider plus facilement les différentes étapes de la méthode et sont plus faciles à exploiter que des photos prises en milieu naturel. En se basant sur les travaux développés dans [3-5], 46 attributs décrivant les propriétés morphologiques de 126 espèces de feuilles simples ont été extraits [6]. L'étude réalisée dans ce papier porte sur les 108 espèces de feuilles simples qui comportent au moins 10 images dans la base de données, sur lesquelles nous avons sélectionné par une analyse factorielle les **23 attributs** les moins corrélés liés à la **Base**, au **Sommet** et au

* Ce travail est financé par l'Agence Nationale de la Recherche avec la référence : ANR-10-CORD-005.

Contour de la feuille. Nous pouvons noter que les classes comportent un nombre inégale d'individus, certaines espèces sont représentées par plus de 200 images, alors que d'autres en compte à peine 10. Enfin, la confusion des espèces à partir de leurs caractéristiques morphologiques est liée à la similarité inter-classe et la variabilité intra-classe [7]. Les 4 images pseudo-scans de la figure 1 proviennent de deux espèces (chêne sessile et chêne pubescent) et illustre bien cette confusion.



Figure 1: Similarité et diversité des caractéristiques morphologiques des feuilles: chêne sessile (à gauche) et le chêne pubescent (à droite)

2.2 Travaux préliminaires sur la classification

Dans le contexte de l'apprentissage statistique, de nombreuses méthodes de classification automatiques sont apparues. Les plus connues sont les méthodes Bayésiennes pouvant faire appel à l'algorithme EM (Expectation Maximization), les méthodes discriminantes telles que les SVM, les arbres de décision, ou encore les méthodes dites de Boosting [8]. L'instabilité des arbres de décision, souvent dépréciée, s'est révélée être un atout pour des procédés qui exploitent ce désavantage telles que les Forêt Aléatoire [9] qui sont simples d'utilisation et robustes.

Des premiers travaux basés sur des **Forêts Aléatoires** appliquées sur l'ensemble des 23 attributs avec une forêt de 200 arbres de décisions et 9 variables sélectionnées à chaque partage) ont donné des résultats encourageants. La décision finale prise par la Forêt Aléatoire est la classe la plus fréquente parmi les 200 résultats de ces arbres de décision [10]. Or, compte tenu de la confusion sur les caractéristiques morphologiques des feuilles, la vraie classe de la feuille n'est pas forcément classée comme étant la sortie de la forêt aléatoire qui obtient le plus de votes, mais peut se situer en deuxième ou troisième position. Au lieu de donner une seule et unique réponse à l'utilisateur, l'application proposera les 5 images canoniques de feuilles, fournies par les botanistes, les plus probables par ordre décroissant.

3 Nouvelle stratégie de classification

Vis-à-vis des problèmes mentionnés précédemment, nous proposons ici une stratégie de classification basée sur des sous-classifieurs associés aux propriétés de la feuille, tout en utilisant la théorie des fonctions de croyance pour raffiner le résultat en fonction de deux sources d'informations reçues.

3.1 Etape de sous-classification

Tout d'abord, l'originalité de nos travaux est d'utiliser des sous-classifieurs pour discriminer les

feuilles par rapport à leurs propriétés morphologiques, telles que la **Base**, le **Sommet** et le **Contour**. L'avantage de cette stratégie est premièrement de simplifier la tâche de classification en divisant le problème initial en sous problèmes qui impliquent moins de classes et d'attributs. Deuxièmement cette démarche, similaire à celle qu'utilisent les botanistes pour reconnaître une plante, propose aux amateurs de botanique une manière d'apprendre à reconnaître une espèce végétale.

