



**Université François Rabelais
Tours**

**Thèse pour obtenir le grade de
Docteur de l'université de Tours**

Discipline : Informatique
Présentée et soutenue publiquement

par :

Muhammad ARIF

Le 25 novembre 2005

**Fusion de Données : Ultime Etape de Reconnaissance de Formes,
Applications à l'Identification et à l'Authentification.**

Directrice de thèse : Pr. Nicole Vincent

Co-encadrant : Thierry Brouard

Jury :

Thierry BROUARD	Maître de conférence	Université de Tours
Hubert CARDOT	Professeur	Université de Tours
Jean-Marc OGIER	Professeur	Université de la Rochelle
Georges STAMON	Professeur	Université de Paris 5
Bruno TACONET	Professeur	Université du Havre
Nicole VINCENT	Professeur	Université de Paris 5

à

Mes parents,

Mes sœurs, mes frères

Ma femme Abida,

et

Mes enfants Muquit, Adam

Remerciements

Je ne sais vraiment pas comment je pourrais assez remercier Jean-Marc Ogier et Bruno Taconet pour avoir accepté d'examiner mon travail dans un temps très limité et pour l'intérêt qu'ils ont manifesté pour ce travail.

Que Georges Stamon et Hubert Cardot reçoivent toute ma gratitude pour avoir accepté de faire partie de mon jury.

Tous mes remerciements vont au Pr. Nicole Vincent pour m'avoir accueilli dans l'équipe RFAI comme « réfugié du domaine » et pour m'avoir encouragé tout long de ma thèse. Je ne peux pas oublier la fraternité qu'elle m'a offerte tout au long de ces années pendant ses années de présence à Tours et aussi étant partie loin, physiquement à Paris. Pour moi c'était un grand plaisir de travailler sous sa direction.

Je voudrais tout particulièrement remercier Thierry Brouard, mon co-encadrant, pour son soutien constant dans la partie de programmation et pour m'avoir laissé utiliser le portable qui lui était attribué. Une fois j'ai parlé de lui à ma famille, j'aimerais bien citer ici la phrase « j'ai un professeur, d'après l'âge, plus petit que moi, d'après la tête, beaucoup plus grand que moi ». Moi, je vois dans sa personnalité un administrateur très grand et très gentil également.

Un grand merci aux membres de l'équipe RFAI, qui contribuent chaque jour à cet esprit de recherche, en particulier pour les précieux conseils et remarques pendant les cafés découvertes si importants ici et pendant les sessions de pré-soutenance de ma thèse. *Special thanks* à Hubert Cardot qui m'a beaucoup apporté scientifiquement et pour tous ses conseils sur la vérification de signature manuscrite et aussi à Romuald, Jean-Yves, Pascal, Jean-Jacques, Nicolas, Mathieu, Rashid, Moustafa, Mohammed, Hubert, Julien, Alain, Yves, Sébastien, ...

Un grand merci aux membres de cette école qui ont donné de leur temps pour me permettre de faire mes recherches sans financement propre. Merci en particulier à Christian Proust, Patrick Martineau, Jean-Charles Billaut, Jean-Louis Bouquard, Gilles Venturini, Claudine Tacquard, Pierre Gaucher, Mohamed Slimane, les personnels de secrétariat et tous les autres que je n'ai pas cité. Tous ont contribué au financement de ce travail, en me permettant de donner des cours et en me confiant la responsabilité technique des salles machines. Je voudrais ajouter un remerciement spécial à Mohand qui m'a soutenu jour après jour sur ce travail et à Françoise la responsable de bibliothèque à qui j'ai toujours dit « oui chef ».

Merci également à tous les étudiants du DI qui, de près ou de loin, ont contribué à l'avancement de ce travail.

Résumé

La fusion de données est une discipline remplie de points forts et de difficultés de toutes sortes. Elle prend une place de plus en plus importante dans de nombreux domaines. Les méthodes développées sont variées mais jusqu'à présent aucune n'est suffisante pour tous les types d'information ou de sources. Parmi les méthodes, on compte les opérateurs d'agrégation ou de vote, l'utilisation des réseaux de neurones artificiels, les chaînes de Markov cachées, la logique floue, les théories de l'incertain (théorie de l'évidence, théorie des possibilités, théorie de probabilités), etc.

Une étude comparative des approches de fusion, en prenant en compte différents aspects du problème traité est présentée au travers d'applications à l'identification et à l'authentification des personnes par la géométrie de la main ou par une signature manuscrite hors ligne. Dans notre méthodologie, plusieurs classifieurs basés sur différents ensembles de caractéristiques sont d'abord réalisés. D'une part nous présentons des caractéristiques traditionnelles et des caractéristiques plus spécifiques à un système de biométrie (globales, statistiques, et géométriques). D'autre part nous avons segmenté l'ensemble de caractéristiques selon chaque type de caractéristiques pour accentuer l'information qu'elles peuvent apporter à la résolution des problèmes et puis nous avons réalisé la fusion. Le travail comporte donc en premier lieu une étude critique des méthodes existantes et en deuxième lieu un apport lié à l'utilisation de la notion du flou dans ce domaine.

Nous proposons un formalisme flou pour définir les degrés d'appartenance d'une forme inconnue aux différentes classes, il repose sur l'information de distance, sur les variations de distance dans les k -plus proches voisins (k -ppv) de la forme entrante, sur le nombre d'occurrences des classes et sur les rangs des classes des k -ppv. Nous introduisons trois paramètres pour définir différents poids et nous montrons que l'optimisation de l'un d'entre eux donne un caractère très général au formalisme flou proposé quand il est employé comme une règle des k -ppv. Ce formalisme proposé est également employé pour définir les masses d'évidence dans la théorie de l'évidence et pour modéliser les distributions de possibilités dans la théorie des possibilités. Enfin, il est utilisé dans une méthodologie de fusion des classifieurs. Son emploi multiple, sa simplicité de mise en œuvre et sa robustesse nous conduisent à conclure qu'il constitue une approche efficace. En traitant deux applications, nous montrons que la fusion de classifieurs au niveau représentation (mesure de distance), est plus riche en information et plus pertinente que les deux autres types d'information décision et rang.

Une des approches développées, la théorie de l'évidence, est employée également pour la détection de contours vue comme une fusion au niveau du pixel. Dans ce cas, on s'intéresse à l'interprétation pixel par pixel des cartes de contours, ce qui demande un système de fournir des informations de contours par des points de vue multi aspects. Les applications traitées montrent le caractère générique du travail.

Abstract

Data fusion is a discipline with many of strong points and difficulties of all kinds. It takes an increasingly important place in many fields. Various methods are developed but until now none of them is satisfactory for all the types of information or sources. The methods studied at large are aggregation operators, majority voting rules, artificial neuronal networks, hidden Markov models, fuzzy logic, the theories of uncertainty (evidence theory, possibility theory, probability theory) etc.

A comparative study of various data fusion approaches in case of two applications of personal identification and authentication through hand geometry and handwritten signatures, taking into account various aspects of problems is presented. In our methodology several classifiers based on various feature sets are initially created. On the one hand we are presenting traditional features and some features more specific to a biometric system (global, statistical, and geometrical). On the other hand the whole features set is divided into various subsets according to the information brought by each type of features to problem solving and then their fusion is carried out with the help of various methods. Work thus comprises first a critical study of the existing methods and secondly our contribution constituting a fuzzy approach in this field.

We are proposing a fuzzy formalism to define various membership levels of an unknown pattern “ x ” to various classes based on the distance information from x to its k -Nearest Neighbors, on the distance variations within the k -Nearest Neighbors (k -NN), on the number of neighbors belonging to each class and the rankings of the classes of k -Nearest Neighbors. We are introducing three parameters to assign various weights to these variables and it has been shown that the optimization of these parameters gives a very general character to our proposed fuzzy formalism when it is employed as a k -NN rule. The proposed membership function is also employed to define the evidence masses in the evidence theory and the possibility distributions in possibility theory. Lastly, it is used in a fusion methodology to combine classifiers avec creation of meta-classifier. Its multiple uses, its simplicity to employ and its robustness lead to conclude that it constitutes an effective approach. By performing two biometric applications, the fusion of classifiers on intermediate level (distance measurement level), being richer in information and more relevant than the other two fusion levels (decision and ranking levels), is found more robust.

One of the developed approaches, evidence theory, is also employed for an edge detection problem where a pixel level fusion is carried out. In this case, pixel by pixel information is first acquired from the edge maps which are obtained with the help of various classical edge detectors from the point of view of multiple aspects. The treated applications show the generic character of work.

Table des matières

Introduction	11
Partie 1 : Etat de l'art.....	17
Chapitre 1: Fusion de données	19
1.1 Introduction	19
1.2 Intérêt de la fusion de données	21
1.3 Définition de la fusion de données	21
1.4 Typologies et niveaux de la fusion.....	23
1.5 Stratégies de fusion	27
1.6 Etapes de l'opération de fusion	28
1.7 Sources et informations	29
1.8 Applications	31
1.9 Conclusion.....	32
Chapitre 2 : Les méthodes de fusion de données	35
2.1 Théorie des probabilités : approche bayésienne.....	36
2.2 Réseaux de neurones artificiels	37
2.3 Chaînes de Markov Cachées (CMC).....	38
2.4 Méthodes des votes	39
2.5 Méthodes de rangs (Borda Count et ses variantes)	41
2.6 Logique floue	42
2.7 Opérateurs d'agrégation	44
2.7.1 Agrégation de données	44
2.7.2 Les opérateurs proposés	45
2.7.3 OWA (Ordered Weighted Averaging operator)	47
2.7.4 AWFO (Aggregator Weight-Functional Operator)	50
2.8 Théorie de l'évidence	53
2.8.1 Principe.....	55
2.8.2 Combinaison des croyances	57
2.8.3 La règle de décision.....	58
2.8.4 Modélisation des fonctions de croyance	58
2.8.5 Méthode de modélisation basée sur la distance	58
2.9 Théorie des possibilités (approche possibiliste).....	59
2.9.1 Principes	60
2.9.2 Obtention des distributions de possibilité	62
2.9.3 Opérateurs de fusion.....	64
2.10 Conclusion.....	66
Chapitre 3 : La place des k-ppv en reconnaissance de formes	69
3.1 Reconnaissance de formes	69
3.1.1 Introduction	69
3.1.2 Caractéristiques	71
3.1.3 Classifieurs	72
3.2 Méthodes de classement.....	73
3.2.1 Classifieur de distance.....	74
3.2.3 Classifieur des k-ppv	76
3.2.3 La règle des k-ppv avec pondération des distances.....	77

3.2.4	L'approche des k-ppv floue.....	79
3.2.5	Les techniques de plus proche prototype dans la règle des k-ppv	81
3.2.6	D'autres propositions	82
3.3	Conclusion.....	83
Partie 2 :	L'utilisation de l'information de distance.....	85
Chapitre 4 :	Au niveau d'un classifieur des k-ppv	87
4.1	Degré d'appartenance.....	87
4.2	Formalisme flou	88
4.2.1	Proposition initiale	88
4.2.2	2eme tentative (amélioration).....	93
4.2.3	Défuzzification	95
4.3	Résultats	96
4.3.1	Exemple des IRIS	96
4.3.2	Exemple 2.....	102
4.4	Discussions	106
4.5	Conclusion.....	109
Chapitre 5 :	Définition des masses d'évidence et des distributions de possibilité.....	111
5.1	Mesure floue.....	111
5.2	Eléments focaux	115
5.3	Masses d'évidence et distributions de possibilité	116
5.4	Conclusion.....	118
Chapitre 6 :	Fusion de classifieurs	119
6.1	Introduction	119
6.2	Illustration sur un exemple	120
6.3	Conclusion.....	123
Partie 3 :	Applications de l'identification et de l'authentification	125
Chapitre 7 :	Identification et authentification	127
7.1	Introduction	127
7.2	Biométrie	128
7.2.1	Différents types de biométrie	129
7.2.2	Un indicateur biométrique idéal	130
7.3	Architecture générale	131
7.4	Les caractéristiques des classifieurs étudiés.....	131
7.5	Evaluation de la performance d'un classifieur.....	132
Chapitre 8 :	Reconnaissance des personnes par leur main.....	135
8.1	La reconnaissance de la main	135
8.1.1	Introduction	135
8.1.2	La biométrie de la main : état de l'art	136
8.1.3	Conclusion.....	144
8.2	Empreinte palmaire (Palmprint).....	145
8.2.1	Introduction	145
8.2.2	Etat de l'art	146
8.2.3	Systèmes en ligne et hors ligne basés sur l'empreinte palmaire	148
8.2.4	Conclusion.....	149
8.3	L'intérêt de la fusion	150
8.4	Fusion multimodalité : systèmes multiples biométriques	151
8.5	Notre système	152
8.5.1	Introduction	152
8.5.2	Module d'acquisition.....	153
8.5.3	Prétraitements.....	154

8.5.4	Extraction des caractéristiques	157
8.6	Classification	163
8.7	Résultats expérimentaux	165
8.7.1	Première évaluation : données de [HaSIS97].....	165
8.7.2	Deuxième évaluation : Notre base de données.....	165
8.7.3	Résultats d'identification.....	166
8.7.4	Conclusion.....	172
8.7.5	Résultats en vérification	174
8.7.6	Problèmes et discussion	176
8.8	Conclusion.....	178
Chapitre 9 : Identification et authentification par signatures manuscrites hors ligne		179
9.1	Introduction	179
9.2	Types de signatures	180
9.3	Méthodes d'analyse des signatures	180
9.4	Les fausses signatures	181
9.5	Etat de l'art	182
9.5.1	Caractéristiques pour la représentation des signatures.....	182
9.5.2	La nouvelle tendance : combinaison	183
9.6	Notre système	185
9.6.1	Introduction	185
9.6.2	Prétraitement des signatures.....	186
9.6.3	Extraction des caractéristiques	188
9.7	Classement	204
9.8	Les bases de données.....	205
9.8.1	La première base de données	205
9.8.2	La deuxième base de données	206
9.9	Résultats expérimentaux	206
9.9.1	Identification des signatures.....	206
9.9.2	Vérification de signatures.....	212
9.10	Conclusions	217
Chapitre 10 : Détection de contour dans une image couleur.....		221
10.1	Introduction	221
10.2	Méthodes de détection de contour.....	221
10.3	Une solution récente : la fusion de données	222
10.4	La méthodologie proposée	223
10.5	Algorithme de fusion.....	223
10.6	Résultats	224
10.7	Une comparaison avec une autre méthode (CED)	229
10.8	Conclusion.....	231
Conclusion générale		233
Annexe		237
Annexe A1 : Données de soudure		237
	(a) pour l'apprentissage	237
	(b) pour les tests	238
Annexe A2 : Résultat de l'identification des personnes par leur main par le formalisme flou proposé		239
Annexe A3 : Résultats de l'identification de signatures manuscrites par le formalisme flou proposé		240
	I : Fusion de deux classifieurs	240
	II. Fusion de trois classifieurs	246

