



HAL
open science

Fusion multimodale pour la reconnaissance d'espèces d'arbres

Rihab Ben Ameer

► **To cite this version:**

Rihab Ben Ameer. Fusion multimodale pour la reconnaissance d'espèces d'arbres. Traitement du signal et de l'image [eess.SP]. Université Grenoble Alpes, 2018. Français. NNT : 2018GREAA005 . tel-01921590

HAL Id: tel-01921590

<https://theses.hal.science/tel-01921590>

Submitted on 13 Nov 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.

THÈSE

Pour obtenir le grade de

DOCTEUR DE LA COMMUNAUTE UNIVERSITE GRENOBLE ALPES

Spécialité : **STIC Traitement de l'information**

Arrêté ministériel : 25 mai 2016

Présentée par

Rihab BEN AMEUR

Thèse dirigée par **Didier COQUIN, Professeur à l'Université de Savoie Mont Blanc** et codirigée par **Lionel VALET, Maître de Conférence à l'Université de Savoie Mont Blanc**

préparée au sein du **Laboratoire d'Informatique, Systèmes, Traitement de l'Information et de la Connaissance** dans l'**École Doctorale SISEO**

Fusion multimodale pour la reconnaissance d'espèces d'arbres

Thèse soutenue publiquement le **04 Juin 2018**,
devant le jury composé de :

Mme. Su RUAN

Professeur à l'Université de Rouen (Présidente du jury)

M. Arnaud MARTIN

Professeur à l'Université De Rennes (Rapporteur)

M. Eric LEFEVRE

Professeur à l'Université d'Artois (Rapporteur)

M. Didier COQUIN

Professeur à l'Université de Savoie Mont Blanc (Directeur de thèse)

M. Lionel Valet

Maître de conférence à l'Université de Savoie Mont Blanc (Co-Directeur de thèse)



mots-clés : système de fusion, reconnaissance d'espèces d'arbres, théorie des fonctions de croyance, fusion multimodale, classification.

Résumé

Les systèmes de fusion d'informations permettent de combiner des données issues de différentes sources d'informations tout en tenant compte de leur qualité. La combinaison de données issues de sources hétérogènes permet de profiter de la complémentarité des données et donc d'avoir potentiellement des performances plus élevées que celles obtenues en utilisant une seule source d'informations. L'utilisation de ces systèmes s'avère intéressante dans le cadre de la reconnaissance d'espèces d'arbres à travers la fusion d'informations issues de deux modalités : les feuilles et les écorces.

Une seule modalité représente éventuellement différentes sources d'informations décrivant chacune une des caractéristiques les plus pertinentes. Ceci permet de reproduire la stratégie adoptée par les botanistes qui se basent sur ces mêmes critères lors de la reconnaissance. L'adoption de cette stratégie entre dans la mise en valeur de l'aspect éducatif. Dans ce cadre, un système de fusion est envisageable afin de combiner les données issues d'une même modalité ainsi que les différentes modalités disponibles. Dans le contexte de la reconnaissance d'espèces d'arbres, il s'agit d'un problème réel où les photos des feuilles et des écorces sont prises en milieu naturel. Le traitement de ce type de données est compliqué vu leurs spécificités dues d'une part à la nature des objets à reconnaître (âge, similarité inter-espèces et variabilité intra-espèce) et d'autre part à l'environnement.

Des erreurs peuvent s'accumuler tout au long du processus précédant la fusion. L'intérêt de la fusion est de prendre en compte toutes les imperfections pouvant entacher les données disponibles et essayer de bien les modéliser. La fusion est d'autant plus efficace que les données sont bien modélisées. La théorie des fonctions de croyance représente l'un des cadres théoriques les plus aptes à gérer et représenter l'incertitude, l'imprécision, le conflit, etc. Cette théorie tire son importance de sa richesse en termes d'outils permettant de gérer les différentes sources d'imperfections ainsi que les spécificités des données disponibles. Dans le cadre de cette théorie, il est possible de modéliser les données à travers la construction de fonctions de masse. Il est également possible de gérer la complexité calculatoire grâce aux approximations permettant de réduire le nombre d'éléments focaux. Le conflit étant l'une des sources d'imperfections les plus présentes, peut être traité à travers la sélection de la règle de combinaison la mieux adaptée.

En fusionnant des sources d'informations ayant des degrés de fiabilité différents, il est possible que la source la moins fiable affecte les données issues de la source la plus fiable. Une des solutions pour ce problème est de chercher à améliorer les performances de la source la moins fiable. Ainsi, en la fusionnant avec d'autres sources, elle apportera des informations

utiles et contribuera à son tour à l'amélioration des performances du système de fusion. L'amélioration des performances d'une source d'informations peut s'effectuer à travers la correction des fonctions de masse. Dans ce cadre, la correction peut se faire en se basant sur des mesures de la pertinence ou de la sincérité de la source étudiée. Les matrices de confusion présentent une source de données à partir desquelles des méta-connaissances caractérisant l'état d'une source peuvent être extraites.

Dans ce manuscrit, le système de fusion proposé est un système de fusion hiérarchique mis en place dans le cadre de la théorie des fonctions de croyance. Il permet de fusionner les données issues des feuilles et des écorces et propose à l'utilisateur une liste des espèces les plus probables tout en respectant l'objectif éducatif de l'application. La complexité calculatoire de ce système de fusion est assez réduite permettant, à long termes, d'implémenter l'application sur un Smart-phone.

keywords : fusion system, tree species recognition, belief function theory, multimodal fusion, classification.

Abstract

Information fusion systems allow the combination of data issued from different sources of information while considering their quality. Combining data from heterogeneous sources makes it possible to take advantage of the complementarity of the data and thus potentially have higher performances than those obtained when using a single source of information.

The use of these systems is interesting in the context of tree species recognition through the fusion of information issued from two modalities : leaves and barks. A single modality may represent different sources of information, each describing one of its most relevant characteristics. This makes it possible to reproduce the strategy adopted by botanists who base themselves on these same criteria. The adoption of this strategy is part of the enhancement of the educational aspect. In this context, a merger system is conceivable in order to combine the data issued from one modality as well as the data issued from different modalities. In the context of tree species recognition, we treat a real problem since the photos of leaves and bark are taken in the natural environment. The processing of this type of data is complicated because of their specificities due firstly to the nature of the objects to be recognized (age, inter-species similarity and intra-species variability) and secondly to the environment.

Errors can be accumulated during the pre-fusion process. The merit of the fusion is to take into account all the imperfections that can taint the available data and try to model them well. The fusion is more effective if the data is well modeled. The theory of belief functions represents one of the best theoretical frameworks able to manage and represent uncertainty, inaccuracy, conflict, etc. This theory is important because of its wealth of tools to manage the various sources of imperfections as well as the specificities of the available data. In the framework of this theory, it is possible to model the data through the construction of mass functions. It is also possible to manage the computational complexity thanks to the approximations allowing to reduce the number of focal elements. Conflict being one of the most present sources of imperfections, can be dealt through the selection of the best combination rule.

By merging sources of information with different degrees of reliability, it is possible that the least reliable source affects the data issued from the most reliable one. One of the solutions for this problem is to try to improve the performances of the least reliable source. Thus, by merging with other sources, it will provide useful information and will in turn contribute in improving the performance of the fusion system.

The performance improvement of an information source can be effected through the correction of mass functions. In this context, the correction can be made based on measures of the relevance or sincerity of the studied source. The confusion matrices present a data source from which meta-knowledge characterizing the state of a source can be extracted. In this manuscript, the proposed fusion system is a hierarchical fusion system set up within the framework of belief function theory. It allows to merge data from leaves and barks and provides the user with a list of the most likely species while respecting the educational purpose of the application. The computational complexity of this fusion system is quite small allowing, in the long term, to implement the application on a Smart-phone.

Remerciements

Cette thèse a été menée au sein du Laboratoire d'Informatique, Systèmes, Traitement de l'Information et de la Connaissance (LISTIC) de l'Université de Savoie Mont Blanc. J'adresse donc mes premiers remerciements à ces deux structures qui m'ont accueilli dans leurs locaux.

Je tiens à remercier Monsieur Eric LEFEVRE, Professeur à l'Université d'Artois, Monsieur Arnaud MARTIN, Professeur à l'Université de Rennes et Madame Su RUAN, Professeur à l'Université de Rouen pour avoir accepté de rapporter sur ma thèse. Les remarques constructives qui accompagneront leur rapport seront d'un grand bénéfice.

Ce travail n'aurait pu être complet sans l'encadrement de Didier Coquin, Professeur à l'Université de Savoie Mont Blanc et Lionel Valet, Maître de Conférences à l'Université de Savoie Mont Blanc. Leurs conseils et leurs qualités humaines m'ont été précieux tout au long de ce travail.

Je remercie également tous les membres du LISTIC pour leur accueil, leurs encouragements et leur sympathie. Je remercie en particulier le personnel administratif, Joëlle et Assia pour m'avoir aidé dans les formalités administratives tout le long de ces années.

Avec ce manuscrit qui représente plus de trois ans de travail c'est une période marquante de ma vie qui s'achève. En effet, ces études doctorales m'ont permis de faire la connaissance de nombreux doctorants et stagiaires. Mention spéciale aux doctorants que j'ai connue au sein du LISTIC et avec qui j'ai passé de très bons moments : Rizlène, Meriem, Amina, Hela, Quentin, Cédric, Matthias, Charles et Mathilde.

Je ne pourrais suffisamment remercier mon compagnon, Seifollah, pour son soutien sans faille. Je tiens à remercier de tout mon Cœur mes soeurs Rahma et Raida qui m'ont soutenues au quotidien. Enfin, je remercie affectueusement ma mère et mon père sans qui je n'aurais pu en arriver là. . .

Table des matières

Introduction générale	1
Motivations	1
Objectifs et contributions	3
Structure du mémoire	4
1 État de l’art	7
1.1 La reconnaissance d’espèces d’arbres	7
1.1.1 LeafSnap	8
1.1.2 Pl@ntNet	10
1.1.3 Folia	10
1.2 Difficultés liées à la reconnaissance des espèces d’arbres	14
1.2.1 La variabilité en fonction de l’âge	14
1.2.2 La variabilité en fonction du degré d’exposition à une source de lumière	15
1.2.3 La variabilité intra-espèce	15
1.2.4 La similarité inter-espèces	16
1.3 La fusion d’informations	18
1.3.1 Définitions de la fusion d’informations	18
1.3.2 Problèmes liés à la fusion d’informations	19
1.3.3 Positionnement de la fusion dans la chaîne de traitement	20
1.3.4 Les topologies de fusion	20
1.3.4.1 La topologie en cascade	21
1.3.4.2 La topologie parallèle	21
1.3.4.3 La topologie de fusion hiérarchique	21
1.3.4.4 La topologie de fusion hiérarchique (série)	22
1.3.4.5 La topologie de fusion conditionnelle	22
1.3.4.6 La topologie de fusion hybride	23
1.3.4.7 Conclusion	23
1.3.5 Les fonctions de fusion	25
1.3.5.1 Les fonctions de fusion linéaires	25
1.3.5.2 Les fonctions de fusion non-linéaires	26
1.3.5.3 Les fonctions de fusion statistiques	28

1.3.5.4	Les fonctions de fusion basées sur des méthodes de calcul intelligent	30
1.3.6	Systèmes de fusion pour la reconnaissance d'espèces d'arbres	30
1.4	La théorie des fonctions de croyance	33
1.4.1	Où se situe cette théorie par rapport aux théories de l'incertain	33
1.4.2	Les fonctions basiques	34
1.4.3	Autres outils	35
1.5	Conclusion	35
2	Modalité feuille : classification et analyse des données à fusionner	37
2.1	Les feuilles de plus près	38
2.1.1	Qu'est ce qu'une feuille ?	38
2.1.2	Description botanique des feuilles	39
2.1.2.1	La forme générale	39
2.1.2.2	La base	39
2.1.2.3	Le sommet	41
2.1.2.4	Le bord	41
2.2	la chaîne de traitement	42
2.2.1	L'acquisition et le pré-traitement de la photo	43
2.2.2	L'extraction d'attributs	44
2.2.2.1	Attributs caractérisant la forme globale	44
2.2.2.2	Attributs caractérisant le contour	44
2.2.2.3	Attributs caractérisant la base et le sommet	45
2.2.3	La classification	45
2.2.3.1	La base de données d'apprentissage et de test	46
2.2.3.2	Stratégies de classification	47
2.2.3.3	Première stratégie de classification : utilisation de la Base de Connaissances Expertes	47
2.2.3.4	Deuxième stratégie de classification : classification dans l'espace des espèces	51
2.3	Évaluation des données à fusionner	51
2.3.1	Performances des classifieurs : évaluation du taux de bonne classification en fonction des dix premières espèces les plus probables	52
2.3.2	Performances des classifieurs : évaluation du taux de bonne classification par espèce	53
2.3.3	Sources d'informations incertaines	55
2.3.4	Sources menteuses contextuellement	56
2.4	Conclusion	57
3	La fusion des caractéristiques des feuilles	59
3.1	Le système de fusion	60
3.2	La construction des fonctions de masse	60
3.2.1	Les fonctions de masse bayésiennes	61
3.2.2	Les fonctions de masse consonantes	62
3.3	Approximation des fonctions de masse	64

3.3.1	L'approximation k-l-x	65
3.3.2	La sommation	66
3.3.3	L'approximation Inner et l'approximation Outer	66
3.4	Choix de la règle de combinaison	67
3.4.1	Règle de combinaison de Dempster	69
3.4.2	La règle de combinaison disjonctive	71
3.4.3	La règle de combinaison adaptative de Dubois et Prade	72
3.4.4	La règle de combinaison PCR6	73
3.4.5	La règle de combinaison DPCR	74
3.4.6	La règle de Florea et Jousselme	76
3.4.7	La règle de combinaison mixte	77
3.4.8	Conclusion	78
3.5	Critères de prise de décision	79
3.6	Expérimentation et résultats	80
3.6.1	Évaluation des méthodes de construction des fonctions de masse	80
3.6.2	Évaluation des méthodes d'approximation des fonctions de masse	83
3.6.3	Évaluation des règles de combinaison	87
3.6.4	Ordre de fusion des classifieurs	88
3.7	Conclusion	90
4	Reconnaissance des espèces d'arbres à partir des feuilles et des écorces	95
4.1	Les écorces de plus près	96
4.1.1	Qu'est ce qu'une écorce ?	96
4.2	Fusion des écorces	97
4.2.1	Extraction d'attributs	97
4.2.1.1	L'orientation de l'écorce	97
4.2.1.2	La couleur	98
4.2.1.3	Les contours verticaux et horizontaux	98
4.2.2	La classification	98
4.2.3	Base de données des écorces	99
4.2.4	Évaluation des données issues des classifieurs	99
4.2.5	Spécificités des données à fusionner	101
4.2.6	Architecture du système de fusion des écorces	102
4.2.7	Construction des fonctions de masse et approximations	102
4.2.8	Règles de combinaison	105
4.3	Fusion multimodale : feuilles et écorces	105
4.4	Techniques de correction des fonctions de masse	107
4.4.1	Techniques de correction basées sur le degré de pertinence	107
4.4.1.1	Le discounting basé sur le degré de pertinence	107
4.4.2	Le discounting contextuel basé sur le degré de pertinence	108
4.4.3	Techniques de correction basées sur le degré de sincérité	109
4.4.3.1	Les différentes formes de non sincérité d'une source d'informations	109
4.4.3.2	Le discounting basé sur le degré de sincérité	110

4.4.3.3	Le discounting contextuel basé sur le degré de sincérité	111
4.4.3.4	Le renforcement contextuel basé sur le degré de sincérité	111
4.5	Estimation de méta-connaissances à partir d'une matrice de confusion	111
4.5.1	Estimation de la pertinence globale d'une source à partir de la matrice de confusion	112
4.5.2	Estimation de la pertinence contextuelle d'une source à partir de la matrice de confusion	112
4.5.2.1	Utilisation du pourcentage de classifications correctes pour chaque contexte	113
4.5.2.2	Utilisation d'une distance	114
4.5.3	Estimation de la sincérité d'une source à partir de la matrice de confusion	114
4.6	La méthode proposée pour la correction des fonctions de masse	116
4.6.1	Construction de fonctions de masse bayésiennes	116
4.6.2	Extraction des méta-connaissances	116
4.6.3	Utilisation des méta-connaissances pour la correction des fonctions de masse bayésiennes	118
4.7	Expériences et résultats : application de la méthode de correction des fonctions de masse	118
4.7.1	Quel degré de sincérité : global ou contextuel ?	118
4.7.2	Impact de la méthode proposée sur les performances des classifieurs	119
4.7.3	Fusion des sources d'informations caractérisant les modalités feuilles et écorces	120
4.8	Conclusion	121
Conclusion et perspectives		123
Annexe A : les résultats des défis LifeClef 2013, 2014 et 2015		129
Annexe B : Composition de la base de données d'apprentissage et de test		131
Annexe C : les bases de données établies par les botanistes		135
Annexe D : les taux de bonne classification par espèce		143
Annexe F : les degrés de sincérité contextuels des classifieurs		155
Bibliographie		161
Liste des figures		171
Liste des tableaux		175

Introduction générale

Motivations

Ces dernières années, le domaine de la fusion d'informations a reçu une attention particulière des chercheurs dans différents domaines. Les techniques de fusion d'informations combinent des informations provenant de plusieurs sources pour obtenir des performances meilleures que celles qui pourraient être obtenues en utilisant une seule source d'informations.

Le concept de fusion d'informations n'est pas nouveau. Les humains présentent un exemple concret utilisant ce concept à travers leur capacité à utiliser plusieurs sens dans la vie de tous les jours. Par exemple, il peut être impossible d'évaluer la qualité d'une substance comestible uniquement à partir du sens de la vision ou du toucher, mais l'évaluation de la comestibilité peut être réalisée en combinant la vue, le toucher, l'odorat et le goût. De même, alors que l'on est incapable de voir en dehors de notre champs de vision ou à travers la végétation, la complémentarité avec le sens de l'ouïe présente une solution pour compenser les limitations du sens de la vision. Ainsi, la fusion de plusieurs sources d'informations est naturellement réalisée par les humains pour obtenir une évaluation plus précise de l'environnement et pouvoir par la suite agir de la meilleure manière possible.

Les progrès récents en extraction de données ont permis d'imiter les capacités de la fusion d'informations naturelles des humains. Actuellement, les systèmes de fusion d'informations sont largement utilisés dans le domaine de l'intelligence artificielle, la robotique, la reconnaissance de formes, etc [1] [2] [3] [4]. La fusion permet de combiner de nombreuses informations issues de sources hétérogènes tout en tenant compte de leurs spécificités à toutes les étapes du processus de fusion. C'est pour cela que la fusion d'informations est de plus en plus employée dans des applications de reconnaissance et c'est dans ce cadre qu'on se place. Dans ce manuscrit, un système de fusion d'informations est proposé afin de reconnaître les espèces d'arbres à partir de photos des feuilles et des écorces.

Ce travail se situe dans le cadre du projet intitulé “Reconnaissance de Végétaux Récréative, Interactive et Educative sur Smartphone” dont l’acronyme est “ReVeRIES”. L’objectif de ce projet est de concevoir des applications ludo-éducatives mobiles qui aideront les utilisateurs à acquérir des connaissances sur les plantes et méthodes employées par les experts en botanique pour reconnaître les familles, les genres et les espèces. Le Projet est financé par l’Agence Nationale de la Recherche (ANR) dans le cadre de l’appel à projets générique 2015. Cinq laboratoires de recherche sont impliqués dans ce projet. Les tâches sont réparties en fonction du domaine de compétence de chaque laboratoire :

- Le Laboratoire d’InfoRmatique en Image et Systèmes d’information (LIRIS) : analyse des photos de feuilles et d’écorces et extraction d’attributs.
- L’Institut de Recherche en Horticulture et Semences (IRHS) : analyse des besoins en termes de connaissances botaniques et mise en place de base de données contenant la connaissance experte.
- Le Laboratoire d’Informatique de l’Université du Maine (LIUM) : conception et mise en place de scénarios de jeux sérieux dont le thème tourne autour de la reconnaissance d’espèces d’arbres.
- L’unité mixte de recherche Environnement Ville Société (EVS) : mise en place de méthodes participatives pour la collecte de données et de systèmes d’informations géographiques volontaires.
- Le Laboratoire d’Informatique, Systèmes, Traitement de l’Information et de la Connaissance (LISTIC) : fusion des données extraites à partir des photos des feuilles et des écorces.

Le projet ReVeRIES fait suite au projet intitulé “Reconnaissance de Végétaux pour des interfaces Smartphones” (ReVeS)¹ qui a été à son tour financé par l’ANR. La thèse de Guillaume Cerutti [5], menée dans le cadre de ce projet, a permis de mettre en place les outils nécessaires pour l’extraction d’attributs à partir des photos des feuilles. L’application Folia² a été développée. Elle permet de reconnaître l’espèce d’un arbre à partir de la photo d’une feuille.

Le travail présenté dans ce manuscrit permettra la mise en place d’un système de fusion pour la reconnaissance des espèces d’arbres. Ce système sera , à long terme, implémenté dans une application mobile. Il permettra à l’utilisateur non seulement de reconnaître l’espèce de l’arbre mais aussi de comprendre les étapes principales de la reconnaissance et d’avoir une explication derrière chaque prise de décision.

1. <http://liris.univ-lyon2.fr/reves/>

2. <https://itunes.apple.com/fr/app/fofia/id547650203?mt=8>

Objectifs et contributions

Certains objectifs doivent être respectés lors de la mise en place du système de fusion visant à reconnaître les espèces d'arbres. Dans cette section, nous présentons les principaux objectifs de ce travail. Nous résumons ensuite les principales contributions apportées.

Objectif 1 :

Le premier objectif de ce travail entre dans la vision globale de la thèse qui consiste à mettre en place un outil éducatif pour la reconnaissance d'espèces d'arbres. La mise en avant de l'aspect éducatif est à respecter et à prendre en compte lors des différents choix à faire.

Objectif 2 :

Le deuxième objectif consiste à faire la reconnaissance en se basant sur des attributs caractérisants la modalité feuille. Ceci nécessite la mise en place d'une chaîne de traitement permettant d'une part la meilleure représentation possible des informations disponibles. D'autre part, elle doit permettre de gérer au mieux toutes les imperfections existantes dans les données : imprécision, incertitude, conflit, ambiguïté... Puis, la complexité calculatoire de la solution proposée doit être réduite pour que l'application puisse fonctionner sur un Smartphone.

Objectif 3 :

Le troisième objectif consiste à rajouter une nouvelle modalité au système de fusion : la modalité écorce. L'ajout de cette modalité doit permettre des meilleures performances. La qualité des données doit être prise en compte pour que cette nouvelle modalité contribue à l'amélioration des résultats obtenus en utilisant uniquement les feuilles.

Contribution 1 :

En réponse à l'objectif 1, on a d'une part choisi de se fonder sur des caractéristiques pertinentes pour la reconnaissance d'espèces d'arbres. Ces caractéristiques sont très proches de celles utilisées par un botaniste. La stratégie proposée consiste donc à reproduire celle adoptée par ces experts de la botanique. Le système proposé se base sur des attributs caractérisant les clés de détermination des espèces d'arbres ce qui permet à l'utilisateur de les découvrir. L'aspect éducatif se manifeste aussi à travers l'architecture du système qui permet à l'utilisateur de suivre le résultat de la fusion chaque fois qu'une nouvelle source d'informations est rajoutée. Par la suite, il peut analyser lui même l'apport de chaque source d'informations et avoir une idée sur les caractéristiques les plus pertinentes (forme globale, bord, base et sommet).

Contribution 2 :

Afin de gérer au mieux les imperfections, l'idée est d'analyser la qualité des données à fusionner. En prenant en compte leurs spécificités, un système de fusion est mis en place dans le cadre de la théorie des fonctions de croyance. Cette théorie a prouvé ses capacités à résoudre des problèmes dans différents domaines. Elle tire sa richesse en termes d'outils permettant de gérer les imperfections des données. Néanmoins, il n'existe pas une solution universelle pouvant être appliquée à tous les problèmes. Une chaîne de traitement spécifique est donc mise en place.

Contribution 3 :

Les imperfections entachant les données issues des écorces sont plus importantes que celles des feuilles. Cette modalité, même si elle apporte de l'information utile pour discriminer certaines espèces, est une source de conflit et d'ambiguïté pour d'autres. Il est donc important de mettre en place les outils permettant d'une part de gérer ces imperfections, et d'autre part, permettre à l'ajout de la modalité écorces d'améliorer les performances du système. L'idée est d'obtenir un maximum d'informations pertinentes à travers la correction des informations initiales. Ceci permettra de diminuer le conflit entre les différentes sources d'informations permettant des résultats potentiellement meilleurs lors de la fusion.

Structure du mémoire

Ce mémoire s'articule autour de quatre chapitres :

Le chapitre 1 présente le positionnement de la thèse et la problématique de la reconnaissance des espèces d'arbres à travers la présentation des outils de reconnaissance existants et des difficultés liées à la reconnaissance d'espèces d'arbres. Ensuite, les différentes notions liées à la fusion d'informations sont analysées. Une étude de nos besoins par rapport aux méthodes existantes permet un positionnement vis à vis de chaque notion.

Le chapitre 2 propose une découverte des feuilles de plus près à travers la présentation de leurs caractéristiques les plus pertinentes. Il présente ensuite les techniques qui ont été utilisées pour l'acquisition, le pré-traitement et l'extraction d'attributs à partir des photos des feuilles. L'étape de classification des données, représentant une étape importante du processus de reconnaissance est présentée en détails. Finalement, les données issues des classifieurs, et qui serviront d'entrée pour la phase de la fusion, sont analysés afin de détecter les imperfections existantes et les prendre en compte lors de la fusion.

Le chapitre 3 s'intéresse à la fusion des caractéristiques des feuilles. Les différents blocs du système de fusion sont présentés. Le premier bloc concerne la modélisation des informations disponibles à travers la construction des fonctions de masse. Le deuxième bloc vise à diminuer

la complexité calculatoire à travers l'approximation des fonctions de masse. Le dernier bloc concerne l'étude des règles de combinaison afin de sélectionner celle la plus adéquate à notre application. Finalement, différentes expériences sont faites afin d'évaluer les différents blocs du système de fusion.

Le chapitre 4 propose une fusion multimodale à travers l'ajout de la modalité écorce. Il présente donc les écorces de plus près tout en mettant l'accent sur les caractéristiques les plus pertinentes. Un système de fusion hiérarchique est proposé afin de fusionner les données issues des feuilles avec celles issues des écorces. Afin d'améliorer la qualité des informations à fusionner, les techniques de correction des fonctions de masse sont étudiées. Une méthode d'extraction de méta-connaissances à partir de la matrice de confusion est proposée. Finalement, les résultats des expériences sont présentés.

Chapitre 1

État de l'art

1.1 La reconnaissance d'espèces d'arbres

Aujourd'hui, notre planète compte environ 3000 milliards d'arbres pour 60000 espèces. La France Métropolitaine compte à elle seule 12 milliards d'arbres. Devant une telle richesse, il est important de mettre en place des outils pour la valoriser, la conserver et faciliter sa compréhension.

Dans ce contexte, la reconnaissance de ces espèces qui nous entourent et qui représentent une ressource vitale pour la société est d'une grande importance. Cette tâche est d'une certaine complexité aussi bien pour des personnes n'ayant aucune connaissance botaniste que pour des botanistes. Pour rendre cette tâche accessible à toute personne, plusieurs travaux ont été effectués. Ces travaux ont consisté tout d'abord à mettre en place des ouvrages contenant la description botanique de plusieurs espèces de plantes. La flore Française de Lamarck [6], apparue en 1779, a été la première flore offrant à l'utilisateur des descriptions succinctes de toutes les plantes qui poussent naturellement en France. D'autres flores sont ensuite apparues. Nous pouvons citer la flore forestière française [7], la flora Gallica [8] et plus récemment la petite flore de France qui est un guide pour la détermination de 1000 espèces les plus courantes en France avec pour chacune, une illustration, une carte de répartition, des informations anatomiques, biologiques et écologiques [9]. Ces ouvrages, même s'ils contiennent des informations pertinentes pour la reconnaissance des espèces d'arbres, ne sont pas simples d'utilisation. Il faut du temps et beaucoup de pratique, lire les clefs de déterminations, les comprendre et comparer les caractéristiques de l'espèce en question avec les caractéristiques des espèces présentées dans la flore pour pouvoir finalement déterminer la bonne espèce.

Pour faciliter l'utilisation de ces flores et les rendre accessibles au maximum de personnes, des flores électroniques ont été mises en place. La flore électronique eFlore¹ est aujourd'hui la source d'informations sur la Flore de France la plus complète. Créée par les membres du réseau Tela Botanica², des amateurs ou des botanistes, elle ne cesse de s'enrichir au fil des années. Des outils en ligne permettant la reconnaissance d'espèces d'arbres ont aussi été mis en place. Visoflora³ est un outil d'identification de plantes en ligne dont le principe permet à l'utilisateur d'indiquer les caractères facilement identifiables de l'espèce. Il peut choisir d'ignorer certains caractères qui lui paraissent ambigus et utiliser d'autres caractères pour affiner la recherche progressivement. Un autre outil en ligne est également proposé sur le site "les arbres"⁴ où l'utilisateur est invité à indiquer certaines caractéristiques de la feuille. L'outil d'identification en ligne affiche ainsi à l'utilisateur des photos de feuilles des espèces répondant aux critères sélectionnés. Ces outils d'identification d'espèces d'arbres en ligne ont permis de faciliter la reconnaissance, mais, utiliser correctement une flore électronique ou saisir les caractéristiques des feuilles restent toujours des tâches compliquées et ennuyeuses pour certaines personnes.

Dans ce contexte, des projets visant à mettre en place des applications mobiles simples à utiliser ont été lancés. Ces applications permettent à un utilisateur, n'ayant aucune connaissance experte, de reconnaître l'espèce d'un arbre en prenant simplement la photo de l'un ou de plusieurs de ses organes. Les sous-sections suivantes vont décrire les applications les plus connues. Dans la section 2, les difficultés liées à la reconnaissance d'espèces d'arbres sont présentées. Ces difficultés liées d'une part à la nature des objets à reconnaître et d'autre part à l'environnement existent aussi bien pour les feuilles que pour les écorces. La section 3 introduit le concept de la fusion d'informations en le définissant, présentant les problèmes qui y sont liés, le positionnement de la fusion dans une chaîne de traitement, les différentes topologies de fusion et les différentes fonctions de fusion. Pour chacune de ces sous-sections, nous allons argumenter les choix que nous allons faire toujours en respectant les objectifs de la thèse.

1.1.1 LeafSnap

Une première application appelée LeafSnap [10] [11] [12] est apparue en 2012 aux États Unis. Elle permet de reconnaître 184 espèces existantes à New York et à Washington à partir des photos de feuilles. Son principe consiste à prendre la photo d'une feuille sur un fond blanc,

1. <http://www.tela-botanica.org/>
2. <http://www.tela-botanica.org/site:accueil>
3. <https://www.visoflora.com/>
4. <http://www.lesarbres.fr/>

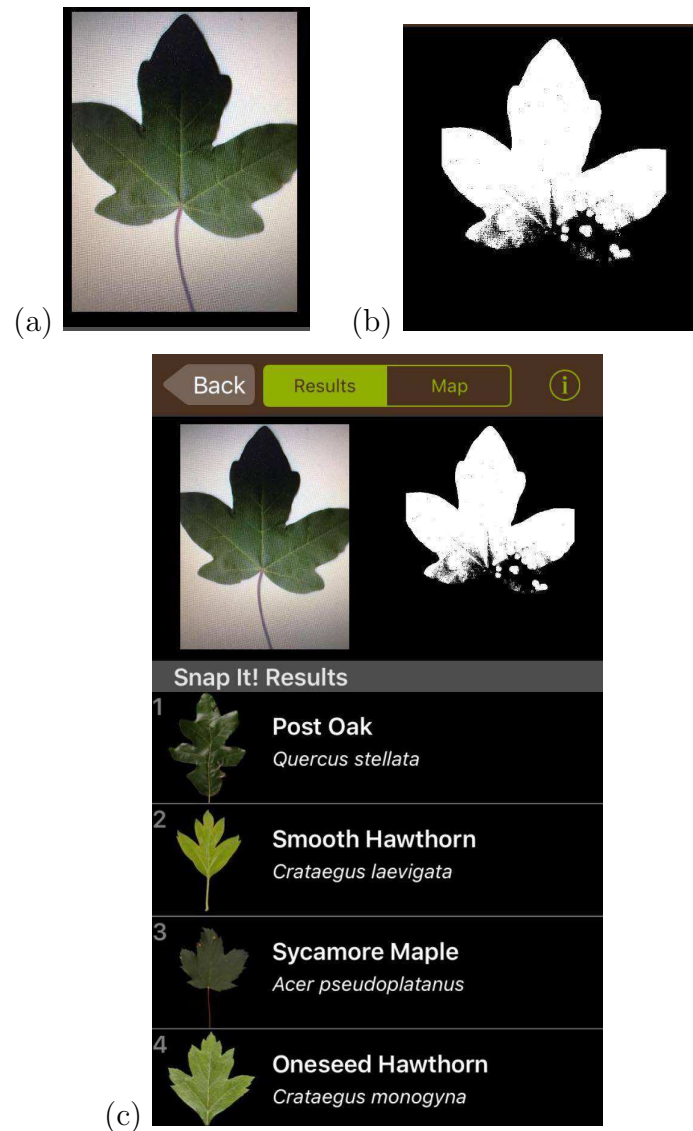


FIGURE 1.1: Étapes de la reconnaissance avec LeafSnap (a) : Prise de la photo de la feuille sur fond blanc, (b) : segmentation , (c) : affichage des résultats (25 espèces sont proposées).

la segmenter afin de séparer la feuille de son arrière plan, extraire des attributs caractérisant la forme de la feuille et utiliser la méthode des k plus proches voisins ou k-NN (k-Nearest Neighbor) [13] pour comparer les attributs extraits aux attributs de la base de données d'apprentissage. Une liste des espèces les plus probables est ensuite présentée à l'utilisateur. Pour chaque espèce, des photos de ses fleurs, ses fruits, son pétiole, ses graines et son écorce sont affichées. La figure 1.1 montre les différentes étapes de la reconnaissance.

1.1.2 Pl@ntNet

Dans le cadre du projet Pl@ntNet⁵, une nouvelle application mobile appelée Pl@ntNet [14] a été mise en place. Son fonctionnement s'approche beaucoup plus du monde réel puisqu'elle se base sur la prise de photos de différents organes de l'arbre pour faire la reconnaissance de 957 espèces d'arbres de la France métropolitaine. En effet, l'utilisation des feuilles seulement peut présenter certaines limitations au système de reconnaissance puisque cet organe n'est présent que pendant une certaine période de l'année. Aussi, dans certains cas où il s'agit de reconnaître des espèces assez similaires, l'information apportée par les feuilles peut être limitée puisqu'elle ne permet pas de distinguer des espèces assez proches.

PlantNet est la première application d'identification d'espèces d'arbres basée sur la prise de photos d'organes multiples. Son mode de fonctionnement consiste à extraire différents attributs caractérisant les photos, les indexer, utiliser un k-NN pour les classifier et faire la fusion en se basant sur le vote majoritaire. Le fonctionnement de l'application est illustré dans la figure 1.2.

L'application Pl@ntNet permet à ses utilisateurs de soumettre leurs photos à une base de données collective. Cet aspect collaboratif fait que la base de données Pl@ntNet contient maintenant des milliers de photos pour des centaines d'espèces. Cette application ne fonctionne que lorsque le smartphone est connecté à internet. En effet, le processus de traitement nécessite de nombreux calculs qui doivent être effectués sur des machines puissantes. De ce fait, la connexion à internet est exigée sinon l'application est incapable de faire la reconnaissance. Ceci pose un problème puisqu'on peut se retrouver dans des situations où l'on n'a plus accès à internet. D'autre part, cette application fait la reconnaissance sans permettre à l'utilisateur de comprendre les clés de la détermination.

1.1.3 Folia

L'application Folia a été mise en place dans le cadre du projet ReVeS⁶. Cette application permet la reconnaissance d'espèces d'arbres à partir des photos des feuilles. Le principe consiste à prendre une photo de la feuille dans son milieu naturel, la segmenter pour séparer la feuille de l'arrière plan, extraire les attributs relatifs aux caractéristiques les plus pertinentes et utiliser un k-NN pour faire la classification. Ce qui distingue l'application Folia des autres applications est son aspect éducatif. Elle permet à l'utilisateur de comprendre les différentes étapes du processus. La figure 1.3 montre les différentes étapes de la reconnaissance. En

5. <http://identify.plantnet-project.org/>

6. <http://liris.univ-lyon2.fr/reves/>

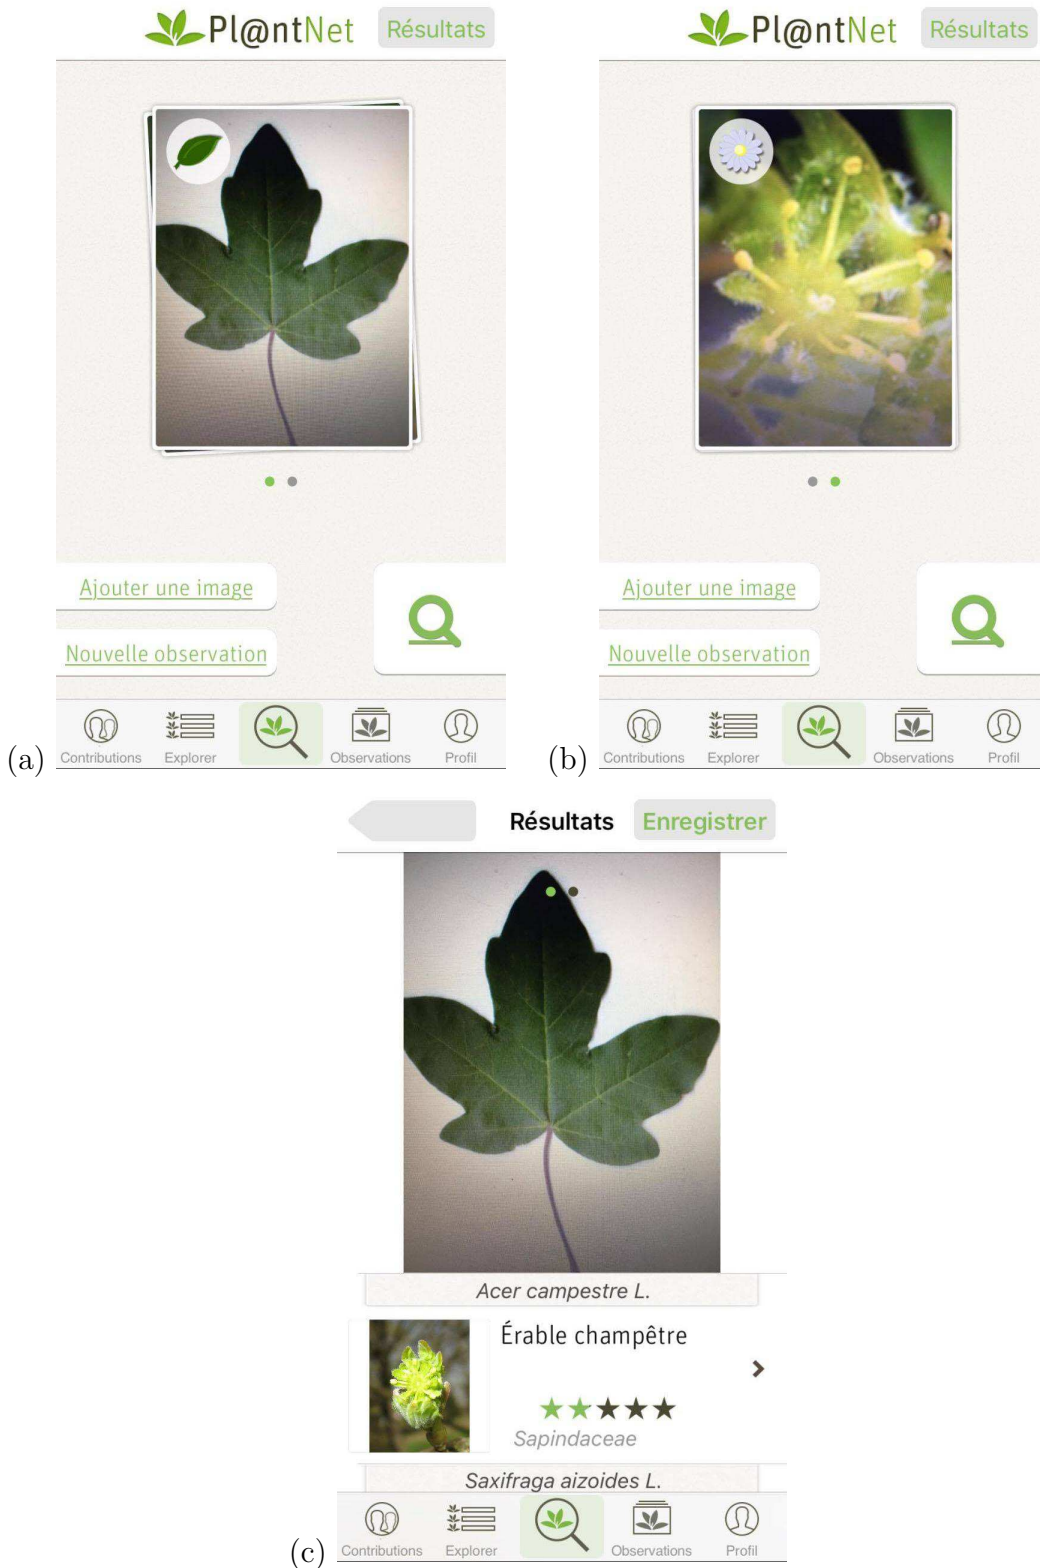



FIGURE 1.2: Étapes de la reconnaissance avec Pl@ntNet (a) : Prise de la photo de la feuille, (b) : prise de la photo de la fleur, (c) : affichage des résultats.




(a)



(b)



(c)



(d)

comparant le mode de fonctionnement de LeafSnap (figure 1.1) et de Pl@ntNet (figure 1.2) à celui de Folia, nous remarquons la grande différence au niveau de la manière dont l'information est présentée à l'utilisateur. Dans LeafSnap et Pl@ntNet nous allons directement au résultat. Par contre, dans Folia, nous découvrons le résultat progressivement, après chaque étape de traitement.

Cette interaction commence à l'étape de segmentation où l'utilisateur est invité dans un

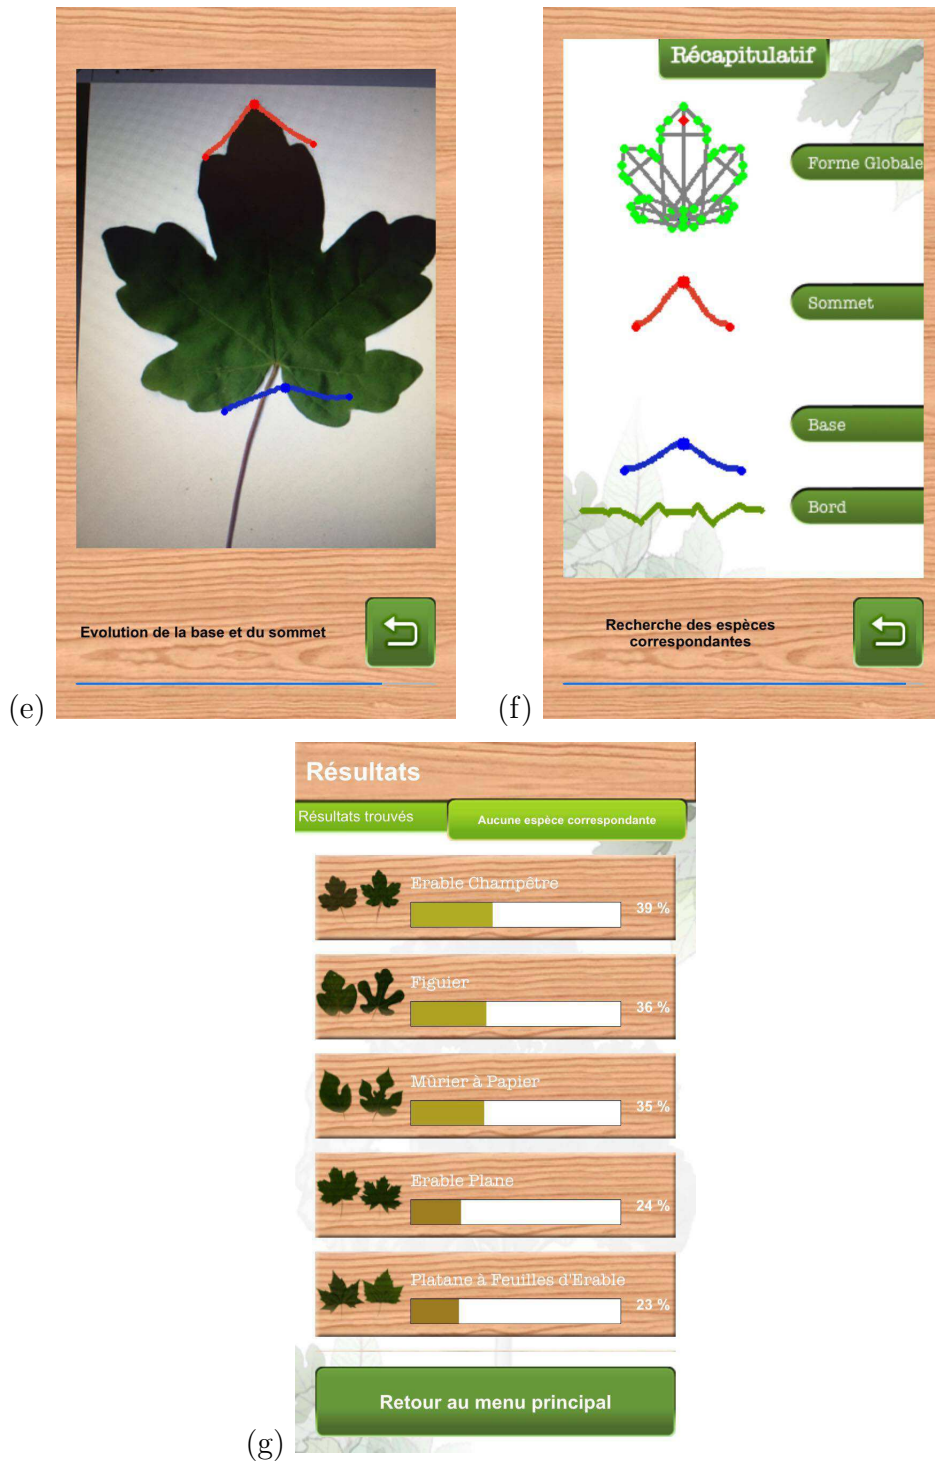


FIGURE 1.3: Étapes de la reconnaissance avec Folia (a) : choix du type de la feuille, (b) : demande de faire une trace, (c) : indication de l'emplacement de la feuille par l'utilisateur, (d) : détection de la forme globale de la feuille, (e) : détection de la base et du sommet, (f) : affichage des clés de détermination, (g) : affichage de la liste des espèces les plus probables

premier temps à indiquer s'il s'agit d'une feuille simple ou composée. Ensuite, il est invité à faire une trace avec son doigt sur l'ensemble des couleurs de la feuille. A partir de cette trace, le programme analyse les couleurs présentes sur la feuille et s'en sert pour faire la segmentation. Un modèle polygonal va se juxtaposer à la forme globale de la feuille. L'utilisateur suit en temps réel cette étape (figure 1.3.d). Puis un modèle déformable va s'ajuster au contour de la feuille, permettant la détection de la base, du sommet et des caractéristiques liées du contour. Ces attributs (clés de détermination pour les botanistes) sont utilisés pour la reconnaissance des espèces, ils sont donc importants et c'est pour cela qu'ils sont affichés à l'utilisateur (figure 1.3.f).

Tous ces détails permettent à un utilisateur novice en botanique de mieux comprendre sur quels paramètres se base l'application Folia pour la reconnaissance des espèces d'arbres, à partir de ses feuilles. L'aspect éducatif est fortement présent. Les algorithmes de segmentation et d'extraction d'attributs de Folia seront expliqués dans le prochain chapitre.

Dans Folia, la fusion des données est faite au niveau des attributs. De ce fait, on ne peut pas connaître l'apport de chaque source d'informations. Par exemple, on ne peut pas savoir si l'information sur la base est plus pertinente que l'information sur le sommet. L'utilisateur est incapable de supprimer les sources d'informations qu'il juge inutiles ou qui apportent du conflit. La classification est réalisée avec un k-NN où toutes les informations sont traitées de la même manière sans prendre en considération la fiabilité de chaque source d'informations ou la qualité des données.

1.2 Difficultés liées à la reconnaissance des espèces d'arbres

Puisque le problème traité est lié à la nature, nous nous trouvons face à plusieurs difficultés en rapport non seulement avec la nature des objets à reconnaître mais aussi à l'environnement. La discrimination des espèces d'arbres est une tâche assez compliquée vue les ambiguïtés au sein d'une même espèce ainsi que les similarités entre les espèces. De plus, plusieurs facteurs naturels viennent compliquer cette tâche tels que l'âge de l'arbre et le degré d'exposition de la feuille à une source naturelle de lumière.