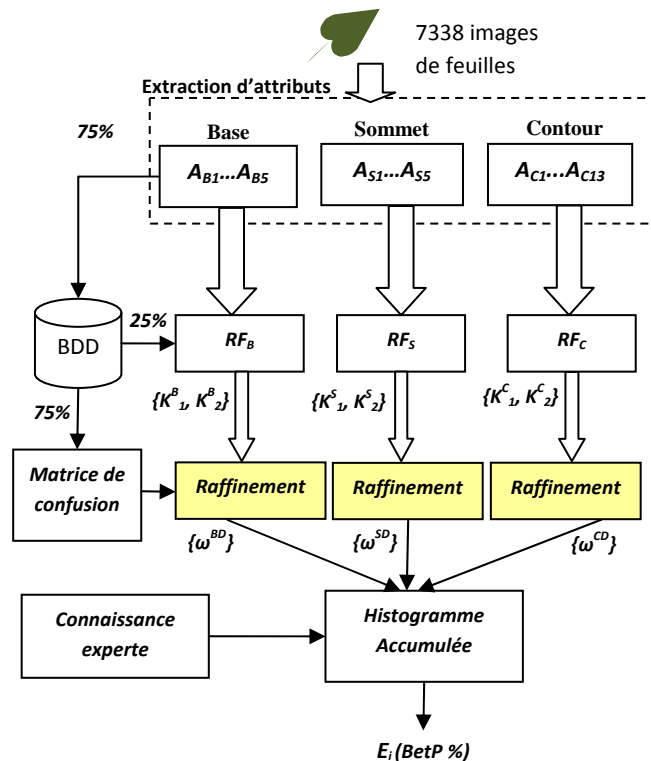


Figure 2: Stratégie de sous-classification liée aux caractéristiques de la feuille avec l'étape de raffinement

La Figure 2 montre les trois catégories d'attributs (A_{Bi} , A_{Si} , A_{Ci}) extraits par les méthodes développées dans [6]. Chaque sous-ensemble d'attributs décrit une propriété de la feuille caractérisant la **Base**, le **Sommet**, et le **Contour**. L'apprentissage des sous-classifieurs RF_i basés sur des **Forêts Aléatoires** est réalisé avec 75% de la base de données totale (BDD) des feuilles. Les sorties de chaque sous-classifieur donnent des valeurs qualitative notée K^B_i , K^S_i , K^C_i avec $i=1$ ou 2 , caractérisant la feuille par rapport à sa **Base**, à son **Sommet** et à son **Contour** respectivement. Une combinaison des valeurs du triplet (K^B_i, K^S_i, K^C_i) permet d'identifier la plupart des espèces d'arbres parmi les 108 possibles.

3.2 Etape de raffinement

Comme nous l'avons évoqué et montré dans la figure 1, il existe une confusion morphologique entre les espèces, si bien qu'il est parfois très difficile de les distinguer, surtout pour un novice en botanique. La figure 3 montre un **Contour** de feuille denté et un autre denté en scie. Les **attributs** extraits pour caractériser le **Contour** de la feuille nécessite une étape de segmentation très performante quel que soit les conditions d'acquisition de la photo.



Figure 3 : La représentation de deux types de Contour de feuille: denté (à gauche) et denté en scie (à droite)

A cause de la confusion morphologique mentionnée ci-dessus, les valeurs de la première sortie des sous-classifieurs RF_i ne correspondent pas forcément aux propriétés réelles de la feuille. Dans ce cas, il est intéressant de considérer aussi la deuxième sortie pour reconnaître la feuille. Pour ce faire, une étape de **raffinement** basée sur la théorie de Dempster-Shafer a été implémentée, afin de déterminer quelle valeur de sortie nous devons prendre en compte. Cette étape de raffinement est schématisée dans la figure 4 et pour mieux l'expliquer elle est appliquée aux attributs du **Contour** de la feuille.

A l'entrée, nous avons les deux premières réponses K_1^C et K_2^C comme étant les **Contours** de feuille possibles, données par le sous-classifieur de contour RF_C . Ces réponses sont obtenues par les deux plus importants votes issus de la forêt aléatoire RF . En divisant K_i^C par le nombre d'arbres de la forêt (ici 200), on obtient une fréquence d'occurrences pour ces réponses. Ces fréquences peuvent être assimilées à des degrés de croyance que la forêt aléatoire attribue à ces deux types de contour. Ainsi, nous obtenons des masses de croyance $m_{RF}(\{K_1^C\})$ et $m_{RF}(\{K_2^C\})$ données par le sous-classifieur RF_C (la première source d'information).