III. Fusion de quatre classifieurs	249
Bibliographie	251

Table des figures

1.1 : Les cinq sens humains exploités par le cerveau donnent lieu à fusion [Wald02].....	20
1.2 : Deux exemples de problèmes de classification en deux dimensions (a) simple, (b) complexe.	22
1.3 : Niveaux hiérarchiques des trois niveaux de fusion, (a) fusion au niveau des caractéristiques (bas niveau), (b) fusion au niveau représentation ou niveau des rangs (niveau intermédiaire), (c) fusion au niveau décision (haut niveau).	25
1.4 : Une architecture de fusion de classifieurs en parallèle	28
1.5 : Les systèmes multimodaux de fusion à base des sources différentes.	30
2.1 : Différents modes de raisonnement.....	51
2.2 : (a) Combinaison adaptative des sources concordantes (b) Combinaison adaptative des sources discordantes.....	66
3.1 : Représentation conceptuelle d'un problème de la reconnaissance de formes.	70
3.2 : Schéma général de sélection de la classe dans un classifieur de distance.	75
3.3 : Exemple en 2 dimensions : Les vecteurs des 2 classes étiquetés en \circ et \times	75
4.1 : Exemple de calcul du degré d'appartenance d'une forme à la classe d'un prototype selon l'équation 4.5 et des variantes.....	90
4.2 : Un résultat intermédiaire du formalisme qui montre un lissage des degrés d'appartenance sans $N_x(C)$ en considérant les 20-ppv	92
4.3 : Résultat de notre formalisme proposé dans un premier temps (où la forme entrante appartient à la classe C_4).	92
5.1 : Liens entre différentes mesures floues.....	113
6.1 : Schéma général de fusion de données au niveau des distances (représentations) par la règle des k-ppv floue proposée.....	120
7.1 : Identification et vérification.....	128
7.2 : Différents types de biométries	130
7.3 : Schéma général d'un système de reconnaissance par un indicateur biométrique.....	131
7.4 : Choix d'un seuil de décision suivant un critère.	133
8.1 : Configuration du système et placement des axes [Jain99].....	139
8.2 : Configuration d'un système de [HaSIS97].	141
8.3 : Les caractéristiques extraites par [Wong02].	141
8.4 : Un dispositif de Time & Attendance Terminal [HandPunch4000]	142
8.5 : Un système d'ouverture de porte, main + carte	143

8.6 : La forme des lignes sur une paume. Trois lignes principales sur une paume : 1- ligne de cœur, 2- ligne de tête et 3- ligne de vie.	146
8.7 : Les images de deux mains scannées en ndg.....	154
8.8 : Binarisation de l'image.	154
8.9 : Élément structurant	155
8.10 : Fermeture et Ouverture	155
8.11 : Rotation de l'image (normalisation)	156
8.12 : représentation des points clés de la main.	157
8.13 : Segmentation des doigts par propagation d'étiquette	158
8.14 : Points limites de fusion de composantes.....	158
8.15 : Ajustement de la segmentation des doigts	159
8.16 : Ajustement de la segmentation des doigts (résultats)	160
8.17 : Mise en évidence de caractéristiques	160
8.18 : Chaînes (vecteur) de largeurs des doigts.....	161
8.19 : Mise en évidence de la zone de l'empreinte palmaire pour les lignes de la main	162
8.20 : Prétraitements, (a) ligne de la main (image originale), (b) égalisation de l'histogramme, (c) détection de contours selon le gradient de Sobel.....	162
8.21 : Découpage en zones de la fenêtre contenant les lignes de la main	163
8.22 : Attribution des directions	163
9.1 : Exemple de signature cursive américaine	180
9.2 : Exemple d'image comportant des pixels irréguliers (a) et après lissage (b).....	187
9.3 : Exemple de signature où le trait comporte des trous.	187
9.4: Une image de signature (a) et ses histogrammes selon deux directions (b), (c).	189
9.5 : Deux histogrammes selon les deux axes de l'ellipse d'inertie.....	191
9.6 : Un exemple d'extraction de contours « classiques »	193
9.7 : Un exemple d'extraction de contours « extérieurs ».....	193
9.8 : Exemple simplifié d'un graphe d'évolution.....	195
9.9 : Exemple de graphe d'évolution	196
9.10 : Graphe ré échantillonné correspondant au graphe précédent	197
9.11 : Définition des zones du graphe d'évolution.....	198
9.12 : Recherche de la frontière entre les zones 1 et 2	199
9.13 : Représentation de la matrice d'analyse M et de la zone de référence.	200
9.14 : Exemple d'extraction de zones rugueuses, seuil = $0.975 \times \text{DFLoc_Max}$	203
9.15 : Exemple de graphe de dimension de masse.	203
9.16 : Deux signatures ayant des dimensions différentes mais presque le même histogramme.	213

9.17 : Exemples de deux types de signatures	217
10.1 : une image en ndg et les quatre images de contour par l'opérateur de Sobel en faisant varier les seuils d'intensité et l'image finale fusionnée.....	225
10.2 : les images de contour par plusieurs méthodes avec un même seuil global pour toutes les méthodes ($T = 0.05$) et l'image finale fusionnée.	226
10.3 : les images de contour par Sobel et avec un même seuil ($T = 0.05$) pour les composantes (R,G,B) et l'image en ndg, et l'image finale fusionnée.....	227
10.4 : Deux résultats de détection de contour pour une comparaison entre l'image en ndg et une des composantes de couleur.	229
10.5 : Une image réelle et détection de contour par plusieurs méthodes.	230
10.6 : Une image artificielle et la détection de contour par deux méthodes.	230

Notations

M	nombre de classes
n	nombre de prototypes ou éléments des M classes (en général)
x	une forme inconnue entrante au système d'une classification
A	représente une proposition contenant une ou plusieurs classes des voisins de x d'après le rang
g	mesure floue
Ω	cadre de discernement ou corps évidentiel
H_n	une proposition singleton
Bel	croissance
P	probabilité
Pl	plausibilité
N	nécessité
Π	possibilité
m	masse de l'évidence
e	un classifieur de distance ou des k-ppv
L	nombre de classifieurs
$f_{xi}(x)$	degré d'appartenance de x aux différentes classes exprimé par les voisins de x
$F_{xi}(x)$	degré d'appartenance normalisé
$F_{Ci}(x)$	degré d'appartenance à une classe C_i
λ	une proportion du nombre de classifieurs

Introduction

Le sujet principal de cette thèse est la fusion de données dans le domaine de la reconnaissance de formes à l'étape ultime (décisionnelle) et de ses applications à l'identification et à la vérification. La classification et la prise de décision, deux étapes importantes dans un problème de reconnaissance de formes, sont considérées comme un large champ d'étude dont le but est de faire identifier des formes par des machines.

Les capacités de reconnaissance sont inhérentes aux humains. Par exemple, un humain peut identifier des formes qui l'entourent juste en les regardant. Il catégorise des objets, il identifie des personnes, il peut lire, écrire et écouter. Quand les humains identifient un objet (un oiseau, un arbre, une voiture, etc.) ils le placent dans les catégories ou les classes. Le cerveau humain et les yeux peuvent différencier entre une personne connue ou étrangère sur la base des connaissances acquises au sujet de la personne. Avant de lire un papier ou un livre, avant la compréhension réelle de la lecture, le cerveau humain identifie la langue de l'écriture.

Dans le domaine de la reconnaissance de formes, il existe aujourd'hui un grand nombre de méthodes d'extraction de caractéristiques et de classification mais les états de l'art de plusieurs travaux réalisés dans le domaine de reconnaissance de formes indiquent qu'une méthode générique applicable à tous les problèmes de la reconnaissance de formes n'existe pas. La phrase énoncée par [Kanal74] « a bag of tools and a bag of problems » en 1974 est encore valide après des années de recherche parce que malgré les nombreux travaux dans le domaine, ceux-ci n'ont pas permis de mettre en évidence la supériorité incontestable d'une méthode de classification sur une autre ou d'un extracteur de caractéristiques sur un autre. Une des solutions envisagées depuis quelques années est de fusionner l'information traduisant plusieurs aspects de la connaissance.

La fusion de données est un terme récent, elle est basée sur l'exploitation de la synergie offerte par les origines variées de l'information à partir de diverses sources. Ici, le mot « donnée » est un terme générique et équivalent à information. De la combinaison des données additionnelles, indépendantes et/ou redondantes résulte généralement une meilleure robustesse du système de reconnaissance par rapport aux systèmes basés sur les données

provenant d'une seule source. L'exemple de la vision humaine binoculaire illustre les avantages et l'intérêt de la fusion de données. Les deux yeux agissent en tant que deux ressources redondantes, la capacité de vue est améliorée par rapport à celle d'un seul oeil. Les sources de données peuvent être de divers types : différents systèmes d'acquisition de données ou divers types de capteurs, différents types de classifieurs basés sur les vecteurs de caractéristiques multiples ou les mesures ou diverses méthodologies, etc. Différents niveaux et architectures de fusion existent également selon la nature et le type d'informations disponibles pour un problème posé.

Des travaux intéressants s'appuyant sur la fusion de données issues de plusieurs classifieurs peuvent être notés depuis les années 90. Les méthodes de combinaison ont ainsi été appliquées avec succès dans des domaines aussi divers que les systèmes biométriques ou l'analyse d'images médicales. L'amélioration des performances des systèmes de reconnaissance est finalement le principal enjeu des recherches menées ces dernières années sur les systèmes de combinaison.

La motivation pour l'utilisation d'une étape de fusion de données est que les classifieurs basés sur différentes approches ou différents ensembles de caractéristiques peuvent se compléter. L'évidence a prouvé qu'une telle combinaison montre très souvent une meilleure performance que celle d'un seul des classifieurs individuels, par contre l'amélioration portée par une démarche de fusion dépend de l'application. Quelques exemples de travaux sont cités dans la littérature, montrant qu'une étape de fusion de données n'apporte pas toujours d'amélioration aux performances par rapport à certains classifieurs individuels [Woods92].

La combinaison des classifieurs peut être également employée pour minimiser le temps requis pour atteindre une performance déterminée. L'optimisation des classifieurs peut prendre beaucoup de temps. Une pertinence élevée d'un système de reconnaissance peut être réalisée par un processus de fusion même si les différents classifieurs ne sont pas entièrement optimisés [Huang95].

Un autre avantage de la fusion de données est de pouvoir employer différents types de caractéristiques. Un classifieur simple repose en général sur seulement un type de vecteur de caractéristiques utilisé comme donnée. Tandis qu'avec une méthodologie de fusion, différents types de caractéristiques distribuées dans plusieurs classifieurs peuvent être combinés pour bénéficier des avantages de chacun collectivement.

Au total il y a plus d'arguments en faveur de la fusion de données qu'en faveur de l'utilisation du meilleur classifieur simple. Si tous les éléments d'un ensemble de classifieurs sont appris et que l'on choisit uniquement le meilleur classifieur, tout l'effort d'apprentissage

des autres classifieurs, est gaspillé. En outre le meilleur classifieur trouvé pendant la phase de l'apprentissage peut ne pas être forcément le meilleur dans la phase de test. Ceci implique qu'en choisissant plusieurs classifieurs et leur fusion peut améliorer la capacité de généralisation.

Motivation et Objectif

La reconnaissance de formes est un domaine vaste basé sur les solutions d'une grande quantité de problèmes concrets. La discipline se développe toujours. Quelques évidences importantes sont les conférences internationales comme « Int. Conference on Pattern Recognition (ICPR) » et un domaine d'application spécifique comme le traitement des documents et de l'écrit « International Conference on Document Analysis and Recognition (ICDAR) ».

Une partie importante des applications de la reconnaissance de formes s'intéresse à la biométrie. La biométrie repose sur le principe de la reconnaissance de caractéristiques physiques. Notamment les empreintes digitales, l'iris, la rétine, la main, l'empreinte palmaire, la signature manuscrite, et les empreintes vocales offrent une preuve irréfutable de l'identité d'une personne puisqu'elles constituent des caractéristiques biologiques ou des comportements humains uniques qui distinguent une personne d'une autre et ne peuvent être associés qu'à une seule personne. La biométrie permet notamment de filtrer les accès aux sites commerciaux (e-commerce), intranets, entrées des bâtiments publics et militaires, systèmes d'automatisation d'hébergement, et enfin, elle peut être l'alliée de la vie privée en permettant de sauvegarder notre identité et l'intégrité des données. La confiance en une technique biométrique a besoin de la technologie la plus pertinente possible pour détecter l'accès d'un malfaiteur. Pour le moment, aucun indicateur biométrique n'est fiable à 100% ce qui a donné naissance à la fusion d'indicateurs biométriques multiples.

De plus, la situation de sécurité dans les secteurs sociaux et commerciaux dans le monde actuellement est une raison forte qui conduit l'auteur à travailler sur ce sujet. Bien que la fusion de plusieurs indicateurs biométriques ne soit pas encore réalisée dans cette thèse, la méthodologie développée permettra de réaliser cette tâche très facilement dans les mois qui viennent.

L'objectif de cette thèse est de contribuer d'une part à une étude complète et approfondie de la façon de fonctionner des méthodes combinant l'information issue de plusieurs classifieurs de distance et d'autre part de proposer un formalisme flou robuste testé dans des contextes variés. Les résultats obtenus avec les données de trois applications différentes

montrent la généralité de notre approche qui peut s'employer dans n'importe quelle application de reconnaissance de formes en utilisant l'information de distance.

Contributions

- Revue de l'état de l'art de la fusion de données (chapitre 1) et les outils utilisés dans la plupart des applications de fusion de données (chapitre 2).
- Un état de l'art sur les règles des k-plus proches voisins utilisées dans le domaine de la reconnaissance de formes et employées pour réaliser la classification de formes (chapitre 3).
- Proposition d'un formalisme flou employé :
 - comme une règle des k-ppv floue (chapitre 4),
 - pour définir les fonctions de masses d'évidence et les distributions de possibilité (chapitre 5),
 - pour la fusion de données dont l'information provient de plusieurs classifieurs de distances (chapitre 6).
- L'utilisation des opérateurs d'agrégation pour des applications assez différentes de celles citées dans la littérature et plus particulièrement, l'emploi de l'opérateur d'agrégation AWFO.
- Un état de l'art sur la reconnaissance de signature manuscrite off line et la reconnaissance de la main.
- Différents niveaux de fusion de données sont étudiés.
- Deux exemples montrent que le choix d'un ensemble de caractéristiques ou d'un classifieur de caractéristiques plus pertinentes que les autres, pour un problème d'identification, n'est pas nécessairement la meilleure approche pour un problème de vérification.

Guide de thèse

Cette thèse est subdivisée en trois parties. La première, composée des chapitres 1 à 3 présente un état de l'art sur la fusion de données, les outils utilisés dans la plupart des applications, quelques rappels sur la reconnaissance de formes et la présentation des règles des k-ppv proposées dans la littérature en classification ou en prise de décision. La seconde partie reflète notre contribution d'un formalisme flou basé sur l'information de distance fournie par des classifieurs de distance pour la classification et la décision dans le chapitre 4. Le chapitre 5 présente notre proposition de modélisation des fonctions de masses de croyance

et les distributions de possibilité. Dans le chapitre 6, la mise en œuvre du formalisme flou proposé est expliquée dans le but de fusionner l'information issue de plusieurs classifieurs. Enfin, la dernière partie composée des chapitres 7, 8, 9, et 10 présente les généralités et trois applications traitées dans cette thèse.

Première partie : état de l'art

Partie 1.A : La fusion de données

Chapitre 1

Ce chapitre présente un état de l'art sur la fusion de données en général. Cette fusion peut s'appliquer aussi bien au domaine de l'image (satellite, aérienne, radar, et ...) qu'à l'information en sortie de classifieurs.

Chapitre 2

Ce chapitre décrit des outils de fusion de données employés dans la plupart des applications de fusion de classifieurs.

Partie 1.B : La place des k-ppv en reconnaissance de formes

Chapitre 3

Ce chapitre introduit quelques rappels sur la reconnaissance de formes en particulier du point de vue de notre travail. Une discussion sur les méthodes de classification proposées en reconnaissance de formes et en particulier l'approche des k-plus proches voisins et ses variantes est présentée.

Seconde partie : Utilisation de l'information de distance

Chapitre 4

Dans ce chapitre, nous présentons la construction d'un formalisme flou afin de définir un degré d'appartenance floue. Dans ce formalisme, trois paramètres influent sur le taux de succès. Une étude expérimentale sur les jeux de données classiques du domaine nous a permis de mettre en évidence la prépondérance d'un seul paramètre important. Ce formalisme est employé pour définir une nouvelle règle floue dans un classifieur basé sur les k-ppv.