1.2.1 La variabilité en fonction de l'âge

Pour plusieurs espèces, l'apparence de la feuille ou de l'écorce varient considérablement au cours des années. La figure 1.4 montre le changement radical de l'écorce de l'espèce "Robinia

pseudoacacia” en fonction de son âge. Cette variation fait que cette espèce peut, suivant son âge, ressembler plutôt à d'autres espèces d'où l'ambiguïté.




FIGURE 1.4: Variation de l'apparence de l'écorce du “*Robina pseudoacacia*” en fonction de l'âge : (a) : très jeune, (b) : jeune, (c) : adulte, (d) : vieille.

1.2.2 La variabilité en fonction du degré d'exposition à une source de lumière

Un deuxième facteur vient rajouter de la complexité au problème de reconnaissance, c'est l'exposition à une source de lumière. Certaines feuilles peuvent être exposées directement au soleil, d'autres moins exposées (en raison d'un feuillage dense autour d'elles par exemple). Ceci engendre la variation de la couleur des feuilles. Ainsi, des feuilles appartenant à une même espèce peuvent avoir des couleurs différentes comme l'illustre la figure 1.5 représentant la variation de la couleur des feuilles appartenant à l'espèce “*Cotinus coggygia Scop*”.



FIGURE 1.5: Variation de la couleur des feuilles de l'espèce “*Cotinus coggygia Scop*”

D'autres facteurs assez importants viennent à leurs tours rajouter de la complexité au problème de reconnaissance. Il s'agit de la variabilité au sein d'une même espèce (variabilité intra-espèce) et de la similarité entre des espèces différentes (similarité inter-espèces)

1.2.3 La variabilité intra-espèce

Cette variabilité au sein de la même espèce est observée autant pour les feuilles que pour les écorces. En effet, bien que les feuilles et les écorces d'une même espèce subissent le même processus de croissance, une importante variabilité est observée au sein de l'espèce comme le

montre les figures 1.6, 1.7 et 1.8. Pour la figure 1.6, la variabilité se manifeste au niveau de la forme générale de la feuille où des feuilles appartenant à une même espèce ont des formes différentes. Pour la figure 1.7 la variabilité est visible au niveau du contour de la feuille. Les trois photos de feuilles représentent la même espèce mais l'une a un contour entier, l'autre un contour denté et la troisième un contour doublement denté. Pour la figure 1.8, les quatre photos représentent la même espèce : *Acer campestre* L, pourtant elles ont des apparences assez différentes.



FIGURE 1.6: Variabilité des feuilles du “Polpulus alba L.” au niveau de la forme globale



FIGURE 1.7: Variabilité des feuilles du “Quercus ilex L.” au niveau du contour



FIGURE 1.8: Variabilité des écorces de l'*Acer campestre* L.

1.2.4 La similarité inter-espèces

En plus de la variabilité intra-espèce, une similarité entre des feuilles ou des écorces appartenant à des espèces différentes est observée. Ceci rajoute de la complexité au problème de classification et de fusion vu qu'une feuille (ou une écorce) peut ressembler plus à une feuille

(ou une écorce) appartenant à une autre espèce qu'à une feuille appartenant à la même espèce. Les figures 1.9 et 1.10 illustrent ce problème pour les feuilles et les écorces respectivement.



FIGURE 1.9: Similitude des feuilles appartenant aux espèces suivantes de gauche à droite : *Ilex aquifolium* L., *Cornus mas* L., *Viburnum tinus* L. et *Palirus spina-christi* Mill.



FIGURE 1.10: Similitude des écorces appartenant aux espèces suivantes de gauche à droite : *Acer Campestre* L., *Acer opalus* Mill., *Aesculus hippocastanum* L. et *Liquidambar styraciflua* L.

La reconnaissance d'espèces d'arbres est une tâche compliquée, à cause des problèmes de variabilité intra-espèce et de similarité inter-espèces. Mais, la fusion d'informations provenant des feuilles avec des informations sur les écorces pourrait faciliter la tâche. En effet, en prenant les feuilles uniquement, nous sommes parfois incapables d'identifier l'espèce surtout s'il s'agit d'une espèce représentant une grande similarité inter-espèces. Ainsi, l'ajout d'une information sur l'écorce pourrait apporter une information utile et efficace pour la discrimination d'espèces non discriminables avec les feuilles seulement. La figure 1.11 illustre le cas des espèces *Cornus mas* L. et *Viburnum tinus* L. ayant des feuilles similaires, mais, des écorces différentes. Dans ce cas précis, l'ajout de l'information sur l'écorce s'avère très utile. D'où la nécessité de mettre en place un système de fusion permettant de combiner les informations issues des feuilles avec les informations issues des écorces tout en prenant en compte l'incertitude, l'imprécision et le conflit existants.

La fusion d'informations est maintenant reconnue comme une solution efficace pour résoudre des problèmes complexes de reconnaissance d'objets. L'idée c'est que les différentes sources d'informations peuvent potentiellement offrir des informations complémentaires, ce qui permet une précision et une performance potentiellement plus élevées.




FIGURE 1.11: Les espèces *Cornus mas* L. et *Viburnum tinus* L. très semblables au niveau des feuilles peuvent être discriminées en rajoutant les écorces : (a) : feuille *Viburnum tinus* L., (b) : feuille *Cornus mas* L., (c) : écorce *Viburnum tinus* L., (d) : écorce *Cornus mas* L.

1.3 La fusion d'informations

La fusion d'informations est une activité de recherche qui est apparue durant les années 60. A cette époque, les systèmes de fusion d'informations ont été utilisés uniquement dans le domaine militaire. Leurs succès, efficacité et performance dans ce domaine ont fait que cette activité de recherche s'est étendue pour englober d'autres domaines [15]. Plusieurs travaux de recherche ont donc été menés permettant ainsi de développer et d'enrichir cette activité en termes d'outils et de techniques de fusion. L'évolution de cette activité a permis l'apparition d'une communauté de chercheurs dont l'activité de recherche principale tourne autour de la fusion d'informations. De nos jours, une conférence internationale⁷ et deux revues⁸ dédiées à la fusion d'informations existent. De nombreuses sessions spéciales sont également régulièrement organisées dans des conférences dont le domaine de recherche est lié à la fusion d'informations.

1.3.1 Définitions de la fusion d'informations

Dans la littérature, plusieurs définitions concernant la fusion d'informations ont été données. Les principales définitions sont présentées.

1. Joint Directors of Laboratories JDL (1987)

« *La fusion est un processus multi-niveaux et à facettes multiples ayant pour objet la détection automatique, l'association, la corrélation, l'estimation et la combinaison d'informations de sources singulières et plurielles.* » [16]

7. "International Conference on Information Fusion"

8. "Information Fusion" et "Journal of Advances in Information Fusion"

2. Wald (1998)

« *La fusion de données constitue un cadre formel dans lequel s'expriment les moyens et techniques permettant l'alliance des données provenant de sources diverses. Elle vise à l'obtention d'information de plus grande qualité ; la définition exacte de "plus grande qualité" dépendra de l'application.* » [17]

3. Bloch (2003)

« *La fusion d'information consiste à combiner des informations issues de plusieurs sources afin d'améliorer la prise de décision.* » [18]

A travers ces définitions, nous remarquons l'emploi des termes combinaison d'informations et alliance des données pour décrire l'action de combinaison d'informations. Nous remarquons aussi que dans toutes ces définitions, la fusion d'informations consiste à fusionner des données issues de plusieurs sources. La définition retenue pour ce travail est celle de Bloch.

L'idée de fusionner des données provenant de plusieurs sources est intéressante car elle permet de prendre en compte leur qualité. Dans ce contexte, il est important de noter qu'une source d'informations peut être décrite de différentes manières dont les plus importantes seront abordées dans la sous-section suivante.

1.3.2 Problèmes liés à la fusion d'informations

Le but principal de la fusion d'informations consiste à exploiter au maximum la diversité des informations disponibles afin d'en tirer le maximum d'informations pertinentes sans qu'elles soient polluées par des imperfections. Pour cela, il est extrêmement important d'interpréter de la bonne façon la contribution potentielle de chaque information afin qu'elle soit correctement modélisée. Les imperfections pouvant polluer une information se présentent sous différentes formes. D'après Dubois et Prade [19], l'information peut être :

- ambiguë, si nous ne savons pas de manière sûre à quoi elle se rapporte.
- bruitée, si elle est soumise à une erreur aléatoire.
- biaisée, si elle est sujette à une erreur systématique.
- incomplète, s'il en manque une partie nécessaire pour caractériser correctement une situation.
- imprécise, si son contenu ne correspond pas au standard de précision attendue ; elle peut aussi être graduelle (floue) si l'ensemble des valeurs auxquelles elle renvoie n'a pas de contour tranché.
- incertaine, si nous n'avons qu'une confiance partielle dans la vérité de l'information.
- incohérente (ou conflictuelle), si elle contredit une ou plusieurs autres informations.

- redondante, si elle est disponible sous plusieurs formes. La redondance n'est cependant pas toujours un défaut car elle peut contribuer à rendre l'information plus explicite.

Dans le cas d'informations imparfaites, la fusion de données est une solution intéressante pour obtenir des informations plus pertinentes. Elle vise à synthétiser une seule information pertinente à partir de l'ensemble des connaissances disponibles. De plus, la position de l'étape de fusion dans une chaîne de traitement n'est pas fixe. Elle varie d'une application à une autre suivant le besoin.

1.3.3 Positionnement de la fusion dans la chaîne de traitement

Dans une chaîne de traitement, la position de l'étape de fusion est variable. Ce positionnement par rapport au processus de traitement dépend de plusieurs facteurs tel que les données disponibles et les objectifs de l'application. Dasarathy définit 3 niveaux de fusion [20] :

- Fusion niveau mesures : appelée aussi fusion **bas niveau** ou fusion niveau signal, elle concerne la fusion de données issues directement des capteurs.
- Fusion niveau attributs : appelée aussi fusion intermédiaire ou fusion **niveau caractéristiques**, elle consiste à fusionner les informations extraites des données ayant subi une phase de traitement.
- Fusion niveau décisions : appelée aussi fusion **haut niveau**, elle consiste à fusionner les décisions prises par chaque source d'information. Ce niveau présente le plus haut niveau de fusion.

Les données extraites à partir des feuilles et des écorces sont sous forme de vecteurs d'attributs. Une fusion au niveau attributs est donc possible mais elle engendre la création d'un vecteur d'attributs dans un niveau abstrait ce qui se contredit avec l'objectif éducatif de l'application. En effet, et pour renforcer l'interactivité avec l'utilisateur, il est préférable de traiter chaque caractéristique à part pour pouvoir ensuite donner des explications pédagogiques aux décisions prises par le système de reconnaissance. Cette explication pédagogique consiste à faire le lien entre les différentes caractéristiques morphologiques et les décisions du système. Pour cela, nous avons décidé de faire la fusion au **niveau décision** ce qui permettra de mieux suivre l'apport de chaque source d'informations.

1.3.4 Les topologies de fusion

Plusieurs types de topologies de fusion existent dans la littérature permettant de combiner les données issues de différents classifieurs. Dans [21], trois topologies de fusion sont proposées : la topologie en cascade, parallèle et hiérarchique. Une autre catégorisation plus

compréhensive a été proposée dans [22] où quatre types de topologies sont proposés : topologie conditionnelle, hiérarchique (en série), parallèle et hybride.

Dans le cadre de la reconnaissance d'espèces d'arbres, l'entrée d'un classifieur est un vecteur d'attributs décrivant une caractéristique.

1.3.4.1 La topologie en cascade

Dans une topologie en cascade, la sortie d'un classifieur est utilisée comme l'entrée du classifieur suivant comme l'illustre la figure 1.12. La prédiction finale est donc obtenue par le dernier classifieur de la chaîne. L'inconvénient majeur de cette topologie est que le classifieur ultérieur est incapable de corriger les erreurs commises par les classifieurs précédents.




FIGURE 1.12: Topologie de fusion en cascade (reproduit à partir de [23])

1.3.4.2 La topologie parallèle

La topologie parallèle combine la sortie de tous les classifieurs en un seul emplacement (simultanément) comme le montre la figure 1.13. La performance de cette topologie dépend fortement de la sélection de la fonction de fusion appropriée. Cette topologie est conseillée si les classifieurs ont des performances assez différentes où lorsqu'un classifieur peu performant peut affecter la performance globale de l'ensemble.




FIGURE 1.13: Topologie de fusion en parallèle (reproduit à partir de [23, 24])

1.3.4.3 La topologie de fusion hiérarchique

Dans la topologie hiérarchique, la topologie en cascade et en parallèle sont toutes les deux utilisées comme illustré dans la figure 1.14. Ceci permet d'obtenir les performances optimales

puisque cette topologie permet de compenser les inconvénients de la topologie en cascade et celle en parallèle.




FIGURE 1.14: Topologie de fusion hiérarchique (reproduit à partir de [23])

1.3.4.4 La topologie de fusion hiérarchique (série)

Cette topologie de fusion définie dans [22] consiste à rajouter successivement des classificateurs afin de réduire le nombre de classes possibles de manière à raffiner le résultat au fur et à mesure de l'ajout de nouveaux classificateurs. Illustrée dans la figure 1.15, une ou plusieurs classes sont rejetées par un premier classificateur. Les classes retenues sont transmises vers le classificateur suivant qui, à son tour, éliminera certaines classes.

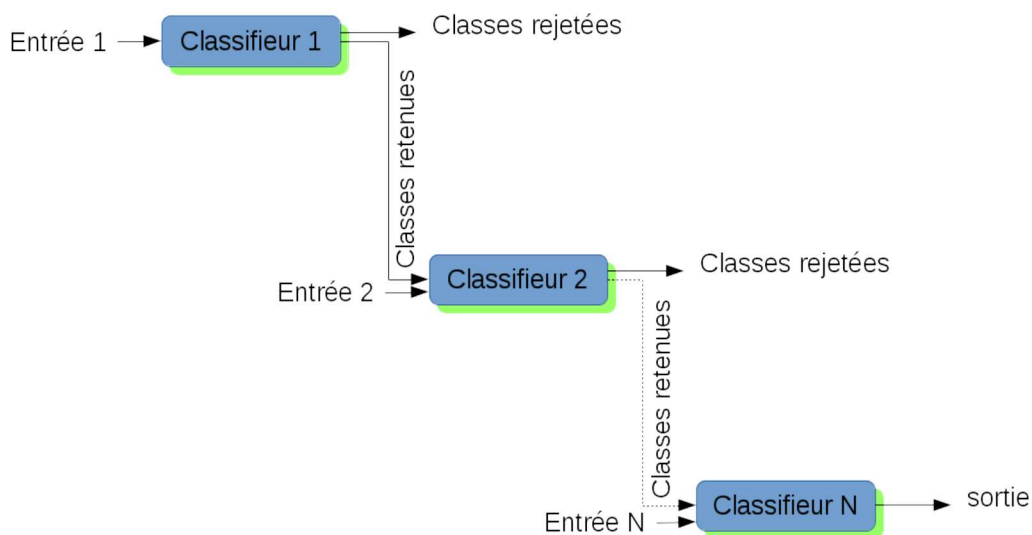


FIGURE 1.15: Topologie de fusion hiérarchique série (reproduit à partir de [24])

1.3.4.5 La topologie de fusion conditionnelle

Dans la topologie conditionnelle, un premier classificateur est d'abord sélectionné. Si l'analyse de la réponse du classificateur affirme qu'il n'est pas assez fiable, un autre classificateur est

sélectionné comme le présente la figure 1.16. Ainsi, le critère utilisé pour évaluer la performance d'un classifieur joue un rôle crucial dans cette topologie.




FIGURE 1.16: Topologie de fusion conditionnelle (reproduit à partir de [24])

1.3.4.6 La topologie de fusion hybride

Une topologie de fusion hybride consiste à sélectionner le meilleur classifieur parmi tous les classifieurs disponibles comme le montre la figure 1.17. Elle présente le meilleur compromis entre la topologie en cascade et celle en parallèle. Le principal inconvénient de cette topologie est sa complexité.

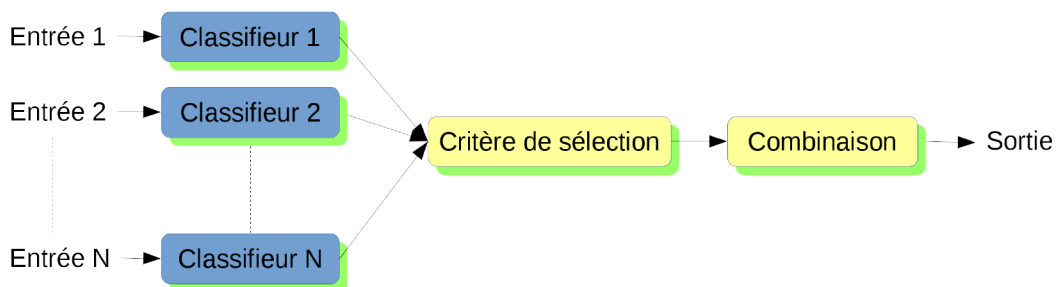


FIGURE 1.17: Topologie de fusion hybride (reproduit à partir de [24])

1.3.4.7 Conclusion

Le critère le plus important à prendre en compte lors du choix de la topologie de fusion est l'aspect éducatif et explicatif de l'application. C'est la topologie du système de fusion qui fixera le degré d'interactivité avec l'utilisateur. Le choix de la topologie de fusion est la première étape de construction d'un système de fusion. Dans notre contexte, nous souhaitons d'abord que l'utilisateur puisse comprendre l'impact de chaque source de données sur la décision prise par le système. Il pourra ainsi, en suivant le processus de fusion étape par étape, décider lui-même s'il souhaite utiliser toutes les sources de données ou s'il préfère se limiter à certaines sources soit parce qu'il trouve qu'elles sont capables à elles seules de fournir un résultat plus cohérent ou parce que les autres sources ne sont pas disponibles.

La topologie en cascade présente l'avantage de fusionner les sources de données deux à deux de manière à ce qu'on puisse suivre les résultats à chaque niveau de fusion et comprendre les éléments qui ont contribué à chaque prise de décision. Mais, si nous utilisons cette topologie, les données issues des écorces seront fusionnées en cascade avec les données issues des feuilles. Donc les classifieurs des écorces seront incapables de corriger les erreurs commises par les classifieurs des feuilles.

Contrairement à la topologie de fusion en cascade, la topologie de fusion parallèle consiste à fusionner toutes les sources de données simultanément et présenter un seul résultat final. Il est donc impossible de regarder les résultats intermédiaires. Cette topologie ne satisfait pas l'aspect éducatif de l'application.

La topologie de fusion hiérarchique est une combinaison entre la topologie de fusion en cascade et la topologie de fusion parallèle. Elle permet ainsi de compenser les inconvénients de chacune. Cette topologie est envisageable lorsqu'on souhaite fusionner des sources de données de performances très différentes ce qui est bien notre cas. En effet, les classifieurs des feuilles et des écorces n'ont pas les mêmes performances. Il est donc préférable de fusionner les données issues des feuilles, fusionner celles issues des écorces et ensuite fusionner les résultats issues des deux modalités pour obtenir un seul résultat final.

La topologie de fusion hiérarchique série permet aussi un suivi de l'apport de chaque source de données à chaque niveau de fusion. Mais, son principe consiste à éliminer des classes à chaque niveau de fusion. Ainsi, une classe rejetée au premier niveau de fusion est rejetée durant tout le processus de fusion. Or, des classes jugées non probables par le premier classifieur peuvent être proposées avec une grande probabilité par les classifieurs qui suivent. Pour appliquer la topologie de fusion hiérarchique série, il faut avoir des sources de données ayant le même degré de fiabilité et ne présentant pas beaucoup de conflit entre elles ce qui n'est pas notre cas.

La topologie de fusion hybride partage le même principe que la topologie de fusion parallèle en ce qui concerne la fusion simultanée de toutes les sources de données. Cette topologie est d'une part rejetée puisque la fusion se fait une seule fois. D'autre part, cette topologie nécessite la mise en place d'un critère de sélection pour choisir les sources de données à fusionner. Ce critère est difficile à fixer puisqu'il s'agit de sources de données fiables contextuellement.

La topologie de fusion conditionnelle se diffère de la topologie de fusion hybride par le fait que la fusion se fait en cascade et non pas en parallèle. Mais, elle utilise le même principe consistant à fixer un critère de sélection permettant de sélectionner les classifieurs les plus pertinents. Comme nous l'avons expliqué pour la topologie hybride, il est compliqué de mettre en place un critère de sélection vu la qualité des sources de données.

Ainsi, nous pouvons conclure que la topologie hiérarchique est la mieux adaptée à notre application et répond le mieux aux objectifs de ce travail. Elle permet un degré d'interactivité satisfaisant avec l'utilisateur qui aura l'occasion de suivre l'avancement du processus de fusion chaque fois qu'une source de données (il s'agit d'un classifieur dans le cadre de notre application) est ajoutée. En plus, les données issues de chaque modalité peuvent être fusionnées à part, évitant ainsi de mélanger des sources d'informations ayant des performances différentes. Donc, pour le système de fusion multimodale, la topologie est hiérarchique et à l'intérieur de ce système de fusion hiérarchique on retrouve la topologie en cascade utilisée pour fusionner les sources d'informations issues d'une même modalité.

Une fois que la topologie du système est choisie, nous passons à la mise en place des outils nécessaires pour la fusion des données. L'étape suivante consiste à choisir la fonction de fusion. Une multitude de fonctions de fusion existe dans la littérature. Un choix doit être fait afin de sélectionner la fonction de fusion la mieux appropriée pour notre application.

1.3.5 Les fonctions de fusion

Dans la littérature différentes catégorisations des fonctions de fusion existent [25] [26]. Dans [27], Canuto présente une des catégorisations les plus informatives consistant à diviser les fonctions de fusion en quatre catégories : les fonctions de fusion linéaires, les fonctions de fusion non linéaires, les fonctions de fusion statistiques et les fonctions de fusion basées sur des méthodes de calcul intelligent.

1.3.5.1 Les fonctions de fusion linéaires

Les fonctions de fusion linéaires telles que le produit, la médiane, le maximum, le minimum et la moyenne représentent les fonctions de fusion les plus simples et faciles à utiliser [25]. Ces fonctions calculent le degré μ_j d'appartenance à une classe ω_j (pouvant être une probabilité, une possibilité ou tout autre mesure) obtenu suite à la fusion de différentes sources de données S_i de la manière suivante :

$$\mu_j = F(d_{1,j}, \dots, d_{N,j}) \quad (1.1)$$

où F est la fonction de fusion et $d_{i,j}$ est la décision d'une source S_i envers une classe ω_j . Les fonctions suivantes sont les fonctions les plus populaires que peut représenter F :

— La moyenne

$$\mu_j = 1/N \sum_{i=1}^N d_{i,j} \quad (1.2)$$

- Le minimum, le maximum ou la médiane ($F = \text{minimum, maximum, médiane}$). A titre d'exemple :

$$\mu_j = \max_i \{d_{i,j}\} \quad (1.3)$$

- Le produit

$$\mu_j = \prod_{i=1}^N d_{i,j} \quad (1.4)$$

Malgré leur facilité d'utilisation, ces méthodes ne tiennent pas compte de la fiabilité et de la performance qui peuvent être variables d'un classifieur à un autre.

1.3.5.2 Les fonctions de fusion non-linéaires

Le vote majoritaire et le vote majoritaire pondéré font partie de la catégorie de fonctions de fusion non-linéaires [27]. Cette catégorie incluant aussi les fonctions de fusion dont le principe consiste à fusionner des listes ordonnées afin d'obtenir une seule liste finale tel que l'algorithme "Borda Count" (BC), l'algorithme "Inverse Ranking Position" (IRP) et l'algorithme "Leave Out" (LO).

- **le vote majoritaire** : le vote majoritaire présente une des plus anciennes stratégies de prise de décision. Chaque classifieur classe un objet indépendamment des autres. La classe finale obtenue suite à la fusion est celle ayant cumulée le plus de votes [24] [25]. Considérons le cas de N classifieurs à fusionner. La fonction de fusion vote majoritaire est capable de donner la bonne réponse uniquement lorsque $N/2 + 1$ classifieurs ou plus ont donné la bonne réponse. En dessous de $N/2 + 1$ réponses correctes, cette fonction de fusion ne pourra pas donner la bonne réponse.
- **le vote majoritaire pondéré** : lorsque les classifieurs n'ont pas le même degré de performance, une plus grande importance est accordée aux classifieurs les plus performants. C'est vrai que cette fonction de fusion prend en compte la fiabilité de chaque classifieur, mais, un classifieur peut avoir une fiabilité variable d'une classe à une autre. Cette variabilité n'est pas prise en compte pour cette règle de fusion.
- **l'algorithme "Borda Count" (BC)** : défini dans [28], BC est un algorithme de fusion qui permet de combiner différentes listes ordonnées des classes les plus similaires afin d'en sortir une seule. Le rang accordé à une classe dans la liste finale est la somme des rangs qui lui ont été accordés dans toutes les listes ordonnées comme le montre la figure 1.18.
- **l'algorithme "Inverse Ranking Position" (IRP)** : défini aussi dans [28], le rang attribué à une espèce dans la liste finale est l'inverse de la somme de l'inverse de ses rangs dans les listes ordonnées de départ comme le montre la figure 1.19.

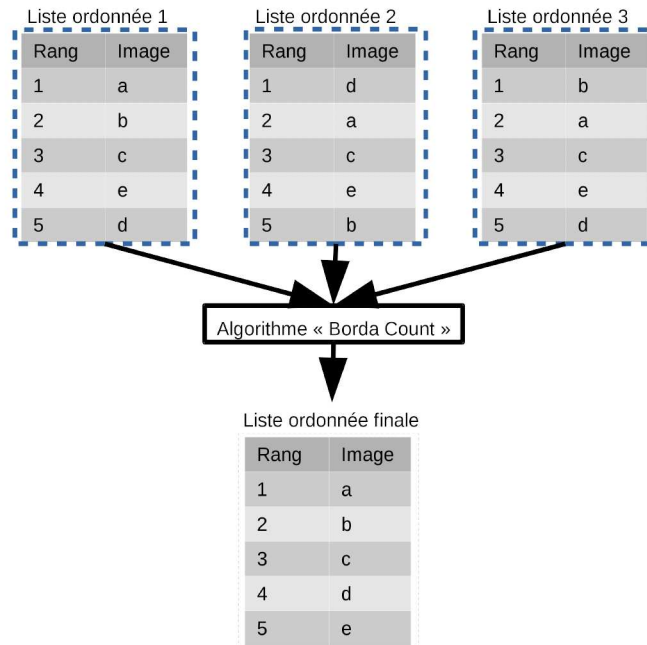


FIGURE 1.18: Exemple de fusion de 3 listes ordonnées en utilisant l’algorithme “Borda Count” (reproduit à partir de [28])

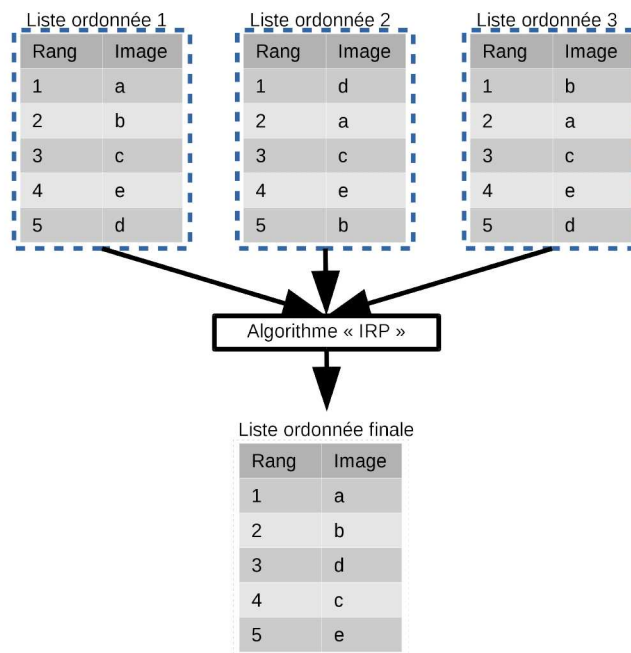


FIGURE 1.19: Exemple de fusion de 3 listes ordonnées en utilisant l’algorithme “IRP” (reproduit à partir de [28])

- **l’algorithme “Leave Out” (LO)** : présenté dans [28], cet algorithme permet de fusionner les différentes listes circulairement suivant un sens choisi dès le début. Supposons qu’il s’agit de 3 listes à fusionner comme le montre la figure 1.20. Nous choisissons de fusionner ces listes en commençant par la liste ordonnée 1, suivie de la liste ordonnée

2, suivie de la liste ordonnée 3. Comme la liste ordonnée 1 est la première à fusionner, l'objet de rang 1 dans cette liste est classé 1 dans la liste finale. Nous passons ensuite à la liste ordonnée 2. L'objet de rang 1 dans cette liste est classé 2 dans la liste finale (sauf s'il a été déjà classé). Pareil pour la liste 3. Une fois que la première ligne de chaque liste est parcourue, nous passons à la deuxième ligne et parcourons les 3 listes ordonnées en respectant le même sens. Le même processus est répété jusqu'à parcourir toutes les lignes des 3 listes.

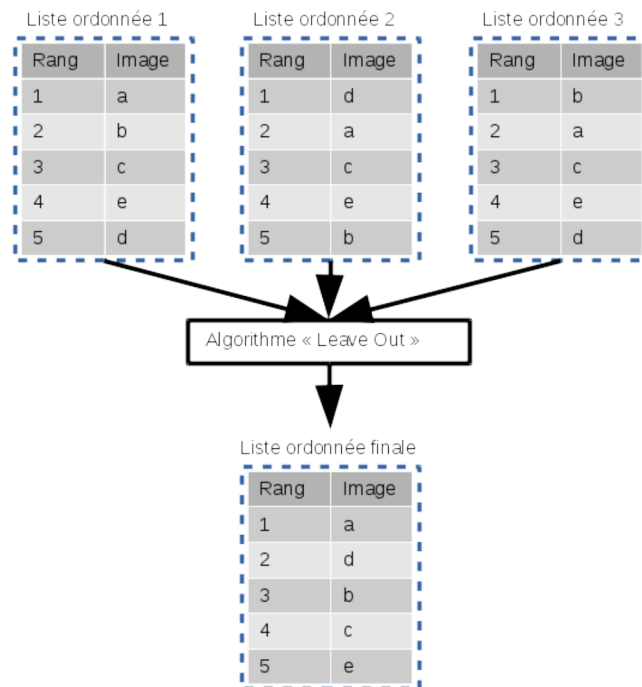


FIGURE 1.20: Exemple de fusion de 3 listes ordonnées en utilisant l'algorithme "Leave Out" (reproduit à partir de [28])

Les fonctions de fusion "BC", "IRP" et "LO" ont prouvé leurs performances comparées à d'autres méthodes de fusion mais elles présentent certains inconvénients. D'abord, le degré de fiabilité des différentes listes n'est pas pris en compte. Ensuite, le degré de conflit ou d'accord entre les listes n'est pas exploité alors que ça aurait pu apporter une information utile. Finalement, dans le cas de la fonction de fusion "BC", le choix de l'ordre dont les listes sont fusionnées est arbitraire ce qui peut influencer le degré de précision.

1.3.5.3 Les fonctions de fusion statistiques

Les fonctions de fusion établies dans le cadre de la théorie des fonctions de croyance font partie des fonctions de fusion statistiques. Ces fonctions seront présentées en détails dans le prochain chapitre et feront l'objet d'une étude détaillée.

Le modèle d'inférence bayésienne fait aussi partie des fonctions de fusion statistiques. Défini dans [29], ce modèle impose une indépendance conditionnelle entre les classifieurs. Notons $i \in \{1, \dots, I\}$ l'ensemble des classifieurs à fusionner tel qu'une matrice de confusion notée $M_{(i)}$ est assignée à chacun. L'ensemble de toutes les matrices de confusion est noté M . Notons que $\alpha_{(i)}$ représente les paramètres relatifs à une matrice de confusion $M_{(i)}$ et que α est l'ensemble des paramètres relatifs à toutes les matrices. Parallèlement, une distribution de probabilité notée $P_{i,j}$ issue d'un classifieur S_i est associée à chaque individu j comme le montre la figure 1.21. La distribution de probabilité dépend du taux d'existence d'une classe dans la base de données. Notons K le vecteur y faisant référence. Finalement, en se basant sur les distributions de probabilités $P_{i,j}$ et la matrice de confusion de chaque classifieur S_i , nous pouvons calculer la probabilité $P_{i,j}$ accordée par chaque classifieur i pour un individu à reconnaître j . La probabilité résultante de la fusion des différents classifieurs est définie ainsi :

$$p(M, P, p|\alpha, K) = \prod_{j=1}^N \{K_{P_i} \prod_{i=1}^I M_i\} p(M|\alpha) \quad (1.5)$$




FIGURE 1.21: Schéma du modèle graphique de l'inférence bayésienne permettant la fusion de données à partir de plusieurs sources de données

L'un des inconvénients majeurs de cette fonction de fusion est qu'elle se base sur l'opérateur produit. Lorsqu'un ou plusieurs classifieurs ont une probabilité très proche de zéro, le résultat final tend vers zéro à son tour. Dans ce cas, la fonction de fusion ne remplira pas son rôle [24].

1.3.5.4 Les fonctions de fusion basées sur des méthodes de calcul intelligent

L'apprentissage profond ou le “deep learning” en anglais est l'une des méthodes de calcul intelligent les plus connues, les plus utilisées et les plus performantes. Le deep learning est un ensemble de méthodes d'apprentissage automatique. Avec ses architectures basées sur des transformations non linéaires, le deep learning permet de modéliser les données avec un niveau d'abstraction assez élevé. Il a permis des progrès importants dans différents domaines tels que la vision par ordinateur, la reconnaissance faciale, la reconnaissance vocale et même la reconnaissance d'espèces d'arbres [30].

Malgré son efficacité, le deep learning présente plusieurs inconvénients. Dans un réseau deep, nous ne pouvons pas savoir ce qui se passe exactement puisque les données sont modélisées dans un niveau d'abstraction assez élevé. Nous pouvons dire que nous parlons d'une boîte noire où l'utilisateur ne sait pas ce qui se passe à l'intérieur. De plus, ces algorithmes nécessitent un temps de calcul important pour calculer des milliers de paramètres lors de l'apprentissage. Pour réduire ce temps de calcul, il faut disposer de machines de calcul puissantes. Dans notre cas, nous voudrions que le système de reconnaissance d'espèces d'arbres soit implémenté sur un smartphone et soit capable d'effectuer tous les calculs en utilisant l'espace mémoire et le processeur disponibles sur l'appareil de l'utilisateur. Ceci pourrait poser un problème avec un réseau deep à cause de la taille mémoire qu'il nécessite pour stocker tous ses paramètres et de la puissance de processeur nécessaire pour effectuer l'ensemble des calculs.

Dans cette section, les fonctions de fusion les plus communes sont introduites. Nous allons maintenant présenter les fonctions de fusion qui ont été utilisées dans le cadre de la reconnaissance d'espèces d'arbres.

1.3.6 Systèmes de fusion pour la reconnaissance d'espèces d'arbres

La thématique de reconnaissance d'espèces d'arbres à partir de plusieurs organes ne cesse d'attirer de plus en plus de chercheurs dans le monde entier. D'une part, cette thématique présente un vrai défi vu sa complexité. D'autre part, pour la plupart des chercheurs, la reconnaissance des espèces d'arbres entre dans une vision globale qui consiste à faciliter l'entrée de toute personne dans le monde de la botanique. Dans ce cadre, plusieurs défis ont été organisés par la campagne d'évaluation “ImageClef”⁹. Ces défis permettent d'avoir une idée sur les techniques et les outils utilisés afin de fusionner plusieurs sources d'information

9. <http://www.imageclef.org/>

et faire la reconnaissance. Dans tout ce qui a été fait nous nous intéressons particulièrement à l'étape de fusion.

Le premier défi a été lancé en 2011 avec "ImageClef 2011"¹⁰ qui a englobé 4 tâches dont la tâche relative à la reconnaissance de 71 espèces d'arbres les plus communes en France Métropolitaine : "Plant identification"¹¹. Contenant 5436 images de feuilles, la base de données est répartie en 3 catégories : les scans, les pseudo-scans et les photos prises en milieu naturel. En 2012, le défi¹² a été lancé sur une base de données plus grande incluant 11572 images de feuilles. Pour ces 2 défis, les méthodes proposées se focalisent principalement sur le choix des attributs à extraire ainsi que le choix de la méthode de classification [31] [32]. Dans toutes les chaînes de traitement proposées (à l'exception de celle proposée dans [33]), la fusion est faite au niveau des attributs consistant ainsi à créer, pour une image donnée, un vecteur issu de la concaténation des différents vecteurs d'attributs. En 2013¹³, la reconnaissance ne se basait plus uniquement sur les photos des feuilles, mais aussi sur celles des fleurs, des fruits, des écorces et de l'aspect global de l'arbre. En plus, le défi ne concernait plus uniquement la reconnaissance d'espèces d'arbres mais aussi des espèces d'herbes. Il s'agissait de reconnaître 250 espèces d'herbes et d'arbres de France. En 2014¹⁴, le nombre d'espèces a évolué d'avantage pour englober 500 espèces d'herbes, d'arbres et de fougères présentés par plus de 60000 images. Un nouveau organe est pris en compte en plus des 5 cités : les photos des branches. Contrairement aux années précédentes, le défi ne consiste plus à reconnaître chaque image séparément, mais à reconnaître l'espèce à partir d'une observation. En effet, une observation est formée de plusieurs images des différents organes pris à partir du même arbre, le même jour et avec le même appareil photo comme le montre la figure 1.22. Des informations concernant la date de la prise de la photo, l'auteur, les données GPS,... ont aussi été fournies avec chaque image.




FIGURE 1.22: Exemple d'une observation prise par le même utilisateur, le même jour et avec le même appareil photo

10. <http://www.imageclef.org/2011>

11. <http://www.imageclef.org/2011/Plants>

12. <http://www.imageclef.org/2012/plant>

13. <http://www.imageclef.org/2013/plant>

14. <http://www.imageclef.org/2014/lifeclef/plant>

Le nombre d'espèces à reconnaître a continué à augmenter en 2015¹⁵ pour atteindre environ 1000 espèces représentées par 113205 images. En 2016¹⁶, des informations concernant la vérité taxinomique au sol ont été fournies afin de faciliter la tâche. En 2017¹⁷, le défi se complique de plus en plus avec 10000 espèces de la flore de l'Europe occidentale, de la flore nord-américaine et aussi des espèces végétales utilisées partout dans le monde.

On note qu'à partir de 2013, la reconnaissance des espèces ne se basait plus sur un seul organe (une seule source d'informations) mais plutôt sur plusieurs organes (plusieurs sources d'informations). Ceci a fait qu'une attention plus importante a été portée à l'étape de fusion. Nous notons alors l'utilisation des méthodes de fusion linéaires telles que la moyenne [33] [34], le maximum [35] [36] et la somme [35]. Nous notons aussi l'utilisation de méthodes de fusion non linéaires telles que la somme pondérée [37] [36] [38], la moyenne pondérée [39], le vote majoritaire [40] et le vote majoritaire pondéré [41] [42], l'algorithme "IRP" [38] [42], l'algorithme "Borda Count" [42] [43], l'algorithme "BordaMNZ" [38] et l'algorithme "Leave Out" [44] [45]. En ce qui concerne les fonctions de fusion statistiques, nous remarquons que la théorie des fonctions de croyance n'a jamais été utilisée. Par contre, l'inférence bayésienne a été présente dans plusieurs travaux [35] [46]. A partir de 2015, la plupart des travaux se sont orientés vers les fonctions de fusion basées sur des méthodes de calcul intelligent et plus précisément vers l'apprentissage profond ou le "deep learning" en anglais [47] [48] [49] [50] [51].

Comme le montre les résultats des défis ImageClef 2013¹⁸, 2014¹⁹ et 2015²⁰ présentés en Annexe A, les méthodes utilisées pour la fusion n'ont pas amélioré les performances du système de reconnaissance. Nous remarquons que l'utilisation des fleurs seules permettent des performances plus élevées qu'en fusionnant des informations sur les différents organes. Ceci reflète la complexité du problème mais il se peut aussi que les méthodes de fusion utilisées n'étaient pas capables de prendre en compte les imperfections des données. Nous notons qu'à partir de 2016, la vision du défi a changé. Avant 2016, le défi considérait chaque modalité séparément. Les taux de bonne classification sont donc calculés pour chaque modalité. Ensuite, les résultats obtenus sont fusionnés permettant ainsi d'avoir un taux de bonne classification global issu de la fusion de toutes les modalités. À partir de 2016, le but n'est plus de faire la reconnaissance de chaque modalité séparément des autres, mais plutôt de considérer toutes les observations disponibles pour une espèce en tant qu'une seule source

15. <http://www.imageclef.org/lifeclef/2015/plant>

16. <http://www.imageclef.org/lifeclef/2016/plant>

17. <http://www.imageclef.org/lifeclef/2017/plant>

18. <http://www.imageclef.org/2013/plant>

19. <http://www.imageclef.org/2014/lifeclef/plant>

20. <http://www.imageclef.org/lifeclef/2015/plant>

d'informations. Le résultat final ne permet plus de voir les performances de chaque modalité séparément des autres.

1.4 La théorie des fonctions de croyance

1.4.1 Où se situe cette théorie par rapport aux théories de l'incertain

Le processus de fusion d'informations englobe généralement 2 phases : l'identification des sources de données et la fusion des données qui y sont issues. La nature et la qualité des données peuvent largement influencer la robustesse et la réponse du système de fusion. Ces données souffrent généralement de plusieurs aspects d'imperfections. Elles peuvent être incertaines, imprécises, incomplètes, non-fiables... Dans ce cadre, plusieurs théories appelées "théories de l'incertain" ont été mises en place. Chacune de ces théories vise à gérer un ou plusieurs types d'imperfections.

La théorie des probabilités est la plus ancienne de ces théories. Elle offre un cadre idéal pour gérer l'incertitude des données et a l'avantage d'être relativement simple d'utilisation. Cette théorie présente malgré tout quelques limitations surtout lorsqu'il s'agit de gérer des données caractérisées par non seulement leur incertitude mais aussi leur imprécision, incomplétude... Une autre théorie appelée "théorie des ensembles flous" a été ensuite introduite par Zadeh en 1965 [52]. Cette théorie, complétant assez bien la théorie des probabilités, vise à traiter l'imprécision des données. La simplicité relative de cette méthode et sa capacité à gérer l'incertitude et l'imprécision des données ont fait sa réputation. En se basant sur la théorie des ensembles flous, Zadeh a ensuite proposé une autre théorie appelée "théorie des possibilités". Plus flexible que la théorie des probabilités et parfaitement compatible avec l'objectif consistant à mieux gérer l'incertitude, la théorie des possibilités permet à l'utilisateur de résoudre des problèmes complexes en s'adaptant aux informations disponibles. Parallèlement aux théories mentionnées ci-dessus, une autre théorie appelée "théorie des fonctions de croyance" a été introduite par Shafer en 1976 [53]. Cette théorie fait partie des théories de l'incertain les plus puissantes. Elle tire son importance de sa richesse en termes d'outils permettant de gérer l'incertitude et l'imprécision. La théorie des probabilités et la théorie des possibilités sont des cas particuliers de la théorie des fonctions de croyance ce qui montre que cette théorie offre un cadre général pour le traitement d'informations imparfaites. Cette théorie permet une meilleure gestion des informations imprécises, conflictuelles et incertaines.

1.4.2 Les fonctions basiques

Soit $\Omega = \{\omega_1, \omega_2, \dots, \omega_N\}$ l'espace de discernement formé par N hypothèses exclusives et exhaustives ω_i . L'ensemble de tous les sous-ensembles A de Ω est appelé l'ensemble puissance de Ω et est noté $2^\Omega = \{A | A \subseteq \Omega\} = \{\emptyset, \omega_1, \omega_2, \dots, \omega_N, \omega_1 \cup \omega_2, \dots, \Omega\}$. Une fonction de masse sur Ω est une application $m^\Omega : 2^\Omega \rightarrow [0, 1]$ telle que :

$$\sum_{A \subseteq \Omega} m(A) = 1 \quad (1.6)$$

La masse $m(A)$ appelée bba (basic belief assignment) représente la croyance accordée à la proposition A . Les sous-ensembles A de Ω ayant une masse non nulle sont appelés des éléments focaux. La fonction de masse $m(\Omega) = 1$ représente l'ignorance totale.

Contrairement à la bba qui représente uniquement la masse accordée exactement à une proposition A , Glenn Shafer définit d'autres mesures appelées fonction de croyance "Bel" et fonction de plausibilité "Pl". La fonction de croyance "Bel" représente la croyance totale accordée à une proposition A sans qu'elle soit accordée à la proposition \bar{A} et est définie par :

$$Bel(A) = \sum_{\emptyset \neq B \subseteq A} m(B), \forall A \subseteq \Omega \quad (1.7)$$

La fonction de plausibilité "Pl" quantifie le degré maximal de croyance qui pourrait être accordé à un sous-ensemble A de Ω . En effet, cette fonction contient les éléments dont la croyance ne contredit pas A et est définie par :

$$Pl(A) = \sum_{B \cap A \neq \emptyset} m(B), \forall A \subseteq \Omega \quad (1.8)$$

La théorie des fonctions de croyance a été mise en place afin de mieux gérer les imperfections qui peuvent entacher des données. Dans le contexte de la reconnaissance d'espèces d'arbres, le conflit entre les sources représente l'un des problèmes majeurs. Pour palier à cela, la théorie des fonctions de croyance offre 2 catégories de solutions [54]. La première se résume dans les différentes règles de combinaison mises en place afin de gérer le conflit entre les sources. Nous citons à titre d'exemple la règle de combinaison de Smet [55], la règle adaptative de Dubois et Prade [56], la règle de Yager [57],... La deuxième catégorie de solutions consiste à corriger les fonctions de masse par différents mécanismes afin qu'elles soient assez représentatives des données. Ces mécanismes incluent le discounting, le discounting contextuel [58] et le renforcement des fonctions de masses issues des différentes sources de données

en prenant en compte leur fiabilité globale, leur fiabilité contextuelle ou leur degré de véracité [59].

Les règles de combinaison ainsi que les différents mécanismes de correction seront étudiés en profondeur respectivement dans les chapitres 2 et 3.

1.4.3 Autres outils

Dans le cadre de la théorie des fonctions de croyance, d'autres outils sont proposés permettant ainsi plus de flexibilités et offrant à l'utilisateur un cadre complet pour gérer ses données. Parmi ces outils, nous citons les opérations de conditionnement et de déconditionnement permettant la prise en compte ou non d'une information jugée certaine. Ces opérations visent à mieux maîtriser l'espace de discernement en le réduisant avec le conditionnement et en l'agrandissant avec le déconditionnement. Elles permettent ainsi de gérer l'imprécision des données. Nous citons aussi les opérations de raffinement et de grossissement permettant la transition d'un espace de discernement grossier à un autre plus raffiné. Ces outils seront présentés dans le chapitre 2.

1.5 Conclusion

La fusion de plusieurs sources d'informations afin d'améliorer les performances obtenus avec une seule source est une technique assez répandue, efficace et permettant de bénéficier de la complémentarité existante entre les différentes sources d'informations. Néanmoins, dans un système de fusion, chaque étape doit être soigneusement étudiée et adaptée à l'application visée afin d'exploiter au maximum la diversité des informations disponibles et d'en tirer le maximum d'informations utiles. Dans le cadre de la reconnaissance d'espèces d'arbres, l'idée consiste à fusionner des informations issues de plusieurs organes de l'arbre (les feuilles et les écorces dans un premier temps) afin d'améliorer la reconnaissance. En effet, des espèces non discriminables avec les feuilles seulement pourraient être discriminables en rajoutant l'information sur l'écorce.

Dans ce chapitre, nous avons tenté de montrer les difficultés liées à la reconnaissance de l'espèce de l'arbre à partir des feuilles et des écorces. D'une part, ces difficultés sont liées aux ambiguïtés au sein d'une même espèce ainsi que les similarités entre des espèces différentes. D'autre part, les facteurs naturels viennent compliquer la tâche : l'âge de l'arbre et l'exposition à la lumière. Tous ces facteurs ajoutent de l'incertitude et de la complexité au problème de reconnaissance d'où la nécessité de mettre en place un système de fusion qui soit capable de

gérer tous les types d'imperfections et de tirer profit des informations disponibles sans être trop influencé par des informations imparfaites.

Dans le cadre de la fusion d'informations, il existe différents niveaux de fusion. Pour l'application, nous avons choisi de faire la fusion au plus haut niveau qui est le niveau décision. Nous avons également présenté les différentes topologies de fusion pouvant être utilisées en montrant l'apport de chacune. Finalement, nous avons montré que les fonctions de fusion peuvent être divisées en plusieurs catégories en expliquant les avantages et les inconvénients de chacune. Nous avons aussi présenté les différentes techniques de fusion qui ont été utilisées dans la littérature. La théorie des fonctions de croyance a été introduite. Le système de fusion proposée est mis en place dans le cadre de cette théorie. Ce choix s'appuie sur le fait que la théorie des fonctions de croyance présente un cadre bien formalisé pour traiter des données imparfaites. Dans le prochain chapitre, la modalité feuille est étudiée de plus près. Les données qui y sont issues sont analysées afin d'avoir une idée sur les imperfections existantes.