D'autre part, il faut noter que compte tenu de la similarité et la variabilité existant sur les différents **Contours**, notre modèle peut se tromper. Afin de visualiser l'efficacité générale des arbres de décision à caractériser les contours de feuilles, nous avons construit, à partir de 75% des données de la base BDD, une matrice de confusion notée MC , dont une ligne MC_i ($i=1\dots n$, n =nombre de contours) représente le nombre d'occurrences d'un contour estimée C_i par les arbres des forêts aléatoires sur un ensemble d'individus du jeu d'apprentissage, et une colonne MC_j ($j=1\dots n$) est le nombre d'individus présentant un contour C_j . Ainsi, après la normalisation des valeurs par rapport à la somme des lignes ou des colonnes, nous pouvons avoir les informations concernant le taux de bonne reconnaissance d'un contour MC_{ii} ($i=j$) et le taux de confusion entre les différents contours MC_{ij} ($i\neq j$). Ces valeurs sont utilisées comme une autre source d'information, notée MC , servant à raffiner les résultats des sous-classifieurs.

Soient K_1^C et K_2^C les deux votes les plus élevés en sortie du sous-classifieur RF_C , correspondant respectivement aux classes C_1 et C_2 . Si nous considérons la matrice de confusion comme une autre source, nous pouvons calculer les croyances sur ces classes, soit $m_{MC}\{C_1\}=MC_{11}$ ou $m_{MC}\{C_2\}=MC_{22}$,

mais aussi sur l'ensemble $m_{MC}\{C_1, C_2\}=MC_{12}$ ou $m_{MC}\{C_2, C_1\}=MC_{21}$. Ces dernières peuvent être interprétées comme des croyances que nous avons sur l'ensemble $\{C_1, C_2\}$, sachant que le sous-classifieur donne un résultat C_1 ou C_2 mais plausiblement confus à C_2 ou C_1 . En outre, pour respecter une croyance totale égale à 1, nous distribuons le reste de la masse sur l'ensemble du contour Ω_C , ce qui fait que :

$$m_{MC}(\Omega_C) = 1 - m_{MC}(\{C_1\}) - m_{MC}(\{C_1\}, \{C_2\}) \quad (1)$$

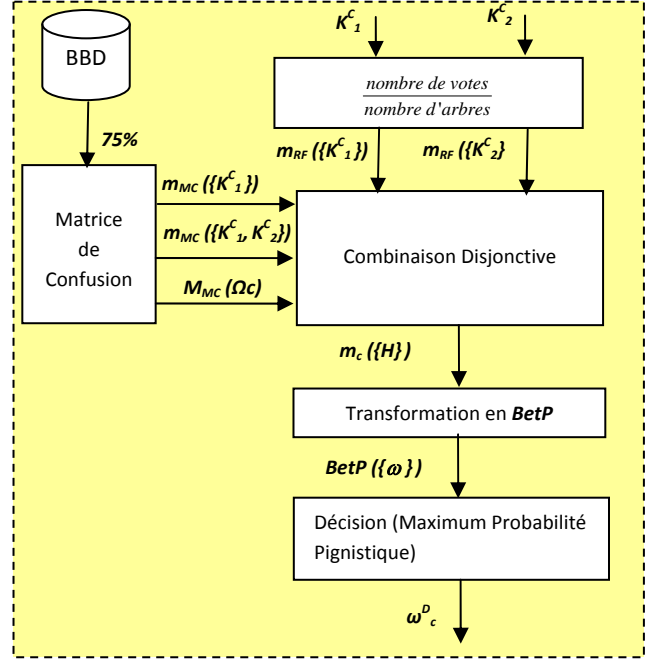


Figure 4 : Etape de raffinement avec la théorie de Dempster-Shafer

Étant donné que nous n'avons aucune information sur la fiabilité de chaque source (RF et MC), nous avons appliqué la règle disjonctive, afin de conserver un raisonnement plus prudent sur la combinaison des sources [11]. La règle, mentionnée dans [11], est utilisée pour réviser la masse de croyance de chaque hypothèse $H \in \Omega_C$:

$$m_c(H) = m_{RF} \cup m_{MC}(H) = \sum_{A \cup B = H} m_{RF}(\{A\})m_{MC}(\{B\}) \quad (2)$$

où A et B sont les éléments focaux de chaque source dont la masse est supérieure à 0.

Une fois les masses des hypothèses révisées, nous les convertissons en une probabilité pignistique par l'équation suivante :

$$BelP(\omega) = \sum_{\{H \subseteq \Omega_C, \omega \in H\}} \frac{m_c(H)}{(1 - m_c(\emptyset))card(H)} \quad (3)$$

$card(H)$ est la cardinalité de l'ensemble H et $m_c(\emptyset)$ est la masse pour l'ensemble vide qui est égale à 0, car notre problème est exprimé dans un monde fermé. Puis, le critère du maximum des probabilités pignistiques est utilisé pour déterminer la valeur de contour ω_C^D devant être prise en compte pour la suite de l'identification de la feuille : $\omega_C^D = \max_{\omega} BelP(\omega)$. Le poids ω_C^D est attribué à toutes les espèces liées à la propriété raffinée. Par exemple, si le sous-classifieur **Contour**, après

raffinement, disait que le contour de la feuille est C_1 avec une probabilité $BetP(\omega) = 0.6$. Par la connaissance experte des botanistes, nous recensons toutes les espèces E_i correspondant à cette propriété et leurs affectons un poids de 0.6. Ces poids sont accumulés pour toutes les propriétés raffinées pour constituer un histogramme qui représente la distribution des probabilités pignistiques sur l'ensemble des espèces. L'espèce la plus probable liée à la feuille étudiée doit être celle qui correspond au mode de l'histogramme cumulé.

4 Résultats

Nous présentons les résultats pour chaque classe d'images (scan, pseudo-scan et photos) en utilisant notre nouvelle stratégie. Les tableaux 1 à 3 montrent l'apport du raffinement (4^{ème} colonne) sur le taux de bonne classification (*si nous prenons deux sorties des arbres pour caractériser la feuille*), en utilisant la théorie de Dempster-Shafer sur les deux sources d'information. Si nous prenons qu'une sortie de sous-classifieur, alors le raffinement n'est pas mis en place. Dans ce cas, la fréquence d'occurrence de l'histogramme de la forêt aléatoire est utilisée comme score pour construire l'histogramme cumulé (5^{ème} colonne).

Table 1: Apport des sous-classifieurs et du raffinement sur le taux de bonne classification sur des scans de feuille

Sous-classifieur	Nbre de sorties de la forêt aléatoire	Taux de reconnaissance des propriétés	Raffinement avec Dempster-Shafer	Taux de reconnaissance des espèces N=1	Taux de reconnaissance des espèces N=2
Base	N = 1	78%		32 %	51%
	N = 2	92%	92%		
Sommet	N = 1	61%			
	N = 2	81%	86%		
Contour	N = 1	75%			
	N = 2	86%	89%		

Table 2: Apport des sous-classifieurs et du raffinement sur le taux de bonne classification sur des pseudo-scans de feuille

Sous-classifieur	Nbre de sorties de la forêt aléatoire	Taux de reconnaissance des propriétés	Raffinement avec Dempster-Shafer	Taux de reconnaissance des espèces N=1	Taux de reconnaissance des espèces N=2
Base	N = 1	70%		36 %	54%
	N = 2	88%	95%		
Sommet	N = 1	56%			
	N = 2	85%	85%		
Contour	N = 1	74%			
	N = 2	84%	95%		

Table 3: Apport des sous-classifieurs et du raffinement sur le taux de bonne classification sur des photos de feuille.