Chapitre 5

Dans ce chapitre, nous décrivons comment nous utilisons le formalisme flou proposé pour définir les masses d'évidence dans la théorie de l'évidence et les distributions de possibilité dans la théorie des possibilités.

Chapitre 6

Ce chapitre présente une méthodologie d'utilisation du formalisme flou pour la fusion de classifieurs.

Troisième partie : Applications d'identification, de vérification et de détection de contours**Chapitre 7**

Ce chapitre introduit les généralités d'un système biométrique pour une application d'identification ou d'authentification.

Chapitre 8

Ce chapitre montre l'intérêt de fusion de données en traitant une application biométrique (identification et vérification par la reconnaissance de main et d'empreinte palmaire). Nous comparons ensuite notre méthode avec d'autres.

Chapitre 9

Dans ce chapitre, nous suivons la même démarche que dans le chapitre précédent mais cette fois dans le cadre d'une application à l'identification et à l'authentification par la reconnaissance de signature manuscrite hors ligne.

Chapitre 10

Nous présentons dans ce chapitre une mise en œuvre de la fusion de données dans le domaine de la détection de contour. Le but ici est de constater l'apport de la fusion plutôt que de proposer une nouvelle méthode de détection de contour dans une image couleur.

Partie 1 : Etat de l'art

Chapitre 1

Fusion de données

L'implémentation du raisonnement humain sur une machine occupe depuis de nombreuses années une place importante dans le domaine scientifique. Les premières approches d'automatisation du raisonnement reposent sur l'imitation du comportement humain par la machine dans le but du traitement de l'information. Ces approches ont donné naissance au terme d'intelligence artificielle [Lefevre01]. Dans le cas de problèmes simples, les méthodes d'obtention des solutions peuvent souvent prendre une forme analytique qui se traduit par des algorithmes, cependant, dans le cas de problèmes plus complexes, c'est-à-dire des problèmes pour lesquels les résolutions sont difficiles à décrire, l'automatisation devient alors plus ardue. Les recherches actuelles, moins ambitieuses qu'à l'origine, s'orientent vers la construction de solutions appropriées à un problème donné par le biais de moyens informatiques. Les problèmes posés par les menaces criminelles et terroristes de nos jours demandent des systèmes d'identification et d'authentification automatiques des personnes plus robustes et de plus en plus fiables. La recherche dans le domaine informatique est en train de résoudre ce problème avec une précision de haut niveau et de plus en plus sûre. Un moyen d'améliorer la robustesse d'un système de reconnaissance est d'exploiter l'intérêt de la fusion de données. D'après [Rouchouze94], la fusion de données est un domaine scientifique encore jeune. En effet, même si on peut répertorier quelques travaux plus anciens, la prise de conscience réelle des potentialités de la fusion peut être estimée se développer au milieu des années 80.

1.1 Introduction

Bien que le concept de fusion de données ait explosé relativement récemment dans la littérature scientifique, il est utilisé depuis fort longtemps dans la nature : ainsi les animaux eux-mêmes exploitent l'information auditive et visuelle pour se protéger contre d'éventuels

risques. De même, pour localiser un emplacement quelconque, ils combinent plusieurs images visuelles des endroits avoisinant le lieu considéré.

On peut aussi citer la vision humaine pour illustrer les bénéfices de la fusion de données. Les deux yeux d'un homme observent les objets sous des angles légèrement différents, et cette stéréovision permet la perception du relief. Exploiter conjointement deux yeux étend donc les capacités données par deux fois un œil. Un autre avantage est la robustesse liée à la redondance. Si l'un des yeux est défaillant, la vision est encore possible, bien qu'en mode dégradé. On peut citer un deuxième exemple dans notre vie quotidienne, les systèmes biologiques. Le système humain utilise ses cinq sens pour percevoir son environnement (au sens très large). Les capteurs de notre corps acquièrent des informations par la vue, l'odorat, le toucher, l'ouïe et le goût. Les données acquises sont traitées par le cerveau. Pour ce faire, le cerveau va en plus utiliser d'autres sources d'information : sa mémoire, son expérience, et ses connaissances a priori. En faisant appel à ses capacités de raisonnement, le cerveau « fusionne » toutes les informations, et effectue des déductions afin de produire éventuellement une représentation de cet environnement et d'ordonner des actions comme il est montré sur la figure 1.1.

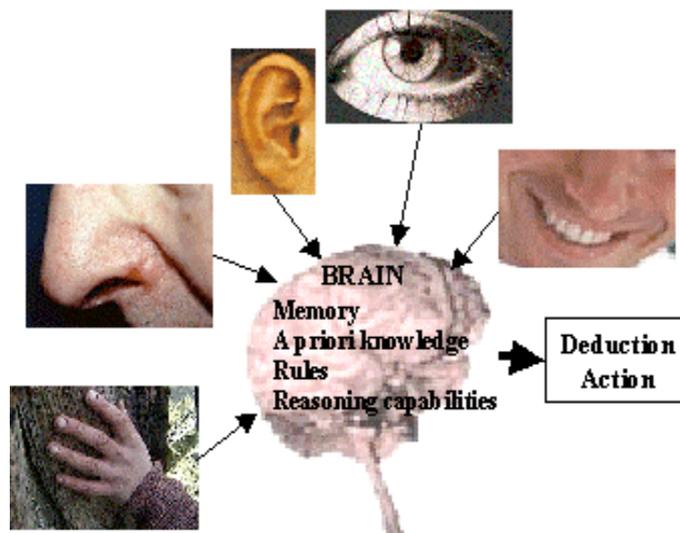


Figure 1.1 : Les cinq sens humains exploités par le cerveau donnent lieu à fusion [Wald02]

La fusion multisources a été initialement développée surtout dans un contexte militaire pour des objectifs tels que la localisation des cibles ennemies, la fusion d'images radar, l'autonomie de véhicules mobiles, etc. Les systèmes employés ont recours à des techniques diverses issues de domaines variés tels le traitement du signal, l'intelligence artificielle,

l'estimation stochastique, la reconnaissance de formes, la classification, etc. De façon générale, la fusion de données est une opération d'intégration de plusieurs données en vue d'en extraire une nouvelle information plus représentative de l'ensemble des données. Dans la section 1.3 nous mentionnons plusieurs définitions qui nous semblent les plus adéquates.

Nous présentons dans ce chapitre les différentes étapes intervenant dans le concept et dans un processus de fusion, puis dans le prochain chapitre nous discutons les principales méthodes utilisées.

1.2 Intérêt de la fusion de données

Les progrès permanents de la science et de la technologie et aussi de l'informatique permettent de disposer d'informations de plus en plus nombreuses et complexes, de nature et de fiabilité différentes. Il est de plus en plus demandé aux systèmes d'information et de communication ou de décision (au sens large) d'aider ou de coopérer avec les experts du domaine applicatif dans le but de décider. La fusion de données permet de répondre à ces demandes et de résoudre ces problèmes.

La fusion de données est un sujet de plus en plus actuel, car susceptible d'aider efficacement les scientifiques à extraire des informations de plus en plus pertinentes et précises. D'après [Waltz90] la fusion de données offre de nombreux avantages :

- Robustesse et fiabilité ; le système est opérationnel même si une ou plusieurs sources d'informations sont défectueuses ;
- Augmentation de la couverture spatiale et temporelle de l'information et des déductions ;
- Accroissement du nombre de dimensions de l'espace des observations, menant à un accroissement de la qualité des déductions, et à une réduction de la vulnérabilité du système ;
- Réduction de l'ambiguïté des déductions : des informations plus complètes ou plus précises permettent un meilleur choix entre les différentes hypothèses ;
- Apport d'une solution à l'explosion de la quantité d'informations disponibles aujourd'hui.

1.3 Définition de la fusion de données

Le concept de la fusion de données est facile à comprendre, mais il est difficile d'en trouver une définition qui rende compte de ce cadre formel et de ses multiples facettes. La difficulté d'une définition exacte de la fusion de données persiste à cause d'une bataille de

mots entre les experts du domaine. Même le sens exact de la fusion varie d'un scientifique à l'autre. Plusieurs mots peuvent être cités qui sont employés pour désigner la fusion comme « merging », « combinaison », « synergie », « intégration », etc. Quelques scientifiques disent que le mot « merging » ne correspond pas à la fusion ou plus précisément que la fusion désigne un domaine plus vaste que merging. Un autre mot, très souvent utilisé à la place de fusion, est « agrégation ». Il est vrai que la fusion et l'agrégation ont pour objectif le même but c'est-à-dire un résultat final plus pertinent et plus robuste à partir d'une variation de données disponibles. Le terme « agrégation » est plutôt utilisé pour les données numériques et / ou des objets (critères) ordonnés.

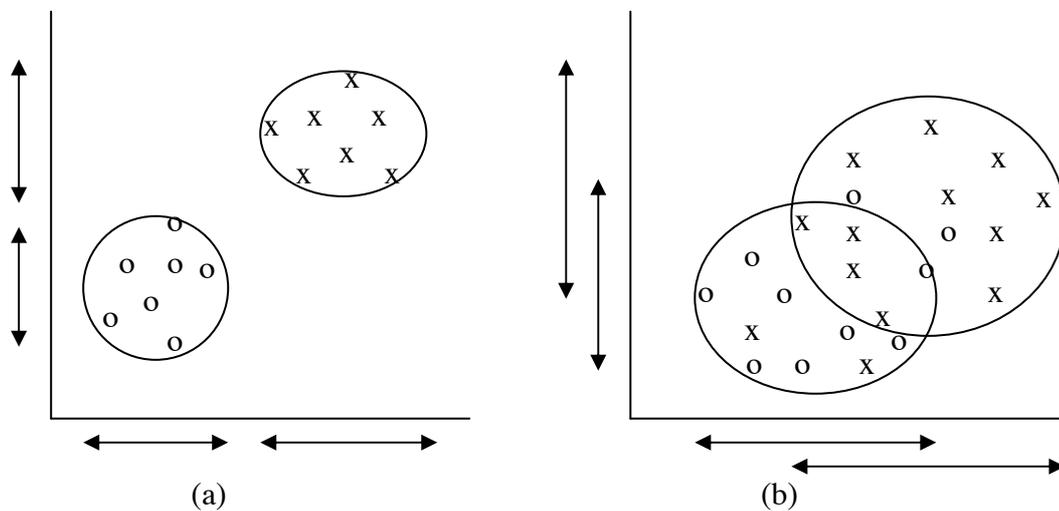


Figure 1.2 Deux exemples de problèmes de classification en deux dimensions (a) simple, (b) complexe.

Dans la figure 1.2, un problème de classification simple (a) et complexe (b) est illustré en deux dimensions où les disques représentent les zones auxquelles appartiennent les descripteurs de chaque classe représentée par ses éléments « o » et « x ». Dans la partie (b) on voit clairement qu'on ne peut pas résoudre le problème posé en utilisant uniquement ces deux critères. On est amené à considérer un espace de dimension supérieure. Cette petite explication nous amène à considérer le terme d'agrégation multicritère comme la fusion de capteurs dans une approche multi-capteurs.

Un point notable ici est le fait qu'effectivement tous ces termes expriment plus ou moins le concept de fusion. De plus, les définitions de fusion de données sont souvent restreintes à un ensemble d'outils ou de méthodes, voire à un ensemble d'informations. Il est rarement

question de qualité et la notion de concept est totalement exclue. En effet, la difficulté de considérer une définition unique est due au fait que la fusion de données est un domaine très appliqué et dans des circonstances très variées. Elle est multidisciplinaire dans un sens et elle se trouve au carrefour de plusieurs sciences. Nous décrivons maintenant deux définitions proposées par deux groupes de spécialistes.

La définition proposée par le Joint Directors of Laboratories (JDL), du ministère de la défense aux Etats-Unis d'Amérique [JDL91] est un cas à part. Elle est appelée « le modèle JDL » et a fait l'objet de nombreuses études. Ce modèle définit la fusion de données comme un processus multi-niveaux 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. Le modèle JDL est extrêmement populaire dans le domaine militaire. Malgré sa popularité et son importance pour le développement de la fusion de données, ce modèle ne constitue pas pour autant une définition de la fusion de données et, en aucun cas, ne fait référence à un cadre conceptuel [Wald02].

Le groupe européen SEE (Société d'électricité et d'électronique), la branche française de l'Institute of Electric and Electronics Engineers (IEEE), et la branche européenne de l'International Society for Photogrammetry and Remote Sensing (ISPRS) ont proposé la définition suivante : *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*. Cette définition met clairement l'accent sur le concept et non plus sur les méthodes, techniques ou stratégies [Wald02]. La définition ajoute que la fusion de données vise à l'obtention d'information de plus grande qualité ; la définition exacte de l'expression « plus grande qualité » dépendra de l'application. La qualité est un mot générique indiquant que le résultat de la fusion est plus satisfaisant pour l'utilisateur que l'ensemble de l'information originale.

Pour notre part, cette définition nous semble la plus adéquate, cependant, nous conseillons de consulter le livre de Wald [Wald02] pour avoir toutes les définitions proposées par les auteurs du domaine.

1.4 Typologies et niveaux de la fusion

Un système de fusion est généralement composé de sources d'information, de moyens d'acquisition d'information, de moyens de communication et de capacités à traiter l'information. Il peut être par conséquent très complexe. Il est fréquent et pratique, lors de l'étude ou de la présentation d'un système, de séparer les aspects topologiques et les aspects

traitement d'informations, même s'il existe des interconnexions. La topologie a une influence importante sur le choix de l'architecture du système de fusion, sur les choix d'outils, des méthodes de traitement et de communication.

On peut trouver dans la littérature plusieurs manières de classer les différentes étapes ou types de fusion. Cette différence provient principalement du niveau où l'opération de fusion est accomplie, de l'objectif de cette opération, du type de sources (ou capteurs) et de l'application considérée.

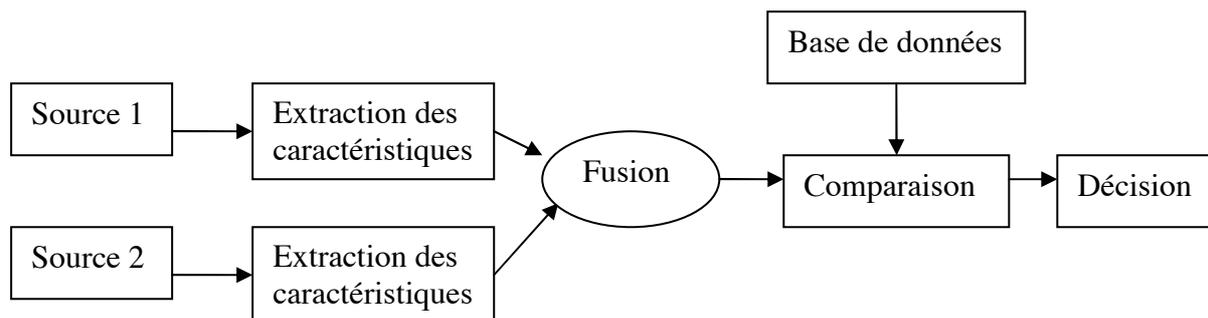
On peut par exemple reprendre la classification générale proposée par [Dasarathy97] qui considère trois principaux niveaux de fusion :

- **fusion de mesures ou des pixels en traitement d'images**, on dit aussi bas niveau ; il concerne la fusion d'informations directement issues des capteurs.
- **fusion d'attributs**, on dit aussi niveau intermédiaire ; il concerne la combinaison d'informations extraites après diverses phases de traitement et d'analyse des mesures.
- **fusion de décisions**, on dit aussi haut niveau, celui-ci concerne la combinaison des décisions obtenues à partir de chaque source. La décision finale est prise en fonction des décisions de tous les capteurs.