Chapitre 2

Modalité feuille : classification et analyse des données à fusionner

D'après les botanistes, les feuilles des arbres sont souvent considérées comme l'organe le plus discriminant lors de la reconnaissance des espèces d'arbres. Pour certaines espèces, il est même suffisant pour faire la reconnaissance sans avoir besoin de regarder les autres organes. Une feuille est considérée comme une seule source de données (au niveau modalité), mais, elle regroupe implicitement plusieurs sources (au niveau mesures) : les caractéristiques de la feuille.

Chaque caractéristique telle que la forme globale, le bord, la base et le sommet peut être considérée comme une source de données issue de la modalité feuille. Actuellement, les botanistes se basent sur ces caractéristiques pour faire la reconnaissance. Comme nous cherchons à reproduire leurs stratégies, nous nous intéressons aux mêmes caractéristiques que ces experts. Nous notons que l'extraction d'attributs décrivant la forme générale, le bord, la base et le sommet a été faite à partir de photos de feuilles prises en milieu naturel.

Pour pouvoir reconnaître une espèce d'arbre à partir de données extraites de photos de feuilles réelles, une chaîne de traitement spécifique doit être mise en place. Cette chaîne doit permettre de :

- respecter l'aspect éducatif de l'application,
- réduire au maximum la complexité calculatoire pour que l'application puisse, à terme, s'exécuter sur un Smart-phone,
- gérer au mieux les imperfections existantes telles que l'incertitude, l'imprécision et le conflit,
- gérer la fusion de plusieurs sources de données sans que la non-fiabilité de l'une affecte l'autre,

- fournir à l'utilisateur une liste réduite des espèces les plus probables.

Dans ce chapitre nous allons étudier et classifier les données extraites à partir des feuilles. La première section permet de découvrir les feuilles de plus près. La deuxième section présente les différents blocs de la chaîne de traitement. La troisième section permet une évaluation des données à fusionner.

2.1 Les feuilles de plus près

2.1.1 Qu'est ce qu'une feuille ?

Une feuille est définie dans l'encyclopédie LAROUSSE par :

« Une feuille est une expansion latérale de la tige des plantes, caractérisée par sa forme aplatie, sa symétrie bilatérale, ses dimensions définies et sa croissance limitée dans le temps et l'espace. »

Les feuilles sont donc un prolongement des tiges caractérisées par une certaine forme tout en ayant une symétrie par rapport à l'axe central et des dimensions bien définies.

Les feuilles présentent une importante diversité au niveau de leur forme globale comme le montre la figure 2.1. A travers cette figure, nous remarquons que les formes des feuilles



FIGURE 2.1: Importante diversité au niveau des formes des feuilles appartenant à différentes espèces.

peuvent être divisées en 2 catégories principales :

- les feuilles simples : constituées d'un seul limbe continu
- les feuilles composées : constituées de plusieurs folioles

Ces deux catégories sont illustrées dans la figure 2.2.




FIGURE 2.2: Feuille composée et feuille simple

2.1.2 Description botanique des feuilles

Afin de décrire les différentes caractéristiques morphologiques des feuilles, les botanistes utilisent des termes précis. Ces termes descriptifs sont utilisés dans les flores et les clés de détermination. Ils permettent de qualifier les propriétés des feuilles tout en utilisant des mots géométriques cherchant à associer une forme de référence aux caractéristiques de la feuille observée.

2.1.2.1 La forme générale

La forme générale de la feuille est la caractéristique la plus apparente et la plus facile à utiliser afin de discriminer des espèces. Néanmoins, il existe une grande variabilité morphologique au niveau de la forme de la feuille en fonction de l'espèce et de la position de la feuille sur la tige. D'après [5], les formes de feuilles les plus communes sont celles représentées dans le tableau 2.1.


En tant qu'objets naturels, les feuilles ont tendance à changer de formes au fur et à mesure de leur croissance. Ainsi, une espèce peut avoir des feuilles d'une certaine forme en début de croissance, passer par différentes formes au cours de sa croissance jusqu'à avoir une forme de feuille stable à partir d'un certain âge. Ceci est illustré dans la figure 2.3. Pour certaines espèces comme l'espèce *Broussonetia papyrifera* L., des feuilles de formes variables peuvent exister sur une même branche.

2.1.2.2 La base

En plus de la forme générale de la feuille, d'autres descriptions plus locales peuvent aider dans la discrimination des espèces. La forme de la base est une caractéristique assez importante. En fonction de l'angle que forme le limbe avec la tige, la base de la feuille peut être

	Linéaire	très étroite et allongée, aux bords quasiment parallèles
	Lancéolée	étroite et allongée, pointue au sommet et généralement plus large à la base
	Elliptique	terme vague, étroite ou large, généralement arrondie et égale à la base et au sommet
	Oblongue	allongée, aux bords quasiment parallèle, arrondie à la base et au sommet
	Ovale	en forme d'oeuf, de largeur moyenne, plus large et arrondie à la base qu'au sommet
	Obovale	opposé à ovale, de largeur moyenne, plus large et arrondie au sommet qu'à la base
	Rhomboidale	de la forme d'un losange, de largeur moyenne, égale à la base et au sommet
	Spatulée	assez étroite, plus large et arrondie au sommet, la base s'étirant vers le pétiole
	Orbiculaire	de la forme d'un cercle, très large et très arrondie à la base et au sommet
	Triangulaire	de la forme d'un triangle, plus au moins large à la base, très pointue au sommet
	Cordée	de la forme d'un coeur, large et incurvée à la base, plus ou moins pointue au sommet
	Palmatilobée	limbe séparé en plusieurs lobes aux nervures se rejoignant à l'extrémité du pétiole
	Pennatilobée	limbe séparé en plusieurs lobes aux nervures échelonnées sur la nervure principale
	Trifoliée	limbe divisé en trois folioles uniquement qui se rejoignent à l'extrémité du pétiole
	Digitée	limbe divisé en plusieurs folioles qui se rejoignent toutes à l'extrémité du pétiole
	Paripennée	limbe divisé en un nombre pair de folioles échelonnées le long du rachis
	Imparipennée	limbe divisé en un nombre impair de folioles avec une foliole terminale

TABLE 2.1: Les formes de feuilles les plus communes (photos reproduites à partir de [5])

FIGURE 2.3: Variation de la forme générale de la feuille du *Broussonetia papyrifera* L. passant progressivement de ovale à palmatilobée.

décrite de différentes manières. Les descriptions les plus communes sont illustrées dans le tableau 2.2.









	Atténuée	limbe très étroit à la base, qui se prolonge en pétiole
	En coin	limbe assez étroit à la base, qui forme un angle aigu assez marqué
	Arrondie	limbe plutôt large à la base, qui forme un angle obtus arrondi et peu marqué
	Oblique	limbe à la base dissymétrique, l'angle s'ouvrant plus largement d'un côté que de l'autre
	Décrochée	limbe à la base dissymétrique, un côté du limbe s'attachant plus bas que l'autre
	Tronquée	limbe aplati à la base, qui forme un angle plat sur une largeur plus au moins importante
	En coeur	limbe large à la base, qui forme un angle rentrant, qui s'arrondit de part et d'autre
	Auriculée	limbe assez large à la base, qui forme deux petites bosses de part et d'autre

TABLE 2.2: Les formes les plus communes de la base d'une feuille (les photos sont reproduites à partir de [5])

2.1.2.3 Le sommet

Le sommet de la feuille présente aussi une caractéristique à prendre en compte pour la discrimination des espèces. L'aspect de l'angle formé au sommet de la feuille est la référence sur laquelle les botanistes se basent afin d'associer une description à chaque aspect. Les descriptions de sommet les plus courantes sont illustrées dans le tableau 2.3.

2.1.2.4 Le bord

Finalement, le bord de la feuille peut être parfaitement lisse comme il peut présenter des dents plus ou moins marquées. Ces différentes formes que peut prendre le bord représentent à elles mêmes une caractéristique morphologique utilisée par les botanistes et pouvant être discriminante dans plusieurs cas. Parmi les descriptions morphologiques pouvant être attribuées au bord de la feuille, les plus communes sont celles illustrées dans le tableau 2.4.

À travers les tableaux 2.1, 2.2, 2.3 et 2.4, nous remarquons l'importante variabilité de l'aspect de la feuille. D'après les botanistes, ces différentes caractéristiques sont les plus importantes et discriminantes lors de la reconnaissance des espèces d'arbres. Le système de reconnaissance se fondera également sur ces caractéristiques.









	Acuminé	limbe très étroit, qui se termine par une pointe effilée plus ou moins longue
	Aigu	limbe se rétrécissant au sommet, en formant une pointe avec un angle aigu
	Obtus	limbe se rétrécissant au sommet, en formant une pointe avec un angle obtus
	Mucroné	limbe se rétrécissant au sommet, qui se termine par une pointe courte dure et arrondie
	Arrondi	lisse assez large au sommet, sans pointe mais s'arrondissant
	Tronqué	limbe aplati au sommet, qui forme un angle plat plus ou moins large
	Rétus	limbe assez large au sommet, qui forme un angle rentrant
	Echancré	limbe assez large au sommet, qui forme une encoche marquée

TABLE 2.3: Les formes les plus communes du sommet (photos reproduites à partir de [5])












	Entier	bord parfaitement lisse, sans aucune aspérité ni aucune échancrure
	Cilié	bord présentant à sa marge de petites poils ou cils fins
	Ondulé	bord sans aspérités mais présentant des sinuosités larges et peu marquées
	Crénelé	bord présentant des dents de petite taille et très arrondies
	Denticulé	bord présentant des dents marquées, mais très fines
	Denté	bord présentant des dents bien marquées, qu'elles soient de taille petite ou moyenne
	Denté en scie	bord présentant des dents bien marquées, toutes orientées vers l'apex de la feuille
	Doublement denté	bord présentant deux niveaux de dents, les petites entre les plus grandes
	Épineux	bord présentant des dents larges et très pointues, voire des épines
	Sinué	bord sans dents mais présentant des sinuosités marquées, de taille moyenne
	Lobé	bord présentant des lobes plus ou moins marqués, et de larges sinus

TABLE 2.4: Les formes les plus communes du bord (photos reproduites à partir de [5])

2.2 la chaîne de traitement

Pour reconnaître l'espèce d'un arbre à partir de la photo d'une feuille, une chaîne de traitement est proposée. Cette chaîne est formée de cinq étapes principales comme l'illustre la

figure 2.4 :




FIGURE 2.4: Chaîne de traitement globale pour la reconnaissance d'espèces d'arbres

- l'acquisition et le pré-traitement de la photo
- l'extraction d'attributs
- la classification
- la fusion
- la prise de décision

Dans ce chapitre, nous détaillons les deux premières étapes de la chaîne de traitement. L'étape de la fusion et de la prise de décision seront détaillées dans le chapitre suivant.

2.2.1 L'acquisition et le pré-traitement de la photo

L'étape d'acquisition et de traitement de la photo ainsi que l'étape d'extraction d'attributs ont fait l'objet de la thèse de Guillaume Cerutti menée au sein du Laboratoire d'InfoRmatique en Image et Systèmes d'information (LIRIS) [5]. Les principaux outils et méthodes utilisées pour la réalisation de ses étapes sont rappelés brièvement.

La prise de photo effectuée en milieu naturel par l'utilisateur est suivie d'une étape de segmentation permettant de séparer la feuille de son arrière plan. La segmentation constitue le point de départ de la chaîne de traitement et présente donc une étape importante qui va influencer tout le reste du processus. Cette étape a fait l'objet d'une étude détaillée dans [5] [37] [60]. L'idée fut de décomposer le processus de segmentation en deux étapes :

1. la première étape prend en compte la connaissance à priori sur la forme de la feuille par un modèle polygonal se déformant progressivement pour estimer la forme globale de la feuille. L'idée fut donc de partir d'une forme connue, l'optimiser en faisant varier ses paramètres de façon à ce qu'elle prenne la forme de la feuille en question et se fonde sur la carte de dissimilarité des couleurs afin d'améliorer l'ajustement à la feuille. Les algorithmes mis en place nécessitent l'intervention de l'utilisateur qui doit préciser une région initiale à l'intérieur de la feuille. Cette région permet d'une part de fixer le point de départ pour le calcul des cartes de dissimilarité. D'autre part, elle permet d'éviter une confusion avec l'arrière plan. Sur ce principe, deux modèles déformables ont été

mis en place traitant respectivement les feuilles simples et les feuilles composées. La connaissance à priori sur la forme évite le débordement dans les régions voisines et permet le maintien d'une forme de feuille plausible.

2. la deuxième étape accorde une certaine flexibilité au modèle obtenu pour qu'il puisse s'étendre et s'adapter localement au contour de la feuille. Cette flexibilité a été assurée grâce à l'utilisation des contours actifs guidés [61]. En effet, le contour correspond bien évidemment au bord de la feuille et donc la transition entre deux régions, correspond à une zone de forts gradients. Il a été néanmoins remarqué qu'un fort gradient n'est pas toujours détecté ce qui nécessite en plus l'utilisation de la carte de dissimilarité des couleurs pour distinguer la feuille de son arrière plan. Une fonction de guidage a permis ensuite de déterminer en tout point de l'image l'intensité avec laquelle le contour devrait être repoussé vers la forme polygonale.

2.2.2 L'extraction d'attributs

2.2.2.1 Attributs caractérisant la forme globale

La feuille étant segmentée, l'étape suivante est l'extraction d'attributs décrivant les caractéristiques morphologiques des feuilles. L'étude menée dans [37] aboutit à l'extraction de quatre vecteurs d'attributs caractérisant la forme globale, la base, le sommet et le bord. L'extraction a nécessité la mise en place d'un certain nombre d'hypothèses dont le but était d'attirer l'attention de l'utilisateur vers les parties qui sont importantes pour un botaniste (forme globale, bord, base et sommet). Pour cela, des notions sémantiques ont été appliquées sur l'ensemble des pixels à traiter qui, en l'état brut, étaient peu porteurs de sens. La forme de la feuille a permis alors une description de haut niveau des propriétés de la feuille adoptant ainsi la stratégie utilisée par les botanistes. La modélisation polygonale de la forme globale a énormément facilité l'interprétation du contour. Cette modélisation a permis l'extraction d'un vecteur de 9 attributs noté \vec{A}_F caractérisant la forme de la feuille [62].

2.2.2.2 Attributs caractérisant le contour

Suite à la mise en place des correspondances entre les chaînes de points dominants et les courbures des feuilles [63], une représentation structurelle du bord de la feuille a été proposée. Deux séquences parallèles de points correspondant au points les plus importants sont formées. Une troisième séquence représentant la médiane entre ces deux séquences est également formée et est considérée comme le descripteur de la modalité bord. Différentes grandeurs permettant de résumer les propriétés du bord de la feuille ont été calculées. Elles

consistent à calculer la fraction du bord pouvant être considérée comme faisant partie d'une pointe, d'un creux ou d'une portion lisse. Elles permettent aussi de caractériser les points concaves et convexes, la courbure, l'orientation et les écarts en position entre les points. Au final, 13 paramètres sont extraits pour caractériser les propriétés du contour sous forme d'un vecteur noté \vec{A}_C .

2.2.2.3 Attributs caractérisant la base et le sommet

L'interprétation du contour de la feuille a permis également l'extraction d'autres paramètres caractérisant des zones d'intérêts particulières. Ces zones sont la base et le sommet. Comme les différentes formes de la base et du sommet existantes dans la nature sont à priori connues, l'idée fut d'utiliser la méthode des modèles paramétriques déformables comme pour la détection de la forme globale de la feuille. Cette méthode a permis d'optimiser les paramètres de construction des modèles pour qu'ils correspondent au mieux à la forme du sommet et de la base. Au final, un vecteur de paramètres a été extrait pour caractériser la forme de la base et du sommet. Certains de ces paramètres représentent les formes retrouvées sur la base et le sommet. D'autres sont peu porteurs de sens puisqu'il s'agit purement de paramètres de construction. Ce vecteur d'attributs est de taille 9 et est noté \vec{A}_{BS} .

2.2.3 La classification

Les attributs issus des travaux de la thèse de Guillaume Cerutti [5] et présentés ci-dessus sont utilisés pour l'étape de classification.

Un classifieur S_i est mis en place pour chaque caractéristique comme le montre la figure 2.5. Chaque classifieur est basé sur une forêt aléatoire [64]. Ce choix a été pris suite à des travaux faits dans le cadre du projet ReVeS¹, qui ont montré que les forêts aléatoires présentent l'une des méthodes de classification les plus aptes à traiter le type de données disponibles pour deux raisons principales : l'algorithme d'apprentissage des forêts aléatoires emploie le principe du bagging ainsi que la méthode des espaces aléatoires. En d'autres termes, c'est un algorithme basé sur une stratégie aléatoire permettant d'améliorer l'ajustement par une combinaison d'un grand nombre de modèles tout en évitant ou contrôlant le sur-ajustement. Le BAGGING est l'acronyme de "Bootstrap AGGregatING". Proposé en 1996 par Breiman dans [65], il consiste à injecter de la diversité au niveau des données. Les forêts aléatoires proposées également par Breiman en 2001 est une amélioration du bagging spécifique aux modèles définis par des arbres binaires (CART) [64]. De nombreux articles comparatifs montrent leur efficacité pour

1. <http://liris.univ-lyon2.fr/reves/>

des problèmes réels complexes [66]. Dans le cadre de la reconnaissance d'espèces d'arbres, nous traitons ce type de problème. L'utilisation du principe du bagging pour la construction des forêts aléatoires permet d'injecter de la diversité aléatoirement dans les arbres de décision. Nous obtenons ainsi des classifieurs ayant des modèles assez différents. La fusion, basée sur le principe du vote majoritaire, des décisions prises par cet ensemble de classifieurs (200 classifieurs par forêt aléatoire) permet forcément des performances plus importantes que celles obtenues par un seul classifieur.

Une forêt aléatoire est formée de 200 arbres. Ce paramètre influence le taux de bonne classification : plus il existe d'arbres, meilleur est le taux de bonne classification. A partir d'un certain nombre d'arbres, les performances de la forêt aléatoire deviennent stables. Dans notre cas, et à travers les expériences faites en variant ce paramètre, il faut 1000 arbres pour obtenir le meilleur taux de bonne classification. Avec un nombre aussi élevé, les temps de calcul deviennent très importants. Le meilleur compromis entre taux de bonne classification et temps de calcul est obtenu pour un nombre d'arbres égale à 200.

Trois forêts aléatoires correspondant à la forme globale de la feuille, du bord et du sommet et de la base sont mis en place comme le montre la figure 2.5. La classification permet l'obtention de données exprimées dans un seul et même référentiel : le référentiel des espèces.




FIGURE 2.5: Mise en place d'un classifieur pour chaque caractéristique

2.2.3.1 La base de données d'apprentissage et de test

Comme la classification est supervisée, elle s'applique en deux étapes : l'étape d'apprentissage et l'étape de test. L'apprentissage consiste à entraîner les classifieurs grâce à une base de données d'apprentissage. L'étape de test permet de tester la capacité des classifieurs à reconnaître les classes déjà apprises. Le principe de la validation croisée est appliqué pour l'apprentissage et le test : un tirage aléatoire permet de sélectionner 90% de la base de données (formée de 5104 individus pour les 72 espèces représentées en Annexe F) pour l'apprentissage et 10% pour le test. Le tirage aléatoire est répété 10 fois. La moyenne obtenue est présentée sur les figures des résultats.

Il est important de noter que le nombre d'individus est variable d'une espèce à une autre. Certaines espèces sont représentées par un nombre réduit d'individus comme l'espèce *Betula Pubescens* : 4 individus au total dont 2 dans la base de données d'apprentissage et 2 dans la base de données de test. Par contre, d'autres espèces sont représentées par un nombre important d'individus comme l'espèce *Ulmus Minor* : 274 individus au total dont 137 dans la base d'apprentissage et 137 dans la base de test. Cette variation au niveau du nombre d'individus par espèce dépend fortement du degré de présence de chaque espèce sur le territoire français. Les espèces les plus présentes sont les plus prises en photos et donc plus présentes dans la base de données. Par contre, celles qui sont moins présentes sur le territoire, sont aussi moins présentes dans la base de données. En Annexe B un récapitulatif du nombre d'individus par espèce pour la base de données d'apprentissage et de test.

2.2.3.2 Stratégies de classification

Pour faire la classification dans l'espace des espèces, deux stratégies sont proposées : la première stratégie est basée sur l'utilisation d'une Base de Connaissances Expertes notée *BCE* et le passage par un espace de classification intermédiaire (l'espace des descriptions morphologiques). La deuxième stratégie consiste à faire la classification directement dans l'espace des espèces (sans passer par un espace de classification intermédiaire) [67].

2.2.3.3 Première stratégie de classification : utilisation de la Base de Connaissances Expertes

La première stratégie de classification consiste à utiliser la *BCE*. Cette base de connaissances mise en place par des experts contient la description morphologique des espèces par rapport aux différentes caractéristiques C_i (voir Annexe C). Pour chaque espèce, nous avons la description morphologique de sa forme globale, son contour, sa base et son sommet et vice versa (pour chaque description morphologique nous connaissons la liste des espèces correspondantes) [68].

Suivant cette approche, un individu est d'abord classé dans l'espace des descriptions morphologiques. A la sortie d'un classifieur S_i , une distribution de probabilité P_i entre les descriptions est obtenue. Ensuite, un passage vers l'espace des espèces est effectué grâce aux correspondances établies entre les descriptions morphologiques et les espèces comme l'illustre la figure 2.6.

Cette stratégie permet de mettre en avant l'aspect éducatif de l'application. En effet, le fonctionnement se fait étape par étape tout en utilisant les mêmes descriptions que celles

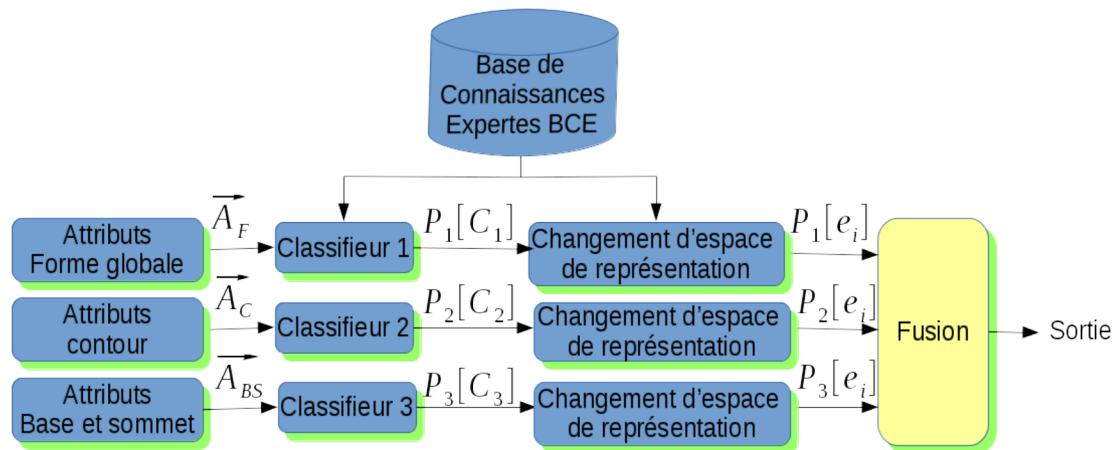


FIGURE 2.6: Première stratégie de classification : classification intermédiaire dans l'espace des descriptions morphologiques

utilisées par les botanistes et tout en suivant une démarche pédagogique simple à comprendre. L'utilisateur est donc capable de comprendre les raisons de chaque décision.

Malgré tous les avantages que présente cette stratégie de classification, son adoption engendre le rajout de beaucoup d'imprécision et de conflit au système de reconnaissance pour les raisons suivantes :

1. l'imprécision de la *BCE* : plusieurs espèces ont la même description morphologique concernant une ou plusieurs caractéristiques. Par exemple, il y a 42 espèces parmi 72 qui ont un contour denté (voir Annexe C). Ainsi, en passant de l'espace des descriptions morphologiques vers l'espace des espèces, une même croyance est accordée à un grand nombre d'espèces. Ceci rajoute de l'imprécision au problème de reconnaissance.
2. l'incomplétude de la *BCE* : pour plusieurs espèces, il manque la description d'une ou plusieurs caractéristiques. Par exemple pour l'espèce "Populus Tremula", il y a la description de la forme globale et du contour mais pas la description de la base et du sommet (figure 2.7). Cette incomplétude peut être due à la non pertinence de ces deux caractéristiques. Donc le botaniste a choisi de ne pas y prêter attention pour se concentrer uniquement sur les caractéristiques discriminantes.
3. descriptions morphologiques différentes d'un botaniste à un autre : une espèce décrite d'une certaine manière par un botaniste peut être décrite autrement par un autre. Ce désaccord entre les points de vue des botanistes est constaté à travers les 2 bases de données que nous avons pu avoir et qui sont présentées en Annexe C. Prenons l'exemple de l'espèce "Acer Campestre". Le botaniste de la première base de données considère que le contour de cette espèce est denté. Alors que le botaniste de la deuxième base de données considère qu'il est sinué ou lobé. Cet exemple est illustré à travers le Tableau 2.5.




FIGURE 2.7: Exemple d’une feuille appartenant à l’espèce “Populus Tremula” montrant la présence de la description morphologique de la forme globale et du contour mais l’absence de celle de la basse et du sommet




Espèce	description morphologique du contour		
	<i>BDE 1</i>	<i>BDE 2</i>	
Acer Campestre	denté 	sinué 	lobé 

TABLE 2.5: Tableau montrant que le contour d’une même espèce peut être décrit différemment par les botanistes

Dans [68], une étude détaillée du système de fusion dans le cas de cette première stratégie de classification a été menée. Les tests ont été réalisés sur des données autres que ceux utilisés dans l’ensemble de ce manuscrit. En effet, au démarrage de la thèse, nous sommes partis sur une base de données primaire dans l’attente de la base de données principale. Il s’agissait donc de 483 individus. Pour chaque individu cinq vecteurs d’attributs caractérisant la forme globale, la forme du lobe, la base, le sommet et le bord sont extraits. Cinq classifieurs ont donc été mis en place, un classifieur par caractéristique.

Il est important de noter que le concept de passage d’un espace de représentation à un

autre a été évoqué dans le cadre de la théorie des fonctions de croyance à travers le raffinement et le grossissement [69][70]. Ces concepts permettent de représenter un même espace à des granularités différentes. Mais, leur application exige que le nouveau cadre de discernement forme une partition du cadre de discernement initial. Cette condition n'est pas respectée dans notre cas.

Soit l'espace de discernement Ω_1 formant l'espace des espèces et soit l'espace de discernement Ω_2 formant l'espace des descriptions morphologiques de la forme globale de la feuille comme l'illustre la figure 2.8. Ω_2 est appelé raffinement de Ω_1 si et seulement si Ω_2 forme une partition de Ω_1 . Or, d'après la base de données représentée en Annexe C, cette condition n'est pas toujours respectée. En effet, une feuille appartenant à une espèce peut avoir plusieurs formes possibles comme l'illustre la figure 2.8. Il existe donc des intersections entre les sous-ensembles formant Ω_2 .

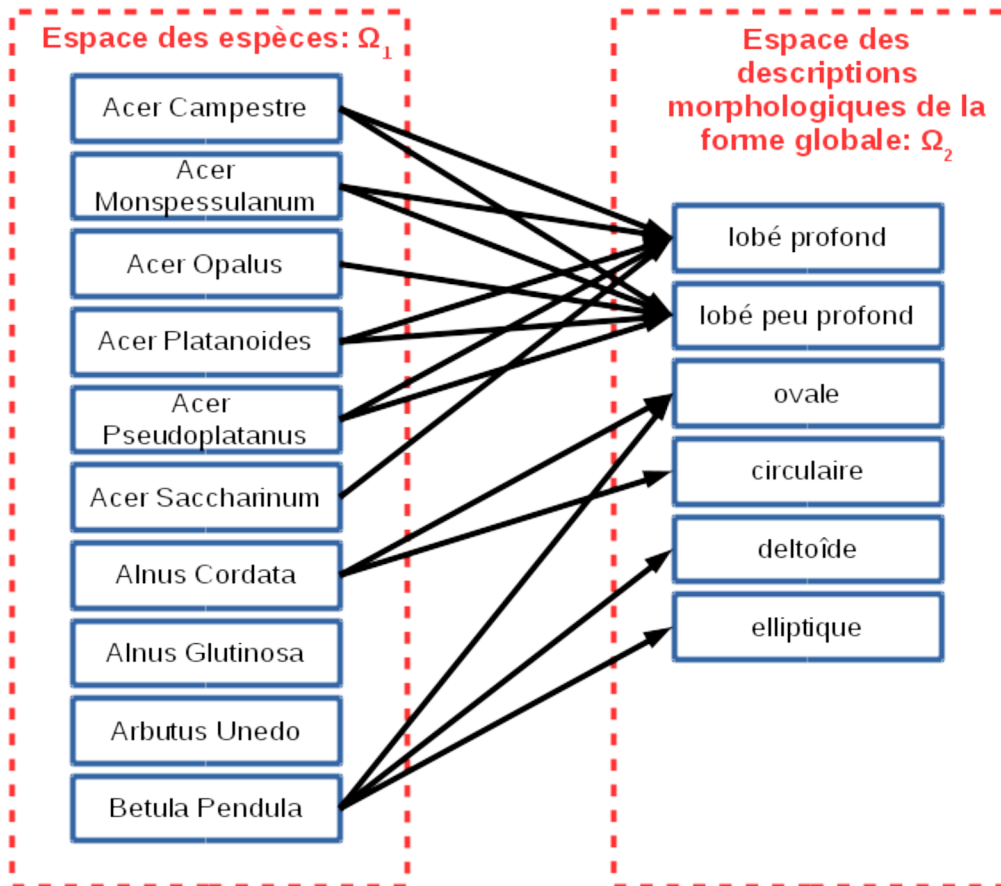


FIGURE 2.8: Exemple de deux espaces de discernement Ω_1 et Ω_2 montrant l'existence d'intersection entre les éléments formant Ω_2

La conclusion tirée à travers cette étude est que le passage par l'espace des descriptions morphologiques introduit beaucoup d'imprécision dans le système de fusion. Ceci engendre la

construction d'éléments focaux de très grande taille. Les résultats finaux sont imprécis. Une même masse peut être attribuée à un grand ensemble d'espèces d'où la perte de spécificité.

Pour toutes ces imperfections liées à l'imprécision, l'incomplétude et l'incohérence des données, nous avons décidé de ne pas passer par l'espace des descriptions morphologiques et de faire la classification directement dans l'espace des espèces. Nous évitons ainsi d'introduire beaucoup d'imperfections dans le processus de fusion.

2.2.3.4 Deuxième stratégie de classification : classification dans l'espace des espèces

Devant la difficulté à obtenir une connaissance experte pertinente, une deuxième stratégie de classification est proposée (figure 2.9). Elle consiste à faire la classification directement dans l'espace des espèces. Les vecteurs d'attributs sont présents à l'entrée des classifieurs, à la sortie, nous obtenons une distribution de probabilité P_i entre les espèces.

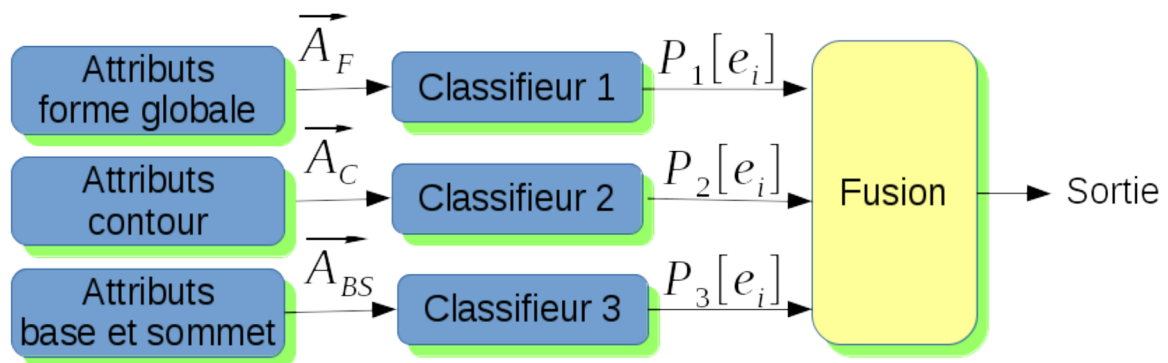


FIGURE 2.9: Deuxième stratégie de classification

Les sorties des classifieurs sont les entrées de l'étape de fusion. Pour cela, une évaluation des données issues de l'étape de classification est nécessaire.

2.3 Évaluation des données à fusionner

Avant d'entamer l'étape de fusion, il est important d'évaluer les données à la sortie des différents classifieurs pour avoir une idée sur les imperfections existantes. Puis, nous pourrions mettre en place les outils et méthodes aptes à gérer les différents types d'imperfections. En effet, bien que les méthodes proposées pour la segmentation et l'extraction d'attributs soient efficaces par rapport aux méthodes existantes, la complexité du problème fait que des erreurs peuvent s'accumuler au fur et à mesure des traitements. Il est donc important d'analyser la qualité des données à ce stade et avant toute opération de fusion.

Les données à fusionner sont les données issues de l'étape de classification. Nous nous intéressons alors à analyser la sortie des différents classifieurs. Nous commençons par évaluer la performance de chaque classifieur séparément. La performance est d'abord évaluée en terme de :

1. taux de bonne classification en fonction des N premières espèces : à la sortie de chaque classifieur S_i , nous obtenons une distribution de probabilité P_i entre les espèces les plus probables. Le taux de bonne classification est calculé en prenant en compte la première espèce la plus probable ($N = 1$), les deux premières espèces les plus probables ($N = 2$) et ainsi de suite jusqu'à la prise en compte des dix espèces les plus probables ($N = 10$).
2. taux de bonne classification par espèce : pour une espèce e_i le taux de bonne classification est la somme des individus appartenant à e_i et bien classés dans e_i divisé par le nombre total d'individus appartenant à e_i

2.3.1 Performances des classifieurs : évaluation du taux de bonne classification en fonction des dix premières espèces les plus probables

Pour la base de données d'apprentissage, nous remarquons que le taux de bonne classification est de 100% pour le classifieur de la forme globale ainsi que le classifieur de la base et du sommet comme le montre la figure 2.10. Ceci montre que ces deux classifieurs ont bien appris les exemples d'apprentissage.

Par contre, pour la base de données de test, nous remarquons que leurs capacités à discriminer les espèces sont limitées. Pour le classifieur de la base et du sommet, le taux de bonne classification est de 73% si nous ne prenons en compte que la première espèce la plus probable. Ce taux de bonne classification augmente au fur et à mesure que le nombre d'espèces augmente jusqu'à atteindre 92% pour $N = 10$. Il en est de même pour le classifieur de la forme globale où le taux de bonne classification est de 76% pour $N = 1$ et de 94% pour $N = 10$.

En ce qui concerne le classifieur du contour, nous remarquons qu'il n'a pas pu apprendre tous les exemples de la base de données d'apprentissage d'où un taux de bonne classification fixé à 76%. Les attributs de la caractéristique contour sont les plus difficiles à extraire. En effet, il n'est pas toujours évident de détecter l'allure des dents sur le bord ce qui engendre des erreurs lors de la segmentation. Une confusion avec l'arrière plan est possible surtout lorsqu'il s'agit de photo prise en milieu naturel. Nous pouvons dire que ce classifieur est le moins performant. Sur l'ensemble de test, nous notons que le classifieur a un taux de bonne

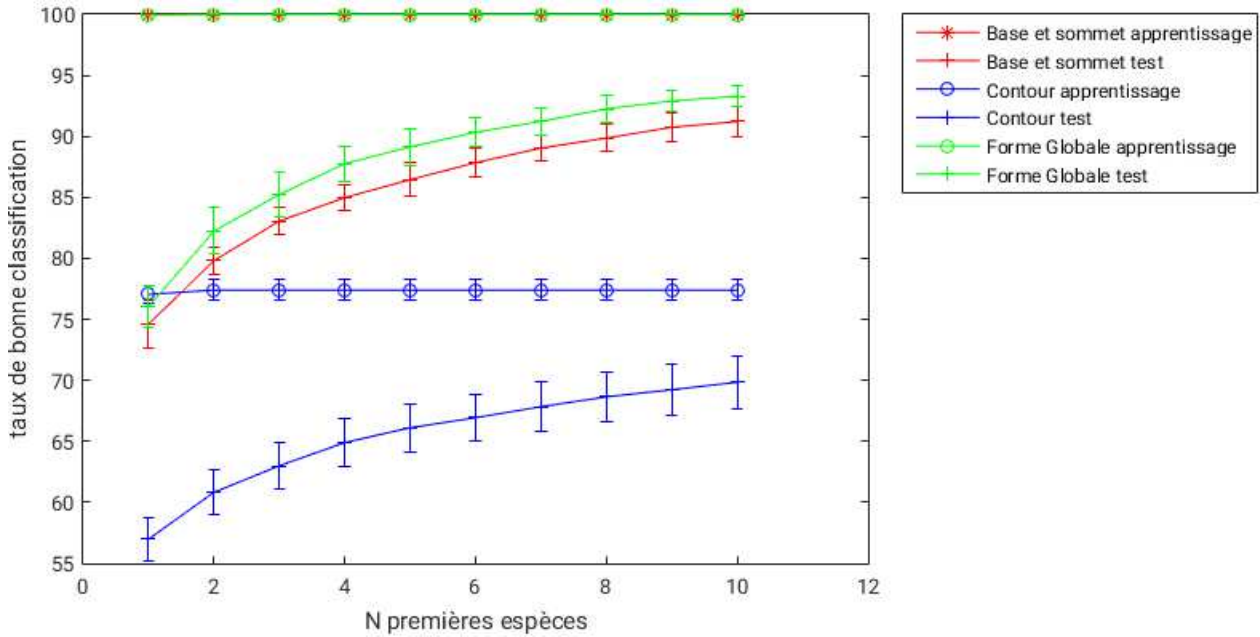


FIGURE 2.10: Taux de bonne classification de chaque classifieur pour la base de données de test et d'apprentissage

classification de seulement 57% si nous ne prenons en considération que la première espèce. Ce taux augmente en fonction du nombre d'espèces proposées jusqu'à atteindre 69% pour $N = 10$.

Nous remarquons que les performances des classifieurs sont limitées surtout pour $N = 1$. Ceci renforce notre choix de fusionner les données issues des différents classifieurs afin d'avoir des performances globales meilleures grâce à la complémentarité entre les données.

2.3.2 Performances des classifieurs : évaluation du taux de bonne classification par espèce

Nous avons également procédé à l'évaluation du taux de bonne classification par espèce. Dans la figure 2.11, un exemple du taux de bonne classification calculé pour quinze espèces de e_1 à e_{15} (les figures représentant le taux de bonne classification par espèce pour les 57 espèces restantes sont présentées en Annexe D).

Nous remarquons que le taux de bonne classification est variable d'une espèce à une autre et d'une caractéristique à une autre. Par exemple, pour le classifieur de la caractéristique contour, le taux de bonne classification est de 100% pour l'espèce e_6 et de 21% seulement pour l'espèce e_7 .

Nous remarquons qu'une espèce peut être bien reconnue par un classifieur alors qu'elle est faiblement reconnue par d'autres. Tel est le cas de l'espèce 7 reconnue avec un taux de bonne

classification de 100% par le classifieur de la caractéristique forme globale. Le taux de bonne classification est de 50% par le classifieur de la caractéristique base et sommet. Mais, il est très faible pour le classifieur de la caractéristique contour : de l'ordre de 21%.

Une espèce peut être bien apprise lors du jeu d'apprentissage mais le classifieur n'arrive pas à la reconnaître pour le jeu de test. Tel est l'exemple de l'espèce 5 illustrée dans la figure 2.11. Nous remarquons que le classifieur de la caractéristique base et sommet apprend à 100% cette espèce mais le taux de reconnaissance sur la base de test est de 20% seulement. Ceci peut s'expliquer de trois manières différentes :

- en raison d'une importante variabilité intra-classe, les paramètres appris étaient trop divergents. Le classifieur a appris des modèles assez variables ne permettant pas d'obtenir un modèle de généralisation.
- l'espèce présente beaucoup de conflit avec d'autres espèces qui lui sont trop similaires et donc le classifieur a du mal à les discriminer.
- le nombre d'individus représentant cette espèce dans la base de données d'apprentissage est très limité ne permettant pas assez d'exemples pour que le classifieur puisse apprendre correctement l'espèce.

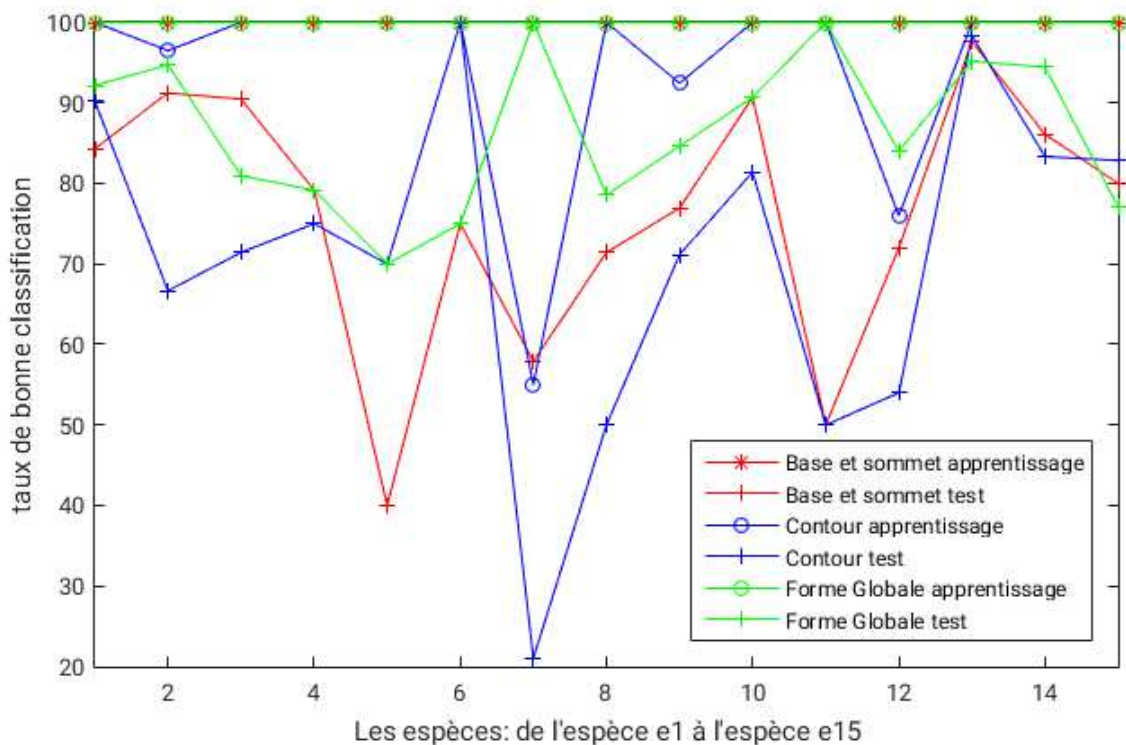


FIGURE 2.11: Taux de bonne classification par espèce : exemple de 15 espèces

2.3.3 Sources d'informations incertaines

Avec une aussi grande variabilité intra-classe et similarité inter-classes, les sorties des classifieurs génèrent des sources d'ambiguïté à travers la qualité des données qu'ils fournissent. Nous remarquons que, pour un individu de test donné, un classifieur propose généralement plusieurs classes en accordant une certaine probabilité à une vingtaine ou une trentaine d'espèces. Cette incertitude est d'autant plus importante que l'espèce à identifier présente des conflits avec d'autres espèces similaires. Tel est l'exemple d'une feuille appartenant à l'espèce "Acer Monspessulanum" (e_2) où le classifieur de la forme globale propose une liste de 19 espèces comme l'illustre la figure 2.12. Sur cette figure, nous avons représenté les 19 espèces par ordre de probabilité décroissante, chaque espèce étant notée par e_i avec une couleur donnée.




FIGURE 2.12: Incertitude du classifieur de la forme globale dans le cas d'une feuille appartenant à l'espèce Acer Monspessulanum (e_2) : 19 espèces sont proposées

Nous remarquons que la bonne espèce est proposée en sixième position. La figure 2.13 illustre les 6 premières espèces les plus probables. Nous remarquons que les espèces avec lesquelles le classifieur s'est trompé sont plutôt des espèces ayant toutes la même forme globale "Palmatilobée" à part l'espèce e_{46} ("Populus Nigra").

Comme illustré par cet exemple, et après de nombreuses expérimentations, nous pouvons dire que le comportement incertain du classifieur est parfois lié à la similarité inter-espèces. De plus, un seul classifieur correspondant à une seule caractéristique de la feuille est incapable de

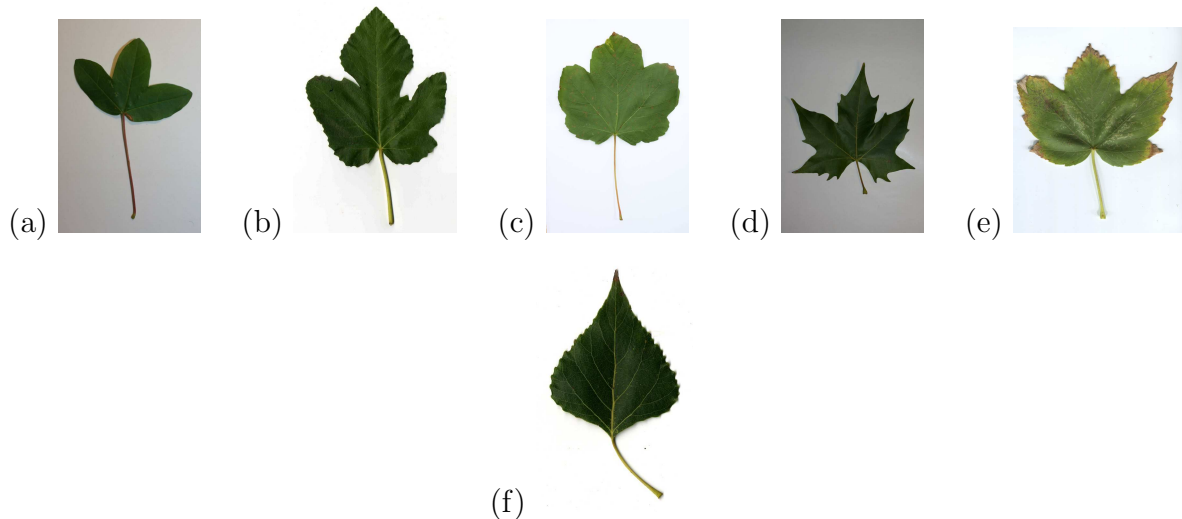


FIGURE 2.13: (a) : e_2 (*Acer Monspessulanum*), (b) : e_{30} (*Ficus Carica*), (c) : e_3 (*Acer Opalus*), (d) : e_{44} (*Platanus Hispanica*), (e) : e_5 (*Acer pseudoplatanus*), (f) : e_{46} (*Polpulus Nigra*)

discriminer des espèces très similaires, d'où l'intérêt de rajouter des informations sur d'autres caractéristiques pertinentes de la feuille.

2.3.4 Sources menteuses contextuellement

Dans certaines situations, nous constatons que le classifieur fournit des informations relativement certaines. Il hésite entre deux ou trois classes seulement en accordant une probabilité importante à la première classe proposée. Parfois, le classifieur attribue toute la probabilité à une seule et unique classe. En proposant cette classe avec une importante probabilité, le comportement certain du classifieur nous pousse à penser qu'il propose la bonne espèce alors que ce n'est pas du tout le cas. Dans ce genre de situation, le classifieur est dit menteur contextuellement [59]. En effet, ce comportement se produit dans certains contextes tel que le contexte lié à l'âge. Une feuille, à un certain âge, peut ressembler plus à une autre espèce qu'à l'espèce à laquelle elle appartient vraiment.

Ceci est illustré à travers les photos des feuilles représentées dans la figure 2.14. Le classifieur de la caractéristique contour accorde toute la probabilité à l'espèce "Buxus Sempervirens" alors qu'il s'agit de l'espèce "Acer Monspessulanum". Nous remarquons que du point de vue contour, les deux espèces ont un contour entier ne représentant ni des creux ni des dents. Puisque le classifieur de la caractéristique contour se base sur cette caractéristique, il est incapable de discriminer les deux espèces représentant un même type de contour.




FIGURE 2.14: (a) : e_7 (Acer Monspessulanum), (b) : e_{13} (Buxus Sempervivirens)

2.4 Conclusion

Dans ce chapitre, nous nous sommes intéressés à l'étude de la modalité feuille. Les vecteurs d'attributs extraits à partir de cette modalité permettent de décrire ses caractéristiques les plus pertinentes.

Lors de la phase de classification, nous avons essayé d'introduire des connaissances expertes pour mettre en valeur l'aspect éducatif de l'application. Ces informations expertes sont assez spécifiques : imprécision, incomplétude et variations d'un expert à un autre. Vue ces spécificités, cette méthode a plutôt engendré l'introduction de données imprécises dans le processus de classification. On aurait pu exploiter cette stratégie d'avantage, mais , en l'absence de sources d'informations supplémentaires pertinentes, nous avons décidé de nous orienter vers une autre approche où la classification est faite directement dans l'espace des espèces. Certes, cette méthode n'a pas le même aspect éducatif, mais elle permet l'obtention de résultats plus certains et précis à la sortie de l'étape de classification.