Sous-classifieur	Nbre de sorties de la forêt aléatoire	Taux de reconnaissance des propriétés	Raffinement avec Dempster-Shafer	Taux de reconnaissance des espèces N=1	Taux de reconnaissance des espèces N=2
Base	N = 1	65%		30 %	48%
	N = 2	83%	87%		
Sommet	N = 1	43%			
	N = 2	67%	87%		
Contour	N = 1	65%			
	N = 2	87%	93%		

Les résultats sur les images issues des scans, pseudo-scans ou photos permettent d'augmenter un taux de reconnaissance de l'espèce d'environ **18%** en utilisant les deux sorties les plus probables des Forêts

Aléatoires. Le taux de reconnaissance est plus faible pour les photos prises en milieu naturel à cause des problèmes dus à la segmentation des images.

5 Conclusion

Une nouvelle stratégie de sous-classification est mise en œuvre pour reconnaître une feuille à partir de ses propriétés morphologiques. La théorie de Dempster-Shafer a été appliquée sur les sorties des sous-classifieurs, afin d'atténuer l'effet de l'incertitude que nous avons sur les propriétés des feuilles. Les probabilités pignistiques servent à produire un histogramme cumulé des espèces. L'application affiche les 5 espèces les plus probables. La méthode proposée permet une augmentation du taux de bonne classification. Une amélioration possible est d'intégrer des informations phytogéographiques (coordonnées GPS, type de sol, ...) qui permettent d'aider à la décision, car certaines espèces d'apparence similaire n'existent pas forcément dans le même environnement.

6 Références

- [1] P. Belhumeur, D. Chen, S. Freiner, D. Jacobs, W. Kress, H. Ling, I. Lopez, R. Ramamoorthi, S. Sheorey, S. White, and L. Zhang. "Searching the world's herbaria : A system for visual identification of plant species", *European Conference on Computer Vision*, 2008.
- [2] H. Goëau, P. Bonnet, A. Joly, D. Barthelemy, N. Boujemaa, and J.-F. Molino, "The imageclef 2012 plant image identification task", in *ImageCLEF 2012 Working Notes*, 2012.
- [3] X.F. Want, D.S. Huang, J.X. Du, X. Huan, and L. Heutte, "Classification of plant leaf images with complicated background", *Applied Mathematics and Computation*, 205 (2): 916-926, 2008.
- [4] F. Mokhtarian and A.K. Mackworth. "A theory of multiscale, curvature-based shape representation for planar curves", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14:789-805, 1992.
- [5] C. Caballero and M. Carmen Aranda. "Plant species identification using leaf image retrieval", in *Proceeding of the ACM International Conference on Image and Video Retrieval*, CIVR 2010, pages 327-334, 2010.
- [6] G. Cerutti, L. Tougne, J. Mille, A. Vacavant, D. Coquin. "Guiding active contours for tree leaf segmentation and identification", in *CLEF (Notebook/Papers/Labs/Workshop)*. 2011
- [7] H. Coste. "Flore descriptive et illustrée de la France et de la Corse et des contrées limitrophes". *Librairie de l'Académie impériale de Médecine*, Paris, 1906.
- [8] R. Schapire. "The boosting approach to machine learning: An overview". *Nonlinear Estimation and Classification*, Springer, 2003.
- [9] L. Breiman. "Random forests", *Machine learning*, 45 (1): 5-32, 2001.
- [10] G. Cerutti, V. Antoine, L. Tougne, J. Mille, L. Valet, D. Coquin, A. Vacavant. "Reves Participation : Tree Species Classification using Random Forests and Botanical Features", *Conference and Labs of the Evaluation Forum*, Rome, 2012.
- [11] T. Denoeux. "The cautious rule of combination for belief functions and some extensions", *Proceeding of the 9th International Conference on Information Fusion*, Florence (Italy), July 2006.