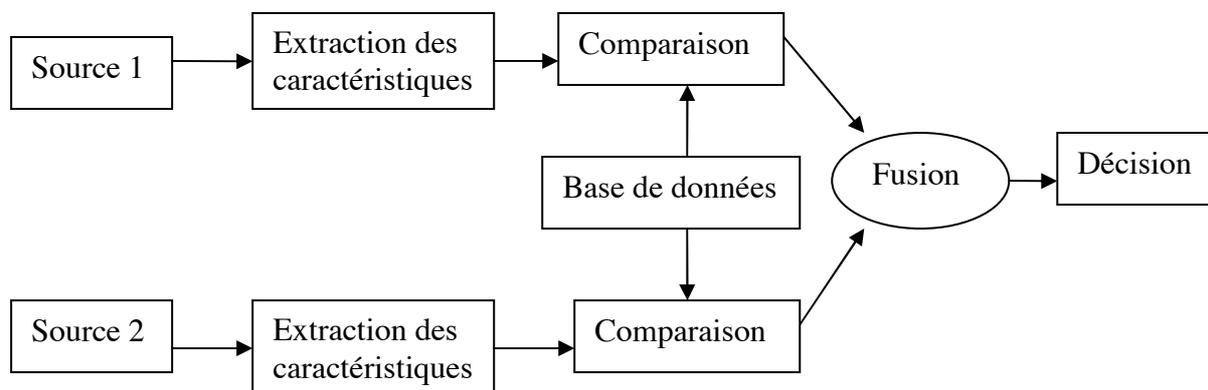
Dans [Xu92] trois niveaux de fusion sont décrits de la manière suivante (dans le domaine de la fusion de classifieurs):

- (i) **Fusion au niveau de la représentation**, un classifieur e attribue à chaque classe des scores traduisant la similarité calculée entre la forme entrante x et les autres formes de la classe ou en donnant un certain degré de ressemblance entre telle ou telle classe.
- (ii) **Fusion au niveau des rangs**, un classifieur e donne les rangs de toutes les classes, le premier rang étant réservé à son choix préféré.
- (iii) **Fusion au niveau de la décision**, un classifieur e indique sa décision d'une classe ou parfois un sous-ensemble de classes.

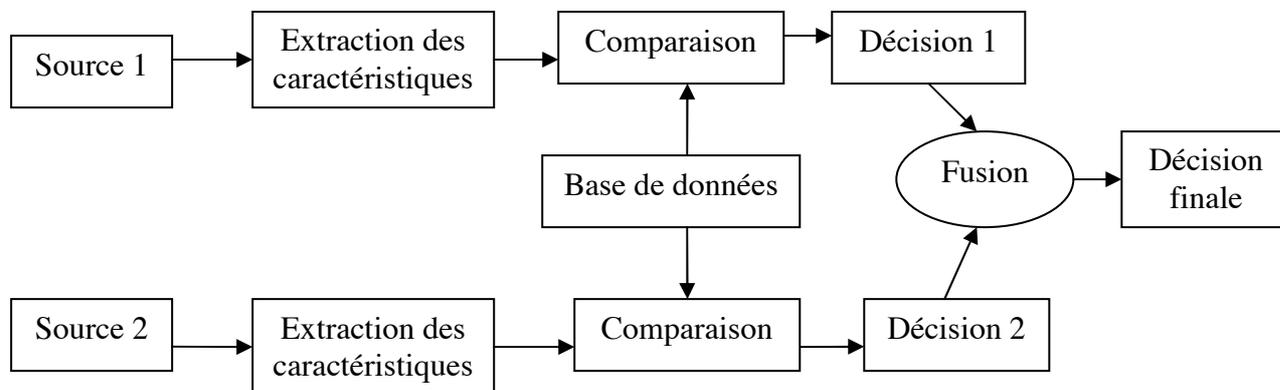
Il est bien évident par ailleurs que ces niveaux peuvent s'enchaîner, comme indiqué sur la figure 1.3 (a), (b), (c) :



(a)



(b)



(c)

Figure 1.3 : Niveaux hiérarchiques des trois niveaux de fusion, (a) fusion au niveau des caractéristiques (bas niveau), (b) fusion au niveau représentation ou niveau des rangs (niveau intermédiaire), (c) fusion au niveau décision (haut niveau).

L'avantage de la fusion bas niveau est qu'elle permet de combiner des données avant qu'elles ne soient déformées par les procédures de traitement et d'analyse. Par contre, la

fusion aux niveaux intermédiaire et haut permet de se rapprocher davantage du raisonnement de l'expert.

Un exemple de fusion du premier niveau consiste en un système télémétrique à plusieurs capteurs dont la sortie (après fusion) est la donnée numérique la plus représentative obtenue, par exemple, par la moyenne (ou moyenne pondérée) de toutes ou de certaines données. Pour le second cas, on peut citer, par exemple, un système télémétrique dont la sortie est cette fois-ci une entité géométrique telle que coin, mur, arête, etc. Pour le troisième, on pourra imaginer qu'à partir de la reconnaissance de certaines caractéristiques de l'environnement, on décide d'une action à entreprendre (parmi un certain nombre d'actions possibles) pour le robot.

Dasarathy a également discuté d'un quatrième niveau de fusion qui consiste en la fusion temporelle c'est à dire la fusion de données acquises à des temps différents. Ce niveau de fusion ne se situe pas dans la même hiérarchie que les trois précédents, parce qu'en réalité, la fusion temporelle peut aussi bien intervenir au niveau des données, qu'au niveau des caractéristiques ou de la prise de décision [Oussalah98].

D'après [Dasigi01] le besoin de "fusion" d'informations se fait sentir dans des problèmes de reconnaissance de formes où des décisions doivent être prises sur la base de différents ensembles de caractéristiques multiples dérivées de l'entrée. Quand l'information des ensembles de caractéristiques est assimilée et intégrée dans une décision finale, la technique est désignée généralement sous le nom de fusion d'informations. En revanche, si différentes décisions sont prises à partir des différents ensembles de caractéristiques, si l'on résout les éventuels conflits et qu'on intègre ces décisions dans une décision globale, la technique s'appelle fusion de décisions. La fusion de décisions est un problème très intéressant et important dans la recherche, elle constitue un domaine à part entière. Dans la communauté de la recherche documentaire, la fusion d'informations s'appelle parfois la combinaison de doutes, et la fusion de décisions s'appelle parfois la combinaison de données [Wald02].

La fusion d'images concerne deux domaines principalement, l'imagerie satellitaire et aérienne d'une part, l'imagerie médicale d'autre part. On la considère cependant comme potentiellement utilisable dans de nombreux autres champs : le contrôle non destructif, la vision des véhicules autonomes ou la surveillance des sites sensibles [Bloch94]. Pour plus d'informations sur la fusion d'images et ses techniques et méthodes développées nous conseillons de voir le livre de Wald [Wald02].

La fusion de classifieurs a montré une amélioration dans le processus de la reconnaissance de formes dans plusieurs applications, telles que : la reconnaissance des caractères, la reconnaissance de la parole, la télédétection, la prospection géophysique et les

applications médicales aussi bien que dans beaucoup d'autres, nous présenterons quelques applications importantes dans une section prochaine.

1.5 Stratégies de fusion

Les stratégies ou architectures de fusion décrivent l'ensemble des sources, la manière dont elles sont assemblées et les techniques mathématiques ou statistiques pour le traitement.

La multiplication des travaux sur la fusion dans les domaines différents (imagerie, intelligence artificielle et reconnaissance de formes, etc.) a entraîné la mise au point de nombreux schémas traitant les données de manières différentes. Les stratégies de fusion proposées peuvent être regroupées en trois approches principales : séquentielle [Gader91], [Prevost03], [Rahman03], parallèle [Sabourin94], [Huang95], [Gader96], [Kim00], [Zouari04], et hybride [Gosselin97], [Kim00], [Bellili02]. D'autres stratégies avec bouclage ou avec interaction sont aussi proposées.

Malgré la diversité des schémas de fusion, la détermination de la meilleure organisation reste un problème ouvert, en effet, la variété des applications de fusion est telle qu'il n'est pas facile de conclure à une stratégie générique et applicable à tous les cas. D'après [Zouari04], l'intérêt porté par les chercheurs majoritairement à la combinaison parallèle de sources (classifieurs) est fondé pour plusieurs raisons :

- le concepteur peut réutiliser les développements de classifieurs effectués antérieurement, chacun pouvant avoir été développé dans un contexte différent et utiliser des représentations différentes qui peuvent être utilisées pour le même problème. Des exemples sont donnés par l'identification de personnes par leur voix, leur visage, ainsi que leur signature.
- Dans la combinaison, il est possible d'utiliser un grand nombre de caractéristiques mais en les distribuant sur des classifieurs différents.
- Deux classifieurs différents peuvent présenter des performances globales équivalentes mais se différencier par les régions où ils sont les plus performants.
- Un classifieur est souvent sensible aux choix initiaux de ses paramètres (k et la distance pour un k -ppv, nombre de couches et nombre de neurones par couche pour une perceptron multicouche, ...). Plutôt que de chercher la meilleure configuration de paramètres, la combinaison de l'ensemble peut tenir compte des avantages de ces classifieurs appris indépendamment.

- Nous pouvons disposer de plusieurs bases d'apprentissage, chacune est collectée de manière différente ou construite dans des conditions différentes, l'apprentissage d'un même classifieur sur ces bases peut produire des résultats différents.

Voici un exemple de fusion de données fournies par des sources (classifieurs) différentes avec une approche de combinaison parallèle :

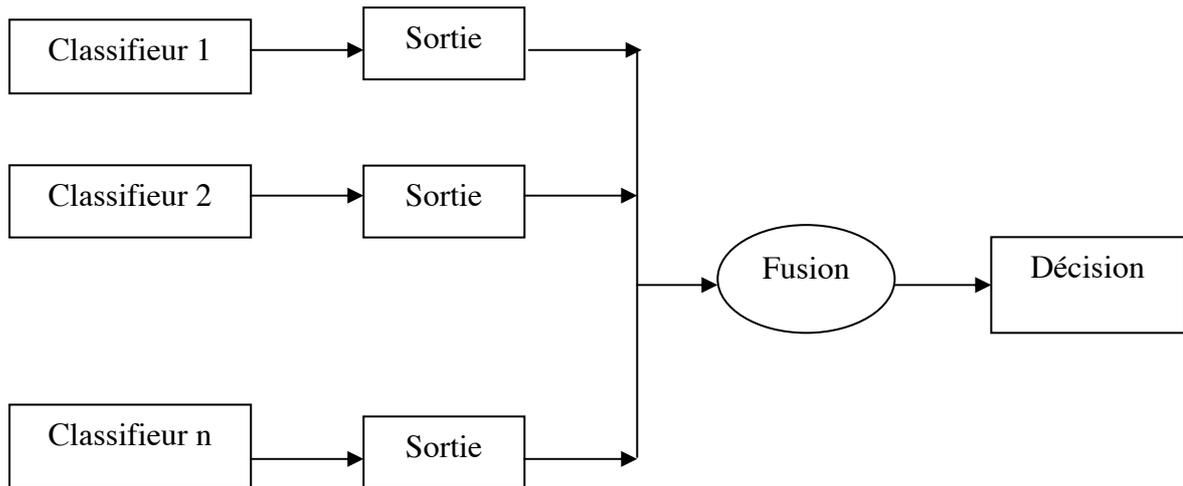


Figure 1.4 : Une architecture de fusion de classifieurs en parallèle.

1.6 Etapes de l'opération de fusion

Pour un niveau hiérarchique donné, l'opération de fusion s'effectue en plusieurs étapes [Oxenham96], [Hall97] et [Wald02].

- i) Alignement : l'alignement ou conditionnement ou encore parfois, harmonisation, consiste à définir un espace commun, dans lequel les informations vont être projetées afin d'y être comparables. Cela veut dire que les observations ou les données sont ramenées dans un même référentiel.
- ii) Corrélation : cette étape concerne la détermination des relations entre les différentes données. Dans notre cas, nous ne sommes pas concerné par cette étape car nos classifieurs sont établis indépendamment et ils sont supposés non corrélés.
- iii) Association ou mise en correspondance : l'association est l'union des différentes représentations issues des informations multi-sources. Chaque mesure se trouve

associée à l'entité correspondante (le résultat de l'étape de corrélation est évidemment utilisé). Cette étape permet aussi de rejeter les données aberrantes suivant un critère sur la matrice de covariance par exemple.

- iv) Combinaison : seules les données obtenues après alignement et qui sont en accord avec l'étape d'association sont combinées pour obtenir une meilleure représentation de l'estimation correspondant à l'attribut avec lequel l'étape i) a été réalisée.

On peut noter par ailleurs que l'étape (ii) peut être imbriquée à l'intérieur de (iii). Par conséquent, trois étapes sont nécessaires pour toute opération de fusion : alignement, mise en correspondance (ou association) et combinaison [Oussalah98]. [Oussalah98] a distingué en plus les notions de fusion statique et de fusion dynamique en définissant :

- Fusion statique : quand le résultat de l'opération de fusion est obtenu indépendamment des états antérieurs. On exploite alors uniquement les données de l'instant courant.
- Fusion dynamique : quand le résultat tient compte des états antérieurs. Tout processus de fusion ayant une formulation itérative rentre dans ce contexte. Cette approche peut être située au même niveau que la fusion temporelle.

1.7 Sources et informations

Le problème général de la fusion est la synthèse (caractérisation et calcul) d'un ensemble d'informations obtenue à partir de la mise en commun d'informations provenant de sources différentes. Les sources d'information peuvent être de trois catégories ; la première catégorie est formée des capteurs physiques soit de type image (caméra, télémètre, radar, images IRM, images ultrasonores), soit de type signal (température, vitesse, accélération, temps de vol...). La deuxième comporte les capteurs logiques (analogiques ou numériques) soit avec modules de traitement de signaux soit avec modules de traitement d'images. La dernière peut être décrite comme des connaissances a priori : par exemple des objets et leurs caractéristiques ; la scène observée (cartes, atlas,...) et des règles d'évolution, etc. Un système de reconnaissance reposant sur plus d'une source d'information est dit un système multimodal. Quelques exemples de systèmes multimodaux à base de sources différentes sont montrés dans la figure 1.6. D'autres catégories de sources peuvent être décrites selon les informations qu'elles donnent par exemple ; les sources redondantes (avec même espace de définition), les

sources complémentaires (avec espaces de définition différents), les sources concordantes (avec des informations compatibles), les sources discordantes (avec des informations incompatibles).

Le nombre de sources pris en compte peut varier selon l'application de fusion. Une seule source peut fournir des informations temporelles ou bien indiquer les différentes caractéristiques d'un seul objet. En effet, une structure multi-capteurs surmonte les imperfections d'une source prise individuellement par l'utilisation d'un secteur de redondance fourni par d'autres sources.