Plusieurs imperfections sont présentes dans les données issues des différents classifieurs. La présence de ces imperfections est d'une part normale vu les conflits existants naturellement au sein d'une même espèce ou entre des espèces différentes. D'autre part, ces imperfections sont le résultat d'un cumul d'erreurs en commençant par l'étape de segmentation, puis par l'étape d'extraction des attributs et s'amplifiant à l'étape de la classification. Étant conscient de toutes ces imperfections, une chaîne de traitement spécifique sera mise en place.

Dans le chapitre 3 nous proposons un système de fusion permettant de fusionner les données issues des feuilles tout en utilisant les outils nécessaires pour gérer les imperfections existantes.

Chapitre 3

La fusion des caractéristiques des feuilles

Un système de fusion permet de combiner des informations issues de plusieurs sources afin d'améliorer la prise de décision. Afin de s'approcher au mieux de l'objectif éducatif que nous nous étions fixés concernant l'application, nous proposons un système de fusion caractérisé par sa topologie en cascade. Cette topologie qui consiste à fusionner en cascade les différentes sources d'informations issues de la modalité feuille, permet à l'utilisateur de voir l'apport de chaque caractéristique.

Ce système est élaboré dans le cadre de la théorie des fonctions de croyance. En effet, les théories de l'incertain présentent un cadre théorique permettant de gérer une ou plusieurs sources d'imperfections. La théorie des fonctions de croyance en fait partie. Elle offre un cadre général pour le traitement d'informations imparfaites. Cette théorie, tire son importance de sa richesse en termes d'outils permettant de gérer l'incertitude et l'imprécision. Néanmoins, il n'existe pas une solution générique pouvant être appliquée quelque soit la situation. Au contraire, pour chaque problème, une chaîne de traitement spécifique, adaptée et prudemment choisie est nécessaire. Pour pouvoir l'appliquer, le cadre théorique de travail doit être défini. Il est d'ailleurs nécessaire de proposer une manière pour construire les fonctions de masse à partir des données disponibles. Ces fonctions de masse doivent être bien représentatives des imperfections et des données disponibles. L'inconvénient majeur de la théorie des fonctions de croyance est sa complexité calculatoire assez élevée comparée à la théorie des probabilités ou la théorie des possibilités. Cette complexité augmente exponentiellement en fonction de la taille de l'espace de discernement (de taille 72 dans notre cas) et du nombre de sources à fusionner. Il est donc nécessaire de trouver les moyens adéquats pour que la complexité soit réduite au maximum.

Dans ce chapitre, la section 1 illustre la topologie du système de fusion ainsi que les différents blocs le composant. La section 2 présente les méthodes de construction de fonctions de masse. La section 3 détaille les méthodes d'approximation des fonctions de masse. La section 4 est une étude détaillée des différentes règles de combinaison. La section 5 présente les différentes expériences réalisées et les résultats obtenus.

3.1 Le système de fusion

Les données à fusionner sont celles issues de l'étape de classification. Nous rappelons qu'à la sortie de chaque classifieur nous obtenons une distribution de probabilité P_i entre les espèces. Le système de fusion, représenté dans la figure 3.1, est formé de 3 étapes :

1. la construction des fonctions de masse : le passage vers la théorie des fonctions de croyance nécessite la construction de fonctions de masse à partir des distributions de probabilités.
2. l'approximation des fonctions de masse : permet de réduire la complexité calculatoire.
3. la combinaison : dans le cadre de la théorie des fonctions de croyance, plusieurs règles de combinaison sont mises en place. Chacune permet de gérer une ou plusieurs source d'imperfections.




FIGURE 3.1: Système de fusion hiérarchique pour la fusion de données issues des feuilles

3.2 La construction des fonctions de masse

La construction des fonctions de masse à partir des distributions de probabilité est une étape importante dans le processus de fusion. En effet, il faut que les fonctions de masse soient suffisamment représentatives de toutes les informations disponibles. Dans notre cas, nous avons pu montrer que les données obtenues à la sortie des classifieurs sont incertaines, que les sources ont différents degrés de fiabilité, qu'elles sont parfois menteuses contextuellement et qu'elles peuvent être conflictuelles. Il est donc important que les fonctions de masse

puissent représenter toutes ces imperfections et prennent en compte le maximum d'informations [71][72].

Dans notre cas, il s'agit d'un cadre de discernement de grande taille (72 hypothèses). Construire 2^{72} éléments focaux et accorder une masse à toutes les combinaisons possibles engendrerait une importante complexité calculatoire. Dans la littérature, il existe plusieurs méthodes pour construire une fonction de masse à partir d'une distribution de probabilité dont les plus connues sont : les fonctions de masse bayésiennes [73][74] et les fonctions de masse consonantes [75][74][76][77].

Dans ce qui suit, nous nous intéressons à la construction de fonctions de masse bayésiennes et consonantes à partir de la distribution de probabilité illustrée dans l'exemple 1. Cette distribution est issue du classifieur de la caractéristique modèle polygonal et correspond à un individu appartenant à l'espèce e_1 ("Acer Campestre") tel que :

Exemple 1

$p(e_1) = 0.0253, p(e_2) = 0.0099, p(e_4) = 0.0350, p(e_6) = 0.0050, p(e_{12}) = 0.0451,$
 $p(e_{13}) = 0.0050, p(e_{16}) = 0.0050, p(e_{22}) = 0.2050, p(e_{24}) = 0.4048, p(e_{32}) = 0.0350,$
 $p(e_{36}) = 0.1750, p(e_{40}) = 0.0049, p(e_{44}) = 0.0050, p(e_{54}) = 0.0099, p(e_{56}) = 0.0150$
 et $p(e_{72}) = 0.0149$

3.2.1 Les fonctions de masse bayésiennes

Une fonction de masse est dite bayésienne si tous ses éléments focaux sont des singletons. Elle est construite à partir d'éléments focaux certains et précis. La masse m_i correspondant à un classifieur S_i est calculée à partir de la distribution de probabilité P_i de la manière suivante :

$$m_i\{e_k\} = P_i(e_k), \quad \forall e_k \in \Omega \quad (3.1)$$

$$m_i\{X\} = 0, \quad si |X| \neq 1 \quad (3.2)$$

où X est tout ensemble contenant plus d'une espèce.

Une masse m_i égale à la probabilité P_i est accordée à chaque élément e_k de Ω ayant une probabilité non nulle. Une masse nulle est accordée à tous les ensembles. Cette méthode permet de construire des éléments focaux précis et certains, mais ne permet pas vraiment de bénéficier des avantages qu'offre la théorie des fonctions de croyance puisque nous continuons à travailler avec des singletons. Le système de fusion risque de devenir moins flexible. L'application de cette méthode sur l'exemple 1 donne le résultat représenté dans le tableau suivant :

Distribution de probabilité P_3 (Modèle polygonal)	bba bayésien
$p(e_1) = 0.0253$	$m(e_1) = 0.0253$
$p(e_2) = 0.0099$	$m(e_2) = 0.0099$
$p(e_4) = 0.0350$	$m(e_4) = 0.0350$
$p(e_6) = 0.0050$	$m(e_6) = 0.0050$
$p(e_{12}) = 0.0451$	$m(e_{12}) = 0.0451$
$p(e_{13}) = 0.0050$	$m(e_{13}) = 0.0050$
$p(e_{16}) = 0.0050$	$m(e_{16}) = 0.0050$
$p(e_{22}) = 0.2050$	$m(e_{22}) = 0.2050$
$p(e_{24}) = 0.4048$	$m(e_{24}) = 0.4048$
$p(e_{32}) = 0.0350$	$m(e_{32}) = 0.0350$
$p(e_{36}) = 0.1750$	$m(e_{36}) = 0.1750$
$p(e_{40}) = 0.0049$	$m(e_{40}) = 0.0049$
$p(e_{44}) = 0.0050$	$m(e_{44}) = 0.0050$
$p(e_{54}) = 0.0099$	$m(e_{54}) = 0.0099$
$p(e_{56}) = 0.0150$	$m(e_{56}) = 0.0150$
$p(e_{72}) = 0.0149$	$m(e_{72}) = 0.0149$

Nous remarquons que la construction de fonctions de masse bayésiennes ne permet pas la modélisation des imperfections des données. Les espèces qui avaient initialement une probabilité faible, ont une masse faible. Celles qui avaient initialement une forte probabilité, ont une forte masse.

3.2.2 Les fonctions de masse consonantes

Les fonctions de masse consonantes consistent à construire des éléments focaux dont certains sont de grandes tailles. La construction se fait en deux étapes. La première consiste à ordonner la distribution de probabilité P_i dans l'ordre décroissant de la manière suivante :

$$P_i(e_{(1)}) \geq P_i(e_{(2)}) \geq P_i(e_{(3)}) \geq \dots P_i(e_{(N-1)}) \geq P_i(e_{(N)}) \quad (3.3)$$

Ainsi, la classe la plus probable est classée en première position et ainsi de suite. Nous reprenons avec le même exemple que celui pris pour la construction des fonctions de masse bayésiennes. Le classement des espèces dans l'ordre décroissant des probabilités donne ceci : $p(e_{24}) > p(e_{22}) > p(e_{36}) > p(e_{12}) > p(e_{32}) > p(e_4) > p(e_1) > p(e_{56}) > p(e_{72}) > p(e_{54}) > p(e_2) > p(e_{13}) > p(e_{16}) > p(e_{44}) > p(e_6) > p(e_{40})$

La deuxième étape consiste à construire les éléments focaux et à leurs attribuer une masse. Le premier élément focal contient l'ensemble de toutes les espèces. Le deuxième est l'ensemble des $N - 1$ espèces les probables et ainsi de suite jusqu'à parcourir toutes les classes de la manière suivante :

$$\begin{aligned}
m_i\{e_{(1)}, e_{(2)}, \dots, e_{(N-1)}, e_{(N)}\} &\equiv N * P_i(e_{(N)}) \\
m_i\{e_{(1)}, e_{(2)}, \dots, e_{(N-2)}, e_{(N-1)}\} &\equiv (N - 1) * (P_i(e_{(N-1)}) - P_i(e_{(N)})) \\
m_i\{e_{(1)}, e_{(2)}, \dots, e_{(N-3)}, e_{(N-2)}\} &\equiv (N - 2) * (P_i(e_{(N-2)}) - P_i(e_{(N-1)})) \\
&\vdots \\
m_i\{e_{(1)}, e_{(2)}, e_{(3)}\} &\equiv (3) * (P_i(e_{(3)}) - P_i(e_{(4)})) \\
m_i\{e_{(1)}, e_{(2)}\} &\equiv (2) * (P_i(e_{(2)}) - P_i(e_{(3)})) \\
m_i\{e_{(1)}\} &\equiv (1) * (P_i(e_{(1)}) - P_i(e_{(2)}))
\end{aligned}$$

La masse attribuée à chaque élément focal dépend de sa taille et de la différence des probabilités entre la classe $N - 1$ et la classe N . Cette méthode engendre la construction d'éléments focaux dont certains sont de grandes tailles. Ceci peut poser un problème lié à la complexité calculatoire puisque nous travaillons dans un espace de discernement de grande dimension. Par contre, elle permet d'avoir des éléments focaux représentés sous forme d'ensembles. Ainsi, nous pouvons profiter des avantages de la théorie des fonctions de croyance qui gère mieux les ensembles que les singletons. Le système de fusion sera ainsi plus flexible. L'application de cette méthode sur notre exemple donne ceci :

$$\begin{aligned}
m_3\{e_{24}, e_{22}, e_{36}, e_{12}, e_{32}, e_4, \mathbf{e}_1, e_{56}, e_{72}, e_{54}, e_2, e_{13}, e_{16}, e_{44}, e_6, e_{40}\} &= 0.0791 \\
m_3\{e_{24}, e_{22}, e_{36}, e_{12}, e_{32}, e_4, \mathbf{e}_1, e_{56}, e_{72}, e_{54}, e_2, e_{13}, e_{16}, e_{44}, e_6\} &= 9.1937e^{-04} \\
m_3\{e_{24}, e_{22}, e_{36}, e_{12}, e_{32}, e_4, \mathbf{e}_1, e_{56}, e_{72}, e_{54}, e_2, e_{13}, e_{16}, e_{44}\} &= 9.8797e^{-05} \\
m_3\{e_{24}, e_{22}, e_{36}, e_{12}, e_{32}, e_4, \mathbf{e}_1, e_{56}, e_{72}, e_{54}, e_2, e_{13}, e_{16}\} &= 2.8337e^{-07} \\
m_3\{e_{24}, e_{22}, e_{36}, e_{12}, e_{32}, e_4, \mathbf{e}_1, e_{56}, e_{72}, e_{54}, e_2, e_{13}\} &= 2.6843e^{-04} \\
m_3\{e_{24}, e_{22}, e_{36}, e_{12}, e_{32}, e_4, \mathbf{e}_1, e_{56}, e_{72}, e_{54}, e_2\} &= 0.0536 \\
m_3\{e_{24}, e_{22}, e_{36}, e_{12}, e_{32}, e_4, \mathbf{e}_1, e_{56}, e_{72}, e_{54}\} &= 2.0155e^{-04} \\
m_3\{e_{24}, e_{22}, e_{36}, e_{12}, e_{32}, e_4, \mathbf{e}_1, e_{56}, e_{72}\} &= 0.0449 \\
m_3\{e_{24}, e_{22}, e_{36}, e_{12}, e_{32}, e_4, \mathbf{e}_1, e_{56}\} &= 9.3794e^{-04} \\
m_3\{e_{24}, e_{22}, e_{36}, e_{12}, e_{32}, e_4, \mathbf{e}_1\} &= 0.0717 \\
m_3\{e_{24}, e_{22}, e_{36}, e_{12}, e_{32}, e_4\} &= 0.0583 \\
m_3\{e_{24}, e_{22}, e_{36}, e_{12}, e_{32}\} &= 2.2232e^{-04} \\
m_3\{e_{24}, e_{22}, e_{36}, e_{12}\} &= 0.0401
\end{aligned}$$

$$m_3\{e_{24}, e_{22}, e_{36}\} = 0.3899$$

$$m_3\{e_{24}, e_{22}\} = 0.0598$$

$$m_3\{e_{24}\} = 0.1998$$

La masse accordée aux espèces qui sont à la base les plus probables a été réduite. Tel est le cas de l'espèce e_{24} ayant à la base une probabilité de 0.4048 mais nous remarquons que la masse qui lui est accordée après cette transformation est de 0.1998. C'est grâce à la prise en compte de la taille de cet élément focal que la masse attribuée à e_{24} est réduite et est redistribuée sur les autres éléments focaux. Il est important de noter que l'espèce e_1 (qui est la bonne espèce) figure dans 10 éléments focaux.

Les fonctions de masse consonantes permettent la construction d'éléments focaux imprécis mais l'avantage est que la bonne espèce apparaît dans plusieurs éléments focaux. C'est vrai qu'il n'y a pas assez d'informations pour préciser quelle est exactement la bonne espèce mais au moins la bonne espèce n'est pas exclue. Au contraire, son apparition dans plusieurs éléments focaux lui donne plus de chances d'être parmi les 10 espèces les plus probables à la fin du processus de fusion.

Une fois que les fonctions de masse sont construites, il ne reste plus qu'à les combiner en limitant la complexité calculatoire. Dans le cas de la fusion des données caractérisant les feuilles, il s'agit de combiner trois sources de données. Le nombre de sources de données va augmenter dès qu'une nouvelle modalité est rajoutée. De plus, l'espace de discernement est de grande taille. Pour ces deux raisons, il s'avère important de trouver une solution qui permette de diminuer la complexité calculatoire. L'idée est donc d'approximer les fonctions de masse.

3.3 Approximation des fonctions de masse

Bien que la théorie des fonctions de croyance permet de résoudre des problèmes dans différents domaines, l'un de ses problèmes majeurs est la complexité des calculs qui est relativement élevée par rapport à d'autres théories telles que la théorie des probabilités et la théorie des possibilités. La complexité calculatoire augmente exponentiellement en fonction du nombre de sources à combiner [78]. Ce problème devient plus important lorsqu'il s'agit d'espace de discernement de grande taille. Or, notre but est de mettre en place un système de fusion que nous pourrions par la suite intégrer dans une application smartphone. La façon de limiter la complexité des calculs a été exposée dans la littérature par plusieurs chercheurs. Les approches existantes reposent soit sur des procédures consistant à effectuer des calculs exacts ou sur des techniques d'approximation.

Dans la première catégorie, un algorithme de calcul optimal a été proposé par Kennes dans [79]. Cet algorithme permet d’optimiser considérablement le nombre d’opérations d’addition et de multiplication lors du calcul des fonctions de masse réduisant considérablement la complexité des calculs. L’inconvénient de cette méthode est que le nombre d’éléments focaux n’est pas réduit puisque c’est une procédure qui fait des calculs exacts. Ceci peut être problématique dans notre cas puisque nous avons à gérer un espace de discernement de grande taille et à effectuer le même calcul pour plusieurs sources d’informations.

D’autres algorithmes permettant de manipuler des classes restreintes ont également été proposés [80] [81]. Ces algorithmes, même s’ils sont efficaces d’un point de vue complexité calculatoire, présentent un inconvénient majeur puisque plusieurs hypothèses ne seront pas forcément respectées dans le cadre de notre application.

La deuxième catégorie d’approches est composée des techniques de Monte-Carlo [82] [83] et des procédures d’approximation des fonctions de masse. Les techniques d’approximation de Monte-Carlo ont prouvé leur efficacité dans certains domaines d’applications où le conflit entre les sources est réduit. L’inconvénient de ces techniques est que leurs performances diminuent considérablement lorsque le conflit devient important [84]. Les procédures d’approximation des fonctions de masse permettent la réduction du nombre d’éléments focaux en se basant sur différents critères de sélection. Nous nous sommes intéressés plus particulièrement aux procédures les plus utilisées : les approximations “Inner” et “Outer” [85], la méthode k-l-x [86] et la méthode de sommation [87].

3.3.1 L’approximation k-l-x

Cette approximation est la plus simple des approximations. Son idée principale consiste à garder uniquement les k éléments focaux ayant les masses les plus importantes et à attribuer une masse nulle à tous les autres éléments focaux, puis à normaliser le résultat [86]. L’inconvénient de cette méthode est qu’elle élimine certaines espèces en se basant sur un seul critère qui est la valeur de la masse. Or, dans notre cas, les différentes sources de données ont des degrés de fiabilité variables d’une espèce à une autre ce qui fait que parfois une faible masse est accordée à la bonne espèce. En appliquant l’approximation k-l-x, nous risquons d’éliminer certains éléments focaux qui sont en réalité très utiles et représentent une information pertinente même si la masse qui leurs était accordée est faible.

3.3.2 La sommation

Une manière simple de diminuer le nombre d'éléments focaux est de regrouper ceux qui sont similaires ou peu importants. C'est sur cette stratégie que se base l'approximation "Som-mation" [87]. Cette approximation consiste à garder les $k - 1$ éléments focaux ayant la masse la plus importante. L'union des éléments focaux restants forme le $k^{\text{ème}}$ élément focal dont la somme de leurs masses est transférée à l'élément k . L'application de cette approximation dans notre contexte spécifique s'avère intéressante. Contrairement à l'approximation $k - l - x$, même les éléments focaux ayant une faible masse seront gardés. Ainsi, un maximum d'in-formation sera transféré permettant plus de flexibilité au processus de fusion. En plus, cette approximation est simple et elle ne demande pas beaucoup d'opérations de calcul ce qui réduit son temps de traitement.

3.3.3 L'approximation Inner et l'approximation Outer

Proposée par Denceux dans [85], le principe de ces approximations consiste à diminuer le nombre d'éléments focaux en les fusionnant et à transférer leurs masses à leur union ou à leur intersection. Afin de déterminer les éléments focaux qui seront fusionnés en premier, une distance mesurant l'impact du remplacement de F_i et F_j par leur union ou leur intersection est calculée.

Dans le cas de l'approximation "Outer", cette distance notée δ_{\cup} est calculée pour chaque paire d'éléments focaux (F_i, F_j) de la manière suivante :

$$\delta_{\cup}(F_i, F_j) = [m(F_i) + m(F_j)]|F_i \cup F_j| - m(F_i)|F_i| - m(F_j)|F_j|. \quad (3.4)$$

Les éléments focaux correspondants aux distances δ_{\cup} les plus petites sont remplacés par leur union. La masse accordée à l'union correspond à la somme des masses des éléments fu-sionnés. Cette opération est répétée jusqu'à atteindre le nombre k d'éléments focaux souhaité.

Pour l'approximation Inner, la distance δ_{\cap} entre chaque paire d'éléments focaux (F_i, F_j) est calculée ainsi :

$$\delta_{\cap}(F_i, F_j) = m(F_i)|F_i| + m(F_j)|F_j| - [m(F_i) + m(F_j)]|F_i \cap F_j| \quad (3.5)$$

Les éléments focaux correspondants aux distances δ_{\cap} les plus petites sont remplacés par leur intersection. La masse accordée à l'intersection correspond à la somme des masses des éléments fusionnés. Les itérations continuent jusqu'à atteindre le nombre k souhaité.

Les approximations Inner et Outer se basent donc sur un calcul de distance afin de décider quels sont les éléments focaux à fusionner en premier. Par rapport à l'approximation Inner, l'approximation Outer semble être plus utile dans notre cas puisqu'elle transfère les éléments focaux à fusionner vers leur union contrairement à l'approximation Inner qui transfère les éléments focaux à fusionner vers leur intersection. Ainsi, l'approximation Outer permet de garder un maximum d'information. Aucune classe n'est éliminée grâce à la prise en compte de l'union.

Malgré sa capacité à transférer le maximum d'information, l'approximation Outer nécessite un nombre d'opérations de calcul beaucoup plus important que celui de l'approximation Somme. En effet, le calcul des distances entre tous les éléments focaux avant chaque approximation peut augmenter considérablement le temps de calcul.

En conclusion, le choix de la méthode d'approximation appropriée se base sur deux critères essentiels : la capacité de l'approximation à garder le maximum d'information et le temps de calcul. L'approximation offrant le meilleur compromis sera choisie. Les expériences présentées dans la suite permettront de comparer les performances des différentes méthodes d'approximation. Une fois que les fonctions de masse sont approximées, il faudra choisir la règle de combinaison la mieux appropriée pour notre application.

3.4 Choix de la règle de combinaison

Afin de gérer au mieux les imperfections des données, plusieurs règles de combinaison ont été proposées dans le cadre de la théorie des fonctions de croyance. Chaque règle a été mise en place pour gérer un ou plusieurs aspects d'imperfections. Vu les performances limitées et variables des sources de données à combiner, nous considérons que nous avons à traiter des sources de données non fiables.

En plus de la non fiabilité des sources, elles sont aussi conflictuelles. Pour évaluer le degré de conflit partiel et global entre les sources, nous avons calculé pour chaque espèce le conflit partiel moyen entre deux sources d'informations d'une part, et d'autre part, le conflit global moyen existant entre toutes les sources à fusionner. Le conflit partiel est calculé entre les sorties des classifieurs $(S_1$ et $S_2)$, $(S_1$ et $S_3)$ et $(S_2$ et $S_3)$. Le calcul du conflit revient à calculer la masse de l'ensemble vide telle que $k_{12} = m_{1 \cap 2}(\emptyset)$ si le conflit est calculé entre deux sources et $k_{123} = m_{\cap}(\emptyset)$ pour le conflit global calculé entre les 3 sources. La figure

3.2 montre le degré de conflit moyen par espèce. Nous remarquons l'existence d'un conflit important entre les sources. Le conflit partiel entre la forme globale et la base et le sommet est le conflit le moins important comparé aux autres conflits partiels.

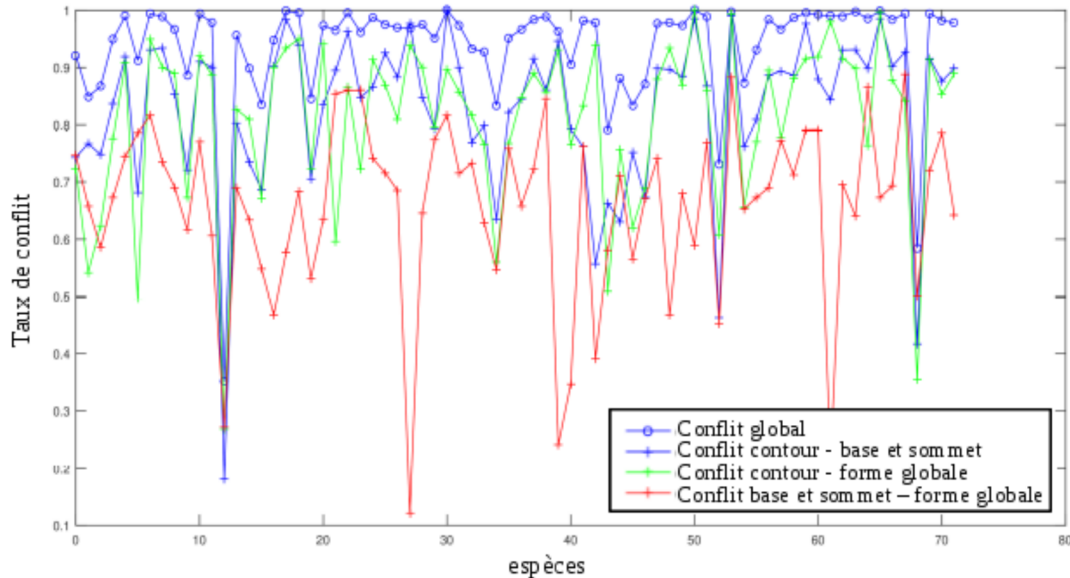


FIGURE 3.2: Conflits partiels et conflit global entre les sources d'informations

Supposons que nous souhaitions fusionner les informations provenant de 2 sources d'informations S_1 et S_2 correspondant à 2 fonctions de masses notées respectivement m_1 et m_2 . La théorie des fonctions de croyance propose différentes règles de combinaison. Les règles de combinaisons pouvant être les mieux adaptées à notre problème sont celles qui permettent de gérer au mieux le conflit. Dans [88], Lefevre et al. définissent 3 sources de conflit :

- **une mesure aberrante donnée par un capteur** : ce type de conflit peut se manifester lors de l'acquisition des données et donc lors de la prise des photos des feuilles.
- **la modélisation imprécise des fonctions de croyance** : la plupart des modèles dérivent de mesures de distances ou de mesures de probabilités. La modélisation des fonctions de croyance en utilisant les fonctions de masse consonantes engendre l'obtention de fonctions de masse imprécises. Ainsi, en utilisant cette approche pour la construction des fonctions de masse, nous nous trouvons face à une deuxième source de conflit.
- **la multitude de sources d'informations à combiner** : ce qui est bien notre cas ce qui présente une troisième source de conflit.

D'après Lefèvre et al. [88] les règles de combinaison proposées dans la littérature représentent des solutions pour gérer ces différentes sources de conflit. Ils divisent ces règles de combinaison en deux catégories :

1. la première catégorie regroupe les règles de combinaison nécessitant que les sources d'informations à combiner soient fiables.
2. la deuxième catégorie regroupe les règles de combinaison où au moins une des sources d'informations est fiable sans savoir forcément laquelle.

Dans la suite, les différentes règles de combinaison appartenant aux deux catégories sont analysées.

3.4.1 Règle de combinaison de Dempster

La règle de combinaison de Dempster a été proposée par Dempster [53] en 1976. L'utilisation de cette règle associative et commutative exige que les 2 sources d'informations soient fiables. Elle est définie de la manière suivante :

$$\left\{ \begin{array}{l} m(\emptyset) = 0 \\ m(A) = \frac{\sum_{\substack{B, C \in 2^\Omega \\ B \cap C = A}} m_1(B)m_2(C)}{1 - k_{12}}, \quad \forall A (\neq \emptyset) \in 2^\Omega \end{array} \right. \quad (3.6)$$

où $k_{12} = \sum_{B \cap C = \emptyset} m_1(B)m_2(C)$ représente le degré de conflit entre les 2 sources d'informations. Le facteur de normalisation $(1 - k_{12})$ consiste à éliminer les parties d'informations conflictuelles entre S_1 et S_2 . Si $k_{12} = 1$, les 2 sources sont considérées en conflit total. La règle de combinaison de Dempster peut être utilisée pour combiner simultanément N sources d'informations ayant des degrés de fiabilité similaires.

La règle de combinaison de Dempster présente un modèle mathématique capable de représenter l'incertitude des données considérant la théorie des probabilités comme un cas particulier. Néanmoins, cette règle de combinaison souffre de plusieurs limitations et faiblesses surtout lorsque le conflit entre les 2 sources d'informations devient important [89] [90] [91] ce qui est bien notre cas. Ce problème a été bien mis en évidence à travers le fameux exemple de Zadeh : considérons $\Omega = \{A, B, C\}$ tel que les masses issues de deux sources d'informations sont définies ainsi : $m_1(A) = 0.9$, $m_1(C) = 0.1$, $m_2(B) = 0.9$ et $m_2(C) = 0.1$. Nous remarquons l'important conflit existant entre les deux sources. Mais, l'application de la règle de combinaison de Dempster conduit au résultat suivant : $m(C) = 1!$ Dans le cadre de la reconnaissance d'espèces d'arbres, nous nous retrouvons devant des exemples aussi conflictuels que l'exemple de Zadeh. L'exemple suivant est un exemple réel représentant le conflit important existant entre les trois sources de données caractérisant les feuilles sachant que la

bonne espèce est l'espèce e_2 .

Exemple 2

$F_{1,j}$	$m_{1,j}$	$F_{2,j}$	$m_{2,j}$	$F_{3,j}$	$m_{3,j}$
$\{e_{13}\}$	1	$\{e_{32}\}$	0.1457	$\{e_3, e_5, e_{32}, e_{46}, e_{67}\}$	0.1997
		$\{e_{32}, e_{69}, e_{17}, e_1, e_2, e_{24}, e_{22}, e_{39}, e_{64}\}$	0.1339	$\{e_3, e_5\}$	0.1890
		$\{e_{32}, e_{69}, e_{17}, e_1, e_2, e_{24}, e_{22}, e_{39}, e_{64}, e_{72}, e_4, e_{21}, e_{28}, e_{20}, e_{47}, e_8, e_{44}, e_3, e_{65}, e_{45}, e_{58}, e_{33}, e_{57}\}$	0.1129	$\{e_3, e_5, e_{32}\}$	0.1343
		$\{e_{32}, e_{69}, e_{17}\}$	0.1051	$\{e_3\}$	0.1156
		$\{e_{32}, e_{69}, e_{17}, e_1, e_2, e_{24}, e_{22}, e_{39}, e_{64}, e_{72}, e_4, e_{21}, e_{28}, e_{20}, e_{47}, e_8\}$	0.0800	$\{e_3, e_5, e_{32}, e_{46}, e_{67}, e_4, e_{17}\}$	0.1031
		$\{e_{32}, e_{69}, e_{17}, e_1, e_2, e_{24}, e_{22}, e_{39}, e_{64}, e_{72}, e_4, e_{21}, e_{28}, e_{20}, e_{47}\}$	0.0731	$\{e_3, e_5, e_{32}, e_{46}, e_{67}, e_4, e_{17}, e_{71}, e_1, e_8, e_{44}, e_{20}, e_{30}\}$	0.0636
		$\{e_{32}, e_{69}, e_{17}, e_1, e_2, e_{24}, e_{22}, e_{39}, e_{64}, e_{72}, e_4, e_{21}, e_{28}\}$	0.0642	$\{e_3, e_5, e_{32}, e_{46}\}$	0.0612
		$\{e_{32}, e_{69}, e_{17}, e_1, e_2, e_{24}, e_{22}, e_{39}, e_{64}, e_{72}, e_4\}$	0.0535	$\{e_3, e_5, e_{32}, e_{46}, e_{67}, e_4, e_{17}, e_{71}, e_1, e_8, e_{44}\}$	0.0540
		$\{e_{32}, e_{69}, e_{17}, e_1, e_2, e_{24}, e_{22}, e_{39}, e_{64}, e_{72}\}$	0.0525	$\{e_3, e_5, e_{32}, e_{46}, e_{67}, e_4, e_{17}, e_{71}, e_1\}$	0.0432
		$\{e_1, e_2, e_3, e_4, e_8, e_{17}, e_{20}, e_{21}, e_{22}, e_{24}, e_{28}, e_{32}, e_{33}, e_{39}, e_{44}, e_{45}, e_{47}, e_{58}, e_{64}, e_{65}, e_{69}, e_{72}\}$	0.1790	$\{e_1, e_3, e_4, e_5, e_8, e_{17}, e_{20}, e_{32}, e_{44}, e_{46}, e_{67}, e_{71}\}$	0.0362

En plus du conflit, cet exemple est intéressant puisqu'il traite un des cas les plus compliqués à résoudre. A partir de cet exemple, le comportement des différentes règles de combinaison vis à vis des imperfections suivantes a été étudié :

1. **Source menteuse contextuellement** : il s'agit de la première source de données relative à la caractéristique contour : cette source propose une seule espèce e_{13} avec une certitude totale. Or la bonne espèce est l'espèce e_2 .
2. **Données imprécises** : la plupart des éléments focaux issus de la deuxième et troisième sources de données sont de grande taille reflétant l'imprécision des données.
3. **Données incertaines** : pour chaque source de données, la masse est répartie sur plusieurs éléments focaux (l'exemple montre 10 éléments focaux obtenus suite à l'application d'une approximation avec un nombre d'éléments focaux égale à dix).

La règle de combinaison de Dempster cherche les intersections existantes entre les éléments focaux des différentes sources de données. En fusionnant les deux premières sources relatives à la caractéristique contour et à la caractéristique base et sommet, nous nous rendons compte que les deux sources d'informations sont en conflit total. En effet, les deux sources proposent des espèces totalement différentes. Aucune espèce n'est commune. L'application de la règle de combinaison de Dempster engendre l'obtention de l'ensemble vide comme élément focal au premier niveau de fusion. Il est donc impossible de procéder au deuxième niveau de fusion.

Plusieurs règles de combinaison ont donc été proposées dans le cadre de la théorie des fonctions de croyance afin de palier aux limitations de la règle de combinaison de Dempster. Nous citons la règle de combinaison de Smet. En proposant de considérer que le monde est ouvert, cette règle commutative et associative est considérée comme la version non normalisée de la règle de combinaison de Dempster. Elle accorde une masse positive à l'ensemble vide [55]. Cette règle est inadaptée à notre cas pour deux raisons : la première est que nous travaillons dans un monde fermé où toutes les hypothèses sont connues. La deuxième est que l'utilisation de cette règle nécessite que toutes les sources d'informations soient fiables ce qui est loin d'être notre cas.

Yager a proposé de transférer le conflit vers l'ignorance [92]. Contrairement à Smet, il admet que l'espace de discernement est exhaustif et par la suite le conflit ne provient pas d'une mauvaise définition de celui-ci. D'après lui, c'est plutôt la non fiabilité des sources à fusionner qui peut être la cause du conflit. Il a donc choisi d'accorder plus de masse à l'ignorance en y additionnant la masse mise sur le conflit. Mais, le transfert de la masse vers l'ignorance engendre la perte de la spécificité de l'information. Dans notre cas, nous préférons transférer la masse vers l'union que vers l'ignorance. Ainsi, nous évitons de perdre une partie de l'information.

3.4.2 La règle de combinaison disjonctive

La combinaison disjonctive est la règle la plus simple et la plus basique pour le traitement de sources non fiables ou conflictuelles. Elle permet de combiner disjonctivement 2 sources d'informations. Elle suppose que l'une contient la bonne information et que l'autre contient l'information erronée sans savoir laquelle. La prise en compte de l'union permet ainsi de garder la bonne information même si l'information erronée est conservée. Proposée par Dubois et Prade en 1986 [93], cette règle commutative et associative est définie comme suit :

$$\left\{ \begin{array}{l} m_{\cup}(\emptyset) = 0 \\ m_{\cup}(A) = \frac{\sum_{B \cup C = A} m_1(B)m_2(C)}{1-k_{12}} \end{array} \right. \quad (3.7)$$

Cette règle peut être utilisée lorsque les sources ne sont pas fiables. Mais, son inconvénient majeur est qu'elle engendre une perte de spécificité.

3.4.3 La règle de combinaison adaptative de Dubois et Prade

La règle de combinaison adaptative de Dubois et Prade définie dans [56] propose d'exploiter un comportement intermédiaire entre la règle conjonctive et la règle disjonctive. Cette règle considère que si l'intersection entre 2 sources d'informations est vide, la vérité réside dans l'union. Cette règle permet ainsi de répartir le conflit partiel sur l'ignorance partielle. La règle commutative mais non associative de Dubois et Prade est définie ainsi :

$$\left\{ \begin{array}{l} m_D(\emptyset) = 0 \\ m_D(A) = \sum_{\substack{B, C \in 2^\Omega \\ B \cap C = A \\ B \cap C \neq \emptyset}} m_1(B)m_2(C) + \sum_{\substack{B, C \in 2^\Omega \\ B \cup C = A \\ B \cap C = \emptyset}} m_1(B)m_2(C), \forall A \in 2^\Omega, A \neq \emptyset \end{array} \right. \quad (3.8)$$




FIGURE 3.3: Classement de l'espèce e_2 dans la liste des 10 espèces ressorties par le système de fusion : application de la règle de combinaison de Dubois et Prade

Appliquée à l'exemple 2, et puisque les 2 premières sources de données sont en conflit total, l'union des éléments focaux est le résultat du premier niveau de fusion comme le montre la figure 3.3. Nous arrivons ainsi à garder la bonne espèce même si elle n'a pas été proposée par

la première source de données. Pour le deuxième niveau de fusion, la bonne espèce e_2 n'a pas été proposée par la troisième source d'informations. Mais, la prise en compte de l'union des éléments focaux en conflit permet de garder cette espèce. Nous remarquons que, grâce à la masse considérable accordée à l'espèce e_2 par la deuxième source d'informations, cette espèce a conservé son importance lors de la fusion même si elle n'a pas été proposée par les autres sources.

Avec la règle de combinaison adaptative de Dubois et Prade, nous sommes capables de gérer les sources conflictuelles et peu fiables grâce à l'opération de disjonction. En effet cette opération présente l'avantage de garder le maximum d'information utile même si elle provient d'une seule source. Ceci est très utile dans notre cas parce que nous sommes souvent confrontés à des cas où une seule source d'informations est capable de donner la bonne espèce. Dans le cadre de la répartition des conflits partiels, d'autres règles dites règles de redistribution proportionnelle du conflit ont été proposées comme la règle de combinaison PCR5.

3.4.4 La règle de combinaison PCR6

Proposée en 2006 par Martin et Osswald, la règle de combinaison PCR6 permet une redistribution du conflit partiel sur les éléments focaux impliqués [94][95]. L'idée est de transférer la masse du conflit uniquement vers les éléments impliqués et proportionnellement à leurs masses individuelles. Ainsi, la spécificité de l'information est entièrement préservée. La règle de combinaison PCR6 est définie pour 2 sources d'informations comme suit :

$$m_{PCR6}(A) = m_{\odot}(A) + \sum_{\substack{B \in 2^\Omega \\ A \cap B = \emptyset}} \left[\frac{m_1(A)^2 m_2(B)}{m_1(A) + m_2(B)} + \frac{m_2(A)^2 m_1(B)}{m_2(A) + m_1(B)} \right] \quad (3.9)$$

La règle de combinaison PCR6 transfère la masse soit vers l'intersection (s'il n'y a pas de conflit), soit vers les éléments impliqués dans le conflit. Cette règle risque de ne pas pouvoir gérer les cas où le conflit est très important. Reprenons l'exemple 2 :

1. La PCR5 transfère la masse vers l'intersection. Dans notre cas, l'espèce e_2 est proposée par une seule source. Elle ne présente donc aucune intersection. Alors, aucune masse ne sera transférée vers e_2 à travers une intersection.
2. La PCR5 transfère la masse vers les éléments impliqués dans le conflit. Un élément n'est impliqué dans le conflit que lorsque son intersection avec un autre élément est l'ensemble vide. Vu la taille des éléments focaux, nous trouvons souvent une ou plusieurs espèces dans l'intersection. Donc la masse ne sera pas transférée vers les éléments impliqués dans le conflit mais plutôt vers les espèces présentes dans l'intersection même si ces

espèces ne contiennent pas la bonne espèce. Reprenons avec les éléments focaux F_{26} et F_{36} . Ces deux éléments ne sont pas considérés comme éléments impliqués dans le conflit puisqu'ils présentent une intersection au niveau des espèces e_1 , e_{17} , e_{20} et e_{32} . La masse est donc transférée vers ces éléments alors qu'aucune de ces espèces n'est la bonne espèce. Ainsi, aucune masse n'est transférée à e_2 . Nous remarquons aussi que pour l'exemple 2, l'espèce e_{32} appartient à tous les éléments focaux de S_2 et S_3 . Donc, dans tous les cas, il n'y aura pas d'intersection vide, donc pas d'éléments en conflit et donc pas de masse transférée vers ces éléments.

3. En combinant un élément focal contenant e_2 avec un élément focal de petite taille et contenant un nombre réduit d'espèces, nous avons plus de chance d'avoir une intersection vide. Dans ce cas, le conflit est redistribué vers les éléments focaux en question. Par la suite, une certaine masse sera accordée à l'élément focal contenant e_2 . Mais, vu l'imprécision des éléments focaux, nous n'avons pas souvent ce cas.

Finalement, c'est presque uniquement par le biais du troisième cas de figure qu'une masse est attribuée à la bonne espèce. Nous notons bien que nous n'avons pas ce cas pour l'exemple 2. Mais, il est possible de l'avoir avec d'autres individus.

Le principe de la PCR5 consistant à transférer de la masse vers les intersections des éléments focaux ou vers les éléments focaux impliqués dans le conflit ne convient pas à notre application. De par de la taille des éléments focaux, les cas où une masse est transférée vers les éléments focaux impliqués dans le conflit sont rares. Dans le cas de l'exemple 2, l'application de la règle PCR5 réduit le nombre d'éléments focaux contenant l'espèce e_2 . Ainsi elle aura moins de chance d'être proposée parmi les 10 premières espèces puisqu'une part importante de l'information est perdue. La figure 3.4 montre le résultat de la combinaison des masses de l'exemple 2 en utilisant la règle de combinaison PCR5. Nous remarquons qu'au premier niveau de fusion l'espèce e_2 est proposée en sixième position. En combinant avec la troisième source d'informations, le système n'est plus capable de proposer la bonne espèce ce qui renforce l'interprétation faite sur le fonctionnement de cette règle vis à vis des données.

3.4.5 La règle de combinaison DPCR

Appelée règle de redistribution proportionnelle du conflit affaibli, cette règle a été proposée par Martin [96]. C'est une extension de la règle de combinaison PCR5. Elle consiste à appliquer une procédure d'affaiblissement dans le but de transférer une partie du conflit




FIGURE 3.4: Classement de l'espèce e_2 dans la liste des 10 espèces ressorties par le système de fusion : application de la règle de combinaison PCR5

partiel vers l'ignorance partielle (l'union). Elle est définie comme suit :

$$\begin{cases} m_{DCPR}(A) = m_{\bigoplus}(A) + \sum_{A \cap B = \emptyset} \epsilon \left[\frac{m_1(A)^2 m_2(B)}{m_1(A) + m_2(B)} + \frac{m_2(A)^2 m_1(B)}{m_2(A) + m_1(B)} \right] \\ + \sum_{\substack{B \cup C = A \\ B \cap C = \emptyset}} (1 - \epsilon) m_1(B) m_2(C) \end{cases} \quad (3.10)$$

où ϵ représente le coefficient d'affaiblissement calculé pour M sources d'informations de la manière suivante :

$$\epsilon(F_1, \dots, F_M) = 1 - \sum_{i=1}^M f_i(F_1, \dots, F_M) \quad (3.11)$$

où i est l'indice de la source d'informations et f est une fonction de conflit donnant le nombre d'éléments focaux $F_i \in 2^\Theta$ en conflit. Une fonction f_i est définie de $(2^\Theta)^M$ dans $[0, \frac{1}{M}]$ tel que :

$$f_i(F_1, \dots, F_M) = \frac{\sum_{j=1}^M \mathbb{1}_{\{F_j \cap F_i\}}}{M(M-1)} \quad (3.12)$$

Cette propriété est très intéressante puisque l'affaiblissement se fait en fonction du nombre d'éléments focaux F_i en conflit.

Cette règle de combinaison est intéressante puisqu'elle transfère de la masse vers l'union en plus des éléments impliqués dans le conflit. Ceci permettra de garder le maximum d'information et représente ainsi une solution pour faire face aux inconvénients de la PCR5.

Appliquée à l'exemple 2, nous remarquons à travers la figure 3.5 que cette règle permet d'améliorer les performances du système à reconnaître l'espèce comparativement aux résultats obtenus avec la PCR5.




FIGURE 3.5: Classement de l'espèce e_2 dans la liste des 10 espèces ressorties par le système de fusion : application de la règle de combinaison DPCR

3.4.6 La règle de Florea et Jusselme

Appelée aussi règle de combinaison robuste, cette règle présentée en détails dans [97][54] est une somme pondérée de la règle conjonctive et disjonctive. Elle est définie de la manière suivante :

$$m_F(A) = \beta_1(k_{12})m_{\ominus}(A) + \beta_2(k_{12})m_{\cup}(A), \forall A \neq \emptyset \quad (3.13)$$

où β_1 et β_2 sont calculés à partir de la mesure de conflit global k_{12} entre 2 sources d'informations de la manière suivante :

$$\beta_1(k_{12}) + (1 - k_{12})\beta_2(k_{12}) = 1 \quad (3.14)$$

où

$$k_{12} = \sum_{A_i \cap B_j = \emptyset} m_1(A_i)m_2(B_j) \quad (3.15)$$

Cette règle prend en compte la mesure du conflit global existant entre les sources en calculant une somme pondérée de la règle disjonctive et la règle conjonctive. En fonction du conflit, une masse plus importante sera accordée aux éléments focaux issus de l'intersection. Ceci revient à dire que la bonne classe réside dans l'intersection. Or, ce n'est pas toujours le cas. Par exemple, lorsque les sources de données ne sont pas fiables et les éléments focaux sont imprécis, les éléments formant l'intersection n'incluent pas forcément la bonne réponse. Par contre, elle peut se trouver dans l'union. Ainsi, en affaiblissant la masse accordée à l'union, cela peut entraîner également l'affaiblissement de la masse accordée à la bonne classe.

Dans le cas de l'exemple 2, l'affaiblissement de la masse accordée à l'union engendre l'affaiblissement de la masse accordée à la bonne espèce. La règle de Florea présente, comme la règle de Dubois et Prade, l'avantage de transmettre les éléments conflictuels vers l'union. Mais, se fonder sur la mesure de conflit global pour affaiblir la masse accordée à l'union

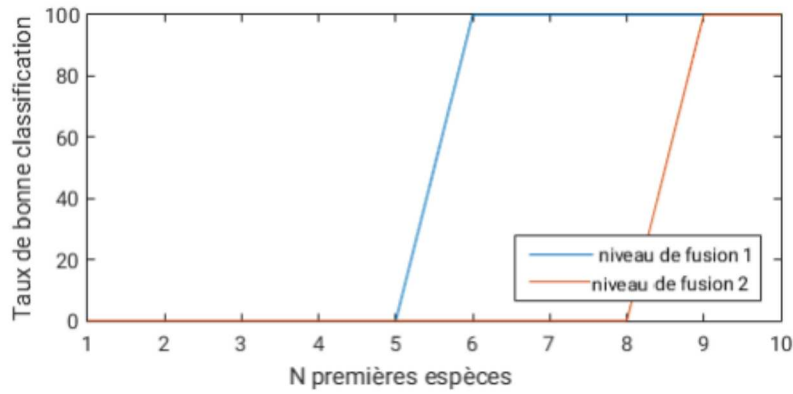


FIGURE 3.6: Classement de l'espèce e_2 dans la liste des 10 espèces ressorties par le système de fusion : application de la règle de combinaison de Florea et Jusselme

ne semble pas très utile pour notre cas. La figure 3.6 montre le résultat de la combinaison des données de l'exemple 2 suite à l'utilisation de la règle de Florea. Nous remarquons que l'espèce est proposée par le système en sixième position pour le premier niveau de fusion. En passant au niveau de fusion suivant et en fusionnant le résultat obtenu avec la troisième source de données, nous remarquons que le résultat se dégrade puisque l'espèce est proposée par le système en neuvième position. En effet, puisque la troisième source de données ne propose pas l'espèce e_2 , le classement de celle-ci a reculé. Une autre raison de ce recul est l'affaiblissement de la masse accordée à e_2 puisqu'elle fait partie des éléments conflictuels. Dans le même esprit de la règle de Florea, plusieurs autres règles de combinaison sont proposées.