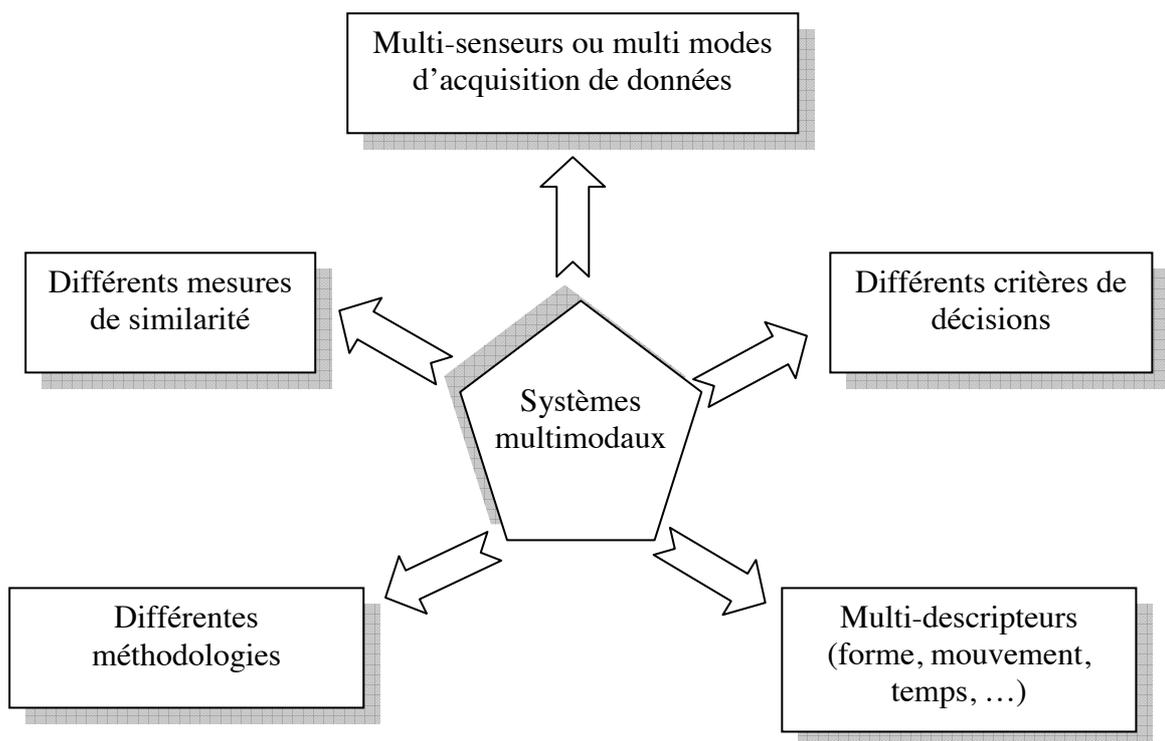


Figure 1.5 : Les systèmes multimodaux de fusion à base des sources différentes.

Le type des informations à fusionner varie selon le domaine d'application. Ces informations peuvent être de nature hétérogène :

soit (a) *symbolique* afin de prendre en compte les relations pouvant exister entre objets ; on pourra avoir par exemple des relations de type structurel (décomposition d'un aéroport en objets plus simples) ou de connexité (un pont se situe toujours au-dessus d'une route, d'une voie ferrée ou d'une rivière).

soit (b) *numérique* : attributs de forme, de radiométrie, de position (altitude), de mouvement (vitesse, accélération), de texture, etc.

Elles pourront être également de type *imparfait* (imprécises, incertaines et incomplètes). C'est le cas qui nous concerne, notre problématique traite des informations imparfaites. C'est pourquoi nous discutons en détail cette notion.

L'imperfection des informations fait appel à plusieurs concepts. Le premier, généralement bien maîtrisé, concerne l'imprécision des informations. L'incertitude est un second concept à différencier de l'imprécision par le fait qu'il ne fait pas référence au contenu de l'information mais à sa qualité. Décrivons, de manière plus détaillée, ces deux notions :

Imprécis : les imprécisions correspondent à une difficulté dans l'énoncé de la connaissance, soit parce que des connaissances numériques sont mal connues, soit parce que des termes du langage naturel sont utilisés pour qualifier certaines caractéristiques du système de façon vague. Le premier cas est la conséquence d'une insuffisance des instruments d'observation (2000 à 3000 manifestants), d'erreurs de mesure (poids à 1% près) ou encore de connaissances flexibles (la taille d'un adulte est environ entre 1,5 mètre et 2 mètres). Le second provient de l'expression verbale des connaissances (température douce, proche de la plage) ou de l'utilisation de catégories aux limites mal définies (enfant, adulte, vieillard).

Incertain : les incertitudes concernent un doute sur la validité d'une connaissance. Celles-ci peuvent provenir de la fiabilité relative à l'observation faite par un système, celui-ci pouvant être sûr, susceptible de commettre des erreurs ou de donner intentionnellement des informations erronées, ou encore d'une difficulté dans l'obtention ou la vérification de la connaissance (l'affirmation d'une forte douleur par un patient). Des incertitudes sont également présentes dans le cas des prévisions (en météorologie par exemple). Pour une proposition incertaine, c'est la vérité même de la proposition qui est en cause.

Il existe d'autres sortes d'imperfections plus ou moins dépendantes de l'imprécision et de l'incertitude, telles que l'incomplétude et l'indétermination. On trouve parfois un problème dû à des connaissances hétérogènes et imparfaites, cas très fréquent en fusion d'images.

1.8 Applications

La fusion de données a d'abord visé à améliorer la qualité des réponses aux problèmes posés par les militaires [Valet00], il y a approximativement vingt cinq ans, mais aujourd'hui elle touche énormément de domaines. Voici quelques applications :

La télédétection [Elachi87] est une science à part entière avec des applications s'étendant depuis le domaine civil de la surveillance jusqu'aux applications militaires. Elle permet de bénéficier de l'information fournie par des satellites d'observation de la Terre. Les données numériques de ces satellites, présentées sous forme d'images, s'avèrent

particulièrement précieuses pour l'évaluation du potentiel territorial et pour la planification dans les secteurs de la forêt, de l'agriculture, de l'environnement, de la géologie et de l'aménagement du territoire. Les sondes qui acquièrent les images sont typiquement aéroportées ou spatiales. En outre, elles peuvent acquérir l'information dans différentes bandes spectrales ou à différentes résolutions. La fusion peut également être employée pour combiner les données radar. Plusieurs applications de la fusion dans ce domaine sont décrites dans [Serpico95], [Pohl98], [Bruzzone99].

La mise au point d'un système de **détection de mines** exploite aussi l'intérêt de la fusion de données [Cremer99], [Cremer01].

La prévision météorologique est un autre exemple d'application de la fusion de données ; l'air, les satellites, des avions et des ballons météorologiques fournissent des mesures sur l'état tridimensionnel de l'atmosphère et sur les propriétés de surface du sol et de l'océan. Au sol, des dizaines de milliers de stations mesurent les paramètres météorologiques, comme la température, le vent, la pression, etc. et les radars suivent les orages et les cellules de pluie. En mer, des bateaux et des bouées automatiques mesurent également les paramètres météorologiques, ainsi que la houle. Toutes ces informations de mesures sont traitées par des experts avec des modèles numériques et de fusion pour faire des prévisions du temps qui sont diffusées par les media ou utilisées par certaines professions [Dai99], [Luo97].

La biométrie donne lieu à plusieurs applications de fusion de données avec les différents indicateurs de biométrie et les systèmes multi indicateurs [BIOMET], [Toh03], [Feng04], [Kumar03], [Ong03], identification de visages [Achermann96], [Brunelli95], vérification de signatures [Zois99], [Sabourin94], [Bajaj97], reconnaissance de la parole [Chibelushi93], [Yu00], [Chen97].

Document et écrit : reconnaissance de chiffres [Beiraghi00], [Cao95], [Cordella98], [Dimauro95], [Duin98], [Heutte94], [Xu92], reconnaissance de caractères et mots manuscrits [Nadal90], [Ho94], [Gader96], classification des documents [Li98].

Applications médicales : traitement d'images médicales et diagnostic médical [Kettler97], [Lefevre01], [Bloch96], [Dromigny-Badin98].

Robotique et véhicules intelligents : [Dubois91], [Abidi92], [Palacharla97], [Jetto99], [Oussalah98], [Oussalah01].

1.9 Conclusion

Dans ce chapitre, nous avons présenté les différentes facettes que comporte la fusion de données. On emploie la fusion de données aussi bien dans la vie quotidienne que dans les

technologies les plus récentes. Il existe plusieurs topologies et niveaux de fusion dont le choix dépend de la nature des sources et de l'information.

De nombreux travaux sur la fusion de données dans les applications réelles montrent que la fusion améliore nettement les performances du système de reconnaissance par rapport à chacune des sources prise isolément.

Dans le prochain chapitre nous allons nous attacher à décrire certaines techniques qui nous ont paru particulièrement intéressantes.

Chapitre 2

Les méthodes de fusion de données

Les méthodes de fusion de données permettent de mettre à profit un nombre maximum de données, en tenant compte de la diversité de leurs natures, en tentant de pallier les faiblesses de certaines avec les points forts des autres, ceci dans le but de fournir une information élaborée, dédiée et pertinente vis à vis du contexte.

Une technique de fusion de données est choisie selon

- la nature des informations fournies par les sources dans une application,
- la source d'information,
- le niveau de fusion.

Chaque technique de fusion de données a ses avantages et ses inconvénients. Le degré de succès est alors toujours dépendant de l'application. Les questions importantes sont:

- Quelle technique doit-on employer pour utiliser toutes les données disponibles ?
- Quelle stratégie de traitement doit-on suivre ?
- Comment utiliser les données d'une façon efficace et opportune?

Différents chercheurs ont travaillé avec différentes méthodologies selon leurs domaines de recherche. Dans la littérature, cependant, on n'a encore proposé aucune technique optimale de fusion, l'optimum change d'une application à l'autre [Dai99]. Mais il y a quand même des méthodes qui donnent en général de meilleurs résultats que d'autres.

Nous listons tout d'abord quelques méthodes de fusion qui nous ont paru les plus importantes dans la littérature parmi les nombreuses méthodes possibles puis nous les classons d'après les résultats de notre propre expérience. Il y a des approches statistiques qui traitent des données multi sources comme un vecteur et classifient les données structurées comme si elles avaient été obtenues par une seule source. Parmi les exemples de méthodes statistiques classiques on peut citer l'approche bayésienne, les réseaux de neurones artificiels, les Chaînes de Markov Cachées, etc. ou plus complexes les champs de Markov (Markov Random Field, MRF) [Solberg96], [Cremer01] et [Taxt97]. Il existe également des méthodes

non statistiques comme la théorie de l'évidence [Dempster67], la logique floue [Zadeh65], la fusion avec une base de règles [Kowalski79], Les méthodes de votes [Klein98], la méthode des rangs de Borda Count, les Linear and log opinion pools [Benediktsson92], les intégrales floues [Tahani90]. Une comparaison expérimentale de plusieurs méthodes de fusion est présentée dans [Kuncheva01].

Dans [Sasiadek02] Sasiadek a catégorisé les techniques de fusion (pour un exemple de fusion multi sources) en trois groupes; premièrement les modèles probabilistes (approche Bayésienne, théorie de l'évidence, statistiques robustes, opérateurs récursifs) ; deuxièmement les techniques de moindres carrés (Filtrage de Kalman, la théorie optimale, régularisation et ellipsoïdes incertains) ; enfin les approches intelligence artificielle (logique floue, réseaux de neurones, algorithmes génétiques).

Dans le cas des informations liées au raisonnement humain deux approches générales existent. La première correspond à l'agrégation de préférences données par plusieurs individus ou l'agrégation de critères en vue d'une prise de décision. On cherche alors un consensus, de telle sorte que la solution satisfasse au mieux les individus ou les critères. La deuxième concerne la fusion d'informations complémentaires en éliminant des inconsistances des descriptions élémentaires et en créant une description globale prenant en compte les descriptions partielles.

Diverses méthodologies existent pour traiter les informations imparfaites et incomplètes, telles que la théorie des probabilités, la théorie de l'évidence, la théorie des possibilités, la logique floue, les méthodes de votes et les réseaux de neurones.

Dans les sections suivantes nous allons décrire quelques méthodes principales avec leurs principes fondamentaux, leurs avantages et leurs inconvénients.

2.1 Théorie des probabilités : approche bayésienne

La notion de probabilité fut introduite par Pascal (1623-1662) afin de traduire le hasard dans le jeu. On distingue aujourd'hui différentes approches telles que, les modèles théoriques, la fréquence d'occurrence d'un événement et une définition dite subjective. Cette dernière probabilité est appelée mesure de confiance Bayésienne.

Les méthodes les plus utilisées pour la gestion de l'incertitude et de la fusion de données ont tout d'abord été envisagées sous l'approche bayésienne. La mise à jour des informations (modélisées par des distributions de probabilité) se fait à l'aide du théorème de Bayes.

L'avantage majeur des probabilités est qu'elles reposent sur de solides bases mathématiques, et qu'il existe une grande variété de méthodes d'apprentissage pour estimer

les lois de probabilité. Mais les probabilités sont définies dans un cadre rigide et ne permettent pas de rendre compte de tous les aspects du jugement humain [Bloch94]. L'un des autres inconvénients majeurs de cette technique réside dans l'exigence de la connaissance parfaite des probabilités, et plus particulièrement de la probabilité a priori. Malheureusement, lorsque les connaissances sur le problème sont imparfaites, ces probabilités ne sont pas connues avec « certitude ». Ces limitations, maintenant bien identifiées [Bezdek], [Appriou91] [Bloch94], [Appriou98] ont donné naissance à de nombreuses extensions ou nouvelles propositions afin de gérer l'incertitude.

Les méthodes bayésiennes sont utilisées pour fusionner des sorties de classifieurs exprimées en probabilités a posteriori.

L'utilisation de la théorie de Bayes consiste à déterminer la classe C_i pour laquelle la probabilité a posteriori $P(C_i/e_1 = C_1, \dots, e_L = C_L)$ est maximum. Pour estimer les probabilités a posteriori, plusieurs études supposent que les classifieurs sont indépendants [Xu92] et que les pondérations peuvent être déterminées à partir de la matrice de confusion obtenue pour les classifieurs sur une base d'apprentissage. La solution proposée par [Xu92] est décrite par :

$$bel(i) = \eta \prod_{t=1}^L P(x \in C_i / e_t(x) = j_t) \quad (2.1)$$

Où e_t ($t = 1, \dots, L$) représente les classifieurs, j_t est la classe assignée par un classifieur par contre η est une constante qui assure que $\sum_{i=1}^M bel(i) = 1$, ($x \in C_i$, $i = 1, 2, \dots, M$ sont mutuellement exclusives et exhaustives), ainsi, on a :

$$\frac{1}{\eta} = \sum_{i=1}^M \prod_{t=1}^L P(x \in C_i / e_t(x) = j_t) \quad (2.2)$$

Finalement, la décision concernant la classe de la forme entrante (signature manuscrite par exemple) est prise en faveur d'une classe pour laquelle $bel(i)$ est maximum.

2.2 Réseaux de neurones artificiels

Le principe général des Réseaux de Neurones Artificiels (RNA) est, à l'origine, inspiré de certaines fonctions de base des neurones naturels du cerveau. Un réseau de neurones artificiel est généralement organisé en plusieurs couches ; une couche d'entrée, une couche de

sortie, et des couches intermédiaires appelées couches cachées. La présence de couches cachées permet de discriminer des classes d'objets non linéairement séparables.

En général, un réseau de neurones est fondamentalement un classifieur, il réalise un travail de classification pendant la phase d'apprentissage, et de classement lors de la reconnaissance. Mais on peut l'utiliser pour réaliser la fusion de données.

Les grands avantages des réseaux de neurones résident dans leur capacité d'apprentissage automatique (approximation universelle (Cybenko, Hornik)), ce qui permet de résoudre des problèmes sans nécessiter l'écriture de règles complexes, tout en étant tolérant aux erreurs. Ils résident aussi dans leur capacité à prendre une décision à partir de critères non formalisables explicitement.