3.4.7 La règle de combinaison mixte

Martin et Osswald ont proposé une extension de la règle robuste de Florea et Jusselme [96]. Contrairement à la règle présentée dans les équations 3.14 et 3.15 où les fonctions de conflits dépendent de la mesure du conflit global, les fonctions de conflit proposées par la règle de combinaison mixte peuvent être fonction du conflit global, des conflits partiels ou de la taille des ensembles en conflit. La règle de combinaison conjonctive, de Florea et celle de Dubois et Prade présentent des cas particuliers de la règle de combinaison mixte. Cette règle permet une plus grande précision lors du calcul des masses à chaque combinaison partielle. La règle mixte est définie de la manière suivante :

$$m_{mixte}(A) = \sum_{B \cap C = A} \delta_1(B, C) m_1(B) m_2(C) + \sum_{B \cup C = A} \delta_2(B, C) m_1(B) m_2(C) \quad (3.16)$$

où δ_1 et δ_2 sont 2 fonctions pouvant être définies de différentes manières. Lorsqu'il s'agit de sources de données non fiables, les définitions suivantes sont utilisées :

$$\delta_1(B, C) = 1 - \frac{|B \cap C|}{|B \cup C|} \quad (3.17)$$

$$\delta_2(B, C) = 1 - \delta_1(B, C) \quad (3.18)$$

Si nous avons un conflit partiel entre B et C , $|B \cap C| = 0$, la masse est transférée vers $B \cup C$. Si $B \subset C$ (ou le contraire) alors $B \cap C = B$ et $B \cup C = C$, ainsi la règle de combinaison mixte transfère la masse vers B et C suivant le rapport de cardinalité $|B|/|C|$. Lorsque $B \cap C \neq B, C, \emptyset$, la masse est transférée vers $B \cap C$ et $B \cup C$. Cette propriété est très importante et s'avère être efficace puisqu'en cas d'intersection entre les éléments focaux, la masse n'est pas transférée uniquement vers l'intersection mais aussi vers l'union. Cela peut résoudre certains problèmes. Considérons l'exemple 2, en cas de la combinaison des éléments focaux $F_{2,6}$ et $F_{3,6}$, la masse est transférée d'une part vers les éléments formant l'intersection donc e_1, e_{17}, e_{20} et e_{32} et d'autre part vers l'union et donc une certaine masse sera accordée à la bonne espèce e_2 .

La figure 3.7 montre que nous obtenons le même classement de e_2 que pour la règle de combinaison de Dubois et Prade et la règle de combinaison DPCR.




FIGURE 3.7: Classement de l'espèce e_2 dans la liste des 10 espèces ressorties par le système de fusion : application de la règle de combinaison Mixte

3.4.8 Conclusion

Le tableau 3.1 met en évidence les différences et les points communs existants entre les différentes règles de combinaison. Ce tableau présente, pour chaque règle de combinaison, les éléments focaux vers lesquels la masse est transférée ainsi que le type de pondération. Nous

remarquons que la masse est généralement transférée soit vers l'intersection soit vers l'union. La PCR5 et la DPCR présentent une certaine différence à ce niveau en transférant de la masse vers les éléments impliqués dans le conflit. Si nous suivons l'ordre chronologique de l'apparition des règles de combinaison, nous remarquons des modifications et des améliorations au niveau de la manière dont les masses sont pondérées lors d'une fusion. C'est en changeant le facteur de pondération que plusieurs règles de combinaison sont apparues ce qui montre l'importance de ce facteur.

Nom de la règle	Masse transférée vers	Type de pondération
Conjonctive	l'intersection	poids constant
Disjonctive	l'union	poids constant
Dempster	l'intersection	poids dépendant du conflit global
Dubois et Prade	l'intersection et l'union	poids constant
PCR6	l'intersection les éléments impliqués dans le conflit	poids constant poids en fonction de m_1 et m_2
DPCR	l'intersection les éléments impliqués dans le conflit l'union	poids constant poids en fonction de m_1 et m_2 et du coefficient d'affaiblissement ϵ poids en fonction du coefficient d'affaiblissement ϵ
Florea	l'intersection et l'union	poids en fonction du conflit global
Mixte	l'intersection et l'union	poids pouvant être en fonction du conflit global, du conflit partiel ou de la taille des ensembles en conflit

TABLE 3.1: Tableau récapitulatif des éléments focaux vers lesquels la masse est transférée et les types de pondération pour les différentes règles de combinaison

Dans la suite, toutes les règles de combinaison adaptatives seront testées pour d'une part évaluer les performances de chacune à gérer les imperfections des données et d'autre part évaluer le temps de calcul nécessaire pour chacune d'elles.

3.5 Critères de prise de décision

L'objectif de l'application étant de présenter à l'utilisateur une liste des 10 premières espèces les plus probables, nous nous intéressons donc au critère de prise de décision "le maximum de probabilité pignistique" ou *BetP*. Ce critère proposé par Smets dans [98] [55],

permet de transformer les fonctions de masse en mesures de probabilités de la manière suivante :

$$BetP(\omega_k) = \frac{1}{1 - m(\emptyset)} \sum_{A \ni \omega_k} \frac{m(A)}{|A|} \quad (3.19)$$

Ainsi, nous sommes capables de fournir à l'utilisateur une liste ordonnée des espèces les plus probables et non pas une liste ordonnée des ensembles d'espèces les plus probables. Le critère de maximum de probabilité pignistique permet de lever l'imprécision pouvant entacher les données suite à l'utilisation des fonctions de masse consonantes.

3.6 Expérimentation et résultats

Une fois que tous les blocs fonctionnels du système sont mis en place, nous pouvons commencer l'évaluation de l'influence de chacun sur le déroulement du processus de fusion. Les différents outils sont évalués un par un en respectant le même ordre de leur utilisation dans le système de fusion. Nous commençons donc par évaluer les différentes méthodes permettant de construire des fonctions de masse à partir des distributions de probabilité. Ensuite, nous passons à l'évaluation des méthodes d'approximations. Et enfin, nous terminons par l'évaluation du comportement de chaque règle de combinaison.

3.6.1 Évaluation des méthodes de construction des fonctions de masse

La méthode de construction des fonctions de masse à partir de distributions de probabilité influence énormément le comportement du système. Il est important de construire des fonctions de masse représentant au mieux toutes les informations disponibles. Deux méthodes pour la construction des fonctions de masse sont évaluées : les fonctions de masse bayésiennes et les fonctions de masse consonantes. Ces deux méthodes sont évaluées en considération des trois paramètres suivant : la règle de combinaison, l'approximation et le nombre k d'éléments focaux.

Le nombre k d'éléments focaux est fixé à 5 dans un premier temps. Deux tests sont effectués :

- un premier test est effectué en faisant varier la règle de combinaison et en appliquant l'approximation $k - l - x$ avec $k = 5$.
- un deuxième test est effectué en faisant varier la méthode d'approximation et en appliquant la règle de combinaison adaptative de Dubois et Prade (toute autre règle de

combinaison aurait pu être utilisée à la place de la règle de combinaison adaptative de Dubois et Prade. Le but est de voir si nous obtenons toujours le même résultat en faisant varier la méthode d'approximation des fonctions de masse).

Le premier test permet de voir l'influence de la variation des règles de combinaison. Les figures 3.8 et 3.9 correspondant respectivement aux résultats obtenus pour le premier et le deuxième niveau de fusion. Nous remarquons que les fonctions de masse consonantes donnent de meilleurs résultats pour les deux niveaux de fusion quelque soit la règle de combinaison

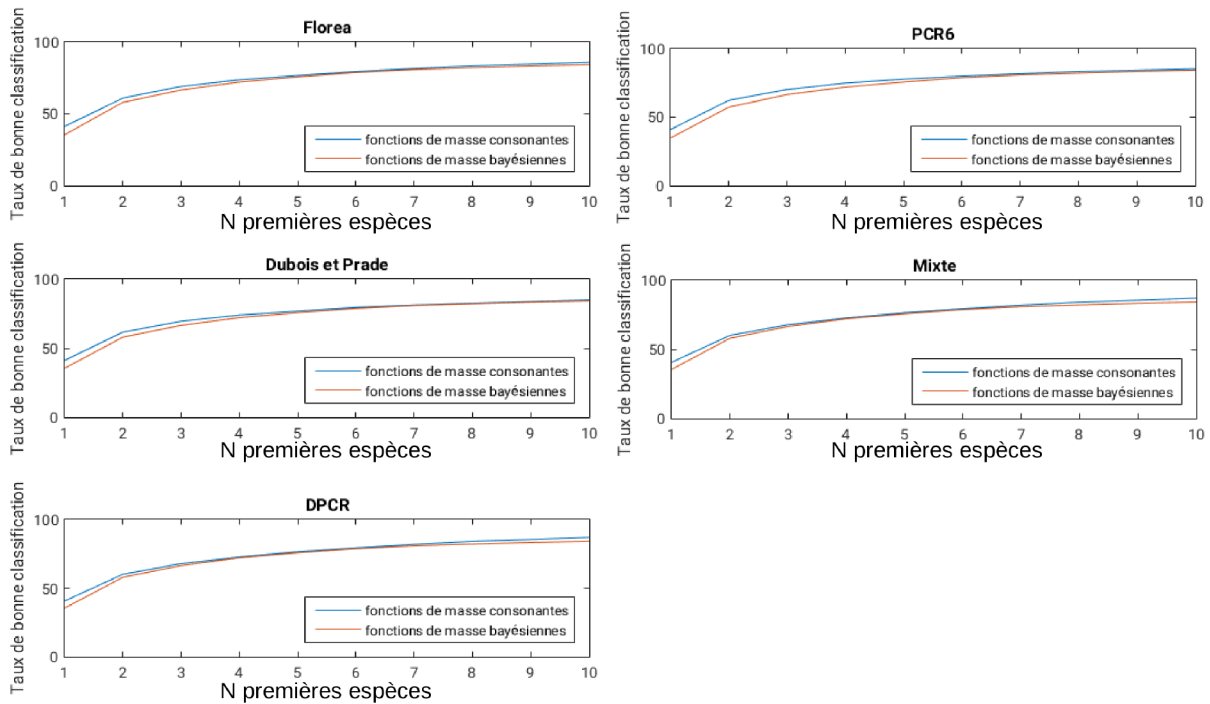


FIGURE 3.8: Influence de la méthode de construction des fonctions de masse pour des règles de combinaison différentes : premier niveau de fusion

Le deuxième test permet de voir l'influence de la méthode d'approximation. Les figures 3.10 et 3.11 correspondent respectivement aux résultats obtenus pour le premier et le deuxième niveau de fusion. Nous remarquons que les fonctions de masse consonantes donnent de meilleurs résultats pour les deux niveaux de fusion quelque soit l'approximation.

En conclusion, quelque soit la règle de combinaison et quelque soit l'approximation, le système de fusion a de meilleures performances en terme de taux de bonne classification lorsque les fonctions de masse sont consonantes.

La construction de fonctions de masse consonantes permet de transférer beaucoup plus de connaissances que celles transférées avec les fonctions de masse bayésiennes. Il est vrai qu'elles sont imprécises, mais, dans le cas de sources conflictuelles et fiables contextuellement, cette

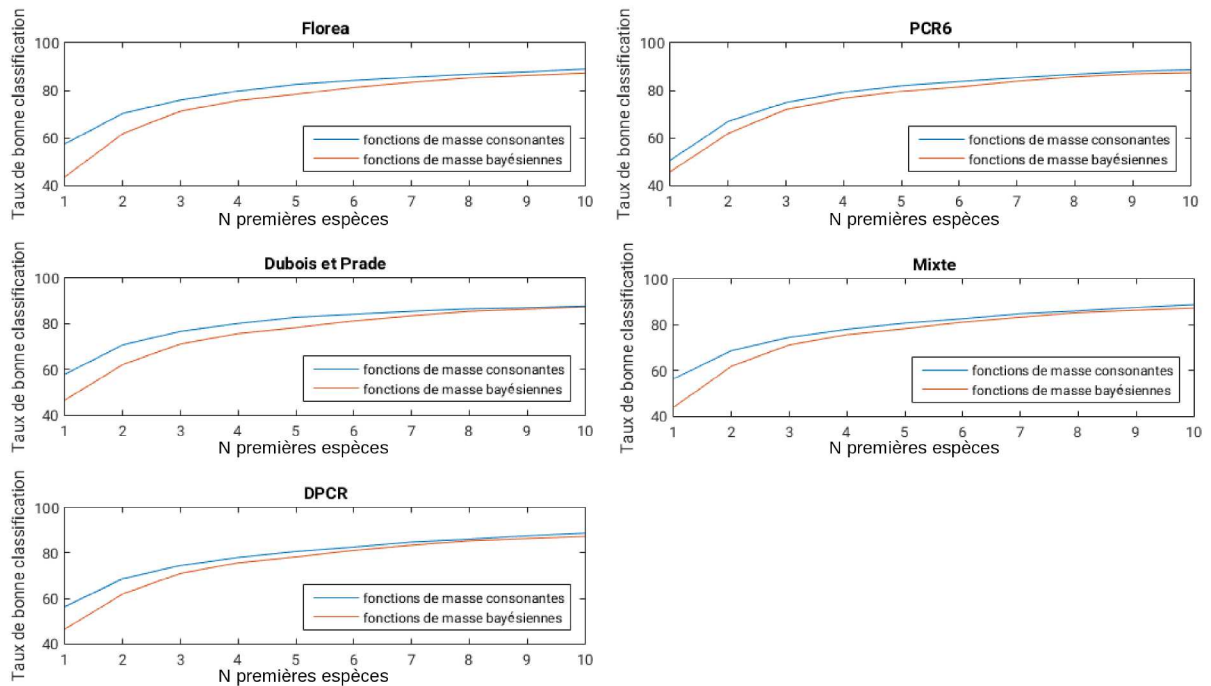


FIGURE 3.9: Influence de la méthode de construction des fonctions de masse pour des règles de combinaison différentes : deuxième niveau de fusion

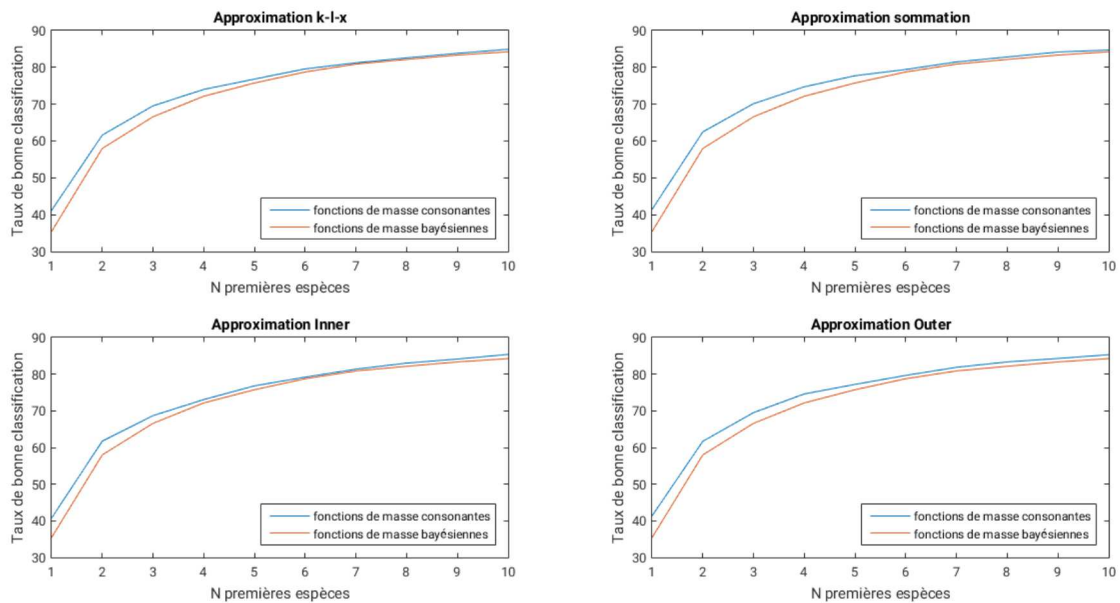


FIGURE 3.10: Influence de la méthode de construction des fonctions de masse pour des méthodes d'approximation différentes : premier niveau de fusion

imprécision est plutôt un avantage puisqu'elle permet plus de flexibilité entre les sources. La méthode de construction des fonctions de masse consonantes est retenue.

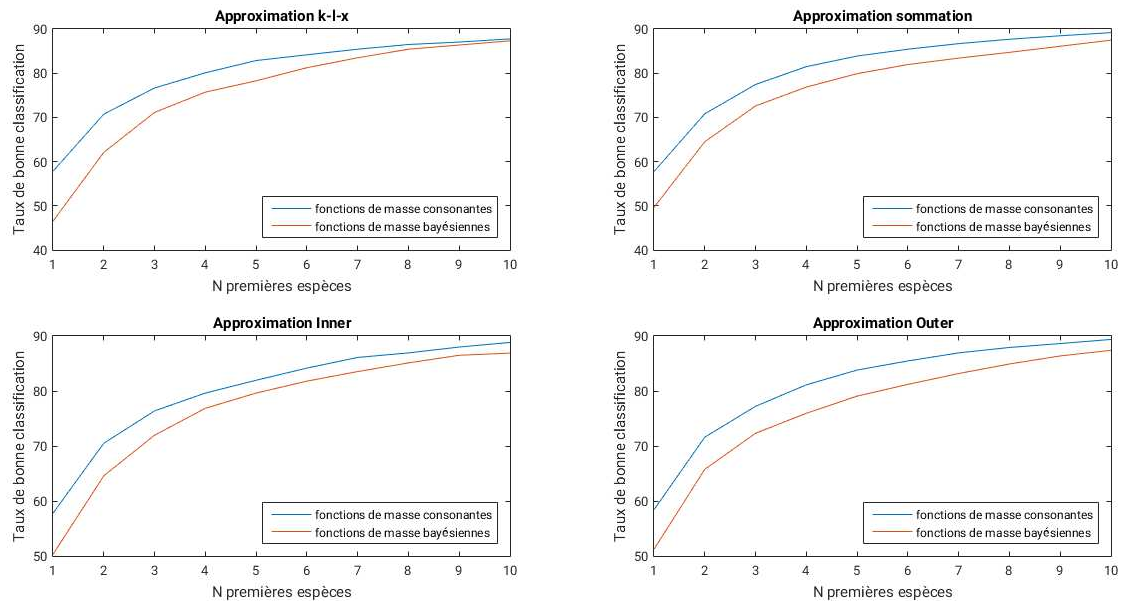


FIGURE 3.11: Influence de la méthode de construction des fonctions de masse pour des méthodes d'approximation différentes : deuxième niveau de fusion

3.6.2 Évaluation des méthodes d'approximation des fonctions de masse




FIGURE 3.12: Évaluation de l'influence des méthodes d'approximation des fonctions de masse sur les performances du système de fusion pour le premier niveau de fusion

Une fois que les fonctions de masse sont construites, nous passons à l'étape d'approximation. Cette étape est nécessaire vu l'augmentation exponentielle de la complexité calculatoire

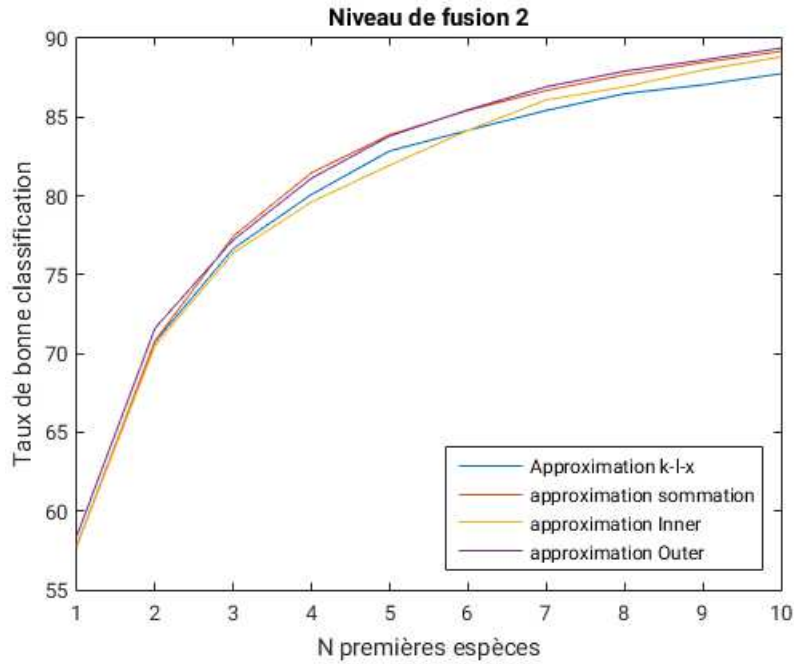


FIGURE 3.13: Évaluation de l’influence des méthodes d’approximation des fonctions de masse sur les performances du système de fusion pour le deuxième niveau de fusion

en fonction du nombre de sources à fusionner ainsi qu’en fonction de la taille de l’espace de discernement. Dans notre cas, le nombre de sources à fusionner continuera à augmenter chaque fois qu’une nouvelle modalité sera rajoutée. L’espace de discernement est considéré de grande taille puisqu’il comporte 72 hypothèses. Il est donc nécessaire d’approximer les fonctions de masse pour diminuer la complexité calculatoire et avoir un temps de calcul acceptable. Pour cela, quatre approximations sont évaluées : l’approximation $k-l-x$, l’approximation sommation, l’approximation “Inner” et l’approximation “Outer”. Dans un premier temps, le nombre d’éléments focaux est fixé à $k = 5$. L’impact de la valeur de k est évaluée par la suite. Comme pour évaluer les méthodes de construction des fonctions de masse, la combinaison est faite avec la règle de combinaison de Dubois et Prade.

D’après les figures 3.12 et 3.13, nous remarquons que le système a des performances similaires avec les différentes approximation surtout au premier niveau de fusion. Au deuxième niveau de fusion, les résultats obtenus avec l’approximation “Outer” et l’approximation sommation sont meilleurs que ceux obtenus avec les autres approximations. Ceci est visible par le taux de bonne classification obtenu pour les 10 premières espèces ressorties par le système.

Afin de faire le choix entre ces deux méthodes d’approximation, un deuxième paramètre est pris en compte : le temps de calcul. Le tableau 3.2 montre le temps de calcul moyen par individu dans le cas d’une approximation “Outer” et une approximation sommation. Les programmes sont implémentés sous MATLAB Version 8.5 (R2015a) et ont été exécutés sur une machine Intel(R) Core(TM) i5-4300M 2.60GHz CPU.

Nous remarquons que le temps de calcul moyen par individu est 14 fois plus important

approximation	temps de calcul moyen par individu
sommation	65ms
outer	1191ms

TABLE 3.2: Temps de calcul moyen par individu : approximation sommation et approximation "Outer"

lorsqu'il s'agit de l'approximation "Outer". En prenant en compte la contrainte temps de calcul, **l'approximation sommation est retenue.**

L'approximation sommation permet de réduire le nombre k d'éléments focaux rendant ainsi les calculs plus faciles et plus rapides. Les figures 3.14 et 3.15 montrent l'influence de la variation de k sur les performances du système de fusion. Il est évident que plus le nombre k d'éléments focaux est important meilleures sont les performances du système. Il faut donc trouver le bon compromis entre performance et temps de calcul. D'après la figure 3.16, nous remarquons que le meilleur taux de bonne classification est obtenu pour $k = 15$. Ceci est visible surtout pour le deuxième niveau de fusion. Mais, pour $k = 15$ le temps de calcul moyen par individu est de $354ms$. Pour une valeur de $k = 10$, le taux de bonne classification est très proche de celui pour $k = 15$ avec un temps de calcul réduit à $199ms$ comme le montre le tableau 3.3. Nous décidons donc de **retenir la valeur $k = 10$.**




FIGURE 3.14: Évaluation de l'influence de la valeur de k sur les performances du système de fusion pour le premier niveau de fusion

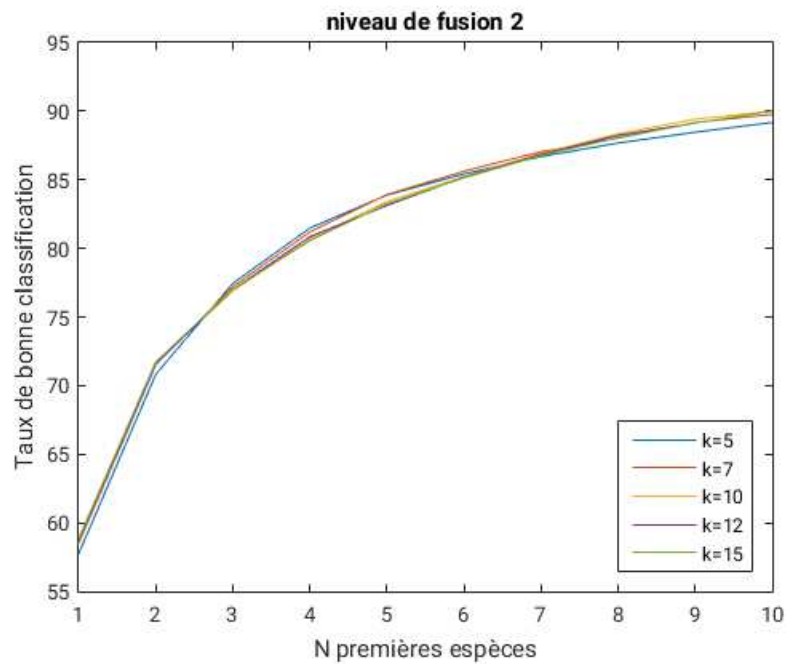


FIGURE 3.15: Évaluation de l'influence de la valeur de k sur les performances du système de fusion pour le deuxième niveau de fusion

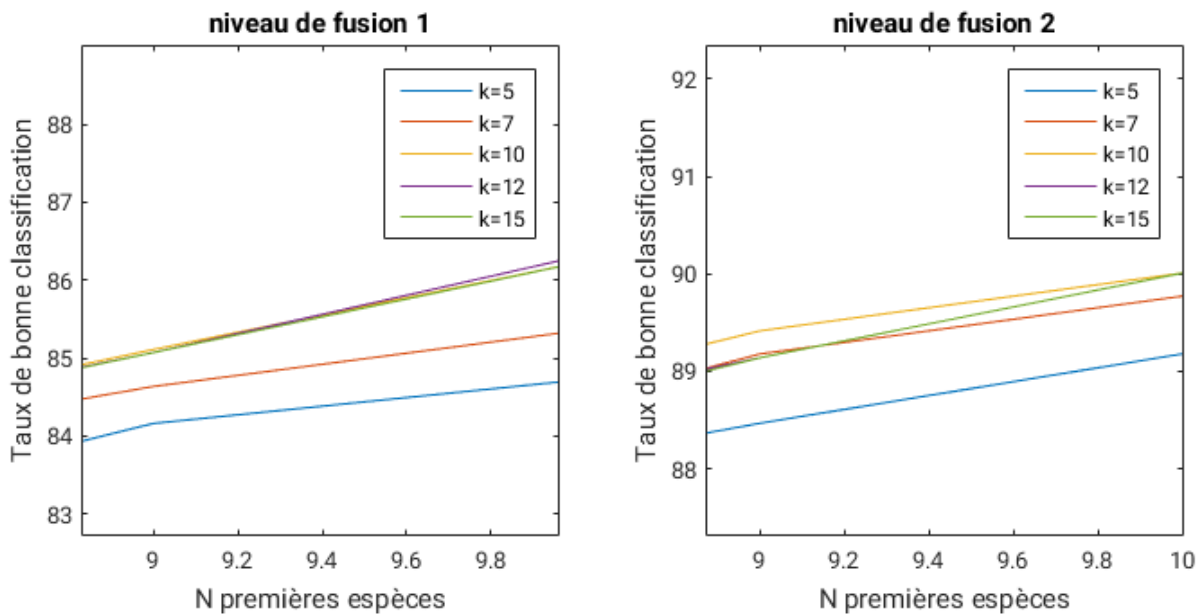


FIGURE 3.16: Évaluation de l'influence de la valeur de k sur les performances du système de fusion pour les deux niveaux de fusion : zoom pour la neuvième et dixième espèces ressorties

approximation	k=5	k=7	k=10	k=12	k=15
sommation	65ms	108ms	199ms	260ms	354ms

TABLE 3.3: Variation du temps de calcul moyen par individu en fonction de la valeur de k

3.6.3 Évaluation des règles de combinaison

En faisant varier la règle de combinaison, nous obtenons les résultats présentés dans la figure 3.17. Le tableau 3.4 présente le temps de calcul moyen par individu pour chaque règle de combinaison. La règle de combinaison DPCR présente le meilleur compromis entre taux de bonne classification et temps de calcul.

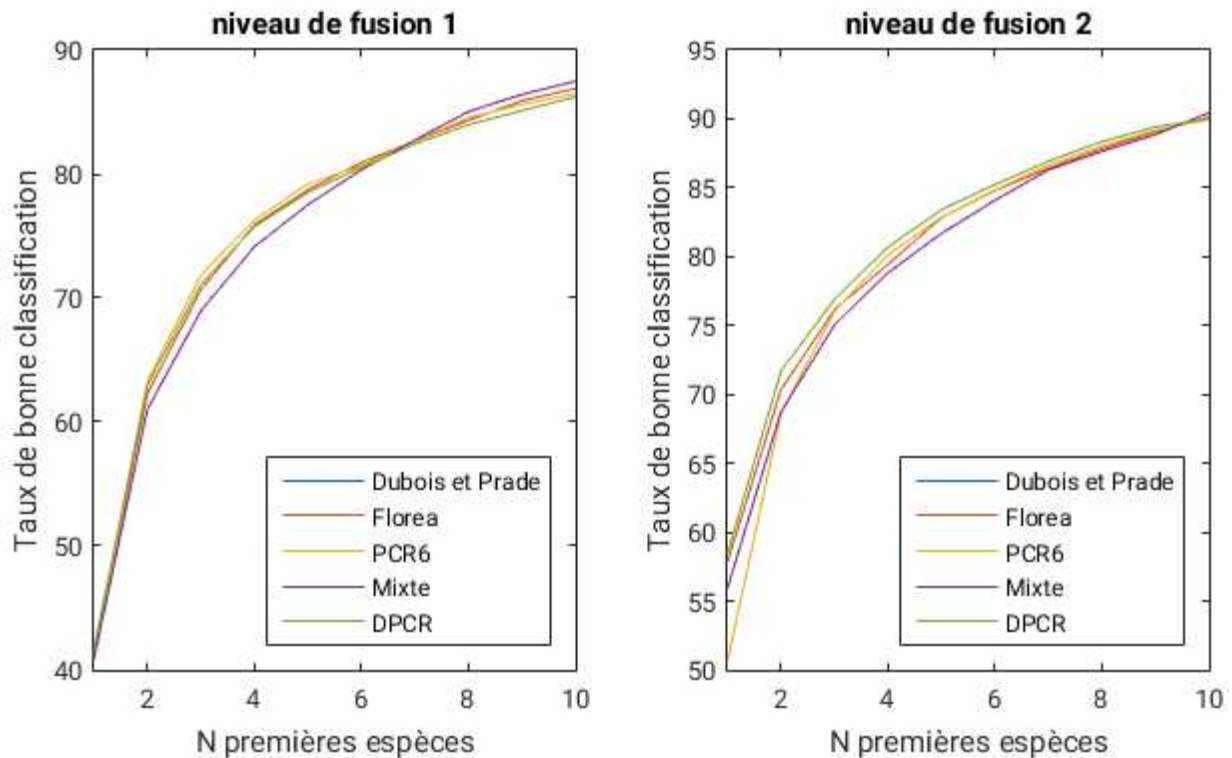


FIGURE 3.17: Évaluation de l'influence des règles de combinaison sur les performances du système de fusion pour les différents niveaux de fusion

règle de combinaison	temps de calcul moyen par individu
Florea	522ms
PCR5	163ms
Dubois et Prade	199ms
Mixte	634ms
DPCR	305ms

TABLE 3.4: Variation du temps de calcul moyen par individu en fonction de la valeur de k

La règle de combinaison DPCR est une règle commutative mais non associative. De ce fait, le résultat de la fusion n'est pas le même si nous combinons dans l'ordre S_1, S_2 puis S_3 ou si nous combinons dans l'ordre S_3, S_1 et S_2 . L'ordre de combinaison des classifieurs nécessite donc d'être étudié vu que la règle de combinaison retenue est non associative. Par contre, si la règle de combinaison retenue est commutative et associative, dans ce cas l'ordre

dans lequel les différentes sources d'informations sont fusionnées n'a aucune influence sur le résultat qui reste inchangé. C'est en fonction de la règle de combinaison choisie que nous pouvons savoir si l'ordre de combinaison a une importance ou pas. Dans notre cas, et vue que la règle de combinaison la mieux adaptée à notre application est une règle commutative mais non associative, l'ordre dans lequel les sources de données sont combinées nécessite d'être étudié.

3.6.4 Ordre de fusion des classifieurs

Les sources de données peuvent être fusionnées dans des ordres différents suivant le critère choisi. Elles peuvent être fusionnées par ordre de performance. Ainsi deux possibilités sont offertes : soit commencer par la source la plus performante et finir avec celle la moins performante, soit commencer avec la moins performante et finir avec la plus performante. Elles peuvent aussi être fusionnées en prenant en compte le degré de conflit partiel existant entre deux sources d'informations. Dans ce cas aussi, deux possibilités sont offertes : soit commencer par les deux sources représentant le plus de conflit et ensuite rajouter la troisième source, soit, au contraire, commencer par fusionner les deux sources les moins conflictuelles et après rajouter la troisième source.

Dans [54], Florea explique que dans le cas de règles de combinaison non-associatives, la dernière source d'information fusionnée a implicitement plus d'importance. De ce fait, l'idée est de fusionner les sources d'informations dans l'ordre croissant de leur performance si le critère choisi est la performance. Sinon dans l'ordre décroissant du degré de conflit si le critère choisi est le degré de conflit partiel. Dans ce cas, les deux sources représentant le plus de conflit partiel sont fusionnées en premier.

La mesure de la performance d'un classifieur revient à la mesure de son taux de bonne classification à la sortie de la forêt aléatoire correspondante. Comme le montre la figure 2.10, le classifieur de la caractéristique contour est le classifieur le moins performant suivi du classifieur des caractéristiques base et sommet et finalement le classifieur de la caractéristique modèle polygonal. L'ordre de fusion est statique. Il est fixe et ne change pas pour tous les individus de l'ensembles de tests.

Le calcul du conflit partiel k_{12} entre deux sources d'informations revient à calculer la masse de l'ensemble vide. Ce conflit est calculé pour chaque individu de l'ensemble de test. Au total, trois conflits partiels sont calculés : k_{12} , k_{13} et k_{23} correspondant respectivement aux conflits entre S_1 et S_2 , S_1 et S_3 et S_2 et S_3 . Suivant le degré de conflit, l'ordre de combinaison est fixé. Cet ordre est dynamique puisqu'il change d'un individu à un autre.

La figure 3.18 montre les résultats obtenus pour les deux ordres de fusion. Le tableau 3.5 montre le temps de calcul nécessaire par individu pour chaque ordre de fusion. Il est évident qu'en calculant le taux de conflit partiel pour chaque individu, le temps de calcul est plus élevé par rapport à la première méthode qui ne nécessite aucun calcul supplémentaire et se base uniquement sur les degrés de performances calculés une seule fois à la sortie des forêts aléatoires.

Nous remarquons sur la figure 3.18 que la méthode dynamique basée sur les conflits partiels donne des résultats presque similaires à ceux obtenus avec la fusion statique pour le premier et le deuxième niveau de fusion. En prenant en compte la contrainte du temps de calcul, **l'ordre de fusion statique est retenu** puisqu'il offre le meilleur compromis entre le taux de bonne classification et le temps de calcul (voir Tableau 3.5).

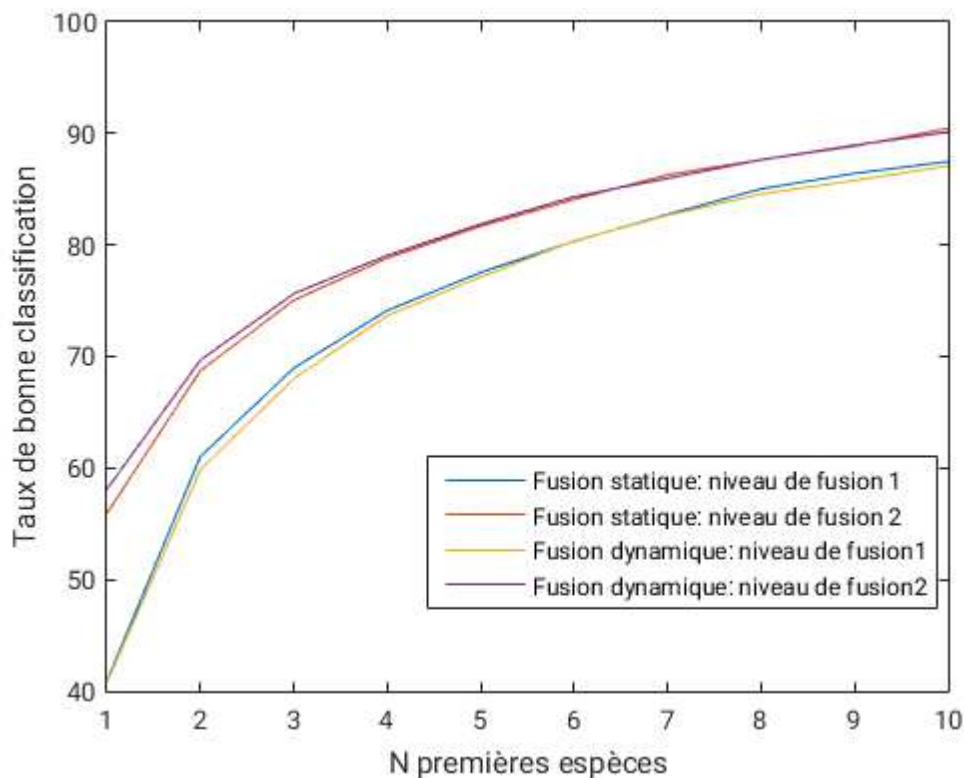


FIGURE 3.18: Évaluation de l'influence de l'ordre de fusion des classifieurs sur les performances du système pour les différents niveaux de fusion

Ordre de fusion	temps de calcul moyen par individu
statique	634ms
dynamique	1031ms

TABLE 3.5: Temps de calcul moyen par individu : fusion statique et fusion dynamique

3.7 Conclusion

Dans ce chapitre un système de fusion est mis en place. Il permet de fusionner les données issues de différentes sources d'informations caractérisant les feuilles des arbres. L'architecture du système permet de répondre à l'objectif éducatif de l'application puisqu'elle permet à l'utilisateur de suivre le processus de fusion et de regarder l'apport de chaque source d'information.

Le contexte de la reconnaissance des espèces d'arbres est un problème réel où les différents types d'imperfections des données existent. Nous avons constitué le cadre théorique du travail en le projetant dans le cadre de la théorie des fonctions de croyance. Face à des données assez spécifiques, l'idée n'était pas d'éliminer les sources d'imperfections, mais, plutôt essayer de modéliser de la meilleure façon possible toutes les imperfections existantes.

La théorie des fonctions de croyance est connue par sa capacité à gérer des données conflictuelles et imprécises. Mais, son inconvénient majeur est sa complexité calculatoire qui augmente exponentiellement en fonction de la taille de l'espace de discernement ainsi que le nombre de sources d'informations à combiner. Or, avoir une complexité calculatoire réduite est un critère essentiel pour notre application. Nous avons donc cherché le meilleur compromis qui permet de réduire la complexité calculatoire tout en gardant un maximum d'informations.

L'un des objectifs principaux de l'application est de présenter à l'utilisateur une liste des 10 espèces les plus probables. Le critère de prise de décision "maximum de probabilité pignistique" permet de construire une distribution de probabilité à partir des fonctions de croyance. Pour accorder une probabilité à une espèce, ce critère se base entre autres sur le nombre d'apparition de l'espèce dans les éléments focaux. Plus ce nombre est important plus la probabilité accordée à l'espèce est importante et plus ses chances d'apparaître parmi les 10 premières espèces sont importantes.

Sachant que les sources d'informations sont conflictuelles et peu fiables, l'idée était de trouver la règle de combinaison pour laquelle les espèces en conflit et ayant une masse faible ne sont pas rejetées. Au contraire, une masse plus importante leur est accordée grâce à la redistribution du conflit sur les éléments en conflit et l'ignorance partielle.

Finalement, et pour voir l'apport du système de fusion proposé par rapport au système de fusion existant actuellement dans Folia, une comparaison est faite en utilisant la même base de données pour l'apprentissage et le test. Il est important de rappeler que dans la version actuelle de Folia, la fusion se fait au niveau des attributs. La classification est faite grâce à un k-NN. Les taux de bonne classification sont calculés pour les 10 premières espèces les plus probables. La figure 3.19 montre que le système de fusion proposé permet des performances

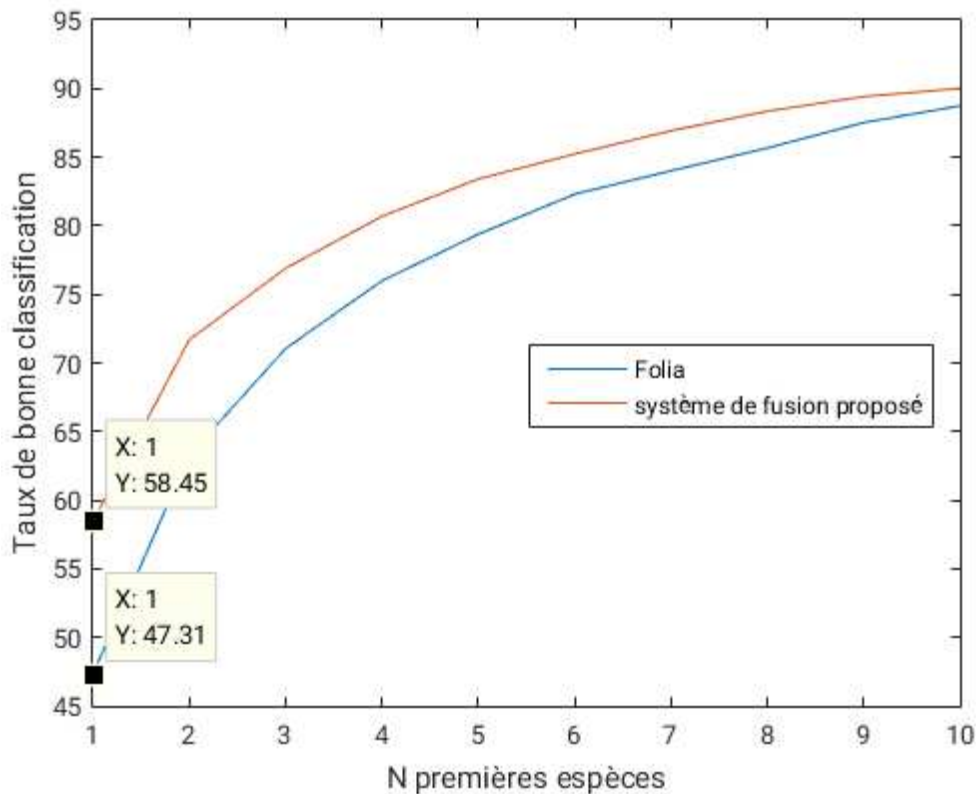


FIGURE 3.19: Comparaison des performances du système de fusion proposé par rapport à celles du système de fusion existant actuellement dans Folia

meilleures que celles de Folia en terme de taux de bonne classification. Cette amélioration est notée surtout pour $N = 1$. Le taux de bonne classification augmente d'environ 11%. Pour $N = 10$ cette amélioration est moins importante.

Le tableau 3.6 présente les avantages et les inconvénients des différentes méthodes utilisées pour la construction des fonctions de masse, l'approximation, le choix des règles de combinaison et le choix de l'ordre de la fusion des sources d'informations.

Dans le prochain chapitre, nous nous intéressons à l'ajout d'une nouvelle modalité à notre système : la modalité écorce. L'apport de cette modalité sera donc étudié. Les mécanismes de correction des fonctions de masse seront employés afin de mieux gérer les imperfections existantes et de pouvoir construire des fonctions de masse mieux représentatives des données disponibles.

		avantages	inconvénients
Construction des fonctions de masse	fonctions de masse consonantes	<ul style="list-style-type: none"> - meilleure représentation des informations disponibles - les éléments focaux sont des ensembles : plus de flexibilité 	<ul style="list-style-type: none"> - imprécision (éléments focaux de grande taille)

	fonctions de masse bayésiennes	- éléments focaux certains et précis	- peu représentatives des informations disponibles - les éléments focaux sont des singletons (flexibilité réduite)
Approximation des fonctions de masse	$k - l - x$	- simple (complexité calculatoire réduite)	- élimination d'une partie des informations disponibles
	Outer	- préservation de toutes les informations disponibles (le nouveau élément focal est l'union des éléments focaux fusionnés)	- imprécision (éléments focaux de grande taille) - complexité calculatoire importante (1191ms/individu)
	Inner	- précision (construction d'éléments focaux de petite taille)	-perte d'une partie des informations disponibles (le nouveau élément focal est l'intersection des éléments focaux fusionnés)
	Sommation	- complexité calculatoire réduite (65ms/individu) - préservation de toutes les informations disponibles	- le k ème élément focal est de grande taille
Les règles de combinaison	conjonctive	- préservation de la spécificité des informations - précision (transfère la masse vers l'intersection)	- ne traite pas le conflit
	disjonctive	- transfère la masse vers l'union - la règle la plus simple pour le traitement de sources non fiables ou conflictuelles	- perte de la spécificité des informations - augmentation de l'imprécision
	Dempster	- affaiblissement de la masse transféré vers les éléments non conflictuels en fonction du conflit	- exige que toutes les sources soient fiables - incapacité de gérer les cas où le conflit est très important

	Dubois et Prade	<ul style="list-style-type: none"> - répartition du conflit partiel sur l'ignorance partielle - gestion des sources conflictuelles et peu fiables grâce à l'opération de disjonction - préservation d'un maximum d'informations 	<ul style="list-style-type: none"> - le conflit partiel est redistribué uniquement sur l'ignorance partielle - pas de pondération pour la redistribution du conflit
	PCR6	<ul style="list-style-type: none"> - préservation de la spécificité de l'information 	<ul style="list-style-type: none"> - le conflit partiel est redistribué uniquement sur les éléments impliqués
	DPCR	<ul style="list-style-type: none"> - redistribution du conflit vers les éléments impliqués ainsi que vers l'ignorance partielle 	–
	Florea et Jousseme	<ul style="list-style-type: none"> - prise en compte du degré de conflit en calculant une somme pondérée sur la conjonction et la disjonction 	<ul style="list-style-type: none"> - une masse plus importante est transférée vers l'intersection
	Mixte	<ul style="list-style-type: none"> - la fonction de conflit dépend du conflit partiel - en présence de conflit ou pas une certaine masse est transférée vers l'ignorance partielle 	<ul style="list-style-type: none"> - le conflit est transféré uniquement vers l'intersection ou l'union
ordre de fusion des classifieurs	statique	<ul style="list-style-type: none"> - complexité calculatoire réduite (634ms/individu) 	<ul style="list-style-type: none"> - même ordre de fusion fixe pour tous les individus
	dynamique	<ul style="list-style-type: none"> - ordre de fusion variable d'un individu à un autre suivant le degré de conflit 	<ul style="list-style-type: none"> - complexité calculatoire importante (1031ms/individu)

TABLE 3.6: Tableau récapitulatif des avantages et inconvénients de toutes les méthodes testées pour la construction des fonctions de masse, la combinaison des sources d'informations et le choix de l'ordre de fusion

Chapitre 4

Reconnaissance des espèces d'arbres à partir des feuilles et des écorces

Contrairement aux feuilles et à d'autres modalités de l'arbre telles que les fleurs et les fruits, l'écorce est l'organe toujours présent quelque soit la saison. L'écorce, présente toute l'année, est une source d'informations importante pour la reconnaissance d'espèces d'arbres. Certaines espèces ont des écorces particulières ce qui facilite la tâche de la reconnaissance. Nous pouvons citer les bouleaux qui ont une écorce blanche se détachant en lanières, le peuplier blanc présentant une écorce lisse gris-vert trouée de petits losanges caractéristiques...

Pour d'autres espèces, l'identification est plus délicate vue la similarité des écorces appartenant à des espèces différentes et la variabilité des écorces appartenant à une même espèce. Généralement l'aspect de l'écorce change en fonction de l'âge. Il est plutôt lisse chez un sujet jeune, se fissure ou se craquelle chez des sujets plus âgés.

Dans ce chapitre, nous nous intéressons d'abord à la fusion des données issues des écorces. Ces données sont extraites à partir de photos d'écorces et décrivent les caractéristiques les plus pertinentes. Nous adoptons la même architecture de fusion que celle pour les feuilles et nous cherchons les paramètres pour lesquels les performances du système de fusion sont les meilleures.

Ensuite, un système de fusion hiérarchique est proposé pour fusionner la modalité feuille avec la modalité écorce.

Pour avoir de meilleures performances pour les écorces, l'idée est de corriger les informations apportées par cette modalité. Nous nous intéressons donc à l'étude des techniques de correction des fonctions de masse. Une méthode est proposée pour extraire des méta-connaissances à partir de la matrice de confusion permettant par la suite de corriger contextuellement les fonctions de masse.




FIGURE 4.1: (a) : cannelée, (b) : crevassée, (c) : lisse, (d) : fibreuse, (e) : fissurée, (f) : se détachant par lanières, (g) : se détachant par écailles, (h) : se détachant par plaques

Finalement, la section expériences et résultats permet de tester l'impact de la méthode proposée sur la performance du système de fusion des écorces, des feuilles et des deux modalités ensemble.

4.1 Les écorces de plus près

4.1.1 Qu'est ce qu'une écorce ?

Une écorce est définie dans l'Encyclopédie LAROUSSE par :

« Une écorce est un ensemble de couches cellulaires de l'axe des végétaux vasculaires, entourant le cylindre central, séparé de celui-ci par un endoderme et recouvert extérieurement par un épiderme. »

Une écorce est donc l'enveloppe des troncs des arbres caractérisée de l'intérieur par un endoderme et de l'extérieur par une couche appelée épiderme ayant différents aspects et variable d'une espèce à une autre.

L'aspect des écorces est aussi varié que les feuilles d'un point de vue visuel. On distingue les écorces lisses, lisses peu fissurées, lisses et cannelées, rugueuses se détachant par lanières, se détachant par plaques, se détachant par écailles, fibreuses, filandreuses, fissurées (les fissures sont verticales), crevassées... La figure 4.1 présente certains aspects d'écorces.

Grâce à ses caractéristiques, l'aspect d'une écorce peut être déterminant dans le reconnaissance de l'espèce d'un arbre. La fusion des informations décrivant ces caractéristiques peut faciliter davantage la reconnaissance.

4.2 Fusion des écorces

La fusion de données issues de plusieurs sources est une technique qui a prouvé sa capacité à résoudre des problèmes complexes dans différents domaines puisque cette technique se base sur la complémentarité des différentes sources d'informations. Dans le cadre de la reconnaissance d'espèces d'arbres, l'utilisation d'informations sur les écorces, en plus des informations qu'on a sur les feuilles, peut potentiellement apporter des informations complémentaires et augmenter les performances du système de reconnaissance en termes de taux de bonne classification.

Avant de procéder à la fusion des données issues des feuilles avec celles issues des écorces, nous procédons tout d'abord à la fusion des données issues des écorces. Les différents attributs extraits sont présentés. Chaque caractéristique est traitée séparément comme pour les feuilles. La mise en place d'un classifieur pour chaque caractéristique permet d'analyser les performances de chacune et d'avoir une idée sur la qualité des données à gérer.

4.2.1 Extraction d'attributs

La tâche d'extraction d'attributs à partir des écorces est prise en charge par le laboratoire LIRIS dans le cadre de la thèse de Sarah Bertrand.

Comme pour les feuilles, les attributs extraits à partir des écorces se situent dans la vision de reproduire la stratégie des botanistes. Ils permettent de décrire les quatre caractéristiques les plus pertinentes de l'écorce : l'orientation, la couleur, les contours horizontaux et les contours verticaux [99].

4.2.1.1 L'orientation de l'écorce

Les écorces peuvent être lisses comme elles peuvent présenter certaines orientations. L'orientation d'une écorce peut être horizontale, verticale ou horizontale et verticale. L'utilisation des ondelettes de Gabor permet de filtrer l'image et de distinguer les orientations et les fréquences des structures formant la texture de l'écorce [100]. Un vecteur de taille 3 noté \vec{AO} caractérisant l'orientation de la structure de l'écorce est ainsi extrait (voir [99] pour plus de détails).

4.2.1.2 La couleur

La couleur est la deuxième caractéristique sur laquelle les botanistes se basent pour la reconnaissance des espèces à partir des écorces. Cette information est extraite à partir de la teinte (H) de l'espace colorimétrique (HSV). Elle code la couleur sans prendre en considération la luminosité. Ainsi, la variance d'éclairage au niveau de l'écorce ne pose plus de problèmes. Un vecteur d'attributs \vec{A}_H décrivant la couleur est donc extrait. Il est de taille 256.

4.2.1.3 Les contours verticaux et horizontaux

Afin de décrire plus précisément la structure de l'écorce, les contours horizontaux et verticaux sont extraits grâce à l'algorithme de Canny [101] permettant ainsi de mieux identifier les différents types d'écorces en caractérisant les écailles, les lanières ou les craquelures de l'écorce. Le principe consiste à quadriller l'image de l'écorce, dessiner des traits verticaux et horizontaux et calculer la fréquence des intersections de ses lignes avec les motifs de l'écorce comme le montre la figure 4.2. Des mots verticaux (Word V) de taille 70 et des mots horizontaux (Word H) de taille 50 représentés respectivement par des vecteurs d'attributs \vec{A}_{MV} et \vec{A}_{MH} sont ainsi extraits.




FIGURE 4.2: Exemple d'extraction d'un mot vertical caractérisant la texture d'une écorce

4.2.2 La classification

Un classifieur (forêt aléatoire formée de 200 arbres) est mis en place pour chaque source d'informations. Il s'agit donc de 4 classifieurs : S_4 traite l'orientation de l'écorce, S_5 traite sa

couleur, S_6 et S_7 traitent respectivement les contours horizontaux et verticaux. A la sortie de chaque classifieur on obtient une distribution de probabilité $P[e_i]$ entre les espèces comme le montre la figure 4.3.

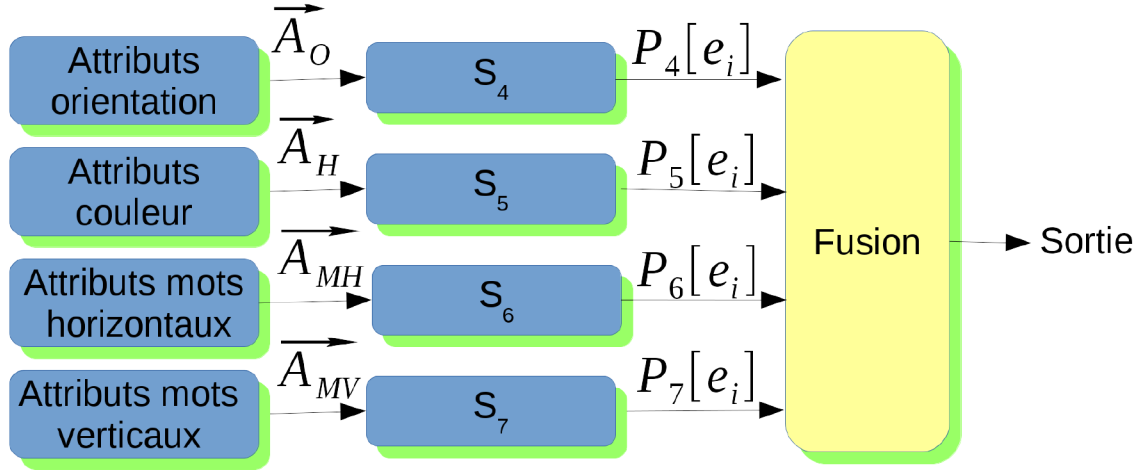


FIGURE 4.3: Classification des écorces

4.2.3 Base de données des écorces

La base de données utilisée est obtenue à partir du défi ImageClef. Elle tire son importance de la diversité existante au sein des différentes espèces contrairement à d'autres bases de données. L'avantage principal de cette base de données est qu'elle contient des photos assez proches de celles qu'un utilisateur pourrait prendre en pleine nature. Par contre, son inconvénient majeur est la variabilité du nombre de photos représentant chaque espèce. En effet, une espèce peut être représentée par une multitude de photos alors que d'autres ne sont représentées que par quelques photos seulement.

Afin d'évaluer l'apport de la fusion des feuilles avec les écorces, nous avons choisi de travailler sur des couples feuille/écorce. Nous avons donc créé un maximum de couples. Au total nous avons obtenu 820 couples pour lesquels chaque photo de feuille correspond à une photo d'écorce.

4.2.4 Évaluation des données issues des classifieurs

Comme le montre la figure 4.4, les performances des classifieurs en terme de taux de bonne classification sont limitées. Le tableau 4.1 présente les différents taux de bonne classification pour le jeu d'apprentissage et de test en cas de la prise en compte uniquement de la première

espèce ressortie ($N = 1$) jusqu'aux dix premières espèces ($N = 10$). On remarque que le classifieur HSV traitant la couleur offre les meilleures performances suivi du classifieur de l'espace de Gabor. Les classifieurs des mots verticaux et horizontaux présentent des performances très limitées.




FIGURE 4.4: Performances des différents classifieurs de la modalité écorce pour l'apprentissage et le test

Classifieur	Taux de bonne classification : apprentissage		Taux de bonne classification : test	
	N=1	N=10	N=1	N=10
HSV	100%	100%	32.07%	65.12%
Gabor	100%	100%	16.1%	53.29%
Word H	96.76%	97.43%	14.88%	43.66%
Word V	97.77%	98.99%	12.07%	48.05%

TABLE 4.1: Taux de bonne classification pour le jeu d'apprentissage et de test ($N = 1$ et $N = 10$)

En comparant les performances des classifieurs des caractéristiques des écorces à celles des feuilles, on remarque que celles des feuilles sont meilleures. La similarité inter-espèces ainsi que la variabilité intra-espèce est beaucoup plus importante pour les écorces que pour les feuilles ce qui explique la difficulté. Même les botanistes affirment que la reconnaissance en se basant sur les feuilles est plus évidente que celle basée sur les écorces. Néanmoins, l'écorce peut apporter des informations pertinentes surtout lorsqu'il s'agit d'espèces ayant des feuilles très semblables, c'est pourquoi une discrimination par les écorces est envisageable.

4.2.5 Spécificités des données à fusionner

Les données issues des classifieurs de la modalité écorce reflètent une incertitude potentiellement plus importante que celle pour les feuilles. Prenons l'exemple d'une écorce appartenant à l'espèce *Acer Monspessulanum* (e_2). On remarque que le classifieur de la couleur (HSV) propose une liste de 34 espèces comme l'illustre la figure 4.5.

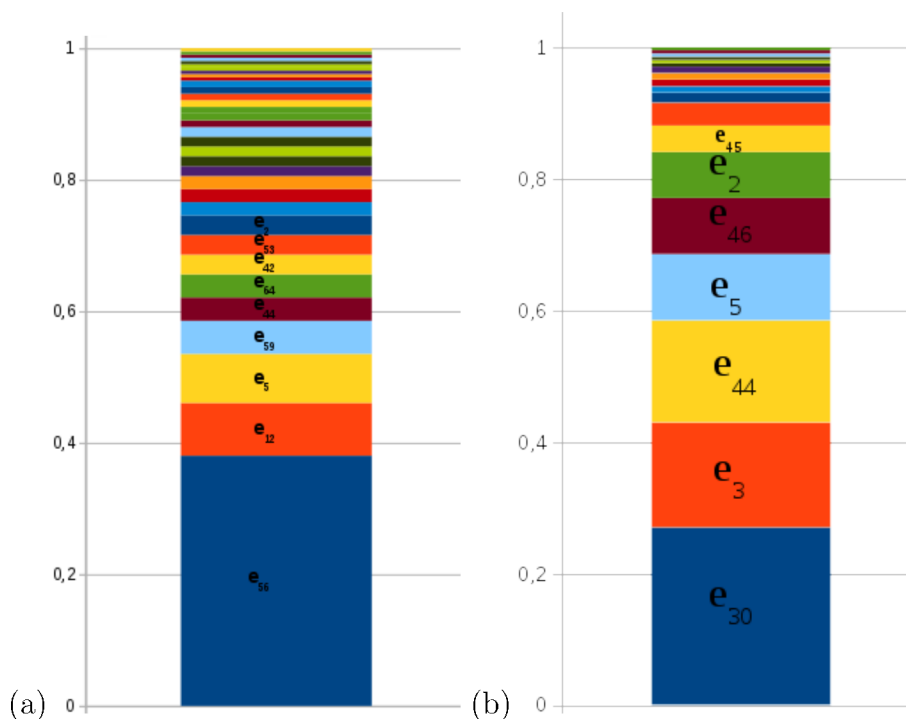


FIGURE 4.5: Incertitude des classifieurs dans le cas d'un individu appartenant à l'espèce *Acer Monspessulanum* (e_2) : (a) modalité écorce-incertitude du classifieur de la caractéristique couleur (HSV), (b) modalité feuille-incertitude du classifieur de la caractéristique forme globale

Un exemple montrant l'incertitude du classifieur de la forme globale d'une feuille appartenant à cette même espèce a été présenté dans le chapitre 2 (figure 2.12). Pour cet exemple, on remarque que l'incertitude du classifieur forme globale de la feuille est réduite par rapport à l'incertitude du classifieur de la couleur de l'écorce. Pour la même espèce, le classifieur de la feuille propose 19 espèces possibles alors que le classifieur de l'écorce en propose 34. L'exemple de la figure 4.5 montre aussi que cette source peut être considérée comme une source menteuse contextuellement vu qu'elle propose l'espèce e_{56} avec une importante certitude alors qu'il s'agit de l'espèce e_2 . Le comportement du classifieur reflète la ressemblance existante entre différentes espèces au niveau de la couleur. Cette ressemblance est illustrée dans la figure 4.6 où l'on remarque que les 8 premières espèces proposées par le système présentent effectivement des teintes de couleur assez similaires à celle de la vraie espèce e_2 .

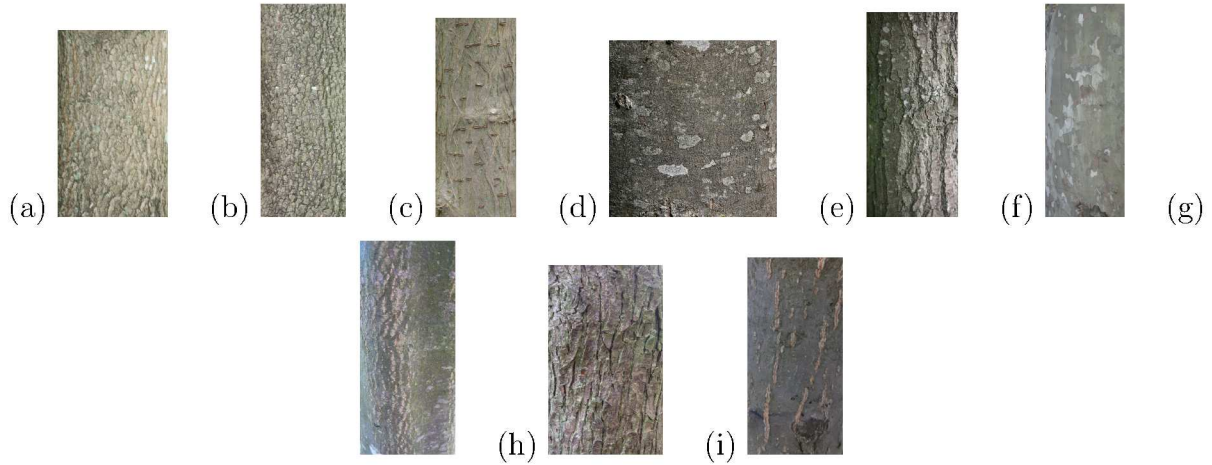


FIGURE 4.6: Ressemblance au niveau de la couleur entre les espèces (a) : e_2 (*Acer Mons-pessulanum*), (b) : e_{56} (*Quercus Ilex*), (c) : e_{12} (*Broussonetia Papyrifera*), (d) : e_5 (*Acer Pseudoplatanus*), (e) : e_{59} (*Quercus Robur*), (f) : e_{44} (*Platanus Hispanica*), (g) : e_{64} (*Sorbus Aria*), (h) : e_{42} (*Ostrya Carpinifolia*), (i) : e_{53} (*Punica Granatum*)

4.2.6 Architecture du système de fusion des écorces

Tout comme les données issues des feuilles, les données issues des écorces sont fusionnées en cascade comme le montre la figure 4.7. On peut ainsi suivre l'apport de chaque source de données.

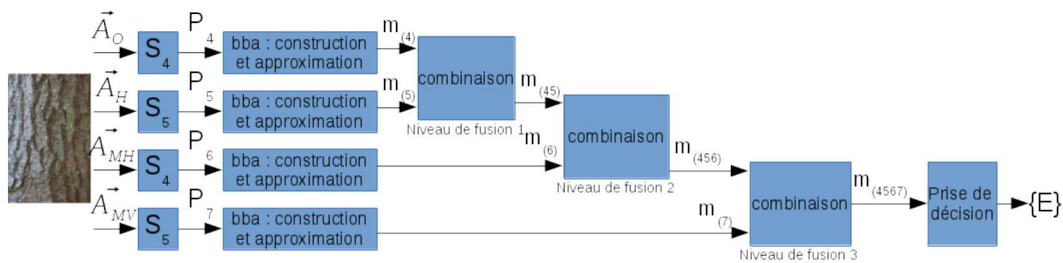


FIGURE 4.7: Architecture du système de fusion des données issues des écorces

4.2.7 Construction des fonctions de masse et approximations

Nous avons montré dans le chapitre précédent que les fonctions de masse consonantes permettent une meilleure représentation des données disponibles et des imperfections les entachant. Nous utilisons donc cette méthode pour construire des fonctions de masse consonantes à partir des distributions de probabilités issues de chaque classifieur caractérisant l'écorce.

Nous nous intéressons maintenant à l'approximation des fonctions de masse visant à réduire la complexité des calculs. On a montré dans le chapitre précédent que les approximations

“inner” et “outer” ne sont pas adaptées à nos besoins puisque leurs temps de calcul est important. Les approximations sommation et $k-l-x$ permettent d’approximer les fonctions de masse avec un temps de calcul réduit. L’application de ces deux approximations pour $k = 5$ donne les résultats présentés dans la figure 4.8 et le tableau 4.2 dont deux remarques peuvent être tirées :

- **la première concerne l’apport de chaque source d’information à chaque niveau de fusion** : nous remarquons que les taux de bonne classification diminuent au fur et à mesure des fusions. Le premier niveau de fusion présente les meilleurs taux qui se dégradent en passant au deuxième niveau et ensuite au troisième niveau de fusion comme le montre le tableau 4.2. Il s’avère donc que les classifieurs “WordH” et “WordV” apportent du bruit plutôt que des informations utiles et ont du mal à assurer une certaine complémentarité aux données issues des deux premiers classifieurs. Puisque ces deux sources n’apportent presque rien à notre système de fusion, nous avons décidé de les éliminer et donc de ne garder que le classifieur HSV et le classifieur de l’espace de Gabor. Suite à cette décision, le système de fusion des écorces ne représentera qu’un seul niveau de fusion.
- **la deuxième concerne les approximations** : nous remarquons d’après le tableau 4.2 que l’approximation $k-l-x$ présente des résultats meilleurs que l’approximation sommation. Ceci peut être expliqué par l’existence de beaucoup de conflits entre les écorces. Ainsi, garder uniquement les cinq premiers éléments focaux et éliminer tout le reste s’avère plus efficace puisque des informations considérées plutôt trop conflictuelles et bruitées sont éliminées. En effet, garder ces informations en utilisant l’approximation sommation s’avère inutile.

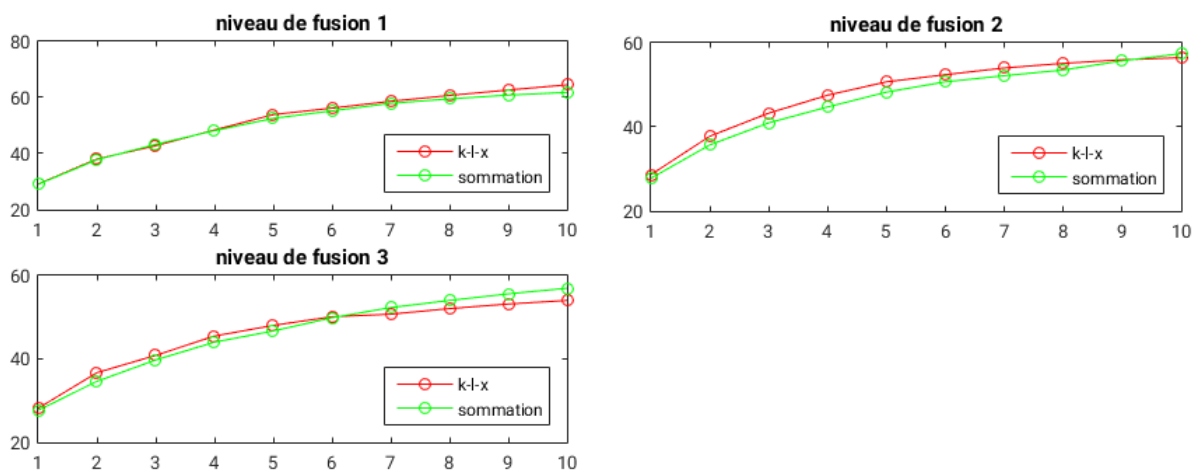


FIGURE 4.8: Résultats de la fusion des données issues des classifieurs de la modalité écorce pour les 3 niveaux de fusion : approximation $k-l-x$ et approximation sommation

	Taux de bonne classification			
	k-l-x		sommmation	
	N=1	N=10	N=1	N=10
Niveau de fusion 1	29.15%	64.51%	29.02%	61.83%
Niveau de fusion 2	28.66%	56.46%	27.80%	57.44%
Niveau de fusion 3	28.17%	54.02%	27.68%	56.95%

TABLE 4.2: Taux de bonne classification pour les différents niveaux de fusion : approximation $k - l - x$ et approximation sommation avec $k = 5$

Nous avons ensuite fait varier la valeur de k pour l'approximation retenue (l'approximation $k - l - x$) afin de retenir la valeur offrant le meilleur compromis entre le taux de bonne classification et la rapidité de calcul. Le tableau 4.3 présente le temps de calcul en fonction de k . La figure 4.9 et le tableau 4.4 présentent les taux de bonne classification obtenus pour chaque valeur de k

Valeur de k	k=5	k=7	k=10	k=12	k=15
Temps de calcul	131ms	171ms	426ms	556ms	802ms

TABLE 4.3: Temps de calcul par individu en fonction de la valeur de k

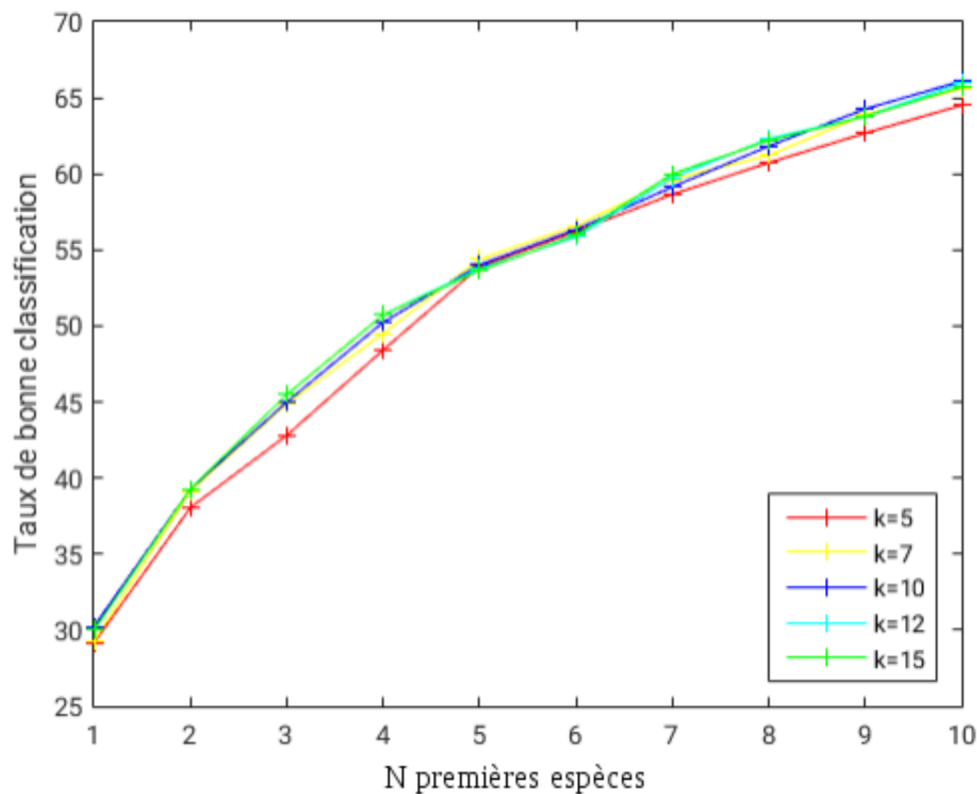


FIGURE 4.9: Variation du taux de bonne classification en fonction de la valeur de k

	Taux de bonne classification	
	N=1	N=10
k=5	29.15%	64.51%
k=7	29.27%	65.61%
k=10	30.24%	66.1%
k=12	30%	65.98%
k=15	30%	65.73%

TABLE 4.4: Taux de bonne classification pour différentes valeurs de k ($N = 1$ et $N = 10$)

Nous remarquons que le meilleur compromis est obtenu pour une valeur de $k = 10$. Pour cette valeur, nous avons un temps de calcul relativement élevé par rapport à celui pour $k = 5$ et $k = 7$ mais qui reste quand même réduit tant qu'il ne dépasse pas les $500ms$. Pour une valeur de $k = 10$, nous obtenons les meilleurs taux de bonne classification. Ces taux sont de 30.24% pour $N = 1$ et de 66.1% pour $N = 10$. On remarque aussi qu'en augmentant encore la valeur de k , le taux de bonne classification diminue. La prise en compte de plus de dix éléments focaux lors de la fusion détériore le processus de fusion puisque des informations potentiellement conflictuelles et inutiles sont introduites dans le système.

4.2.8 Règles de combinaison

Les données issues des écorces présentent plus de conflits que les données issues des feuilles. Nous avons remarqué qu'au niveau de l'approximation des fonctions de croyance, l'approximation choisie pour les écorces n'est pas la même que celle choisie pour les feuilles.

Pour les écorces, d'après la figure 4.10, la règle de combinaison mixte présente les meilleures performances. En cas de conflit, cette règle de combinaison permet de transférer la masse vers l'ignorance partielle. Visiblement, cette méthode est la mieux adaptée pour le type de données issues des classifieurs des écorces. Le taux de bonne classification est de 31.34% pour ($N = 1$) et de 68.17% pour ($N = 10$)

Nous remarquons aussi d'après la figure 4.10 que la règle de combinaison DPCR donne les mêmes résultats que la règle de combinaison de Dubois et Prade. De plus, la règle de combinaison de Florea donne les mêmes performances que la règle de combinaison PCR5.

4.3 Fusion multimodale : feuilles et écorces

Suite à la fusion des données issues de la modalité feuilles et la fusion de celles issues de la modalité écorces, nous passons maintenant à la fusion de ces deux modalités. Comme

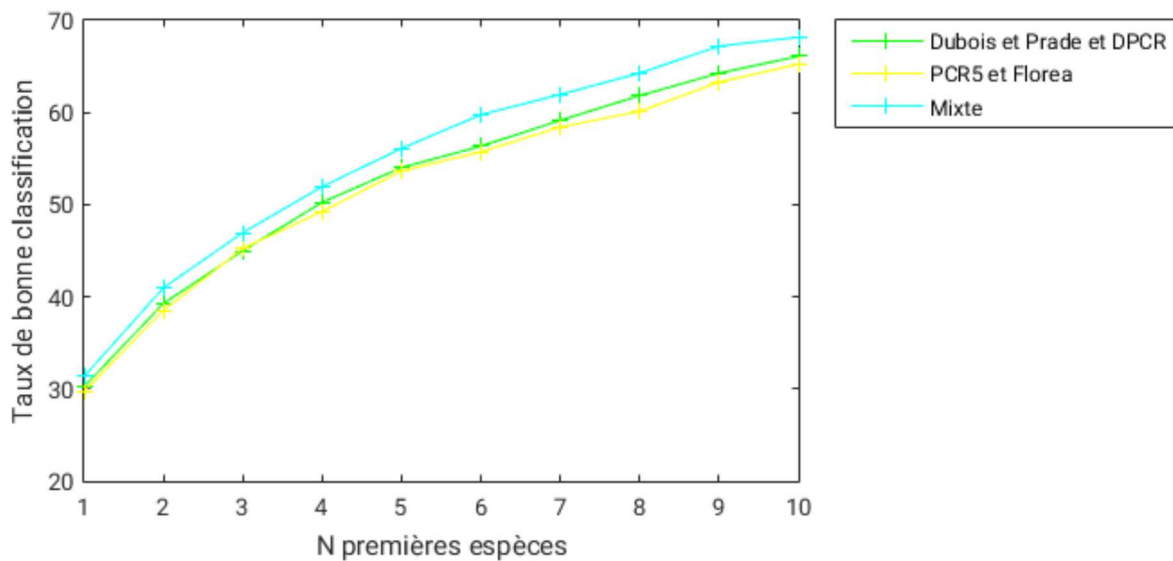


FIGURE 4.10: Variation du taux de bonne classification en fonction des règles de combinaison

chaque modalité a des performances différentes, nous avons choisi de fusionner chacune à part et ensuite de les fusionner ensemble [102][103]. Les résultats issus de chaque fusion sont maintenant combinés en respectant la topologie hiérarchique présentée dans la figure 4.11.

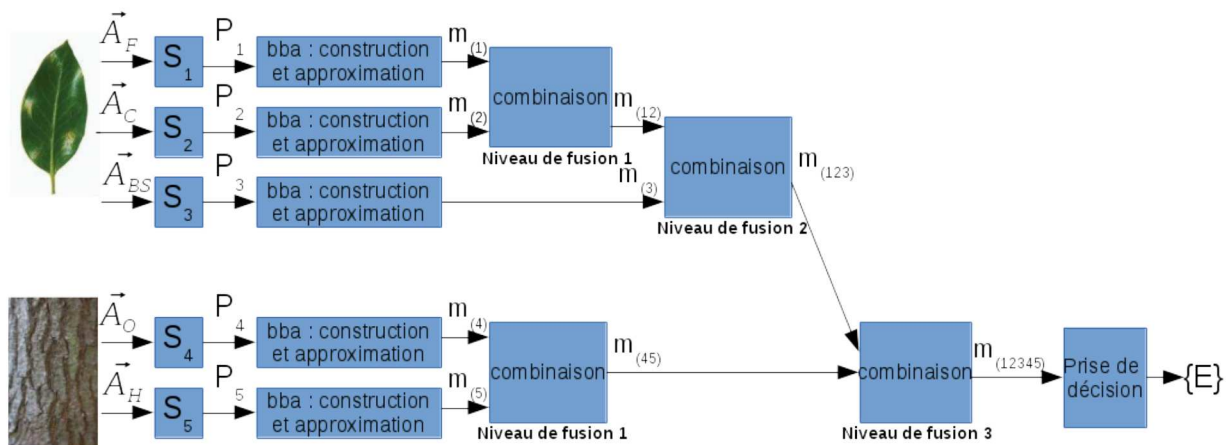


FIGURE 4.11: Système de fusion multimodale

La fusion multimodale conduit à l'obtention des résultats présentés dans la figure 4.12 représentant le taux de bonne classification en fonction des règles de combinaison. On remarque que la fusion des feuilles avec les écorces dégrade les performances du système. Avec la règle de combinaison Mixte, le taux de bonne classification pour les 10 premières espèces obtenues suite à la fusion des données des feuilles avec celles des écorces est de 86.22% alors qu'il est de 90.44% dans le cas des feuilles seules. Comme ces deux sources de données ont des performances différentes, leur fusion engendre la diminution des performances de la source la

plus performante. En effet, le rajout des informations sur les écorces rajoute du conflit aux données issues des feuilles et engendre l'attribution d'informations erronées dans le système de fusion. L'idée est donc de chercher une solution afin d'améliorer les performances des écorces pour que leur fusion avec les feuilles apporte des informations utiles et donc moins de confusion. Cette amélioration peut être envisageable à travers la correction des fonctions de masse.




FIGURE 4.12: Taux de bonne classification des feuilles, des écorces et des deux modalités en fonction des règles de combinaison

4.4 Techniques de correction des fonctions de masse

La théorie des fonctions de croyance offre un cadre flexible pour modéliser et gérer l'incertitude des informations. Plusieurs outils sont proposés dans la littérature, ils permettent de modifier ou corriger une partie des informations en se basant sur des informations supplémentaires sur la pertinence ou la sincérité d'une source.

4.4.1 Techniques de correction basées sur le degré de pertinence

4.4.1.1 Le discounting basé sur le degré de pertinence

Historiquement, le discounting est le premier outil de correction proposé dans la littérature [53] [104]. Il se base sur le degré de pertinence d'une source d'information S pour affaiblir la masse de l'information qu'elle apporte [105]. Le discounting a été développé dans le cadre du TBM (Transferable Belief Model) [55]. Supposons qu'une source d'information S fournisse une information représentée par une fonction de masse m_S et supposons que β , avec β dans

$[0, 1]$, soit le degré de pertinence relatif à cette source S . Le discounting est donc effectué de la manière suivante :

$$m(A) = \beta m_S(A) + (1 - \beta)m_\Omega(A), \forall A \subseteq \Omega \quad (4.1)$$

Le discounting consiste donc à affaiblir la fonction de masse initiale en fonction de son degré de pertinence et à accorder plus de masse à l'ignorance. L'opération inverse du discounting, appelée, de-discounting a été introduite dans [106]. Si après avoir effectué le discounting il s'avère que l'information sur la pertinence de la source était fausse, le de-discounting permet de retrouver $m_S(A)$ à partir de $m(A)$ comme suit :

$$m_S(A) = \frac{m(A) - (1 - \beta)m_\Omega(A)}{\beta}, \forall A \subseteq \Omega \quad (4.2)$$

Cette méthode de correction utilise le degré de pertinence global pour affaiblir les fonctions de masse. Or, cette mesure est insuffisante puisque le degré de pertinence peut varier d'une classe à une autre. Vu la qualité des données, il serait plus utile d'appliquer des méthodes de correction contextuelles où l'affaiblissement d'une fonction de masse tient compte de chaque contexte.

4.4.2 Le discounting contextuel basé sur le degré de pertinence

Dans [58], Mercier et al. ont étudié le discounting contextuel basé sur le degré de pertinence contextuel d'une source d'informations. Son application nécessite la présence d'informations supplémentaires sur la pertinence d'une source d'informations conditionnellement dans différents contextes \mathcal{A} de Ω tels que l'union des sous-ensembles \mathcal{A} forment une partition de Ω . Supposons que β_A , avec β_A dans $[0, 1]$, soit le degré de pertinence d'une source S dans un contexte A et que l'union des éléments de contexte \mathcal{A} forment la partition \mathcal{A} de Ω . La croyance m obtenue suite à la prise en compte des éléments de contexte \mathcal{A} est définie comme suit :

$$m = m_S \bigoplus_{A \in \mathcal{A}} A_{\beta_A} \quad (4.3)$$

où A_{β_A} représente une simple fonction de masse ayant comme éléments focaux \emptyset et A dont les masses correspondantes sont β_A et $1 - \beta_A$ respectivement. Un cas plus général du discounting contextuel est traité dans [107]. Son application est plus simple et plus générale puisque la formation d'une partition de Ω par les éléments de contexte A n'est plus exigée. Ainsi, cet outil de correction peut être appliqué même si les éléments de contexte A ne forment

pas une partition de Ω . Supposons que β_A , avec β_A le degré de pertinence accordé à une source d'informations dans un contexte A et que \mathcal{A} soit l'ensemble des contextes pour lesquels nous connaissons contextuellement le degré de pertinence de la source d'informations. La fonction de masse résultante de la prise en compte de ces éléments de contexte est calculée comme suit :

$$m = m_S \cup (\bigcap_{A \in \mathcal{A}} (\bar{A})^{1-\beta_A}) \quad (4.4)$$

Le discounting contextuel étudié dans ce paragraphe se base sur des éléments de contexte apportant des informations par rapport à la pertinence contextuelle de la source d'informations. Cette technique de correction des fonctions de masse est intéressante dans notre cas puisque la pertinence de nos classifieurs est variable d'une espèce à une autre. Grâce à cette technique, il serait possible d'introduire les informations supplémentaires sur la pertinence contextuelle de chaque source d'informations vis à vis de chaque espèce. Le discounting contextuel peut également s'appliquer afin de modifier contextuellement une fonction de masse en se basant sur une autre mesure de fiabilité : la sincérité.

4.4.3 Techniques de correction basées sur le degré de sincérité

4.4.3.1 Les différentes formes de non sincérité d'une source d'informations

Le modèle de discounting contextuel présenté dans [105] est basé sur le degré de sincérité et n'en étudie qu'une seule forme. En effet, il considère qu'une source d'informations S est sincère si elle dit la vérité pour tout $\omega \in \Omega$ sinon elle n'est pas sincère. Une analyse plus approfondie a donc été menée dans [59] et a permis la prise en compte de plus d'informations par rapport à la mesure de sincérité d'une source de données. Dans ce contexte, [59] propose une définition plus flexible d'une source de données non sincère en proposant qu'une source peut être sincère (respectivement non sincère) uniquement pour certaines valeurs ω de Ω . Dans ce cadre, 3 cas sont étudiés :

- **source menteuse contextuellement en \bar{A}** : une source de données S est dite menteuse contextuellement en \bar{A} si elle est sincère pour l'ensemble des valeurs $\omega \in A$ ($A \subseteq \Omega$) et non sincère pour l'ensemble des valeurs $\omega \in \bar{A}$ ($\bar{A} \subseteq \Omega$). Dans ce cas, si la source donne l'information que $\omega \in B$, on en déduit que $\omega \in B \cap A$.
- **source positivement sincère** : une source est dite positivement sincère (respectivement positivement non sincère) pour $\omega \in \Omega$ si elle donne l'information que ω est une solution possible et sait que ω est une solution possible (respectivement n'est pas une

solution possible). Supposons qu'une source donne l'information que $\omega \in B$ et que cette source est considérée positivement non sincère pour \bar{A} . On en déduit que $\omega \in B \cap A$.

- **source négativement sincère** : une source est dite négativement sincère (respectivement négativement non sincère) pour $\omega \in \Omega$ si elle donne l'information que ω n'est pas une solution possible et sait que ω n'est pas une solution possible (respectivement une solution possible). Supposons qu'une source donne l'information que $\omega \in B$ et que cette source est négativement non sincère pour A . On déduit que $\omega \in B \cup A$.

4.4.3.2 Le discounting basé sur le degré de sincérité

Il est possible d'estimer la sincérité ou pas d'une source d'informations en supposant qu'elle soit fiable. Ainsi, les décisions correctes et les décisions incorrectes de la source correspondent respectivement à un comportement sincère ou non sincère de la source d'informations. Supposons qu'une source d'informations soit sincère avec un degré β et non sincère avec un degré $1 - \beta$. D'après [108], la correction des fonctions de masse en prenant en compte la méta-connaissance sur la sincérité d'une source peut se faire de 3 manières différentes :

- En affaiblissant la masse initiale tout en accordant de la masse à l'ignorance comme suit :

$$m = \beta m_S + (1 - \beta) m_\Omega \quad (4.5)$$

- En affaiblissant la masse initiale accordée à A ($\forall A \subseteq \Omega$) tout en accordant plus de masse à son complément \bar{A} ($\forall \bar{A} \subseteq \Omega$) de la manière suivante :

$$m = \beta m_S + (1 - \beta) \bar{m}_S \quad (4.6)$$

- En affaiblissant la masse initiale d'un facteur de $\beta = 1 - 2\epsilon$ et en accordant de la masse à l'ignorance comme suit :

$$m = (1 - 2\epsilon) m_S + 2\epsilon m_\Omega \quad (4.7)$$

où ϵ est le taux d'erreur de classification. Suivant le degré de sincérité de la source d'informations, la masse initiale est affaiblie tout en accordant de la masse à l'ignorance comme le montre les équations 4.5 et 4.7. L'équation 4.6 présente une manière un peu différente puisque l'affaiblissement de la masse initiale est couplé à un transfert de la masse vers \bar{A} qui est l'ensemble complément de l'élément focal A en question. Cette approche est très intéressante puisqu'elle permet une meilleure préservation de la spécificité de l'information. Dans la prochaine section, nous nous intéressons particulièrement à cette approche et nous proposerons une méthode pour définir contextuellement l'ensemble complément \bar{A} de A .

4.4.3.3 Le discounting contextuel basé sur le degré de sincérité

La définition des différentes formes de non véridicité dans [59] a permis de définir une nouvelle forme de discounting contextuel basé sur le degré de sincérité. Supposons que la source S soit négativement non véridique en A . Cette nouvelle forme de discounting contextuel est définie comme suit :

$$m = m_S \bigoplus_{A \in \mathcal{A}} A_{\beta_A} \quad (4.8)$$

4.4.3.4 Le renforcement contextuel basé sur le degré de sincérité

Dans [107], Mercier et al. définissent un nouveau mécanisme de correction appelé renforcement contextuel. Supposons que la source S soit positivement non véridique en \bar{A} . Cette nouvelle forme de renforcement contextuel est définie comme suit :

$$m = m_S \bigodot_{A \in \mathcal{A}} A_{\beta_A} \quad (4.9)$$

Ces 2 nouvelles formes de discounting représentées dans les équations 4.8 et 4.9 sont intéressantes puisque le discounting tient compte de la sincérité contextuelle de la source d'informations. Mais son application nécessite la mise en place d'hypothèses par rapport à la sincérité de la source. Il faut donc avoir une méta-connaissance permettant d'affirmer si la source est négativement non véridique en A ou si elle est positivement non véridique en \bar{A} .

Dans cette section, nous avons présenté les différents mécanismes de correction des fonctions de masse. Dans la suite, nous nous intéressons à l'estimation des méta-connaissances indispensables pour l'application de ces mécanismes.

4.5 Estimation de méta-connaissances à partir d'une matrice de confusion

L'application des mécanismes de correction nécessite des connaissances sur l'état de la source d'informations à traiter. Ces connaissances appelées "méta-connaissances" permettent de caractériser l'état d'une source de données : pertinente ou pas, sincère ou pas. Ces méta-connaissances sont généralement incertaines et souvent présentées par des fonctions de masse [59]. Dans le cadre de la fusion de classifieurs, nous nous intéressons à l'estimation de méta-connaissances à partir des matrices de confusion obtenues pour chaque classifieur. Ceci a été d'abord étudié par Mercier et al. dans [109]. Ensuite et dans le même contexte, Lefevre et al.

ont proposé dans [108] une méthode permettant d'estimer la pertinence ainsi que la sincérité d'une source de données à partir de la matrice de confusion. Notre application concerne la fusion de données issues de différents classifieurs. Ainsi, dans notre cas, l'estimation des méta-connaissances est faite à partir des matrices de confusion.

Une matrice de confusion $M_i = (n_{kl})_{k \in \{1, \dots, K\} l \in \{1, \dots, K\}}$ est un tableau caractérisant les performances d'une source de données S_i sur un ensemble de test formé de K classes (Tableau 4.5). Chaque ligne k de la matrice de confusion représente la décision prise en faveur de w_k . Chaque colonne l représente la vérité w_l . Notons que $n_{k.} = \sum_{l=1}^K n_{kl}$ représente le nombre d'objets classés dans w_k et $n_{.l} = \sum_{k=1}^K n_{kl}$ représente le nombre d'objets classés dans w_l . Le nombre total d'objets classés est $n = \sum_{k=1}^K \sum_{l=1}^K n_{kl}$

Vérité Décision	$w_1 \dots w_l \dots w_K$
w_1	$n_{11} \dots n_{1K}$
\vdots	\ddots
w_k	$\vdots \quad n_{kl} \quad \vdots$
\vdots	\ddots
w_K	$n_{K1} \dots n_{KK}$

TABLE 4.5: Illustration d'une matrice de confusion

4.5.1 Estimation de la pertinence globale d'une source à partir de la matrice de confusion

L'estimation de la pertinence d'une source revient généralement à calculer son taux de bonne classification comme l'explique Elouedi et al. dans [110]. Ce taux de bonne classification est donné par :

$$T_f = \frac{\sum_{k=1}^K n_{kk}}{n}, \forall k \in \{1, \dots, K\} \quad (4.10)$$

4.5.2 Estimation de la pertinence contextuelle d'une source à partir de la matrice de confusion

Dans [109], Mercier et al. définissent deux manières pour calculer la pertinence contextuelle pour chaque contexte $w_l, l \in \{1, \dots, K\}$.

4.5.2.1 Utilisation du pourcentage de classifications correctes pour chaque contexte

La première méthode consiste à regarder la diagonale de la matrice de confusion pour exploiter le degré de pertinence $T_f\{w_l\}$ pour chaque contexte w_l . Ce degré de pertinence, sachant que la vérité est w_l , est le nombre d'individus bien classés divisé par le nombre d'individus appartenant à w_l . D'où :

$$T_f[w_l] = \frac{n_{ll}}{n_{.l}} \quad (4.11)$$

A partir de ces éléments de contexte, la masse d'une source d'informations S peut être affaiblie en appliquant le discounting contextuel de la manière suivante :

$$m = m_S \bigoplus_{l=1}^K \{w_l\}_{T_f[w_l]} \quad (4.12)$$

Exemple 1 :

Soit la matrice de confusion représentée dans le tableau 4.6 :

Vérité Décision	a	b	c	d
a	8	1	0	0
b	0	6	0	0
c	0	2	6	1
d	0	1	4	9

TABLE 4.6: Exemple d'une matrice de confusion

Le degré de pertinence $T_f[w_l]$ pour chaque contexte w_l est :

$$\begin{aligned} T_f[a] &= \frac{8}{8} = 1 \\ T_f[b] &= \frac{6}{10} = 0.6 \\ T_f[c] &= \frac{6}{10} = 0.6 \\ T_f[d] &= \frac{9}{10} = 0.9 \end{aligned}$$

Supposons qu'une source d'informations génère la fonction de masse m_S suivante :

$$m_S(\{a, c\}) = 0.8 \text{ et } m_S(\Omega) = 0.2.$$

L'application du discounting contextuel proposé dans 4.12 consiste à combiner disjunctivement la fonction de masse initiale avec les éléments de contexte tels que :

$$m = m_S \bigoplus \{a\}_1 \bigoplus \{b\}_{0.6} \bigoplus \{c\}_{0.6} \bigoplus \{d\}_{0.9}.$$

Ou en d'autres termes :

$$m = \left\{ \begin{array}{l} m_S\{(a, c)\} = 0.8 \\ m_S\{(\Omega)\} = 0.2 \end{array} \right. \oplus \left\{ \begin{array}{l} m\{(b)\} = 0.4 \\ m\{(\emptyset)\} = 0.6 \end{array} \right. \oplus \left\{ \begin{array}{l} m\{(c)\} = 0.4 \\ m\{(\emptyset)\} = 0.6 \end{array} \right. \oplus \left\{ \begin{array}{l} m\{(d)\} = 0.1 \\ m\{(\emptyset)\} = 0.9 \end{array} \right.$$

Ce qui donne :

$$m(\{a, c\}) = 0.8 * 0.6 * 0.9 = 0.432$$

$$m(\{a, b, c\}) = 0.8 * 0.4 * 0.9 = 0.288$$

$$m(\{a, c, d\}) = 0.8 * 0.6 * 0.1 = 0.048$$

$$m(\Omega) = 0.8 * 0.4 * 0.1 + 0.2 = 0.232$$

4.5.2.2 Utilisation d'une distance

Cette méthode consiste à calculer une distance pour déterminer le taux de fiabilité $T_{fd}[w_l]$ d'une source dans les différents contextes w_l . Le nombre de fausses décisions est pris en compte tel que :

$$T_{fd}[w_l] = 1 - \sqrt{\frac{1}{2} \sum_{k=1}^K \left(\frac{n_{kl}}{n_l} - \delta_{k,l} \right)^2} \quad (4.13)$$

où $\delta_{k,l} = 1$ si $k = l$ et 0 sinon. L'affaiblissement de la masse m peut être donc effectué en utilisant la mesure T_{fd} de la manière suivante :

$$m = m_S \bigoplus_{l=1}^K \{w_l\}_{T_{fd}[w_l]} \quad (4.14)$$

L'affaiblissement contextuel d'une fonction de masse en se basant sur son de degré de pertinence contextuel s'avère intéressant. Mais, dans notre cas, l'application de cette approche revient à combiner disjonctivement la fonction de masse initiale aux 72 éléments de contexte qu'on peut ressortir grâce à la matrice de confusion. Ceci est très compliqué d'un point de vue calculatoire puisqu'il s'agit d'effectuer 72 combinaisons pour chaque fonction de masse et pour chaque source d'informations.

4.5.3 Estimation de la sincérité d'une source à partir de la matrice de confusion

Il est possible d'estimer la sincérité d'une source toujours à l'aide d'une matrice de confusion. Dans [108], Lefèvre et al. présentent les 3 approches pouvant être utilisées :

- génération d'une fonction de masse bayésienne caractérisant la sincérité d'une source telle que :

$$\begin{aligned} m(\{T\}) &= 1 - \epsilon \\ m(\{\bar{T}\}) &= \epsilon \end{aligned} \quad (4.15)$$

où ϵ est le taux d'erreur de classification.

- génération d'une fonction de masse issue du pari $BetP(T) = 1 - \epsilon$ et $BetP(\bar{T}) = \epsilon$ correspondant à la fonction de masse suivante :

$$m(\{T\}) = \begin{cases} 1 - 2\epsilon & \text{si } \epsilon \leq 1/2 \\ 0 & \text{ailleurs} \end{cases} \quad (4.16a)$$

$$m(\{\bar{T}\}) = \begin{cases} 0 & \text{si } \epsilon \leq 1/2 \\ 2\epsilon - 1 & \text{ailleurs} \end{cases} \quad (4.16b)$$

$$m(\mathcal{T}) = \begin{cases} 2\epsilon & \text{si } \epsilon \leq 1/2 \\ 2(1 - \epsilon) & \text{ailleurs} \end{cases} \quad (4.16c)$$

- génération d'une fonction de masse pour caractériser la sincérité d'une source en se basant sur les travaux de Dempster [111] :

$$\begin{aligned} m(\{T\}) &= \frac{1 - \epsilon}{1 + 1/n} \\ m(\{\bar{T}\}) &= \frac{\epsilon}{1 + 1/n} \\ m(\mathcal{T}) &= \frac{1}{n + 1} \end{aligned} \quad (4.17)$$

Le calcul des méta-connaissances telles que présentées dans les équations 4.15, 4.16 et 4.17 permettent l'obtention des fonctions de masse présentées dans les équations 4.5, 4.6 et 4.7 respectivement.