D'après [Serpico95] et [Bruzzzone99], les classifieurs de réseaux de neurones fournissent une intégration efficace de différents types de données. L'approche non paramétrique qu'ils mettent en œuvre permet l'agrégation de différentes sources provenant d'un vecteur de données sans qu'il soit besoin de faire l'hypothèse d'une distribution probabiliste spécifique des données à fusionner. Un exemple de fusion multi sources par l'approche connexionniste est décrit dans [Simone02]. Leur difficulté de mise en œuvre réside dans :

- 1) le choix du modèle (architecture) ; a) variables d'entrée à choisir (étude de la sensibilité), si le nombre de variables d'entrée constituant du bruit est trop grand. b) nombres de neurones sur la/les couches cachées.
- 2) l'apprentissage, (a) choix de l'algorithme ; apprentissage par descente de gradient ; problème des minima locaux. (b) réglage des paramètres.
- 3) Les données ; beaucoup de données, données complètes, pas de points aberrants, données bien réparties dans l'espace des entrées.
- 4) temps de traitement, car les applications opérationnelles peuvent nécessiter des réseaux à plusieurs milliers de neurones.

Cependant, ce sont de véritables boîtes noires qui ne permettent pas d'interpréter les modèles construits. En cas d'erreurs du système, il est quasiment impossible d'en déterminer la cause.

2.3 Chaînes de Markov Cachées (CMC)

Les chaînes de Markov cachées (CMC) sont des outils statistiques dont l'élaboration remonte aux années 1920 par A. A. Markov et sa fameuse théorie des chaînes de Markov. Au fil des recherches la notion de « chaîne de Markov cachée » a été introduite et un grand nombre d'applications ont été développées.

Il y a trois problèmes fondamentaux liés aux chaînes de Markov cachées ; le problème de l'évaluation, le problème de la détermination du chemin d'états, le problème de l'apprentissage (supervisé ou non supervisé). Quelques autres problèmes liés aux CMC sont : le dépassement de la capacité de représentation des nombres en machine, l'insuffisance de données pour l'apprentissage, la mise à jour des modèles lorsque les processus varient dans le temps, le choix de l'architecture de la CMC la mieux adaptée aux données, le choix d'une bonne estimation initiale des probabilités de la CMC.

Le choix du nombre d'états d'une CMC pose toujours un sérieux problème, étant donné qu'il n'existe pas de méthode théorique pour le résoudre. De plus, les états ne sont pas nécessairement liés à un phénomène physique observable. En général, deux approches sont suivies :

- on effectue des tests avec différents nombres d'états, afin de sélectionner une valeur « optimale ».
- on relie la CMC à une explication physique, et on trouve un nombre d'états d'après des connaissances *a priori* du domaine.

L'algorithme Forward permet le calcul de la vraisemblance des observations (séquences d'états), l'algorithme de Viterbi trouve le chemin optimal, le plus probable, à suivre et l'algorithme de Baum-Welch réalise l'apprentissage supervisé (ré-estimer les paramètres d'une CMC). Ces algorithmes sont détaillés dans [Rabiner89]. Dans [Brouard99], ces algorithmes ont été réutilisés afin de permettre un apprentissage et une détermination entièrement automatique de l'architecture (nombre d'états et transitions autorisées) des CMC. Nous les avons réutilisés pour effectuer une fusion des classifieurs par CMC. On modélise chaque avis d'un expert (classifieur) par une observation. L'apprentissage de la CMC réalise la fusion. On réalise le découpage par l'algorithme Viterbi.

2.4 Méthodes des votes

Il y a maintenant plus de 200 ans que le principe du vote a été formalisé par le mathématicien et philosophe Condorcet [Condorcet1785]. Depuis, plusieurs méthodes de vote ont été proposées. Ces méthodes sont les plus simples à mettre en œuvre ; elles sont sans apprentissage et non paramétriques. Elles sont surtout utilisées dans les élections.

Une méthode simple pour combiner les sorties des sources multiples est d'employer un procédé de vote. Dans ce cas-ci, chaque source doit fournir une décision de son choix.

Typiquement, un nombre impair de sources d'information à fusionner est employé, pour éviter des ambiguïtés, et la décision finale est basée sur une règle de majorité. Dans le domaine de la reconnaissance de formes, les méthodes de vote ont été utilisées dans des applications diverses comme en reconnaissance de l'écrit [Xu92], [Chou94], [Kimura91], [Nadal90], pour la vérification de signatures [Sabourin94], et la vérification de haut-parleur [Farrell95] et [Farrell98]. Dans [Farrell95] et [Farrell98] la méthode de vote a été comparée aux méthodes linéaires et de « log opinion pool ». Ici, la méthode de vote a été moins efficace que les deux autres, mais elle a apporté une amélioration de performances quand elle est utilisée pour des sources de natures différentes.

Dans le cadre de la fusion au niveau de la décision, les méthodes de vote consistent à interpréter chaque sortie d'un classifieur comme un vote pour l'une des classes possibles. La classe ayant un nombre de votes majoritaire ou supérieur à un seuil préfixé est retenue comme décision finale. Les votes des classifieurs ne sont pas pondérés et chaque classe reçoit autant de votes qu'il y a de classifieurs à combiner. La plupart de ces méthodes ne nécessitent qu'un seul niveau de décision.

Les méthodes de vote peuvent pratiquement toutes être dérivées de la règle avec seuil, exprimée par :

$$e(x) = \begin{cases} C_i & \text{si } \sum_{j=1}^L e_{i,j} = \max_{t=1}^M \sum_{j=1}^L e_{t,j} \geq \lambda.L \\ \text{rejet} & \text{sinon} \end{cases} \quad (2.3)$$

L est le nombre des classifieurs, et λ correspond à la proportion de classifieurs qui peut avoir des valeurs entre 0 et 1. Quand $\lambda = 1$, la classe finale est choisie si tous les classifieurs sont d'accord sinon la réponse finale est le rejet. Cette méthode aussi appelée majorité unanime est très restrictive même s'il s'agit d'une méthode fiable, elle présente en conséquence l'inconvénient majeur de produire un taux de reconnaissance assez faible, surtout lorsque le nombre de classifieurs augmente. Pour $\lambda \geq 0,5$, il s'agit du vote à la majorité simple. La classe finale est décidée si plus de la moitié des classifieurs l'ont proposée. D'après [Ji97] l'utilisation du vote majoritaire est justifiée dans les situations où il est difficile d'obtenir d'autres types de sorties de l'information à partir des classifieurs que des décisions et surtout dans les problèmes où l'on combine un très grand nombre de

classifieurs et pour lesquels il est difficile d'appliquer d'autres méthodes de fusion plus complexes.

Dans un cas de conflit entre deux classes (ayant chacune la moitié des votes exactement), nous utilisons les informations supplémentaires comme les performances individuelles des classifieurs. La classe C_q choisie est celle pour laquelle la somme des performances des classifieurs en sa faveur est supérieure à la même somme pour les autres.

Dans le cadre de la fusion au niveau représentation, une méthode de vote à la pluralité peut être utilisée. Cette méthode a été développée dans les années 1970, elle tient compte d'un ensemble de classes et de l'ensemble de leurs rangs. Chaque classifieur vote pour M classes mais on ne regarde que les k premiers ($1 \leq k \leq N_T$). Le paramètre k peut varier d'un classifieur à l'autre mais dans notre étude nous ne l'avons pas fait varier pour rester dans le cas d'un classifieur de type k -ppv. Toutes les classes placées dans les k premiers choix ont un vote de poids égal à 1 alors que celles placées après ne votent pas. La classe ayant le maximum de votes est choisie comme la décision finale.

2.5 Méthodes de rangs (Borda Count et ses variantes)

Les méthodes de rangs sont appropriées pour les problèmes qui impliquent de nombreuses classes. Les rangs sont associés aux étiquettes de classe. La méthode utilise l'ordre des classes par exemple celui estimé par un expert s'ils sont nombreux. Les méthodes de rangs réduisent un ensemble de classes en réduisant le nombre de classes candidates sans perdre la vraie classe. En réduisant le nombre de classes et en listant à nouveau les classes restantes, la classe vraie devrait apparaître en tête des rangs. Un exemple d'utilisation de cette méthode est cité dans [Ho94] pour la reconnaissance de caractères imprimés.

La méthode de Borda count [Borda1781] est à l'origine une méthode de vote dans laquelle chaque électeur donne un rang à toutes les alternatives possibles. A l'alternative rangée la première (dans le cas de n alternatives) sont affectées n voix et chaque alternative suivante obtient une voix de moins. Puis, pour chaque alternative, toutes les voix sont additionnées et l'alternative qui a reçu le nombre le plus élevé de voix gagne l'élection. Cette méthode, présentée en 1770 par Jean-Charles de Borda, peut être facilement adaptée aux problèmes de classification. Lorsqu'on utilise cette méthode, les classifieurs sont considérés comme des votants et les classes comme les alternatives [Van-Erp00]. Pour un problème à deux classes, le Borda Count est un vote à la majorité.

Etant donnés L classifieurs, portant chacun sur M classes, on suppose connus n prototypes pour les M classes. La distance de l'élément inconnu à chacun des prototypes

donne une indication sur la classe d'appartenance de l'élément à classer en fonction de la classe du prototype. On trie tout d'abord les résultats de chaque classifieur par ordre de rang croissant. La classe, parmi M classes, correspondant au mieux aux données (la plus petite dans le cas de distances par exemple) reçoit alors n votes. L'élément associé à la seconde de ces classes reçoit ensuite $n - 1$ votes. On procède ainsi jusqu'à la dernière de ces données ce qui donnera alors 1 vote à l'élément concerné. La somme de tous les votes des éléments concernant une même classe donne le nombre de votes pour cette classe. De cette façon, on obtient les nombres de votes pour toutes les classes. On exécute ces étapes pour chacun des L classifieurs et on additionne les votes obtenus pour les classifieurs précédents par les différentes classes. Au final, on obtient donc un tableau qui donne le nombre total de votes obtenus par chacune des classes dans les différents classifieurs. La classe correspondant à la forme reconnue est alors celle qui a obtenu le plus de votes.

La méthode de Borda a deux variantes [Van-Erp00]. La méthode de Borda Médiane est une variante très proche de la méthode de Borda originale. Au lieu de sommer les votes relatifs aux indices des différentes classes dans les classifieurs, on en extrait la médiane. La méthode de Nanson exécute $M - 1$ fois la méthode de Borda originale sur les classifieurs. A chaque itération, les occurrences de la classe qui a obtenu le moins de votes sont supprimées des données à traiter à l'itération suivante. Cette méthode s'arrête lorsqu'il n'y a plus qu'une seule classe à traiter.

2.6 Logique floue

La théorie de la logique floue (des sous-ensembles flous) a été introduite par Zadeh en 1965 [Zadeh65] comme une extension de la logique binaire d'une part et une amélioration de la logique multivaluée (admettant plusieurs valeurs de vérité) d'autre part. L'importance de la logique floue réside dans le fait qu'elle s'approche du raisonnement humain par l'intégration et le traitement du caractère approximatif, vague, imprécis ou flou de la connaissance humaine. Les termes linguistiques tels que « environ », « moyenne », « approximativement » sont de nature à donner un caractère flou aux phrases énoncées. Par exemple, la règle « si le prix est inférieur à 6 000 euros, j'achète » sera intuitivement utilisable si le prix est de 6 002 euros, mais elle ne pourrait être exploitée en logique classique puisque le prix indiqué ne satisferait pas la prémisse.

Dans cette théorie les propositions prises en charge sont des propositions floues définies à partir d'un ensemble L de variables linguistiques (V (une variable définie sur X), X (un ensemble de référence), T_v (des sous-ensembles flous normalisés de X)) et d'un ensemble M

de modificateurs. Leur valeur de vérité appartient à l'intervalle $[0, 1]$ et elle est fournie par la fonction d'appartenance de la caractérisation floue utilisée dans la proposition floue. Une valeur de vérité égale à 1 (respectivement à 0) correspond à une proposition absolument vraie (respectivement absolument fausse). Il est possible de faire appel à des qualifications de vérité (« V est A » est vrai, très vrai, peu vrai, ...), des qualifications de probabilité (« V est A » est probable, très probable, peu probable, ...), des qualifications de possibilité (« V est A » est possible, très possible, peu possible, ...).

Un système basé sur la logique floue en général est composé de quatre étapes [Berkan97]:

Fuzzification : L'objectif de cette étape est de définir les variables d'entrée et aussi les fonctions d'appartenance des attributs de chaque variable. Les variables d'entrée sont les données mixtes de types numériques et symboliques (linguistiques). Les fonctions prennent différentes formes : triangle, cloche ou encore trapèze. Ces fonctions d'appartenance sont choisies dans la plupart des exemples par des experts du domaine ou après une phase d'apprentissage.

Inférence : Le but de cette étape est de catégoriser chaque variable d'entrée selon les valeurs floues standard comme « petit », « moyen », et « grand », etc. par exemple. On a donc ici des règles floues qui sont aussi définies par des experts.

Composition : Dans cette étape toutes les sorties des fonctions d'appartenance sont combinées. Ce processus de combinaison est généralement réalisé graphiquement.

Défuzzification : En sortie, le système flou ne doit pas communiquer des valeurs floues qu'il serait seul à pouvoir exploiter. Il lui est donc nécessaire de fournir des valeurs précises, c'est le rôle de la défuzzification. Cette étape s'effectue toujours à l'aide des degrés d'appartenance. A partir des degrés d'appartenance, on obtient autant de valeurs qu'il y a de fonctions d'appartenance. Pour prendre la décision, on peut soit conserver le maximum du degré d'appartenance, soit calculer la moyenne pondérée, soit déterminer le centre de gravité des degrés assignés.

Les opérateurs comme les opérateurs classiques t-norme et t-conorme et leurs extensions développées par d'autres auteurs [Hamacher76], [Yager80], [Weber83], [Gupta91] sont employés pour la combinaison d'informations.

Il convient d'utiliser la logique floue lorsque des imperfections entachent la connaissance dont nous disposons sur le système, lorsqu'une modélisation rigoureuse de celui-ci est difficile, lorsqu'il est très complexe, lorsque notre façon naturelle d'aborder le problème passe par une vue globale de certains de ses aspects.

On remarque ainsi que la théorie des sous-ensembles flous permet seulement de modéliser l'imprécision liée à une information alors que l'incertitude n'est déterminée que de façon implicite [Oussalah98]. La mise en place d'un système flou nécessite une attention particulière lors de la phase de test de manière à détecter les éventuelles aberrations du système.

Les domaines d'application de la logique floue sont multiples depuis la fin des années soixante. [Bouchon-Meunier95] a décrit les différents domaines techniques dans lesquels il existe des utilisations de la logique floue comme les systèmes experts, la commande de processus, la robotique, la planification, les langages de programmation, la décision multicritères, la décision de groupe, l'optimisation, l'ordonnancement, les bases de données, la recherche documentaire, la reconnaissance des formes, la classification, le traitement d'image, etc.

2.7 Opérateurs d'agrégation

Trouver un avis acceptable pour plusieurs interlocuteurs qui émettent initialement des avis différents sur la caractérisation d'un même critère ou agréger les préférences obtenues pour diverses éventualités à partir de l'utilisation de plusieurs critères nécessite le choix d'un opérateur d'agrégation. Il doit refléter la façon dont intervient chacun des éléments dans le résultat agrégé cherché. Les opérateurs d'agrégation transforment un nombre fini d'entrées en résultat unique. Les opérateurs envisageables sont très nombreux et sont appliqués dans beaucoup de domaines théoriques et pratiques, tels que les logiques multivaluées, la commande floue, la prise de décision multicritère [Calvo03] la prédiction du temps [Clemen87], le commerce et le marketing [Harvey00] et les tâches de prédiction [Rantilla99].