Comme nous l'avons mentionné, nous nous intéressons à l'affaiblissement de la fonction de masse tel que proposé dans l'équation 4.6. En effet, dans certaines applications il est facile de définir l'ensemble \bar{A} complément de A . Ceci est encore plus simple lorsqu'il s'agit d'un espace de discernement de petite taille ou lorsque des connaissances pertinentes sont disponibles (comme l'avis d'un expert). Dans notre cas, nous pouvons assimiler l'ensemble \bar{A} complément de A à l'ensemble de toutes les classes appartenant à l'espace de discernement

Ω mais n'appartenant pas à A . Supposons que A soit formé de 10 espèces, une masse sera transférée vers l'ensemble complément \bar{A} formé de 62 espèces. La spécificité de l'information peut donc être perdue comme c'est le cas lorsque la masse est transférée vers l'ignorance. Pour toutes ces raisons, et vue la qualité des données traitées ainsi que les informations disponibles, nous nous sommes intéressés à la définition de l'ensemble complément \bar{A} pour chaque contexte.

4.6 La méthode proposée pour la correction des fonctions de masse

La méthode de correction proposée consiste à renforcer, contextuellement, la masse attribuée à certaines classes. Cette correction nécessite l'extraction d'informations à partir de la matrice de confusion de la base de données de test afin de définir l'ensemble complément \bar{A}_i de chaque contexte c_i . L'approche proposée est constituée des 3 étapes suivantes :

- **construction des fonctions de masse bayésiennes** à partir des distributions de probabilités obtenues à la sortie d'un classifieur
- **extraction des méta-connaissances contextuelles** à partir de la matrice de confusion. Ces méta-connaissances permettent de définir un ensemble complément \bar{A}_i pour chaque contexte c_i
- **utilisation contextuelle des méta-connaissances** pour corriger les fonctions de masse bayésiennes.

4.6.1 Construction de fonctions de masse bayésiennes

À la sortie d'un classifieur, nous obtenons une distribution de probabilité $P(e_i)$ entre les espèces. Pour passer de la théorie des probabilités vers la théorie des fonctions de croyance, nous construisons des fonctions de masse bayésiennes et nous y transférons toutes les informations disponibles comme nous l'avons expliqué dans le Chapitre 2.

4.6.2 Extraction des méta-connaissances

Le but de cette étape est d'utiliser la matrice de confusion pour définir, pour chaque contexte c_i , l'ensemble complément \bar{A}_i . Dans notre cas, il s'agit de 72 contextes correspondants aux 72 espèces formant l'espace de discernement Ω .

Dans une matrice de confusion, chaque ligne k représente la décision prise en faveur de w_k . Chaque colonne l représente la vérité w_l . En parcourant la matrice de confusion ligne par ligne sans considérer la diagonale, il est possible d'extraire, pour une décision w_k , l'ensemble des espèces dans lesquelles se trouve la vérité. Cet ensemble est l'ensemble complément \overline{A}_k pour un contexte c_k correspondant à une décision w_k .

Exemple 2 :

Soit la matrice de confusion représentée dans le tableau 4.7

Vérité Décision	e_1	e_2	e_3
e_1	3	0	2
e_2	1	4	2
e_3	1	0	3

TABLE 4.7: Exemple d'une matrice de confusion

Analysons la matrice de confusion ligne par ligne sans tenir compte de la diagonale. La première ligne correspond à la décision e_1 . Nous remarquons à travers la troisième colonne que le classifieur décide e_1 alors qu'il s'agit de e_3 . Nous considérons donc, que pour le contexte c_1 correspondant à la décision e_1 , l'ensemble complément est $\overline{A}_1 = \{e_3\}$. Donc, l'idée est d'attribuer une masse à e_3 chaque fois que le classifieur décide e_1 .

La deuxième ligne correspond à la décision e_2 . Nous remarquons à travers la première colonne qu'une fois sur 5 le classifieur décide e_2 alors qu'il s'agit de e_1 et à travers la troisième colonne que le classifieur décide e_2 alors qu'il s'agit de e_3 . Donc une masse sera accordée à e_1 et e_3 chaque fois que le classifieur décide e_2 .

La troisième ligne correspond à la décision e_3 . D'après la première colonne, une fois sur 5 le classifieur décide e_3 alors qu'il s'agit de e_1 .

En parcourant la matrice de confusion ligne par ligne, et suivant la décision du classifieur, les trois ensembles compléments correspondants respectivement à une décision en faveur de e_1, e_2 et e_3 sont obtenues :

$$\begin{aligned}
 L(\text{décision} = e_1) &= L_1 = \overline{A}_1 = \{e_3\} \\
 L(\text{décision} = e_2) &= L_2 = \overline{A}_2 = \{e_1, e_3\} \\
 L(\text{décision} = e_3) &= L_3 = \overline{A}_3 = \{e_1\}
 \end{aligned}
 \tag{4.18}$$

4.6.3 Utilisation des méta-connaissances pour la correction des fonctions de masse bayésiennes

Suite à l'extraction des ensembles compléments de chaque contexte, la correction des fonctions de masse est effectuée en appliquant l'approche présentée dans l'équation 4.6. L'application de l'équation 4.6 ne doit pas changer la forme bayésienne de la fonction de masse pour que nous puissions ensuite construire des fonctions de masse consonantes. Les informations disponibles seront donc représentées de la meilleure manière possible. La fonction de masse initiale sera affaiblie de β et une masse égale à $(1 - \beta)/|\overline{A}_i|$ est accordée à chaque élément de l'ensemble complément. Suivant la manière dont le degré de sincérité β est calculé, la correction peut s'effectuer de deux manières :

- β = degré de sincérité global de la source d'informations.
- β = degré de sincérité contextuel. Dans ce cas, la valeur de β est extraite à partir de la diagonale de la matrice de confusion et ce pour les 72 hypothèses.

Pour affaiblir une fonction de masse, l'idée est de faire varier contextuellement la valeur de β . Ainsi, si le classifieur décide qu'il s'agit de l'espèce e_2 , la valeur contextuelle de β est celle correspondant au degré de sincérité du classifieur par rapport à l'espèce e_2 . Il est important de noter que dans notre cas, nous considérons que la décision d'un classifieur correspond à l'espèce ayant le maximum de masse. Les diagonales des matrices de confusion de chaque source d'informations sont présentées en Annexes 13 et 14. On remarque que pour la plupart des espèces, la valeur contextuelle de β est nulle. Ainsi, dans ces cas, la fonction de masse initiale est multipliée par zéro et une masse nulle est accordée à l'ensemble complément. En d'autres termes, la fonction de masse devient nulle.

4.7 Expériences et résultats : application de la méthode de correction des fonctions de masse

4.7.1 Quel degré de sincérité : global ou contextuel ?

Lorsque le degré de sincérité est global, la valeur de β est la même pour tous les contextes. Par contre, lorsque le degré de sincérité est contextuel, la valeur de β dépendra du contexte. Nous remarquons que dans plusieurs contextes, la valeur de β est nulle : 30 contextes pour le classifieur Gabor et de 47 contextes pour le classifieur HSV. Même si les valeurs contextuelles de β permettent d'habitude de prendre en compte la sincérité contextuelle vis à vis de chaque

cas, dans notre cas cette approche s'avère inutile puisque, dans la majorité des contextes, β a une valeur nulle.

4.7.2 Impact de la méthode proposée sur les performances des classifieurs

Dans le but d'évaluer les performances des classifieurs avant et après la correction des fonctions de masse, l'idée est d'utiliser la procédure de validation croisée 10 fois dite *10-fold-cross-validation* [112]. Les méta-connaissances sont extraites à partir de 9/10^{ème} des échantillons, et l'efficacité de la méthode de correction est testée sur le 10^{ème} restant. Cette opération est répétée 10 fois, et à chaque fois les échantillons de configuration et de test sont tirés aléatoirement. Le résultat final est la valeur moyenne des 10 résultats correspondants aux 10 répétitions.

La figure 4.13 présente les résultats obtenus sans et avec la correction des fonctions de masse de la base de données de test. Nous remarquons une amélioration significative des performances des classifieurs pour les deux modalités. Néanmoins, à travers le tableau 4.8 représentant l'écart type pour chaque classifieur, nous remarquons que l'écart type est souvent important. En effet, en tirant aléatoirement les données de configuration, les ensembles formés peuvent être assez représentatifs des variations existantes dans les données comme ils peuvent être faiblement représentatifs de ces variations. La qualité des méta-connaissances extraites varie donc en fonction de la pertinence de la base de données de configuration ce qui influence par la suite la capacité du système de fusion à généraliser.

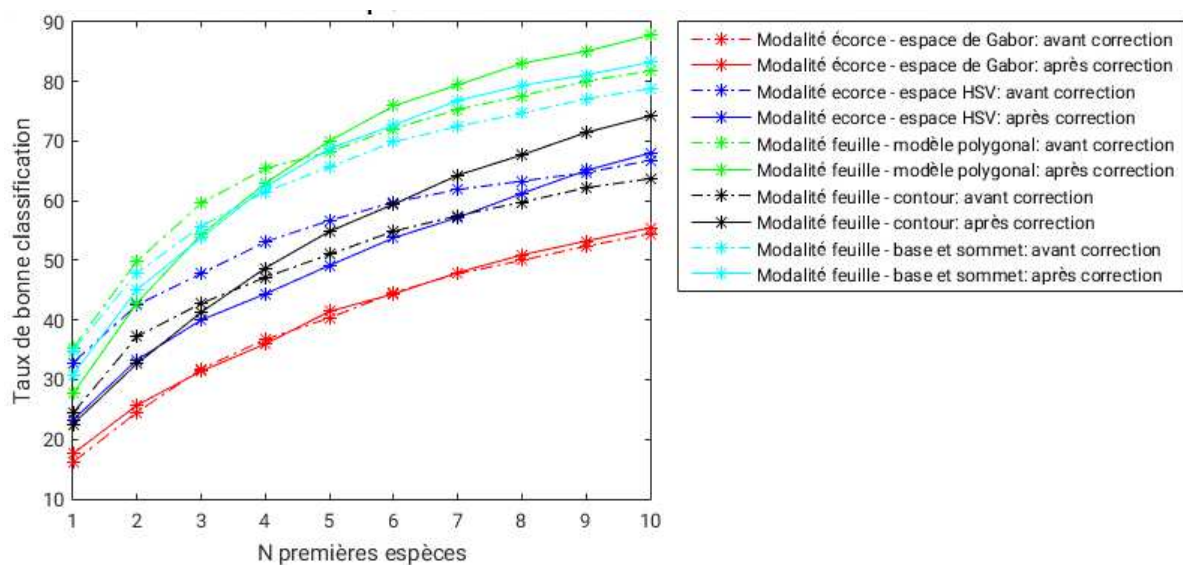


FIGURE 4.13: Évaluation des performances des classifieurs avant et après la correction des fonctions de masse : BDD de test

Modalité	Caractéristique	Écart-type					
		sans correction			avec correction		
		N=1	N=5	N=10	N=1	N=5	N=10
Écorce	Espace HSV	5.1435	5.4553	3.9829	3.9850	4.7771	6.9034
	Espace de Gabor	5.6459	5.9688	7.0126	3.3050	6.9748	4.1773
Feuille	Contour	3.7012	4.3951	5.0837	5.3637	6.5911	4.4604
	Base et sommet	5.4614	3.9912	3.2008	3.8133	3.8328	3.2924
	Modèle polygonal	4.4604	4.7424	4.3574	4.4326	6.0894	2.9342

TABLE 4.8: Écarts-types des différents classifieurs avec et sans la correction des fonctions de masse

4.7.3 Fusion des sources d'informations caractérisant les modalités feuilles et écorces

L'application de la correction des fonctions de masse a contribué à l'amélioration des performances des classifieurs. Il est donc intéressant de voir l'impact de cette technique sur le résultat de la fusion. La figure 4.14 présente les résultats de la fusion des classifieurs des 2 modalités sans et avec la correction des fonctions de masse.

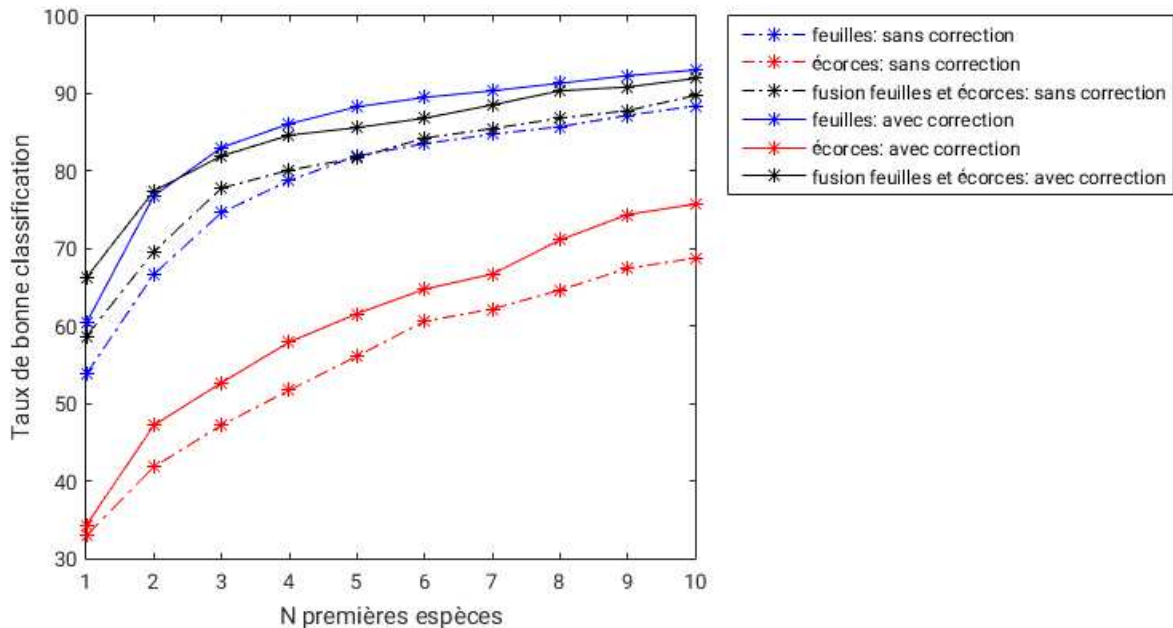


FIGURE 4.14: Résultats de la fusion sans et avec la correction des fonctions de masse

À partir de la figure 4.14 nous remarquons que la fusion des classifieurs de chaque modalité, suite à la correction des fonctions de masse, engendre une amélioration par rapport aux résultats obtenus sans correction. Nous remarquons aussi que la fusion de la modalité feuille avec la modalité écorce permet une amélioration d'environ 6% pour $N = 1$. À partir de $N = 3$, l'ajout de la modalité écorce entraîne une dégradation des performances par rapport à celles

obtenus en utilisant uniquement la modalité feuille. L'approche utilisée pour la correction des fonctions de masse a prouvé ses capacités à gérer le type de données traitées, mais, l'ajout de la modalité écorce n'apporte qu'une légère amélioration des performances du système de fusion.

4.8 Conclusion

L'objectif de ce chapitre est de fusionner les données issues des feuilles avec celles issues des écorces. Le but de cette fusion multimodale est d'améliorer potentiellement les performances pouvant être atteintes en utilisant une seule modalité. Vu la qualité des données issues des écorces, cette amélioration n'était pas évidente. L'idée était donc de corriger les données issues de cette modalité.

La correction des fonctions de masse peut se faire de différentes manières. Le plus important pour que la correction soit efficace est d'avoir une idée précise sur les imperfections les plus présentes dans les données à corriger. La taille de l'espace de discernement est l'une des contraintes les plus importantes que nous devons prendre en compte lors du choix de la méthode de correction. Puisqu'il est de grande taille, certaines méthodes de correction contextuelles ne peuvent pas être appliquées car la complexité calculatoire risque de devenir très importante. L'application des méthodes de correction nécessite d'avoir des méta-connaissances sur l'état de la source d'informations.

Dans notre cas, la non sincérité des sources d'informations présente l'une des imperfections les plus présentes. Nous avons donc considéré que toutes les sources d'informations ne sont pas sincères. L'idée est ensuite de mettre de la masse sur les classes pouvant potentiellement contenir la bonne espèce. L'ensemble de ces espèces est extrait à partir de la matrice de confusion. Cette méthode est intéressante dans notre cas puisque, à la sortie du système de fusion, nous nous intéressons à la liste des 10 espèces les plus probables et non pas à la première espèce la plus probable seulement. Dans ce cas, en mettant de la masse sur les espèces contenant potentiellement la bonne espèce, nous augmentons les chances de cette espèce pour qu'elle soit dans les 10 premières espèces. Les chances sont moins faibles si nous ne considérons que la première espèce à la sortie d'un système de fusion. En effet, la méthode proposée devait potentiellement être plus efficace du moment qu'un certain nombre d'espèces est toléré à la sortie du système.

La méthode proposée a prouvé ses performances à améliorer les performances des classificateurs des deux modalités. Néanmoins, les résultats de la fusion multimodale présentent une dégradation par rapport aux résultats obtenus en utilisant uniquement la modalité feuille.

Conclusion générale et perspectives

Tout au long du processus visant à reconnaître les espèces d'arbres, explicité et évalué dans cette thèse, un certain nombre de problèmes scientifiques ont été soulevés. Nous avons tenté de mettre en place une chaîne de traitements pour résoudre les différents problèmes. Les blocs de la chaîne de traitements ont prouvé leur efficacité dans le cas spécifique de notre application. Ils peuvent être efficaces pour d'autres applications. Plusieurs points ont été abordés afin de trouver une solution à un problème aussi complexe tout en respectant certains objectifs. Ces problèmes concernent à la fois la mise en place d'une architecture en correspondance à l'objectif éducatif de l'application, l'analyse des données à fusionner, la mise en place des outils adéquats pour gérer les imperfections les plus présentes et la fusion multimodale.

Il est clair que la contribution principale de ce travail est la mise en place d'une chaîne de traitements complète pour la reconnaissance d'espèces d'arbres à partir de photos de feuilles et d'écorces prises en milieu naturel. Cette chaîne de traitements caractérisée par son aspect éducatif, est mise en place en prenant en compte les spécificités des données. La chaîne de traitements proposée est un ensemble de blocs. Un outil est utilisé dans chaque bloc afin de résoudre un problème spécifique. La plupart des outils utilisés sont des outils existants. La contribution principale de cette thèse est comment utiliser ces outils dans le contexte spécifique de notre application pour qu'ils nous aident à répondre aux objectifs fixés. Ce système sera, à termes, concrétisé sous forme d'une application. En plus des botanistes et des amateurs de la botanique, cette application pourrait être utilisée dans les écoles pour initier les élèves à la reconnaissance des espèces d'arbres.

Dans la suite, nous résumons les contributions apportées à chaque étape du système de reconnaissance. Nous proposons aussi des pistes d'amélioration pour donner une idée des axes possibles d'extension des travaux de recherche présentés dans cette thèse.

La topologie de fusion

L'un des objectifs principaux de la thèse est l'aspect éducatif de l'application. La topologie de fusion hiérarchique du système de fusion a permis de mettre en valeur cet aspect. Cette topologie permet à l'utilisateur de suivre l'apport de chaque source d'informations puisque chaque niveau de fusion correspond à l'ajout d'une et une seule source. En comparant les résultats obtenus à chaque niveau de fusion, l'utilisateur pourrait savoir quelles sont les caractéristiques les plus pertinentes dans la reconnaissance et quelles sont les sources apportant de la confusion. En plus de sa contribution à la mise en valeur de l'aspect éducatif de l'application, la topologie choisie permet de traiter chaque modalité séparément des autres. Pour le moment, nous n'avons que des données sur les feuilles et les écorces. Des données peuvent être extraites à partir d'autres modalités. Grâce à la topologie de fusion choisie, l'intégration de ces nouvelles modalités dans le système de fusion est simple puisqu'il s'agira d'ajouter un nouveau bloc pour chaque nouvelle modalité.

L'extraction d'attributs et la classification

L'étape d'extraction d'attributs, faite dans le cadre de la thèse de G.Cerutti, a permis d'extraire un vecteur d'attributs décrivant chaque caractéristique pertinente de la feuille. En effet, dans le cadre de l'objectif éducatif de l'application, l'idée était de reproduire la stratégie adoptée par les botanistes lors de la reconnaissance des espèces d'arbres en se basant sur les mêmes clés de détermination. L'étape de classification consiste donc à traiter chaque caractéristique séparément des autres. Aucune fusion n'est faite au niveau des attributs.

Pour mettre plus en valeur l'aspect éducatif de l'application, nous avons essayé de faire la classification dans un espace intermédiaire : l'espace des descriptions morphologiques. Ensuite, en utilisant une base de données établie par des botanistes nous passons vers l'espace des espèces. Cette méthode n'a pas été efficace et a montré d'avantage la complexité du problème puisque nous avons constaté que même les botanistes ont parfois une vision différente envers une même espèce. Nous avons aussi constaté l'importante similarité entre les espèces puisque les botanistes accordaient à plusieurs espèces la même description morphologique d'une ou plusieurs caractéristiques. Devant la non pertinence des informations fournies par les experts, nous nous sommes orientés vers une classification directement dans l'espace des espèces. L'évaluation des performances des classifieurs reflète elle aussi la complexité du problème. En effet, nous avons remarqué que les performances de la plupart des classifieurs sont limitées. Puisque cette thèse s'intéresse principalement à la fusion des données, nous avons décidé de gérer les imperfections lors de la fusion.

La modélisation et la fusion des données issues des feuilles

Une part importante du travail a consisté à analyser la qualité des données à fusionner pour pouvoir mettre en place les outils adéquats pour une meilleure gestion des imperfections existantes. Nous avons constaté que les données à fusionner sont incertaines et que les sources d'informations ne sont pas assez fiables et qu'elles sont conflictuelles et menteuses contextuellement. En effet, fusionner des données aussi imparfaites était un défi pour cette thèse.

L'idée était donc de travailler dans le cadre de la théorie des fonctions de croyance vue ses performances à gérer ce type de données. Il fallait donc trouver une solution pour modéliser toutes les informations disponibles et surtout les imperfections les entachant. Nous avons choisi de construire des fonctions de masse consonantes. Cette méthode de passage de la théorie des probabilités vers la théorie des fonctions de croyance présente l'avantage de construire des éléments focaux formés d'ensembles et non pas de singletons. Ceci offre plus de flexibilité et permet de profiter des avantages de la théorie des fonctions de croyance. À travers la modélisation des informations disponibles avec des fonctions de masse consonantes, un certain degré d'imprécision est ajouté aux données. L'ajout de ce degré d'imprécision était plutôt bénéfique puisqu'il a permis entre autres de mettre de la masse sur des espèces qui avaient initialement des probabilités faibles. Même les espèces les moins probables sont donc représentées par les fonctions de masse consonantes ce qui permet de faire face à la performance limitée ainsi que la non sincérité des classifieurs. C'est grâce à la complémentarité entre les différentes sources d'informations que l'imprécision, ajoutée à un certain niveau du processus de reconnaissance, sera levée.

Puisque à long termes nous envisageons d'implémenter la chaîne de traitements dans une application Smart-phone, il fallait réduire au maximum la complexité calculatoire. Cette complexité est susceptible d'augmenter exponentiellement en fonction de la taille de l'espace de discernement. Nous nous trouvons donc obligés de respecter deux critères importants qui sont : la préservation d'un maximum d'informations sans trop diminuer leur spécificité et la nécessité de garder une complexité calculatoire réduite. Une approximation des fonctions de masse est donc nécessaire. Nous avons constaté que l'approximation sommation est la mieux adaptée à notre cas puisqu'elle permet une réduction du nombre d'éléments focaux sans éliminer ceux ayant une faible masse.

La combinaison des fonctions de masse issues des différentes sources est l'étape suivante de la chaîne de traitements. Devant la multitude de règles de combinaison, il a fallu étudier chacune d'elles pour choisir la règle la plus apte à gérer le type de données. Chaque règle de combinaison permet de transférer de la masse vers des éléments focaux précis. Dans notre cas,

les sources de données sont parfois en conflit total. Certaines règles de combinaison telles que la règle de combinaison de Dempster ou la règle de combinaison conjonctive ne peuvent pas être utilisées. Aussi, vu la taille de l'espace de discernement, il vaut mieux ne pas transférer la masse des éléments en conflit vers l'ignorance totale comme le propose plusieurs règles de combinaison. Nous avons aussi remarqué que dans certains cas, la vérité est proposée par une seule source d'informations. Il fallait donc trouver la règle de combinaison qui puisse gérer toutes les spécificités des données à fusionner. Dans notre cas et après plusieurs expériences, nous avons constaté que la règle de combinaison DPCR est la plus apte à gérer les imperfections des données fusionnées.

La fusion des données issues des écorces

La deuxième modalité traitée dans cette thèse est la modalité écorces. Comme la fusion de données issues de plusieurs sources peut potentiellement augmenter les performances d'un système de fusion, l'idée était de fusionner les données issues des feuilles avec celles des écorces. L'analyse des données issues des classifieurs des écorces a permis de déduire que les imperfections existantes dans ces données sont plus importantes que celles des feuilles : les classifieurs de cette modalité sont moins performants, leurs degrés d'incertitude sont plus importants. La complexité du problème de fusion est donc plus importante. Devant des performances variables des deux modalités, le mieux est de considérer chacune à part et de procéder à la fusion des résultats finaux issus de chacune.

La fusion des données issues des feuilles avec celles issues des écorces

En fusionnant les données issues des feuilles avec celles des écorces, nous avons remarqué la détérioration des performances du système de fusion. L'ajout de la modalité écorce a plutôt apporté des informations erronées au système de fusion.

L'idée était donc de corriger les fonctions de masse issues des écorces afin d'améliorer les performances de cette modalité. En analysant les méthodes de correction existantes dans la littérature, nous avons constaté que la plupart ne peuvent pas être appliquées par cause de la complexité calculatoire qui risque d'augmenter exponentiellement ou par cause de leur tendance à mettre de la masse vers l'ignorance ce qui engendre une perte de la spécificité des données.

L'idée était donc d'extraire des méta-connaissances à partir de la matrice de confusion de chaque classifieur. Ces méta-connaissances permettent de définir un ensemble complément

pour chaque décision prise par un classifieur. Théoriquement, cette méthode devait contribuer à l'amélioration des performances des classifieurs, mais, dans la pratique les résultats n'étaient pas satisfaisants pour les écorces ainsi que pour les feuilles. Nous avons remarqué une dégradation importante des performances du système de fusion. Cette piste mérite d'être encore étudiée afin de trouver une méthode efficace pour la correction des fonctions de masse.

Perspectives

Les travaux effectués dans cette thèse présentent un système de fusion solide pour la reconnaissance d'espèces d'arbres, mais la difficulté du problème est telle que des améliorations sont envisageables.

À commencer par la classification. Deux axes d'améliorations pourront être exploités pour cette phase. La première concerne la possibilité de faire de la sous classification au sein de chaque espèce. En effet, pour les espèces ayant une variabilité intra-espèce assez importante, il serait intéressant de créer des groupes au sein de cette même espèce. Chaque groupe est une sous-classe de l'espèce concernée. Ceci facilitera l'étape d'apprentissage pour les classifieurs qui seront capables de créer des modèles plus clairs pour chaque sous-classe d'espèce. Nous parlons ainsi de sous-classification des espèces.

Le deuxième axe d'amélioration pour la phase de classification concerne le choix des classifieurs. Les classifieurs utilisés dans cette thèse sont des forêts aléatoires. Il serait intéressant d'utiliser d'autres classifieurs tel que les classifieurs crédibilistes. Ainsi, à la sortie d'un classifieur, nous obtiendrons directement des fonctions de masse. Nous n'aurions plus besoin de chercher un moyen pour passer de la théorie des probabilités vers la théorie des fonctions de croyance. Il est possible qu'un classifieur crédibiliste permette la construction de fonctions de masse plus représentatives que celles que nous avons obtenu en construisant des fonctions de masse consonantes.

Toujours dans la classification, nous avons remarqué que les formes des feuilles peuvent changer tout au long du processus de croissance. Une feuille jeune peut donc être très différente d'une feuille appartenant à la même espèce mais plus âgée. Dans ce cas, il est possible que cette feuille ressemble plutôt à une autre espèce qu'à l'espèce à laquelle elle appartient. Pour réduire l'ambiguïté apporté par ce genre de modifications naturelles que subissent les feuilles, il serait peut être intéressant d'ajouter des informations sur la saison, si les modifications de forme dépendent de la saison. Le système de classification devra donc prendre en compte cette information supplémentaire lors de l'apprentissage.

La possibilité d'ajouter les écorces adaptativement constitue également une piste à exploiter. En effet, nous avons remarqué que pour l'instant l'ajout des écorces n'apporte pas une information utile. Il serait peut être plus intéressant d'ajouter la modalité écorce adaptativement pour chaque contexte. Pour les individus où la modalité feuille est capable à elle seule de reconnaître l'espèce, la modalité écorce ne sera pas utilisée. Par contre, pour les individus où les espèces ne sont pas discriminables avec les feuilles seulement, les informations sur l'écorce sera ajoutée.

La correction des fonctions de masse est aussi une piste intéressante qui pourrait contribuer à l'amélioration des performances du système de fusion. Elle nécessite l'extraction de méta-connaissances suffisamment représentatives de toutes les espèces. Cette extraction est délicate vu la qualité des informations. Il serait peut être plus utile d'avoir l'aide d'un botaniste afin de ressortir des éléments de contexte qui peuvent potentiellement contribuer à la correction contextuelle des fonctions de masse.

L'architecture du système de fusion proposée est faite de manière à ce que l'ajout d'autres modalités au système de fusion soit assez facile. Plusieurs modalités peuvent être utilisées comme les fruits et les fleurs. En plus des modalités, il serait aussi intéressant d'ajouter des informations de géolocalisation permettant ainsi d'augmenter la certitude du système de fusion.

Finalement, il serait intéressant de travailler sur une base de données plus importante où chaque espèce est représentée par un nombre suffisant d'individus. En effet, pour la base de données utilisées dans cette thèse, certaines espèces étaient mal représentées ce qui constitue l'un des facteurs majeurs derrière l'incapacité du système à les reconnaître.

Annexe A




FIGURE 15: Résultats du défi LifeClef 2013 montrant les performances de chaque modalité séparément ainsi que le résultat de la fusion de toutes les modalités




FIGURE 16: Résultats du défi LifeClef 2014 montrant les performances de chaque modalité séparément ainsi que le résultat de la fusion de toutes les modalités




FIGURE 17: Résultats du défi LifeClef 2015 montrant les performances de chaque modalité séparément ainsi que le résultat de la fusion de toutes les modalités

Annexe B

Espèce	Nombre d'individus	
	Base de données d'apprentissage	Base de données de test
1	52	51
2	57	57
3	21	21
4	25	24
5	11	10
6	9	8
7	20	19
8	14	14
9	53	52
10	44	43
11	2	2
12	50	50
13	125	124
14	37	36
15	35	35
16	67	66
17	74	74
18	25	25
19	20	19
20	61	61
21	64	63
22	31	30
23	4	3
24	53	53
25	16	15

26	15	14
27	7	6
28	79	78
29	31	31
30	44	44
31	4	3
32	72	71
33	53	52
34	50	50
35	14	13
36	12	11
37	12	12
38	9	8
39	28	27
40	76	76
41	91	90
42	2	2
43	64	64
44	58	58
45	52	52
46	83	83
47	24	23
48	26	25
49	9	9
50	25	25
51	2	2
52	8	8
53	38	37
54	6	6
55	28	28
56	110	109
57	24	23
58	51	51
59	10	9
60	11	10

61	14	13
62	4	3
63	13	13
64	10	10
65	11	11
66	42	41
67	13	13
68	8	7
69	137	137
70	14	13
71	16	15
72	92	91

TABLE 9: Modalité feuille : nombre d'individus par espèce pour les bases de données d'apprentissage et de test

Annexe C

Espèces	forme globale	base	sommet	contour
AcerCampestre	lobé profond ou lobé peu profond			dentée
AcerMonspessulanum	lobé profond ou lobé peu profond			entière
AcerOpalus	lobé peu profond			dentée
AcerPlatanoides	lobé profond ou lobé peu profond	cordée ou tronquée	aigu	dentée
AcerPseudoplatanus	lobé profond ou lobé peu profond			dentée
AcerSaccharinum	lobé profond			dentée
AlnusCordata	ovale ou circulaire	cordée ou arrondie ou tronquée	aigu ou arrondi	dentée
AlnusGlutinosa				dentée
ArbutusUnedo				dentée
BetulaPendula	deltοïde ou ovale ou elliptique			dentée
BetulaPubescens	deltοïde ou ovale ou elliptique			dentée
BroussonetiaPapyrifera	lobé profond ou ovale			dentée
BuxusSempervirens	ovale ou elliptique			entière
CarpinusBetulus	elliptique	arrondie	aigu	dentée
CastaneaSativa	oblong	arrondie ou en coin	aigu	dentée
CeltisAustralis				dentée
CercisSiliquastrum				entière
CornusMas				entière

CornusSanguinea				entière
CorylusAvellana				dentée
CotinusCoggygria				entière
CrataegusAzarolus	lobé profond ou lobé peu profond			dentée
CrataegusLaevigata	lobé profond ou lobé peu profond			dentée
CrataegusMonogyna	lobé profond ou lobé peu profond	en coin ou tronquée	aigu ou arrondi	dentée
DiospyrosKaki				entière
EriobotryaJaponica				dentée
EuonymusEuropaeus				dentée
EuphorbiaCharacias				entière
FagusSylvatica				entière ou ondulée
FicusCarica				dentée ou entière
FrangulaDodonei				entière
HederaHelix				entière ou ondulée
IlexAquifolium				dentée
LaurusNobilis	elliptique ou ovale	arrondie ou en coin	aigu ou arrondi	entière ou ondulée
LigustrumVulgare	elliptique ou ovale	arrondie	arrondi ou échancré	entière ou ondulée
LiquidambarStyraciflua	circulaire	tronquée ou cordée	aigu	denté
MagnoliaGrandiflora				entière ou ondulée
MalusSylvestris				dentée
MorusAlba	ovale ou elliptique	cordée	aigu	dentée
NeriumOleander				entière
OleaEuropaea				entière
OstryaCarpinifolia				dentée
PittosporumTobira				entière ou ondulée
PlatanusHispanica				dentée

PopulusAlba				dentée
PopulusNigra	triangulaire ou deltoïde	tronquée ou arrondie	aigu	dentée
PopulusTremula				dentée ou ondulée
PrunusAvium	ovale ou elliptique	arrondie ou asymétrique	aigu	dentée
PrunusDulcis				dentée
PrunusLaurocerasus	elliptique ou oblong ou obovale	en coin ou arrondie	aigu	dentée
PrunusPadus				dentée
PrunusSpinosa	ovale ou elliptique	arrondie	arrondi ou aigu	dentée
PunicaGranatum				entière
QuercusCerris				dentée
QuercusCoccifera				dentée ou ondulée
QuercusIlex	elliptique ou ovale	arrondie ou tronquée	aigu ou arrondi	dentée ou ondulée
QuercusPetraea				entière ou ondulée
QuercusPubescens				entière ou ondulée
QuercusRobur	lobé peu profond ou lobé profond	cordée ou asymétrique ou arrondie	arrondi	entière ou ondulée
QuercusRubra	lobé profond ou lobé peu profond	en coin ou arrondie ou asymétrique	aigu	denté
RhamnusCathartica				dentée
SalixAlba				entière ou dentée
SalixCaprea				entière ou dentée
SorbusAria				dentée
SorbusTorminalis				dentée

SyringaVulgaris	ovale	cordée ou tronquée	aigu	entière
TiliaCordata				dentée
TiliaPlatyphyllos	ovale ou circulaire	cordée ou tronquée	aigu	dentée
UlmusMinor	ovale	assymétrique	aigu	dentée
ViburnumLantana				dentée
ViburnumOpulus	ovale	arrondie	aigu	dentée
ViburnumTinus	ovale ou elliptique	en coin ou ar- rondie	aigu ou ar- rondi	entière

TABLE 10: Base de données experte 1

Espèces	forme globale	base	sommet	contour
AcerCampestre		En cœur	Obtuse ou aiguë	Sinué ou lobé
AcerMonspessulanum		En cœur	obtuse	Entier ou lobé
AcerOpalus		En cœur	obtuse	Lobé ou sinué
AcerPlatanoides		En cœur	Acuminée ou aiguë	lobé
AcerPseudoplatanus		En cœur	acuminée	denté ou lobé
AcerSaccharinum				lobé
AlnusCordata	suborbiculaire ou ovale	En cœur	obtuse	denté en scie
AlnusGlutinosa	suborbiculaire ou obovale	En coin ou tronquée	tronquée	Denté ou sinué
ArbutusUnedo	Ovale ou obovale ou oblongue	Atténuée ou en coin	obtuse	denté en scie
BetulaPendula	Ovale ou triangu- laire		acuminée	doublement denté
BetulaPubescens	Ovale		Acuminée ou aiguë	denté
BroussonetiaPapyrifera	Ovale ou ellip- tique		acuminée	Lobé ou denté

BuxusSempervirens	Ovale ou lancéolée		Arrondie ou tronquée	entier
CarpinusBetulus	Ovale ou ob-longue		acuminée	doublement denté
CastaneaSativa	Obovale ou ob-longue	En cœur ou arrondie ou tronquée	acuminée	denté
CeltisAustralis	Ovale ou lancéolée	arrondie	acuminée	
CercisSiliquastrum	orbiculaire	En cœur	Tronquée ou arrondie	entier
CornusMas	ovale	en coin	Acuminée ou aiguë	entier
CornusSanguinea	Ovale ou elliptique		acuminée	
CorylusAvellana	suborbiculaire	En cœur	acuminée	doublement denté
CotinusCoggygria	Obovale ou suborbiculaire	en coin	Obtuse ou arrondie	entier
CrataegusAzarolus	obovale	en coin	mucronée	Pennatifide ou denté ou lobé
CrataegusLaevigata	obovale	en coin	obtuse	denté
CrataegusMonogyna	ovale	en coin		Pennatifide ou denté ou lobé
DiospyrosKaki	suborbiculaire ou elliptique		Acuminée ou aiguë	entier
EriobotryaJaponica	Obovale ou ob-longue	En coin ou atténuée	aiguë	
EuonymusEuropaeus	Ovale ou lancéolée		acuminée	denticulé
EuphorbiaCharacias	linéaire	en coin	aiguë	entier
FagusSylvatica	ovale	en coin	aiguë	Entier ou ondulé
FicusCarica	triangulaire	En cœur	obtuse	lobé
FrangulaDodonei				

HederaHelix	ovale		Acuminée ou obtuse	Entier ou lobé
IlexAquifolium	Ovale ou elliptique	En coin ou arrondie	Aiguë ou épineuse	Épineux ou entier ou denté ou sinué
LaurusNobilis	Elliptique ou lancéolée	atténuée	Aiguë ou acuminée	Entier ou ondulé
LigustrumVulgare	Elliptique ou lancéolée	en coin	obtuse	entier
LiquidambarStyraciflua				lobé
MagnoliaGrandiflora	Elliptique ou obovale		Acuminée ou aiguë	entier
MalusSylvestris	Ovale ou suborbiculaire	arrondie	acuminée	
MorusAlba	ovale	En cœur ou arrondie	aiguë	denté ou lobé
NeriumOleander	lancéolée	en coin	aiguë	entier
OleaEuropaea	Ovale ou oblongue ou lancéolée	atténuée	Aiguë ou obtuse ou mucronée	entier
OstryaCarpinifolia	Ovale ou lancéolée		Acuminée ou aiguë	doublement denté
PittosporumTobira	obovale	atténuée	arrondie	entier
PlatanusHispanica			acuminée	denté ou lobé
PopulusAlba	Suborbiculaire		obtuse	Siné ou anguleux ou lobé
PopulusNigra	triangulaire		acuminée	Denté ou crénelé
PopulusTremula	Suborbiculaire		aiguë	Siné ou denté
PrunusAvium	Obovale ou elliptique		acuminée	doublement denté
PrunusDulcis	Elliptique ou lancéolée			crénelé

PrunusLaurocerasus	Oblongue ou lancéolée	en coin	Aiguë ou acuminée	
PrunusPadus	obovale		acuminée	denticulé
PrunusSpinosa	Obovale ou oblongue ou lancéolée	en coin	acuminée	denté
PunicaGranatum	oblongue	en coin	Obtuse ou arrondie	entier
QuercusCerris	Obovale ou oblongue		aiguë	Pennatifide ou sinué
QuercusCoccifera	Ovale ou oblongue	Tronquée ou en cœur	Aiguë ou épineuse	épineux ou entier ou denté
QuercusIlex	Ovale ou oblongue	tronquée	Aiguë ou épineuse	épineux ou entier ou denté
QuercusPetraea	obovale	en coin	arrondie	Siné ou lobé
QuercusPubescens	obovale	tronquée	arrondie	Lobé ou sinué ou pennatifide
QuercusRobur	Obovale ou oblongue	Auriculée		Siné ou lobé
QuercusRubra	obovale			Lobé ou épineux
RhamnusCathartica	Ovale ou elliptique	en coin	acuminée	denticulé
SalixAlba	lancéolée		acuminée	denticulé
SalixCaprea	Ovale ou obovale ou oblongue	Arrondie ou tronquée	obtuse	
SorbusAria	Ovale ou elliptique		Arrondie ou obtuse	
SorbusTorminalis	ovale	En cœur ou tronquée	acuminée	Doublement denté ou lobé
SyringaVulgaris	Ovale ou triangulaire ou cordée	En cœur	acuminée	entier

TiliaCordata	cordée	En cœur	acuminée	denté en scie
TiliaPlatyphyllos	Ovale ou cordée	En cœur	acuminée	denté en scie
UlmusMinor	ovale		Acuminée ou aiguë	
ViburnumLantana	Ovale ou suborbiculaire	En cœur	arrondie	denté
ViburnumOpulus			aiguë	Denté ou lobé
ViburnumTinus	Ovale ou oblongue		Obtuse ou aiguë	entier

TABLE 11: Base de données experte 2

Annexe D

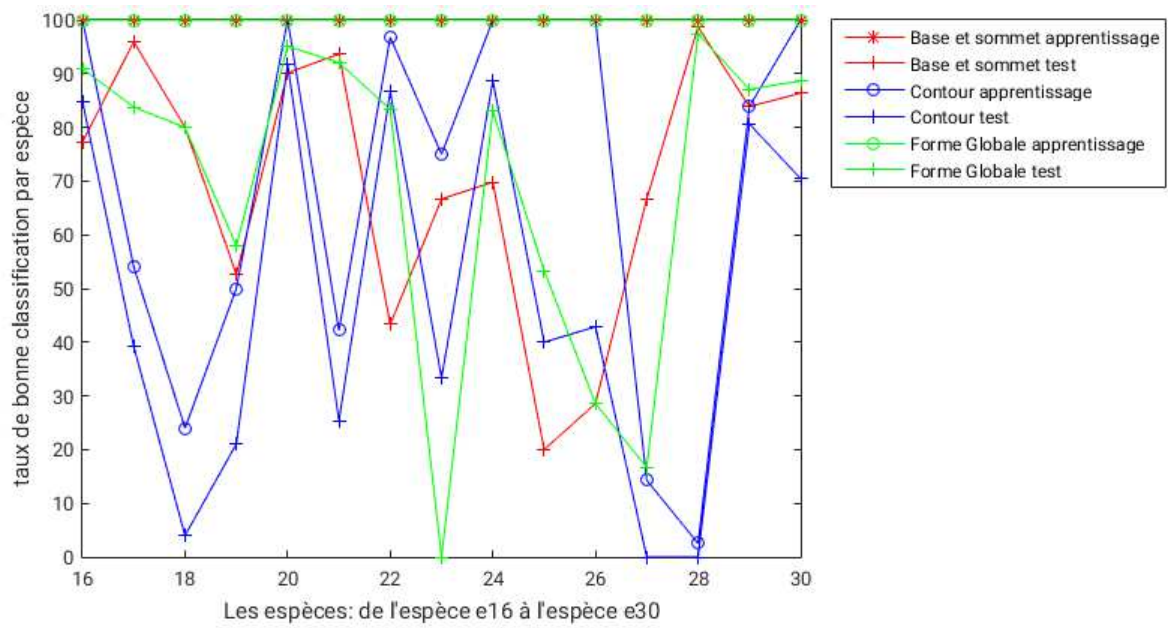


FIGURE 18: Taux de bonne classification par espèce : de l'espèce e_{16} à l'espèce e_{30}

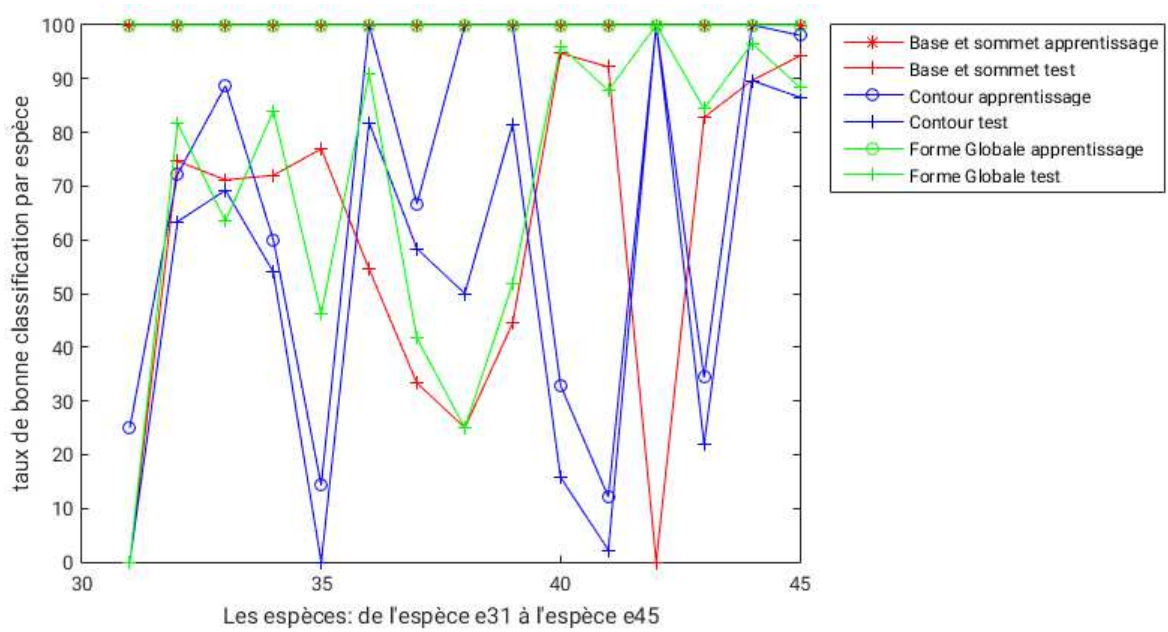


FIGURE 19: Taux de bonne classification par espèce : de l'espèce e_{31} à l'espèce e_{45}

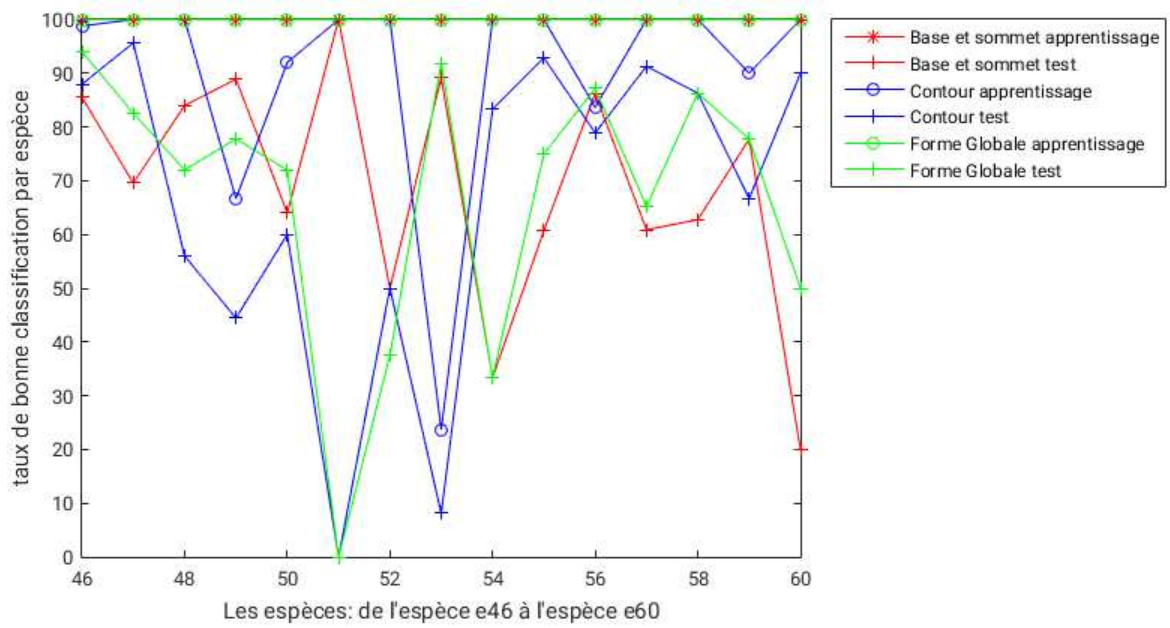
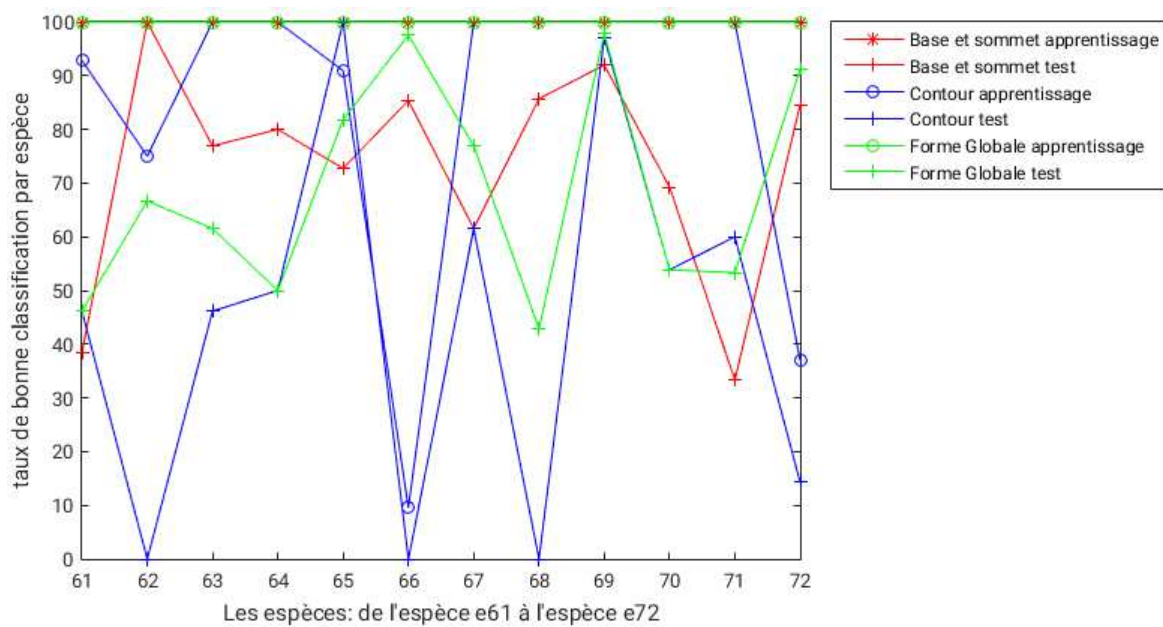

































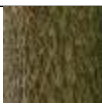




















FIGURE 20: Taux de bonne classification par espèce : de l'espèce e_{46} à l'espèce e_{60}

















FIGURE 21: Taux de bonne classification par espèce : de l'espèce e_{61} à l'espèce e_{72}















Annexe E



















Nom de l'espèce	Photo de la feuille	Photo de l'écorce
Acer campestre		
Acer monspessulanum		
Acer opalus Mill		
Acer platanoides		
Acer pseudoplatanus		
Acer saccharinum		
Alnus cordata		








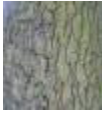








<i>Alnus glutinosa</i>		
<i>Arbutus unedo</i>		
<i>Betula pendula</i> Roth		
<i>Betula pubescens</i> Ehrh		
<i>Broussonetia papyrifera</i>		
<i>Buxus sempervirens</i>		
<i>Carpinus betulus</i>		
<i>Castanea sativa</i>		
<i>Celtis australis</i>		
<i>Cercis siliquastrum</i>		
<i>Cornus mas</i>		



















Cornus sanguinea		
Corylus avellana		
Cotinus coggygria		
Crataegus azarolus		
Crataegus laevigata		
Crataegus monogyna		
Diospyros kaki		
Eriobotrya japonica		

Euonymus europaeus		
Euphorbia characias		
Fagus sylvatica		
Ficus carica		
Frangula dodonei		
Hedera helix		
Ilex aquifolium		
Laurus nobilis		

Ligustrum vulgare		
Liquidambar styraciflua		
Magnolia grandiflora		
Malus sylvestris		
Morus alba		
Nerium oleander		
Olea europaea		

<i>Ostrya carpinifolia</i>		
<i>Pittosporum tobira</i>		
<i>Platanus x hispanica</i>		
<i>Populus alba</i>		
<i>Populus nigra</i>		
<i>Populus tremula</i>		
<i>Prunus avium</i>		
<i>Prunus dulcis</i>		
<i>Prunus laurocerasus</i>		

Prunus padus		
Prunus spinosa		
Punica granatum		
Quercus cerris		
Quercus coccifera		
Quercus ilex		
Quercus petraea		
Quercus pubescens		

Quercus robur		
Quercus rubra		
Rhamnus cathartica		
Salix alba		
Salix caprea		
Sorbus aria		
Sorbus torminalis		
Syringa vulgaris		
Tilia cordata		











Tilia platyphyllos		
Ulmus minor		
Viburnum lantana		
Viburnum opulus		
Viburnum tinus		

TABLE 12: La liste des 72 espèces

Annexe F

degré de sincérité contextuel des classifieurs de la modalité feuille			
Espèce	Base et Sommet	Contour	Modèle polygonal
e_1	0,3125	0,5	0,3125
e_2	0,4	0,2	0,8
e_3	0,4	0	0,4
e_4	0,3333333333	0,3333333333	0,3333333333
e_5	0	0	0
e_6	0	0,6	0,6
e_7	0,3333333333	0	0,3333333333
e_8	0,2307692308	0,0769230769	0,3076923077
e_9	0,347826087	0,1304347826	0,3043478261
e_{10}	0,3023255814	0,2558139535	0,4418604651
e_{11}	0	0	0
e_{12}	0,4838709677	0,0322580645	0,4516129032
e_{13}	1	1	0,6666666667
e_{14}	0,1666666667	0,0555555556	0,1666666667
e_{15}	0,5	0,3571428571	0,2142857143
e_{16}	0,4814814815	0,4074074074	0,5
e_{17}	0,7368421053	0	0,5263157895
e_{18}	0,375	0	0,125
e_{19}	0	0	0
e_{20}	0,4	0,8	0,4
e_{21}	0,6	0,1	0,5
e_{22}	0,5	0,5	0,5
e_{23}	0	0	0
e_{24}	0,0833333333	0,4166666667	0,0833333333
e_{25}	0,1666666667	0	0
e_{26}	0	0	0
e_{27}	0	0	0
e_{28}	0,5	0	0,5

<i>e</i> ₂₉	0,4	0,0666666667	0,0666666667
<i>e</i> ₃₀	0,3333333333	0,1666666667	0,4166666667
<i>e</i> ₃₁	0	0	0
<i>e</i> ₃₂	0,2	0	0,4
<i>e</i> ₃₃	0,5	0	0,25
<i>e</i> ₃₄	0,5833333333	0,3333333333	0,3333333333
<i>e</i> ₃₅	1	0	0
<i>e</i> ₃₆	0,0909090909	0,1818181818	0,0909090909
<i>e</i> ₃₇	0,0833333333	0,0833333333	0,0833333333
<i>e</i> ₃₈	0	0	0
<i>e</i> ₃₉	0	0,125	0,25
<i>e</i> ₄₀	0,8	0,1	0,7
<i>e</i> ₄₁	0,6857142857	0	0,4
<i>e</i> ₄₂	0	0	0
<i>e</i> ₄₃	1	0	0,5
<i>e</i> ₄₄	0,3793103448	0,5862068966	0,724137931
<i>e</i> ₄₅	0,3	0,6	0,4
<i>e</i> ₄₆	0,4166666667	0,4166666667	0,75
<i>e</i> ₄₇	0	0,6	0,2
<i>e</i> ₄₈	0,2777777778	0	0,0555555556
<i>e</i> ₄₉	0,2222222222	0	0,3333333333
<i>e</i> ₅₀	0	0,25	0
<i>e</i> ₅₁	0	0	0
<i>e</i> ₅₂	0	0	0,1666666667
<i>e</i> ₅₃	0,25	0	0
<i>e</i> ₅₄	0	0	0
<i>e</i> ₅₅	0,5	0,5	1
<i>e</i> ₅₆	0,3538461538	0,3538461538	0,3846153846
<i>e</i> ₅₇	0,125	0,625	0
<i>e</i> ₅₈	0,1666666667	0,4166666667	0,0833333333
<i>e</i> ₅₉	0,3333333333	0,1111111111	0,2222222222
<i>e</i> ₆₀	0	0,7	0,1
<i>e</i> ₆₁	0	0	0
<i>e</i> ₆₂	0	0	0
<i>e</i> ₆₃	0,1	0	0
<i>e</i> ₆₄	0	0	0
<i>e</i> ₆₅	0	0	0,6666666667
<i>e</i> ₆₆	0,5	0	0,5
<i>e</i> ₆₇	0,1666666667	0,1666666667	0,5

e_{68}	0,1428571429	0	0,1428571429
e_{69}	0,4166666667	0,9166666667	0,6666666667
e_{70}	0	1	0,5
e_{71}	0,2	0,4	0
e_{72}	0,3913043478	0	0,3913043478

TABLE 13: Diagonales des matrices de confusion des classifieurs de la modalité feuille

degré de sincérité contextuel des classifieurs de la modalité écorce		
Espèce	espace HSV	espace de Gabor
e_1	0,3125	0,0625
e_2	0	0
e_3	0	0
e_4	0	0
e_5	0,2	0
e_6	0,2	0
e_7	0	0
e_8	0,2307692308	0
e_9	0,4347826087	0,3913043478
e_{10}	0,5581395349	0,3720930233
e_{11}	0	0
e_{12}	0,4516129032	0,2580645161
e_{13}	0	0
e_{14}	0,1111111111	0,0555555556
e_{15}	0,2142857143	0,0714285714
e_{16}	0,6296296296	0,2777777778
e_{17}	0,1578947368	0,0526315789
e_{18}	0,125	0
e_{19}	0	0
e_{20}	0,2	0,2
e_{21}	0,4	0
e_{22}	0	0
e_{23}	0,5	0,5
e_{24}	0	0
e_{25}	0,1666666667	0
e_{26}	0,1428571429	0
e_{27}	0	0
e_{28}	0	0
e_{29}	0,1333333333	0

e_{30}	0,1666666667	0
e_{31}	0	0
e_{32}	0	0
e_{33}	0	0
e_{34}	0	0
e_{35}	0	0
e_{36}	0,1818181818	0
e_{37}	0,1666666667	0
e_{38}	0	0
e_{39}	0,625	0,125
e_{40}	0,1	0
e_{41}	0,4857142857	0,0857142857
e_{42}	0	0
e_{43}	0	0
e_{44}	0,5689655172	0,4827586207
e_{45}	0,35	0,2
e_{46}	0,1666666667	0,0833333333
e_{47}	0,2	0
e_{48}	0,1666666667	0,0555555556
e_{49}	0,4444444444	0,1111111111
e_{50}	0	0
e_{51}	0	0
e_{52}	0,3333333333	0
e_{53}	0,25	0
e_{54}	0,3333333333	0,1666666667
e_{55}	0	0
e_{56}	0,6923076923	0,4923076923
e_{57}	0	0,125
e_{58}	0,1666666667	0
e_{59}	0,2222222222	0,1111111111
e_{60}	0,1	0
e_{61}	0	0
e_{62}	0	0
e_{63}	0	0
e_{64}	0,1	0
e_{65}	0	0,3333333333
e_{66}	0,1666666667	0
e_{67}	0	0
e_{68}	0,2857142857	0,1428571429

e_{69}	0,25	0,0833333333
e_{70}	0	0
e_{71}	0	0
e_{72}	0,3913043478	0,0434782609

TABLE 14: Diagonales des matrices de confusion des classifieurs de la modalité écorce

Bibliographie

- [1] Pauline Minary, Frédéric Pichon, David Mercier, Eric Lefevre, and Benjamin Droit. Face pixel detection using evidential calibration and fusion. *International Journal of Approximate Reasoning*, 91 :202–215, 2017.
- [2] Mira Bou Farah, David Mercier, François Delmotte, and Éric Lefèvre. Methods using belief functions to manage imperfect information concerning events on the road in vanets. *Transportation Research Part C : Emerging Technologies*, 67 :299–320, 2016.
- [3] Thanh-Long Nguyen, Didier Coquin, and Reda Boukezzoula. An evidential system for color recognition using multi-cameras. In *Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA), 2017 IEEE International Conference on*, pages 89–93. IEEE, 2017.
- [4] Samir Hachour, François Delmotte, David Mercier, and Eric Lefèvre. Object tracking and credal classification with kinematic data in a multi-target context. *Information Fusion*, 20 :174–188, 2014.
- [5] Guillaume Cerutti. *Segmentation et interprétation d’images naturelles pour l’identification de feuilles d’arbres sur smartphone*. PhD thesis, Lyon 2, 2013.
- [6] Jean-Baptiste de Monet de Lamarck et al. *Flore française ou descriptions succinctes de toutes les plantes qui croissent naturellement en France disposées selon une nouvelle méthode d’analyse; et précédées par un exposé des principes élémentaires de la botanique*. Desray, 1815.
- [7] Jean-Claude Rameau, Dominique Mansion, and Gérard Dumé. *Flore forestière française : région méditerranéenne*, volume 3. Forêt privée française, 2008.
- [8] Jean-Marc Tison and Bruno de Foucault. *Flora gallica : flore de France*. Biotope Mèze, 2014.
- [9] Thomas Régis, David Busti, and Margarethe Maillart. *Petite flore de France*. Biotope Mèze, 2014.

-
- [10] Neeraj Kumar, Peter N Belhumeur, Arijit Biswas, David W Jacobs, W John Kress, Ida C Lopez, and João VB Soares. Leafsnap : A computer vision system for automatic plant species identification. In *Computer Vision–ECCV 2012*, pages 502–516. Springer, 2012.
- [11] Peter N Belhumeur, Daozheng Chen, Steven Feiner, David W Jacobs, W John Kress, Haibin Ling, Ida Lopez, Ravi Ramamoorthi, Sameer Sheorey, Sean White, et al. Searching the world’s herbaria : A system for visual identification of plant species. In *European Conference on Computer Vision*, pages 116–129. Springer, 2008.
- [12] Gaurav Agarwal, Peter Belhumeur, Steven Feiner, David Jacobs, W John Kress, Ravi Ramamoorthi, Norman A Bourg, Nandan Dixit, Haibin Ling, Dhruv Mahajan, et al. First steps toward an electronic field guide for plants. *Taxon*, 55(3) :597–610, 2006.
- [13] Thomas Cover and Peter Hart. Nearest neighbor pattern classification. *IEEE transactions on information theory*, 13(1) :21–27, 1967.
- [14] Hervé Goëau, Pierre Bonnet, Alexis Joly, Vera Bakić, Julien Barbe, Itheri Yahiaoui, Souheil Selmi, Jennifer Carré, Daniel Barthélémy, Nozha Boujemaa, et al. Pl@ ntnet mobile app. In *Proceedings of the 21st ACM international conference on Multimedia*, pages 423–424. ACM, 2013.
- [15] Benoît Lelandais, Su Ruan, Thierry Denceux, Pierre Vera, and Isabelle Gardin. Fusion of multi-tracer pet images for dose painting. *Medical image analysis*, 18(7) :1247–1259, 2014.
- [16] Franklin E White Jr. Data fusion lexicon, joint directors of laboratories. *Technical panel for C*, 3, 1987.
- [17] Lucien Wald. A european proposal for terms of reference in data fusion. In *Commission VII Symposium” Resource and Environmental Monitoring”*, volume 32, pages 651–654, 1998.
- [18] Isabelle Bloch. Fusion d’informations en traitement du signal et des images. *Hermes Science Publication*, 2, 2003.
- [19] Didier Dubois and Henri Prade. La problématique scientifique du traitement de l’information. *Information-Interaction-Intelligence*, 1(2) :79–98, 2001.
- [20] Belur V Dasarathy. Sensor fusion potential exploitation-innovative architectures and illustrative applications. *Proceedings of the IEEE*, 85(1) :24–38, 1997.

- [21] Yi Lu. Knowledge integration in a multiple classifier system. *Applied Intelligence*, 6(2) :75–86, 1996.
- [22] Louisa Lam. Classifier combinations : implementations and theoretical issues. In *International Workshop on Multiple Classifier Systems*, pages 77–86. Springer, 2000.
- [23] Romesh Ranawana and Vasile Palade. Multi-classifier systems : Review and a roadmap for developers. *International Journal of Hybrid Intelligent Systems*, 3(1) :35–61, 2006.
- [24] Francesco Gargiulo, Claudio Mazzariello, and Carlo Sansone. Multiple classifier systems : theory, applications and tools. In *Handbook on Neural Information Processing*, pages 335–378. Springer, 2013.
- [25] Ludmila I. Kuncheva. *Combining Pattern Classifiers : methods and algorithms*. John Wiley Sons, Inc., 2014.
- [26] Lei Xu, Adam Krzyzak, and Ching Y Suen. Methods of combining multiple classifiers and their applications to handwriting recognition. *IEEE Transactions on systems, man, and cybernetics*, 22(3) :418–435, 1992.
- [27] Anne Magaly de Paula Canuto. *Combining neural networks and fuzzy logic for applications in character recognition*. PhD thesis, University of Kent at Canterbury, 2001.
- [28] Mladen Jović, Yutaka Hatakeyama, Fangyan Dong, and Kaoru Hirota. Image retrieval based on similarity score fusion from feature similarity ranking lists. In *International conference on Fuzzy Systems and Knowledge Discovery*, pages 461–470. Springer, 2006.
- [29] Zoubin Ghahramani and Hyun-Chul Kim. Bayesian classifier combination. 2003.
- [30] Hervé Goëau, Pierre Bonnet, and Alexis Joly. Plant identification in an open-world (lifeclef 2016). *CLEF working notes*, 2016, 2016.
- [31] Hervé Goëau, Pierre Bonnet, Alexis Joly, Nozha Boujemaa, Daniel Barthelemy, Jean-François Molino, Philippe Birnbaum, Elise Mouysset, and Marie Picard. The imageclef 2011 plant images classification task. In *ImageCLEF 2011*, pages 0–0, 2011.
- [32] Hervé Goëau, Pierre Bonnet, Alexis Joly, Itheri Yahiaoui, Daniel Barthelemy, Nozha Boujemaa, and Jean-François Molino. The imageclef 2012 plant identification task. In *ImageCLEF 2012*, pages 0–0, 2012.
- [33] Sébastien Paris, Xanadu Halkias, and Hervé Glotin. Participation of lsis/dyni to imageclef 2012 plant images classification task. In *CLEF (Online Working Notes/Labs/Workshop)*, 2012.

- [34] Hideki Nakayama. Nlab-utokyo at imageclef 2013 plant identification task. In *CLEF (Working Notes)*. Citeseer, 2013.
- [35] Cristina Serban, Alexandra Siriteanu, Claudia Gheorghiu, Adrian Iftene, Lenuta Alboae, and Mihaela Breaban. Combining image retrieval, metadata processing and naive bayes classification at plant identification 2013. In *CLEF (Working Notes)*, 2013.
- [36] Issolah Mohamed, Lingrand Diane, and Precioso Frédéric. Plant species recognition using bag-of-word with svm classifier in the context of the lifeclef challenge.
- [37] Guillaume Cerutti, Laure Tougne, Céline Sacca, Thierry Joliveau, Pierre-Olivier Maza-gol, Didier Coquin, and Antoine Vacavant. Late information fusion for multi-modality plant species identification. In *Conference and Labs of the Evaluation Forum*, pages Working–Notes, 2013.
- [38] Hervé Goëau, Alexis Joly, Itheri Yahiaoui, Vera Bakić, Anne Verroust-Blondet, Pierre Bonnet, Daniel Barthélémy, Nozha Boujemaa, and Jean-François Molino. Plantnet participation at lifeclef2014 plant identification task. In *CLEF2014 Working Notes. Working Notes for CLEF 2014 Conference, Sheffield, UK, September 15-18, 2014*, pages 724–737. CEUR-WS, 2014.
- [39] Gábor Szűcs, Dávid Papp, and Dániel Lovas. Viewpoints combined classification method in image-based plant identification task. In *Working Notes for CLEF 2014 Conference*, volume 1180, pages 15–18, 2014.
- [40] Niko Sünderhauf, Chris McCool, Ben Upcroft, and Tristan Perez. Fine-grained plant classification using convolutional neural networks for feature extraction. In *CLEF (Working Notes)*, pages 756–762, 2014.
- [41] Dénes Paczolay, András Bánhalmi, L Nyúl, Vilmos Bilicki, and Árpád Sárosi. Wlab of university of szeged at lifeclef 2014 plant identification task. In *Working notes of CLEF 2014 conference*, 2014.
- [42] Thi-Lan Le, Nam-Duong Duong, Hai Vu, and Thi Thanh-Nhan Nguyen. Mica at lifeclef 2015 : Multi-organ plant identification. In *CLEF (Working Notes)*, 2015.
- [43] Sungbin Choi. Plant identification with deep convolutional neural network : Snumedinfo at lifeclef plant identification task 2015. In *CLEF (Working Notes)*, 2015.
- [44] Vera Bakic, Sofiene Mouine, Saloua Ouertani-Litayem, Anne Verroust-Blondet, Itheri Yahiaoui, Hervé Goëau, and Alexis Joly. Inria’s participation at imageclef 2013 plant identification task. In *CLEF (Online Working Notes/Labs/Workshop) 2013*, 2013.

- [45] Ivica Dimitrovski, Gjorgji Madjarov, Dragi Kocev, and Petre Lameski. Maestra at lifeclef 2014 plant task : Plant identification using visual data. In *CLEF (Working Notes)*, pages 705–714, 2014.
- [46] Julien Champ, Titouan Lorieul, Maximilien Servajean, and Alexis Joly. A comparative study of fine-grained classification methods in the context of the lifeclef plant identification challenge 2015. In *CLEF : Conference and Labs of the Evaluation forum*, volume 1391, 2015.
- [47] Siang Thye Hang, Atsushi Tatsuma, and Masaki Aono. Bluefield (kde tut) at lifeclef 2016 plant identification task. In *Working notes of CLEF 2016 conference*, 2016.
- [48] Bálint Pál Tóth, DP Márton Tóth, and G Szúcs. Deep learning and svm classification for plant recognition in content-based large scale image retrieval. In *Working notes of CLEF 2016 conference*, 2016.
- [49] Julien Champ, Hervé Goëau, and Alexis Joly. Floristic participation at lifeclef 2016 plant identification task. In *CLEF 2016-Conference and Labs of the Evaluation forum*, pages 450–458, 2016.
- [50] Chris McCool, Z Ge, and Peter Corke. Feature learning via mixtures of dcnn for finegrained plant classification. In *Working notes of CLEF 2016 conference*, 2016.
- [51] Mostafa Mehdipour Ghazi, Berrin Yanikoglu, and Erchan Aptoula. Open-set plant identification using an ensemble of deep convolutional neural networks. *Working notes of CLEF*, 2016.
- [52] Lotfi A Zadeh. Fuzzy sets. *Information and control*, 8(3) :338–353, 1965.
- [53] Glenn Shafer et al. *A mathematical theory of evidence*, volume 1. Princeton university press Princeton, 1976.
- [54] Mihai Cristian Florea, Anne-Laure Jousselme, Éloi Bossé, and Dominic Grenier. Robust combination rules for evidence theory. *Information Fusion*, 10(2) :183–197, 2009.
- [55] Philippe Smets and Robert Kennes. The transferable belief model. *Artificial intelligence*, 66(2) :191–234, 1994.
- [56] Didier Dubois and Henri Prade. Representation and combination of uncertainty with belief functions and possibility measures. *Computational intelligence*, 4(3) :244–264, 1988.

- [57] Ronald R Yager. On the relationship of methods of aggregating evidence in expert systems. *Cybernetics and System*, 16(1) :1–21, 1985.
- [58] David Mercier, Benjamin Quost, and Thierry Dencœux. Refined modeling of sensor reliability in the belief function framework using contextual discounting. *Information Fusion*, 9(2) :246–258, 2008.
- [59] Frédéric Pichon, David Mercier, Éric Lefevre, and François Delmotte. Proposition and learning of some belief function contextual correction mechanisms. *International Journal of Approximate Reasoning*, 72 :4–42, 2016.
- [60] Guillaume Cerutti, Violaine Antoine, Laure Tougne, Julien Mille, Lionel Valet, Didier Coquin, and Antoine Vacavant. Reves participation-tree species classification using random forests and botanical features. In *Conference and Labs of the Evaluation Forum (CLEF)*, page 1, 2012.
- [61] Timothy F Cootes, Christopher J Taylor, David H Cooper, and Jim Graham. Active shape models-their training and application. *Computer vision and image understanding*, 61(1) :38–59, 1995.
- [62] Chunfeng Lian, Su Ruan, Thierry Dencœux, Fabrice Jardin, and Pierre Vera. Selecting radiomic features from fdg-pet images for cancer treatment outcome prediction. *Medical image analysis*, 32 :257–268, 2016.
- [63] C-H Teh and Roland T. Chin. On the detection of dominant points on digital curves. *IEEE Transactions on pattern analysis and machine intelligence*, 11(8) :859–872, 1989.
- [64] Leo Breiman. Random forests. *Machine learning*, 45(1) :5–32, 2001.
- [65] Leo Breiman. Bagging predictors. *Machine learning*, 24(2) :123–140, 1996.
- [66] Manuel Fernández-Delgado, Eva Cernadas, Senén Barro, and Dinani Amorim. Do we need hundreds of classifiers to solve real world classification problems. *J. Mach. Learn. Res*, 15(1) :3133–3181, 2014.
- [67] Rihab Ben Ameer, Lionel Valet, and Didier Coquin. Sub-classification strategies for tree species recognition. In *Pattern Recognition (ICPR), 2016 23rd International Conference on*, pages 2139–2144. IEEE, 2016.
- [68] Rihab Ben Ameer, Lionel Valet, Didier Coquin, and Sylvie Galichet. Système d’aide à la reconnaissance d’espèces d’arbres à partir d’une base de connaissance incomplète, partielle et conflictuelle. In *25 ièmes rencontres francophones sur la Logique Floue et ses Applications (LFA’2016)*, 2016.

- [69] Alain Appriou. 01-approche générique de la gestion de l'incertain dans les processus de fusion multisenseur. 2005.
- [70] David Mercier, Eric Lefevre, and Daniel Jolly. Association pour le suivi d'objets dans le cadre des fonctions de croyance, appliquée aux véhicules intelligents. *Revue des Nouvelles Technologies de l'Information, numéro spécial " Fouille de données complexes"*, E-18, pages 25–50, 2010.
- [71] R Ben Ameer, Lionel Valet, and Danièle Coquin. Fusion system based on belief functions theory and approximated belief functions for tree species recognition. In *Image Processing Theory Tools and Applications (IPTA), 2016 6th International Conference on*, pages 1–6. IEEE, 2016.
- [72] R Ben Ameer, Didier Coquin, and Lionel Valet. Influence of basic belief assignments construction on the behaviour of a fusion system for tree species recognition. In *Information Fusion (Fusion), 20th International Conference on*, pages 1–8. IEEE, 2017.
- [73] John J Sudano. Inverse pignistic probability transforms. In *Information Fusion, 2002. Proceedings of the Fifth International Conference on*, volume 2, pages 763–768. IEEE, 2002.
- [74] Minh Ha-Duong. Hierarchical fusion of expert opinions in the transferable belief model, application to climate sensitivity. *International Journal of Approximate Reasoning*, 49(3) :555–574, 2008.
- [75] Didier Dubois, Henri Prade, and Philippe Smets. A definition of subjective possibility. *International Journal of Approximate Reasoning*, 48(2) :352–364, 2008.
- [76] Esmâ Nur Cinicioglu. Decision making with consonant belief functions : Discrepancy resulting with the probability transformation method used. *Yugoslav Journal of Operations Research*, 24(3) :359–370, 2014.
- [77] Astride Aregui and Thierry Denœux. Constructing consonant belief functions from sample data using confidence sets of pignistic probabilities. *International Journal of Approximate Reasoning*, 49(3) :575–594, 2008.
- [78] Nic Wilson. Algorithms for dempster-shafer theory. In *Handbook of defeasible reasoning and uncertainty management systems*, pages 421–475. Springer, 2000.
- [79] Robert Kennes. Computational aspects of the mobius transformation of graphs. *IEEE Transactions on Systems, Man, and Cybernetics*, 22(2) :201–223, 1992.

-
- [80] Jeffrey A Barnett. Computational methods for a mathematical theory of evidence. In *IJCAI*, volume 81, pages 868–875, 1981.
- [81] Glenn Shafer and Roger Logan. Implementing dempster’s rule for hierarchical evidence. *Artificial Intelligence*, 33(3) :271–298, 1987.
- [82] Serafín Moral and Nic Wilson. Markov chain monte-carlo algorithms for the calculation of dempster-shafer belief. In *Proceedings of the Twelfth AAI National Conference on Artificial Intelligence*, pages 269–274. AAAI Press, 1994.
- [83] Serafin Moral and Antonio Salmeron. A monte carlo algorithm for combining dempster-shafer belief based on approximate pre-computation. In *European Conference on Symbolic and Quantitative Approaches to Reasoning and Uncertainty*, pages 305–315. Springer, 1999.
- [84] Serafin Moral and Nic Wilson. Importance sampling monte-carlo algorithms for the calculation of dempster-shafer belief. In *Proceeding of IPMU*, volume 96. Citeseer, 1996.
- [85] Thierry Dencœux. Inner and outer approximation of belief structures using a hierarchical clustering approach. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 9(04) :437–460, 2001.
- [86] Bjørnar Tessem et al. Approximations for efficient computation in the theory of evidence. *Artificial Intelligence*, 61(2) :315–329, 1993.
- [87] John D Lowrance, Thomas D Garvey, and Thomas M Strat. A framework for evidential-reasoning systems. In *Classic Works of the Dempster-Shafer Theory of Belief Functions*, pages 419–434. Springer, 2008.
- [88] Eric Lefevre, Olivier Colot, and Patrick Vannoorenberghe. Belief function combination and conflict management. *Information fusion*, 3(2) :149–162, 2002.
- [89] Catherine K Murphy. Combining belief functions when evidence conflicts. *Decision support systems*, 29(1) :1–9, 2000.
- [90] LA Zadeh. On the validity of dempster’s rule of combination of evidence. electronics research laboratory memorandum no. ucb/erl m79/24. *University of California, Berkeley*, 1979.
- [91] Didier Dubois and Henri Prade. On the unicity of dempster rule of combination. *International Journal of Intelligent Systems*, 1(2) :133–142, 1986.

- [92] Ronald R Yager. On the dempster-shafer framework and new combination rules. *Information sciences*, 41(2) :93–137, 1987.
- [93] Didier Dubois and Henri Prade. A set-theoretic view of belief functions logical operations and approximations by fuzzy sets. *International Journal Of General System*, 12 (3) :193–226, 1986.
- [94] Arnaud Martin and Christophe Osswald. Human expert fusion for image classification. *Information & Security. An International Journal*, 20 :122–141, April 2006.
- [95] Arnaud Martin and Christophe Osswald. A new generalization of the proportional conflict redistribution rule stable in terms of decision. *Advances and Applications of DSMT for Information Fusion : Collected Works*, 2 :69–88, 2006.
- [96] Arnaud Martin and Christophe Osswald. Toward a combination rule to deal with partial conflict and specificity in belief functions theory. In *Information Fusion, 2007 10th International Conference on*, pages 1–8. IEEE, 2007.
- [97] Mihai Cristian Florea. *Combinaison d'informations hétérogènes dans le cadre unificateur des ensembles aléatoires : approximations et robustesse*. PhD thesis, Université Laval, 2007.
- [98] Philippe Smets. The combination of evidence in the transferable belief model. *IEEE Transactions on pattern analysis and machine intelligence*, 12(5) :447–458, 1990.
- [99] Sarah Bertrand, Guillaume Cerutti, and Laure Tougne. Bark recognition to improve leaf-based classification in didactic tree species identification. In *VISAPP 2017-12th International Conference on Computer Vision Theory and Applications*, 2017.
- [100] Zhi-Kai Huang, De-Shuang Huang, Ji-Xiang Du, Zhong-Hua Quan, and Shen-Bo Guo. Bark classification based on gabor filter features using rbpnn neural network. In *Neural Information Processing*, pages 80–87. Springer, 2006.
- [101] John Canny. A computational approach to edge detection. *IEEE Transactions on pattern analysis and machine intelligence*, (6) :679–698, 1986.
- [102] Rihab Ben Ameer, Lionel Valet, and Didier Coquin. A fusion system for tree species recognition through leaves and barks. In *Computational Intelligence (SSCI), 2016 IEEE Symposium Series on*, pages 1–8. IEEE, 2016.
- [103] Sarah Bertrand, Rihab Ben Ameer, Guillaume Cerutti, Didier Coquin, Lionel Valet, and Laure Tougne. Bark and leaf fusion systems to improve automatic tree species recognition. *Ecological Informatics*, 46 :57–73, 2018.

-
- [104] Philippe Smets. Belief functions : the disjunctive rule of combination and the generalized bayesian theorem. *International Journal of approximate reasoning*, 9(1) :1–35, 1993.
- [105] Frédéric Pichon, Didier Dubois, and Thierry Denoeux. Relevance and truthfulness in information correction and fusion. *International Journal of Approximate Reasoning*, 53(2) :159–175, 2012.
- [106] Thierry Denoeux and Philippe Smets. Classification using belief functions : relationship between case-based and model-based approaches. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 36(6) :1395–1406, 2006.
- [107] David Mercier, Éric Lefèvre, and François Delmotte. Belief functions contextual discounting and canonical decompositions. *International Journal of Approximate Reasoning*, 53(2) :146–158, 2012.
- [108] E Lefevre, F Pichon, D Mercier, Z Elouedi, and B Quost. Estimation de sincérité et pertinence à partir de matrices de confusion pour la correction de fonctions de croyance. In *Rencontres Francophones sur la Logique Floue et ses Applications (LFA)*, pages 115–122, 2014.
- [109] D Mercier, Z Elouedi, and E Lefevre. Sur l’ajustement d’une fonction de croyance par une matrice de confusion. In *Rencontres Francophones sur la Logique Floue et ses Applications (LFA)*, pages 277–283, 2010.
- [110] Zied Elouedi, Eric Lefevre, and David Mercier. Discountings of a belief function using a confusion matrix. In *Tools with Artificial Intelligence (ICTAI), 2010 22nd IEEE International Conference on*, volume 1, pages 287–294. IEEE, 2010.
- [111] Arthur P Dempster. New methods for reasoning towards posterior distributions based on sample data. *The Annals of Mathematical Statistics*, pages 355–374, 1966.
- [112] Ron Kohavi et al. A study of cross-validation and bootstrap for accuracy estimation and model selection. In *Ijcai*, volume 14, pages 1137–1145. Montreal, Canada, 1995.

Table des figures

1.1	Étapes de la reconnaissance avec LeafSnap (a) : Prise de la photo de la feuille sur fond blanc, (b) : segmentation , (c) : affichage des résultats (25 espèces sont proposées).	9
1.2	Étapes de la reconnaissance avec Pl@ntNet (a) : Prise de la photo de la feuille, (b) : prise de la photo de la fleur, (c) : affichage des résultats.	11
1.3	Étapes de la reconnaissance avec Folia (a) : choix du type de la feuille, (b) : demande de faire une trace, (c) : indication de l'emplacement de la feuille par l'utilisateur, (d) : détection de la forme globale de la feuille, (e) : détection de la base et du sommet, (f) : affichage des clés de détermination, (g) : affichage de la liste des espèces les plus probables	13
1.4	Variation de l'apparence de l'écorce du "Robina pseudoacacia" en fonction de l'âge : (a) : très jeune, (b) : jeune, (c) : adulte, (d) : vieille.	15
1.5	Variation de la couleur des feuilles de l'espèce "Cotinus coggygria Scop"	15
1.6	Variabilité des feuilles du "Polpulus alba L." au niveau de la forme globale	16
1.7	Variabilité des feuilles du "Quercus ilex L." au niveau du contour	16
1.8	Variabilité des écorces de l'Acer campestre L.	16
1.9	Similitude des feuilles appartenant aux espèces suivantes de gauche à droite : Ilex aquifolium L., Cornus mas L., Viburnum tinus L. et Palirus spina-christi Mill.	17
1.10	Similitude des écorces appartenant aux espèces suivantes de gauche à droite : Acer Campestre L., Acer opalus Mill., Aesculus hippocastanum L. et Liquidambar styraciflua L.	17
1.11	Les espèces Cornus mas L. et Viburnum tinus L. très semblables au niveau des feuilles peuvent être discriminées en rajoutant les écorces : (a) : feuille Viburnum tinus L., (b) : feuille Cornus mas L., (c) : écorce Viburnum tinus L., (d) : écorce Cornus mas L.	18
1.12	Topologie de fusion en cascade (reproduit à partir de [23])	21
1.13	Topologie de fusion en parallèle (reproduit à partir de [23, 24])	21
1.14	Topologie de fusion hiérarchique (reproduit à partir de [23])	22
1.15	Topologie de fusion hiérarchique série (reproduit à partir de [24])	22
1.16	Topologie de fusion conditionnelle (reproduit à partir de [24])	23
1.17	Topologie de fusion hybride (reproduit à partir de [24])	23
1.18	Exemple de fusion de 3 listes ordonnées en utilisant l'algorithme "Borda Count" (reproduit à partir de [28])	27
1.19	Exemple de fusion de 3 listes ordonnées en utilisant l'algorithme "IRP" (reproduit à partir de [28])	27

1.20	Exemple de fusion de 3 listes ordonnées en utilisant l’algorithme “Leave Out” (reproduit à partir de [28])	28
1.21	Schéma du modèle graphique de l’inférence bayésienne permettant la fusion de données à partir de plusieurs sources de données	29
1.22	Exemple d’une observation prise par le même utilisateur, le même jour et avec le même appareil photo	31
2.1	Importante diversité au niveau des formes des feuilles appartenant à différentes espèces.	38
2.2	Feuille composée et feuille simple	39
2.3	Variation de la forme générale de la feuille du <i>Broussonetia papyrifera</i> L. passant progressivement de ovale à palmatilobée.	40
2.4	Chaîne de traitement globale pour la reconnaissance d’espèces d’arbres	43
2.5	Mise en place d’un classifieur pour chaque caractéristique	46
2.6	Première stratégie de classification : classification intermédiaire dans l’espace des descriptions morphologiques	48
2.7	Exemple d’une feuille appartenant à l’espèce “ <i>Populus Tremula</i> ” montrant la présence de la description morphologique de la forme globale et du contour mais l’absence de celle de la base et du sommet	49
2.8	Exemple de deux espaces de discernement Ω_1 et Ω_2 montrant l’existence d’intersection entre les éléments formant Ω_2	50
2.9	Deuxième stratégie de classification	51
2.10	Taux de bonne classification de chaque classifieur pour la base de données de test et d’apprentissage	53
2.11	Taux de bonne classification par espèce : exemple de 15 espèces	54
2.12	Incertitude du classifieur de la forme globale dans le cas d’une feuille appartenant à l’espèce <i>Acer Monspessulanum</i> (e_2) : 19 espèces sont proposées	55
2.13	(a) : e_2 (<i>Acer Monspessulanum</i>), (b) : e_{30} (<i>Ficus Carica</i>), (c) : e_3 (<i>Acer Opalus</i>), (d) : e_{44} (<i>Platanus Hispanica</i>), (e) : e_5 (<i>Acer pseudoplatanus</i>), (f) : e_{46} (<i>Polpulus Nigra</i>)	56
2.14	(a) : e_7 (<i>Acer Monspessulanum</i>), (b) : e_{13} (<i>Buxus Sempervivirens</i>)	57
3.1	Système de fusion hiérarchique pour la fusion de données issues des feuilles	60
3.2	Conflits partiels et conflit global entre les sources d’informations	68
3.3	Classement de l’espèce e_2 dans la liste des 10 espèces ressorties par le système de fusion : application de la règle de combinaison de Dubois et Prade	72
3.4	Classement de l’espèce e_2 dans la liste des 10 espèces ressorties par le système de fusion : application de la règle de combinaison PCR5	75
3.5	Classement de l’espèce e_2 dans la liste des 10 espèces ressorties par le système de fusion : application de la règle de combinaison DPCR	76
3.6	Classement de l’espèce e_2 dans la liste des 10 espèces ressorties par le système de fusion : application de la règle de combinaison de Florea et Joussetme	77
3.7	Classement de l’espèce e_2 dans la liste des 10 espèces ressorties par le système de fusion : application de la règle de combinaison Mixte	78
3.8	Influence de la méthode de construction des fonctions de masse pour des règles de combinaison différentes : premier niveau de fusion	81

3.9	Influence de la méthode de construction des fonctions de masse pour des règles de combinaison différentes : deuxième niveau de fusion	82
3.10	Influence de la méthode de construction des fonctions de masse pour des méthodes d'approximation différentes : premier niveau de fusion	82
3.11	Influence de la méthode de construction des fonctions de masse pour des méthodes d'approximation différentes : deuxième niveau de fusion	83
3.12	Évaluation de l'influence des méthodes d'approximation des fonctions de masse sur les performances du système de fusion pour le premier niveau de fusion . .	83
3.13	Évaluation de l'influence des méthodes d'approximation des fonctions de masse sur les performances du système de fusion pour le deuxième niveau de fusion .	84
3.14	Évaluation de l'influence de la valeur de k sur les performances du système de fusion pour le premier niveau de fusion	85
3.15	Évaluation de l'influence de la valeur de k sur les performances du système de fusion pour le deuxième niveau de fusion	86
3.16	Évaluation de l'influence de la valeur de k sur les performances du système de fusion pour les deux niveaux de fusion : zoom pour la neuvième et dixième espèces ressorties	86
3.17	Évaluation de l'influence des règles de combinaison sur les performances du système de fusion pour les différents niveaux de fusion	87
3.18	Évaluation de l'influence de l'ordre de fusion des classifieurs sur les performances du système pour les différents niveaux de fusion	89
3.19	Comparaison des performances du système de fusion proposé par rapport à celles du système de fusion existant actuellement dans Folia	91
4.1	(a) : cannelée, (b) : crevassée, (c) : lisse, (d) : fibreuse, (e) : fissurée, (f) : se détachant par lanières, (g) : se détachant par écailles, (h) : se détachant par plaques	96
4.2	Exemple d'extraction d'un mot vertical caractérisant la texture d'une écorce .	98
4.3	Classification des écorces	99
4.4	Performances des différents classifieurs de la modalité écorce pour l'apprentissage et le test	100
4.5	Incertitude des classifieurs dans le cas d'un individu appartenant à l'espèce <i>Acer Monspessulanum</i> (e_2) : (a) modalité écorce-incertitude du classifieur de la caractéristique couleur (HSV), (b) modalité feuille-incertitude du classifieur de la caractéristique forme globale	101
4.6	Ressemblance au niveau de la couleur entre les espèces (a) : e_2 (<i>Acer Monspessulanum</i>), (b) : e_{56} (<i>Quercus Ilex</i>), (c) : e_{12} (<i>Broussonetia Papyrifera</i>), (d) : e_5 (<i>Acer Pseudoplatanus</i>), (e) : e_{59} (<i>Quercus Robur</i>), (f) : e_{44} (<i>Platanus Hispanica</i>), (g) : e_{64} (<i>Sorbus Aria</i>), (h) : e_{42} (<i>Ostrya Carpinifolia</i>), (i) : e_{53} (<i>Punica Granatum</i>)	102
4.7	Architecture du système de fusion des données issues des écorces	102
4.8	Résultats de la fusion des données issues des classifieurs de la modalité écorce pour les 3 niveaux de fusion : approximation $k-l-x$ et approximation sommation	103
4.9	Variation du taux de bonne classification en fonction de la valeur de k	104
4.10	Variation du taux de bonne classification en fonction des règles de combinaison	106
4.11	Système de fusion multimodale	106

4.12	Taux de bonne classification des feuilles, des écorces et des deux modalités en fonction des règles de combinaison	107
4.13	Évaluation des performances des classifieurs avant et après la correction des fonctions de masse : BDD de test	119
4.14	Résultats de la fusion sans et avec la correction des fonctions de masse	120
15	Résultats du défi LifeClef 2013 montrant les performances de chaque modalité séparément ainsi que le résultat de la fusion de toutes les modalités	129
16	Résultats du défi LifeClef 2014 montrant les performances de chaque modalité séparément ainsi que le résultat de la fusion de toutes les modalités	130
17	Résultats du défi LifeClef 2015 montrant les performances de chaque modalité séparément ainsi que le résultat de la fusion de toutes les modalités	130
18	Taux de bonne classification par espèce : de l'espèce e_{16} à l'espèce e_{30}	143
19	Taux de bonne classification par espèce : de l'espèce e_{31} à l'espèce e_{45}	144
20	Taux de bonne classification par espèce : de l'espèce e_{46} à l'espèce e_{60}	144
21	Taux de bonne classification par espèce : de l'espèce e_{61} à l'espèce e_{72}	145

Liste des tableaux

2.1	Les formes de feuilles les plus communes (photos reproduites à partir de [5])	40
2.2	Les formes les plus communes de la base d’une feuille (les photos sont reproduites à partir de [5])	41
2.3	Les formes les plus communes du sommet (photos reproduites à partir de [5])	42
2.4	Les formes les plus communes du bord (photos reproduites à partir de [5])	42
2.5	Tableau montrant que le contour d’une même espèce peut être décrit différemment par les botanistes	49
3.1	Tableau récapitulatif des éléments focaux vers lesquels la masse est transférée et les types de pondération pour les différentes règles de combinaison	79
3.2	Temps de calcul moyen par individu : approximation sommation et approximation “Outer”	85
3.3	Variation du temps de calcul moyen par individu en fonction de la valeur de k	86
3.4	Variation du temps de calcul moyen par individu en fonction de la valeur de k	87
3.5	Temps de calcul moyen par individu : fusion statique et fusion dynamique	89
3.6	Tableau récapitulatif des avantages et inconvénients de toutes les méthodes testées pour la construction des fonctions de masse, la combinaison des sources d’informations et le choix de l’ordre de fusion	93
4.1	Taux de bonne classification pour le jeu d’apprentissage et de test ($N = 1$ et $N = 10$)	100
4.2	Taux de bonne classification pour les différents niveaux de fusion : approximation $k - l - x$ et approximation sommation avec $k = 5$	104
4.3	Temps de calcul par individu en fonction de la valeur de k	104
4.4	Taux de bonne classification pour différentes valeurs de k ($N = 1$ et $N = 10$)	105
4.5	Illustration d’une matrice de confusion	112
4.6	Exemple d’une matrice de confusion	113
4.7	Exemple d’une matrice de confusion	117
4.8	Écarts-types des différents classifieurs avec et sans la correction des fonctions de masse	120
9	Modalité feuille : nombre d’individus par espèce pour les bases de données d’apprentissage et de test	133
10	Base de données experte 1	138
11	Base de données experte 2	142
12	La liste des 72 espèces	154
13	Diagonales des matrices de confusion des classifieurs de la modalité feuille	157
14	Diagonales des matrices de confusion des classifieurs de la modalité écorce	159

Mots-clés : système de fusion, reconnaissance d'espèces d'arbres, théorie des fonctions de croyance, fusion multimodale, classification.

Résumé

La reconnaissance d'espèces d'arbres est une tâche difficile aussi bien pour des personnes n'ayant pas de connaissances expertes que pour les botanistes. Ceci est dû aux multiples spécificités des espèces d'arbres : similarités inter-espèces, variabilités intra-espèces, facteurs environnementaux... Nous nous intéressons donc à mettre en place un outil éducatif, simple d'utilisation, qui permettrait à toute personne de s'introduire dans le monde de la botanique et de comprendre la stratégie de la reconnaissance des espèces d'arbres. L'idée est d'essayer de reproduire la stratégie des botanistes lors de la reconnaissance tout en se basant sur deux modalités : les feuilles et les écorces. Les systèmes de fusion d'informations permettent de combiner les données issues de ces deux sources d'informations tout en tenant compte de leur qualité. La combinaison de données issues de sources hétérogènes permet de profiter de la complémentarité des données et donc d'avoir potentiellement des performances plus élevées que celles obtenues en utilisant une seule source d'informations. Un système de fusion hiérarchique est proposée dans cette thèse. Il est élaboré dans le cadre de la théorie des fonctions de croyance. Différents outils sont utilisés afin de gérer les imperfections les plus présentes telles que l'incertitude, l'imprécision et le conflit.

Keywords : fusion system, tree species recognition, belief functions theory, multimodal fusion, classification.

Abstract

Tree species recognition is a difficult task for people with no expert knowledge as well as botanists. This is due to the multiple tree species specificities : inter-species similarities, intra-species variability, environmental factors ... We are therefore interested in setting up an educational tool, easy to use, that would allow any person to introduce into the world of botany and understand the strategy of tree species recognition. The idea is to try to reproduce the botanists' strategy during the recognition while basing on two modalities : the leaves and the barks. Information fusion systems make it possible to combine data from these two sources of information while taking into account their quality. The combination of data from heterogeneous sources allows to take advantage of the data complementarity and therefore potentially to have higher performances than those obtained when using a single source of information. A hierarchical fusion system is proposed in this thesis. It is developed in the belief function theory frame. Different tools are used to manage the most common imperfections such as uncertainty, inaccuracy and conflict.