2.7.1 Agrégation de données

« Agrégation de données » est un terme équivalent à la fusion de données, utilisé en particulier par les chercheurs du domaine des raisonnements humains (interprétation ou évaluation des experts) dans le but de prendre une décision finale face à plusieurs avis par exemple. Pour aborder le domaine des classifieurs avec cette terminologie, nous considérons chaque classifieur comme un expert qui donne son avis en comparant la similarité ou ressemblance entre plusieurs formes. Un système avec plusieurs classifieurs revient à un problème d'*agrégation multicritères* qui consiste à synthétiser des informations traduisant des aspects ou des points de vue différents et parfois conflictuels au sujet d'un même ensemble

d'objets. Ce problème se pose de manière cruciale dans de nombreuses procédures d'évaluation, de comparaison ou de classification utilisées en aide à la décision.

L'agrégation de données est un vaste sujet et elle est aussi considérée comme un des champs de la fusion de données. Dans le cadre du problème de l'agrégation de type multicritères, on cherche à satisfaire des critères préalablement définis. On dispose de candidats (des objets susceptibles de satisfaire ces critères) que l'on cherche à évaluer, à classer (éventuellement) dans le but de prendre une décision sur la valeur de ces candidats. Cette évaluation est rendue délicate par le fait que certains critères peuvent être partiellement contradictoires ou tellement lointains que leur satisfaction simultanée est presque impossible ; un compromis doit alors être réalisé dans ce cas. Pour résoudre ce type de problèmes, en général, on peut distinguer deux approches [Grabish95], l'approche ordinale et l'approche globale.

L'approche ordinale ou relationnelle : on cherche à comparer les candidats potentiels par paires, pour chaque critère. On obtient ainsi une relation de préférence pour chaque critère. Il s'agit ensuite d'agréger ces relations de préférences afin d'obtenir une nouvelle relation pour l'ensemble des critères. Cette méthode a été introduite par [Roy68.] et [Fodor92].

L'approche cardinale ou globale : on cherche dans ce cas à classer les candidats : chaque candidat pouvant être évalué par rapport à chaque critère, on s'appliquera à agréger ces évaluations dites marginales afin d'obtenir une évaluation globale pour chaque candidat. Dans le cas où les évaluations pour chaque critère (évaluations marginales) sont des nombres réels, on obtient un classement (ordre total) des candidats, ce qui n'est pas naturellement le cas lorsque les évaluations sont des nombres flous. Dans le premier cas, cette approche coïncide avec celle de la théorie de l'utilité décrite dans [Keeney76]. Le classement total obtenu permet donc de prendre une décision mais peut masquer des problèmes de cohérence des critères sous-jacents [Kelman96].

2.7.2 Les opérateurs proposés

Il existe une multitude d'opérateurs utilisés dans ce domaine, toutefois certains auteurs se sont appliqués à catégoriser ces opérateurs. Pour choisir un opérateur, il existe différentes approches :

Une approche pragmatique : elle consiste à tester un grand nombre d'opérateurs et à comparer leurs résultats sur des problèmes particuliers.

Une approche intuitive : elle consiste à préciser les propriétés souhaitables intuitivement et à répertorier les opérateurs les satisfaisant.

Une approche axiomatique : elle définit les propriétés mathématiques que doit vérifier l'opérateur d'agrégation.

Les différents opérateurs proposés dans la littérature peuvent être consultés dans les travaux originaux ou bien dans différents états de l'art du domaine. Nous citons ici quelques opérateurs importants et leurs références.

Tout d'abord, les opérateurs classiques de type t-normes et t-conormes peuvent être employés comme opérateurs d'agrégation de données. Ces opérateurs permettent par exemple de donner une grande importance aux cas extrêmes, ce qui est le cas si l'on représente un raisonnement agrégatif pessimiste (un résultat agrégé qui satisfait tous les intervenants) ou optimiste (un résultat agrégé qui satisfait au moins un intervenant). Il y a également des opérateurs de type min et max avec pondération [Dubois86a], [Dubois86b].

Une autre famille est constituée des opérateurs de type moyenne (les moyennes quasi-arithmétiques et les médianes, etc.), ils ont un comportement peu chaotique, ayant tendance à ramener l'évolution globale vers le « centre » des évaluations marginales. Ce sont de bons outils par défaut lorsque la connaissance sur le procédé d'agrégation est faible et que l'on ne sait donc pas très bien quelle attitude adopter. Ici, on obtient un résultat intermédiaire. Un inconvénient majeur de ce type d'attitude est le risque de proposer comme élément représentatif un élément très différent de tous les éléments de départ (si ces éléments sont regroupés en deux blocs par exemple). La médiane permet de pallier cet inconvénient. Une autre approche consiste à attribuer des poids différents (moyenne pondérée) aux éléments à agréger. Quelques références importantes : les opérateurs de type moyenne (sans pondération) ; quasi-arithmétique [Aezel66], arithmétique, quadratique, harmonique, géométrique [Dyckhoff84], médiane [Yager94d], [Dubois82] avec pondération [Dyckhoff84].

Les opérateurs somme symétrique ont été étudiés en détail par [Silver79] en particulier pour agréger deux arguments (définition d'une opération). Un tel opérateur a été utilisé pour combiner des informations imprécises [Dubois85].

Les opérateurs de compensation ont été introduits par Zimmermann et Zysno [Zimmermann80] lors d'expériences menées pour connaître les opérateurs d'agrégation les mieux adaptés à la modélisation du comportement humain dans ce domaine. Le min et le max ne convenant pas car trop extrêmes, et la moyenne arithmétique produisant un biais sur les résultats obtenus, les auteurs ont alors proposé ces opérateurs permettant de se trouver entre le mode conjonctif et le mode disjonctif, cela par l'intermédiaire du choix d'un paramètre $\gamma \in$

[0, 1]. Ces opérateurs, outre le fait de donner des résultats satisfaisants dans la pratique, couvrent une large gamme allant du produit (pour $\gamma = 0$) à la somme probabiliste (pour $\gamma = 1$) représentant des attitudes respectivement conjonctive et disjonctive extrêmes. Il est malheureusement difficile de caractériser ces opérateurs ou d'en connaître les propriétés mathématiques. Le choix du coefficient γ doit donc se faire en tâtonnant, suivant des procédures d'essai vérification. Ceci suppose que l'on dispose d'entrées-sorties fournies par des experts humains. Cette approche est discutée en détail par [Dubois84].

Les opérateurs MICA (Monotonic Identity Commutative Aggregator) ont été introduits par Yager [Yager94]. Un autre moyen d'agréger des valeurs de critères est d'utiliser les intégrales floues [Choquet53], [Sugeno77], aussi appelées l'intégrale floue de Sugeno, l'intégrale de Choquet et l'intégrale floue induite proposée dans [Yager02].

Maintenant nous allons détailler deux classes d'opérateurs d'agrégation (OWA et AWFO) implémentées dans cette thèse pour leurs propriétés en fusion de données.

2.7.3 OWA (Ordered Weighted Averaging operator)

Une importante famille est celle des opérateurs dits OWA (Ordered Weighted Averaging Operators), cette famille a été introduite par Yager [Yager88]. Leurs extensions (les OWA pondérés) sont très souvent utilisées dans le cadre de l'agrégation multicritères. Avec un vecteur de pondérations introduit par Yager [Yager88], ces opérateurs peuvent aussi modéliser des cas particuliers d'opérateurs flous de type pessimiste ou optimiste. Dans [Yager93] est décrite une famille de ces opérateurs. Dans [Herrera 96] un OWA opérateur linguistique (LWAO) est introduit pour le processus de prise de décision de groupe dans un contexte d'environnement linguistique.

Ces opérateurs représentent principalement deux concepts :

(i) Le décideur peut agir sur l'agrégation en imposant une satisfaction plus ou moins stricte de l'ensemble des critères : on peut représenter toutes les nuances allant de « tous les critères doivent être satisfaits » à « au moins un critère doit être satisfait » et cela intuitivement grâce à la liaison avec les quantificateurs linguistiques.

(ii) Il est possible d'introduire une notion de pondération entre les critères (OWA pondérés) : plus un critère est important dans la prise de décision finale plus son poids est élevé (pondération statique).

Les opérateurs sont reconnus des outils puissants et simples dans ce domaine. La classe des opérateurs OWA (OWA, OWA pondérés, quasi-OWA etc.) est la classe des opérateurs

commutatifs, monotones, idempotents et stables par rapport aux transformations linéaires positives de mêmes gradients, à zéros distincts et valeurs ordonnées. Il est possible de représenter des attitudes optimistes ou pessimistes. Il est aussi montré dans quelques travaux que dans certains cas où l'on souhaite respecter la commutativité, l'opérateur OWA est équivalent à l'intégrale de Choquet.

2.7.3.1 Définition

Un opérateur d'agrégation F ,

$$F : [0,1]^n \rightarrow [0,1]$$

est appelé un Ordered Weighted Averaging (OWA) Operator de dimension n s'il est associé à un vecteur de pondérations $W : W = [w_1 \dots w_n]^t$ tel que :

$$(1) \quad w_i \in [0,1]$$

$$(2) \quad \sum w_i = 1$$

et $F(a_1, a_2, \dots, a_n) = \sum b_j \cdot w_j$ où b_j est le j -ième plus grand élément des $\{a_1, a_2, \dots, a_n\}$.

2.7.3.2 Caractéristiques

Il est montré dans [Yager88] que les opérateurs OWA sont une généralisation des opérateurs flous couramment utilisés (Min et Max) puisque ces derniers en sont un cas particulier :

Si $w_1 = 1$ et $w_j = 0$ pour $j \neq 1$, alors $F(a_1, a_2, \dots, a_n) = \text{Max } [a_i]$

Si $w_n = 1$ et $w_i = 0$ pour $i \neq n$, alors $F(a_1, a_2, \dots, a_n) = \text{Min } [a_i]$

On trouve également la médiane et plus généralement les statistiques d'ordre :

Si $n = 2k+1$ et $w_{k+1} = 1$ et $w_i = 0$ pour $i \neq k+1$, alors

$$F(a_1, a_2, \dots, a_n) = \text{med } (a_1, a_2, \dots, a_n)$$

Si $w_k = 1$ et $w_i = 0$ pour $i \neq k$, alors

$$F(a_1, a_2, \dots, a_n) = w_k : \text{statistique d'ordre } k.$$

Entre les deux valeurs extrêmes, on trouve également la moyenne arithmétique usuelle :

Si $w_i = 1/n \forall i$ alors $F(a_1, a_2, \dots, a_n) = 1/n \sum a_i$

Afin de rendre le réglage du vecteur de pondération plus facile, une « mesure d'optimisme » (ou degré d'Orness) a été introduite par Yager [Yager 88]. Intuitivement, cet indice $\text{Opt}(W)$ correspond au numéro moyen (au sens de l'espérance) de la donnée b_j la plus caractéristique de l'ensemble des données de départ. Il caractérise donc l'opérateur OWA auquel il est associé en indiquant comment celui-ci se comporte en moyenne : s'il a tendance

à choisir comme élément représentatif l'élément le plus grand de la collection, on dira qu'il est optimiste et a contrario si c'est l'élément le plus petit qui est choisi on dira que l'OWA est pessimiste. Le coefficient d'optimisme est défini par :

$$\text{Opt}(W) = \sum w_j \times h_n(j), \text{ où } h_n(j) = n-j / n-1$$

Dans [O'Hagan90] une méthode pour déterminer le vecteur de pondérations à partir de la simple donnée du coefficient d'optimisme α est proposée. Les pondérations sont obtenues automatiquement en résolvant le problème suivant :

$$\text{Maximiser :} \quad \sum w_j \ln(w_j) \quad (\text{dispersion})$$

$$\text{Avec les 3 contraintes:} \quad \sum w_j \times h_n(j) = \alpha$$

$$\sum w_j = 1$$

$$w_j \geq 0 \text{ pour tout } j$$

Le choix de α permet à l'utilisateur de privilégier les nombres grands (si α est grand) ou petits (si α est petit) dans l'agrégation.

2.7.3.3 Quantificateur logique

Comme on l'a déjà remarqué, le comportement du décideur face à la satisfaction simultanée des critères peut varier de « tous les critères » à « au moins un critère ». On observe donc que ce comportement est facilement représentable par un quantificateur logique, du moins dans les deux cas extrêmes cités ci-dessus (quantificateur universel et existentiel respectivement). Pour généraliser, Zadeh [Zadeh83] a proposé le concept de quantificateur linguistique ou quantificateur flou permettant de passer continûment du quantificateur existentiel au quantificateur universel.

Supposons que l'on dispose d'une collection de critères dont Q critères doivent être satisfaits. Q étant un quantificateur RIM, Yager [Yager88] a proposé la solution suivante : on associe au quantificateur linguistique Q un opérateur OWA de dimension n dont le vecteur de poids est déterminé par :

$$\forall i = 1, \dots, n, \quad w_i = Q(i/n) - Q(i-1/n).$$

On a ainsi une correspondance simple entre la proportion des critères à prendre en compte et le vecteur de pondération de l'opérateur OWA.

2.7.4 AWFO (Aggregator Weight-Functional Operator)

AWFO (Aggregation Weight-Functionnal Operators) est comparativement un nouvel opérateur d'agrégation combinant les caractéristiques des opérateurs AND / OR et qui possède des propriétés mathématiques. Vincent et al. dans [Vincent96] ont introduit cet opérateur en 1996 pour agréger des éléments de même nature et d'origines différentes, les données sont affectées de poids variables suivant leur place dans l'univers.

Selon les auteurs de AWFO [Vincent96], [Vincent97] cet opérateur conserve le même mode de distribution générale des données que dans les opérateurs OWA [Yager88] mais il diffère fondamentalement de ces opérateurs dans la définition des poids affectés à chacune des valeurs. Les valeurs ne sont plus triées par ordre croissant. Les poids ne doivent pas dépendre seulement de chaque valeur, mais également de la distribution générale des données. Une concentration des données dans un sous-domaine restreint et la position de ces sous-domaines dans l'univers doivent avoir une influence, peut-être non linéaire, sur les résultats. D'autre part la définition de l'opérateur doit pouvoir être modifiée en fonction du mode de raisonnement que l'on se propose de modéliser.

Ainsi les poids fonctionnels sont en fait composés de deux fonctions indépendantes. La première, appelée h , *fonction signifiante*, est indépendante des données ; elle traduit le caractère du mode de raisonnement et intervient de la même manière dans tous les coefficients. Elle permet d'accentuer, dans le sens souhaité, certaines particularités. La seconde, appelée g , *fonction relative*, traduit les positions relatives de chaque variable par rapport aux autres.

2.7.4.1 Modélisation

Afin d'affecter les poids à des valeurs données, on va utiliser le concept de fonction de poids qui va générer des poids dynamiques en fonction du contexte au contraire d'autres opérateurs qui ont des poids fixes. Le fait de calculer les poids à partir d'une fonction croissante va correspondre à un comportement optimiste, dans ce cas on va donner plus d'importance aux grandes valeurs. Par contre calculer les poids à partir d'une fonction décroissante va refléter un comportement pessimiste.

On distingue deux cas de figure (figure 2.1) :

- La décision finale peut être faite à partir des sources d'informations plutôt défavorables : ce cas peut être interprété comme le cas pessimiste.
- Tandis que dans le cas optimiste on s'appuie davantage sur les informations favorables pour prendre une décision.

Par exemple : On suppose qu'on a 3 données (0,1, 0,8, 0,9)

- si on décide uniquement selon le 0,1 on est dans le cas pessimiste.
- si on décide 0,6 on est dans le cas moyen.
- si on décide uniquement selon le 0,9 on est dans le cas optimiste.

Ainsi dans les jugements humains, il est possible de "renforcer" les informations. Le renforcement optimiste des résultats est le fait de pondérer davantage les informations favorables, par des poids significatifs :

$$1/6(0,1 + 2 \times 0,1 + 3 \times 0,9) = 0,73$$

D'un autre côté le renforcement pessimiste va minimiser le risque, tout en utilisant toutes les valeurs :

$$1/6(4 \times 0,1 + 0,1 + 0,9) = 0,35$$

A noter que si les poids sont tous égaux à 1, on considère un comportement neutre.

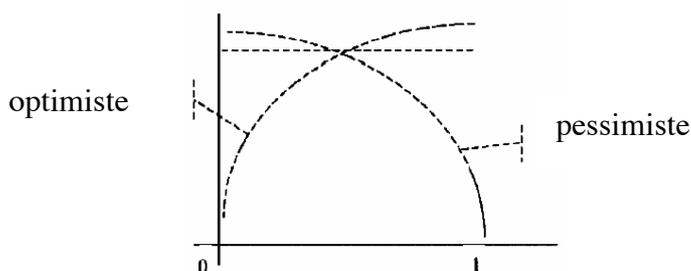


Figure 2.1: Différents modes de raisonnement

Pour cela il a été proposé une formule générale pour le processus d'agrégation, représentant un nouvel opérateur nommé Aggregation Weight-Functional Operators (AWFO).

2.7.4.2 Définitions

Soient n variables linguistiques : X_1, \dots, X_n et n ensembles flous A_1, \dots, A_n sur X_1, \dots, X_n respectivement, soit $X = X_1, \dots, X_n$ qui prend les valeurs $x_0 = (x_0^1, \dots, x_0^n)$; On note σ le résultat donné à partir de $A_1 x_0^1, \dots, A_n x_0^n$ et défini par :

$$\sigma(A_1 \{x_1^0\}, \dots, A_n \{x_n^0\}) = \frac{1}{n} \sum_{i=1}^n f(A_i \{x_i^0\}) . A_i \{x_i^0\} \quad (2.4)$$

où f est une fonction choisie par le décideur qui en particulier reflète le comportement voulu (optimiste, pessimiste, moyen) et qui dépend du contexte du problème.

Propriétés : Comme la fonction f est choisie, cela fait que la formule (2.4) a l'avantage de ne pas dépendre du nombre d'arguments. D'autre part :

- Il n'est pas nécessaire d'ordonner le vecteur d'entrée x_i^0
- L'opérateur est commutatif.
- L'opérateur n'est pas associatif.

Définition de la classe des fonctions pondérées : $\forall a = (a_1, a_2, \dots, a_n)$; g est une fonction définie en suivant les 3 étapes suivantes.

1^{ère} définition : poids relatifs (g)

Soient n variables (a_1, a_2, \dots, a_n) leurs G -poids relatifs sont définis par les n fonctions g_i , i allant de 1 à n :

Si $\forall a, a = G$ alors $g_i(a) = 0$

Sinon :

$$g_i(a) = \frac{\sum_{d(a_j, G) \geq d(a_i, G)} d(a_j, G)}{\sum_{j=1}^n d(a_j, G)} \quad (2.5)$$

G est une valeur choisie dans le même domaine que les valeurs à agréger, d est une distance dans \mathbf{R} mais aussi entre éléments de nature différente. Dans tous les cas $g_i(a) \in [0,1]$

2^{ème} définition : fonctions pondérées (h)

Alors la fonction de poids est définie comme :

$\forall a = (a_1, a_2, \dots, a_n)$

$$f(a_i) = h \circ g_i(a) \quad (2.6)$$

$f(a_i)$ est choisi comme le poids de a_i pour les éléments du n -uplet (a_1, a_2, \dots, a_n) .

Exemple

On va prendre l'exemple du cas optimiste, en choisissant la fonction h appartenant à une famille de fonctions avec deux paramètres $\beta \in \mathfrak{N}^+$ $\alpha \in [0,1]$

$h : [0,1] \rightarrow [0,1]$

$$h_{\alpha, \beta}(x) = (1 - \alpha) x^\beta + \alpha \quad (2.7)$$

Ces fonctions ont la propriété d'être des fonctions croissantes. Dans ce cas la fonction pondérée f est définie par :

$$f(a_i) = (1 - \alpha) \left(\frac{\sum_{a_j \leq a_i} d(a_j, G)}{\sum_{j=1}^n d(a_j, G)} \right)^\beta + \alpha \quad (2.8)$$

La donnée a , est constituée de n valeurs, toutes dans un même intervalle (non nécessairement numérique), dont les extrémités seront notées α pour la borne inférieure et β pour la borne supérieure. L'opérateur d'agrégation est défini dans ce cas par :

$$\sigma(a_1, \dots, a_n) = \frac{1}{n} \sum_{i=1}^n \left[(1 - \alpha) \left(\frac{\sum_{a_j \leq a_i} d(a_j, G)}{\sum_{j=1}^n d(a_j, G)} \right)^\beta + \alpha \right] \cdot a_i \quad (2.9)$$

Dans [Vincent97], l'introduction d'une pondération des différentes variables à agréger est proposée. En notant w_i le poids affecté à la i^{e} variable avec la contrainte :

$$\sum_{i=1}^n w_i = 1 \quad (2.10)$$

La formule de l'opérateur modifié est décrite alors par :

$$\sigma(a) = \max \left\{ \alpha, \min \left[\beta, \frac{1}{n} \lim_{x \rightarrow a} \sum_{i=1}^n w_i \cdot f_{a,i}(x) \cdot x_i \right] \right\} \quad (2.11)$$

2.8 Théorie de l'évidence

La théorie de l'évidence, proposée par Glenn Shafer en 1976 [Shafer76], prenant appui sur les bases formulées par Dempster [Dempster67], est aussi appelée « théorie de Dempster-

Shafer » ou « théorie des croyances ». Dans son essai, Shafer propose une nouvelle interprétation des travaux de Dempster qui identifie les probabilités inférieures à des degrés de croyance (ou probabilités épistémiques) tout en conservant les règles de combinaison de ces degrés de croyance. La théorie Bayésienne est alors envisagée comme un cas particulier de cette théorie. Cette théorie permet de gérer les situations d'ignorance ce qui n'est pas le cas dans le cadre de la théorie des probabilités. La modélisation des informations se fait à l'aide de fonctions de croyance. Une fois les fonctions de croyance obtenues, la fusion est réalisée par l'intermédiaire de la règle de combinaison de Dempster.

Au contraire de la théorie des probabilités, l'utilisation de la théorie de l'évidence ne nécessite pas de connaissance a priori sur le problème à traiter d'une part et permet d'autre part de répartir la croyance non seulement sur les hypothèses élémentaires mais aussi sur des compositions d'hypothèses. Son troisième avantage sur la théorie des probabilités est que la théorie de l'évidence n'impose aucune relation entre un événement et sa négation, cette approche ne modélise que la croyance créditée à une classe, sans influencer la croyance attribuée aux autres classes. La difficulté de mise en œuvre de la théorie de l'évidence reste dans l'obtention des fonctions de croyance car il n'existe pas de méthodes génériques pour ce problème. Dans la plupart des cas, la modélisation utilisée dépend de l'application envisagée [Dromigny-Badin98], [Gruyer99].

L'opérateur de combinaison de Dempster, appelé également somme orthogonale, vérifie certaines propriétés intéressantes et son utilisation a été justifiée de manière théorique par plusieurs auteurs. Toutefois, dans certaines situations, cet opérateur ne peut pas être utilisé. Lorsque les sources d'informations ne sont ni indépendantes ni parfaitement fiables et dans le cas où la construction des fonctions de masses est trop imprécise, une masse de conflit est engendrée.

Les origines des masses de conflit dans divers cas peuvent provenir d'une mesure aberrante issue d'un capteur, et peuvent être dues soit à un mauvais fonctionnement du capteur, soit à une mauvaise évaluation de la plage de fonctionnement du capteur. Dans le cas où le capteur fonctionne correctement, cette situation pourrait correspondre à la non prise en compte d'une hypothèse dans le cadre de discernement. Dans d'autres cas on peut aussi avoir conflit, par exemple en fonction d'une modélisation imprécise de fonctions de croyance ou du nombre de sources impliquées dans le processus de fusion.

Pour résoudre le problème d'un conflit, plusieurs règles de combinaison sont proposées. On peut distinguer deux familles. La première regroupe des règles de combinaison de [Smets90a] et de [Yager83] reposant sur le postulat de fiabilité des sources à fusionner. La

seconde (opérateur de [Yager87], et de [Dubois88], etc.) suppose qu'au moins une des sources soit fiable mais on ignore laquelle.

Dans la première famille, et selon la même idée que l'opérateur de Dempster, Smets [Smets90a] considère que les sources à fusionner sont fiables et il préconise alors de ne pas redistribuer la masse conflictuelle sur l'ensemble des propositions mais uniquement sur l'ensemble vide ϕ . Notons qu'une approche similaire proposée par Yager [Yager83] repose sur l'introduction d'une nouvelle hypothèse dans le cadre de discernement.

Dans la seconde famille, Yager [Yager87] propose d'attribuer la masse conflictuelle à l'ensemble Ω . La combinaison proposée par Dubois et Prade [Dubois88], dans le cadre de la fusion de deux sources d'informations, impose de redistribuer la masse conflictuelle aux propositions pour lesquelles les sources sont contradictoires. Une autre méthode, reposant sur la définition de coefficients de fiabilité, permet de gérer la combinaison de sources non fiables, en introduisant la fiabilité de l'information. Pour plus en détail voir [Lefevre01].

La théorie de l'évidence a été utilisée dans des domaines divers et à tous les niveaux de la fusion de données. On peut citer un certain nombre de domaines d'application exploitant les avantages de cette théorie comme indiqué dans [Lefevre01] : Fusion multi-capteurs, diagnostic, classification, combinaison de classifieurs, télédétection, traitement d'image, reconnaissance de formes, surveillance de l'environnement, etc.

2.8.1 Principe

Soit $\Omega = \{H_1, H_2, H_3, \dots, H_M\}$ l'ensemble des propositions possibles du problème posé, appelé cadre de discernement ou corps évidentiel. On suppose que le cadre de discernement est exhaustif et que les hypothèses sont exclusives. Cette notion est aussi appelée monde fermé (closed world). Toutefois, il est possible de s'affranchir de cette condition en admettant que l'ensemble Ω est un cadre de discernement non exhaustif. Cette approche est alors appelée hypothèse du monde ouvert (open world) [Smets90a]. Nous préférons garder l'hypothèse d'exhaustivité de Ω . A partir de cet ensemble Ω , on définit un ensemble noté 2^Ω , l'ensemble des 2^M parties A de Ω . Cet ensemble est défini de la manière suivante :

$$2^\Omega = \{A/A \subseteq \Omega\} = \{\phi, \{H_1\}, \dots, \{H_M\}, \{H_1, H_2\}, \dots, \Omega\}.$$

Cet ensemble contient les hypothèses singletons de Ω , toutes les disjonctions possibles de ces hypothèses ainsi que l'ensemble vide. Par la suite, nous noterons H_n une hypothèse singleton, et A une proposition désignant indifféremment une hypothèse ou une disjonction d'hypothèses. Une information (qui peut être issue d'un capteur, d'un agent, d'un expert, ...)

traduisant une opinion sur l'état d'un système est caractérisée par des degrés de croyance dans les différentes hypothèses. Ces degrés de croyance peuvent être décrits par une *fonction de croyance* ou *d'allocation de masse* notée m qui est définie par :

$$m : 2^\Omega \rightarrow [0,1] \quad (2.12)$$

Cette fonction vérifie les propriétés suivantes :

$$\begin{aligned} m(\phi) &= 0, \\ \sum_{A \subseteq \Omega} m(A) &= 1 \end{aligned} \quad (2.13)$$

La quantité $m(A)$ est la part de croyance placée strictement sur A . La quantité se différencie d'une probabilité par le fait que la totalité de la croyance est répartie non seulement sur les hypothèses singletons H_n mais aussi sur les hypothèses composites A . on peut alors accorder une partie de la croyance à une proposition, et ainsi affecter à l'ensemble des hypothèses contenues dans la proposition une croyance à la réalisation de chacune d'entre-elles sans prendre parti pour l'une d'elles précisément. Les sous-ensembles de 2^Ω dont la masse est non nulle, sont appelés *éléments focaux*. Une situation d'ignorance totale est donnée par $m(\Omega) = 1$ et de certitude totale (sur une hypothèse singleton) par $m(H_n) = 1$.

La fonction d'allocation de masse m permet de construire la notion de Crédibilité (croyance) et de Plausibilité :

La fonction de Crédibilité est définie par :

$$Bel(\phi) = 0 \quad (2.14)$$

$$\forall A \subseteq \Omega, A \neq \phi, Bel(A) = \sum_{B \subseteq A} m(B) \quad (2.15)$$

$Bel(A)$ regroupe l'ensemble des croyances apportées par les éléments qui composent A . Elle correspond à la quantité d'information qui est tout entière contenue dans le sous-ensemble considéré.

La fonction de plausibilité, notée Pl , exprime que plus un élément est vrai, moins son contraire l'est. Si A est une proposition, $Pl(A)$ mesure combien l'information apportée par une source ne contredit pas A . Elle est définie :

$$Pl(\phi) = 0, \\ Pl(A) = \sum_{B \cap A \neq \phi} m(B) \quad \forall A \subseteq \Omega, A \neq \phi \quad (2.16)$$

La plausibilité de A est également reliée à la crédibilité du complémentaire de A . Elle correspond à toute l'information ne créditant pas la véracité du complémentaire de A .

$$Pl(A) = 1 - Bel(\bar{A}) \quad (2.17)$$

Dans la théorie de Dempster-Shafer, on peut interpréter l'intervalle défini par $[Bel(A), Pl(A)]$ comme un encadrement de la probabilité réelle de A ; $Bel(A)$ est « la Probabilité basse » et $Pl(A)$ est « la Probabilité haute ».

La distribution de masse de croyance m et la fonction de crédibilité Bel sont deux représentations équivalentes d'une même information.

2.8.2 Combinaison des croyances

Si nous disposons de plusieurs sources d'information, et de fonctions d'allocation de masse, le problème est de combiner les informations. Par exemple pour deux sources S_1 et S_2 produisant les masses m_1 et m_2 , le vecteur de masse m par fusion ($m = m_1 \oplus m_2$), d'après la règle orthogonale de Dempster, est donné par :

$$m(H) = \frac{1}{1-K} \sum_{A \cap B = H} m_1(A).m_2(B) \quad \forall H \subseteq \Omega, \text{ et } H \neq \phi \quad (2.18)$$

$$\text{où } K = \sum_{A \cap B = \phi} m_1(A).m_2(B) \quad (2.19)$$

K est la masse de croyance conflictuelle existant entre les fonctions de croyance à combiner. Si $K = 0$, les sources sont en parfait accord mais si K est égal à 1, elles sont en conflit total. Alors, les informations ne peuvent pas être fusionnées par cette méthode.

2.8.3 La règle de décision

Une fois toutes les masses obtenues, la dernière étape est de prendre la décision. Plusieurs règles de décision sont déjà définies, le plus souvent la décision repose sur le maximum de la croyance ou de la plausibilité. A partir des fonctions de croyance, on peut considérer la probabilité pignistique [Smets90b]. Plus généralement, la fonction de décision δ pour une forme entrante x est de la forme :

$$\delta(x) = H_n \text{ avec } H_n = \arg [\max Y(H_i)], \quad H_i \in \Omega \quad (2.20)$$

où $Y(\cdot)$ est la fonction de crédibilité (bel), ou de plausibilité ou de probabilité pignistique. L'usage de fonctions de coût est présenté dans [Donoeux97].

2.8.4 Modélisation des fonctions de croyance

Si la théorie de l'évidence est employée, la modélisation des fonctions de croyance utilisée dépend, dans la plupart des cas, de l'application envisagée [Xu92], [Kim95], [Bloch96], [Appriou99], [Lefevre01], etc. Cependant, on peut regrouper les principales méthodes de modélisation de fonctions de croyance en reconnaissance de formes en deux approches : celle basée sur les vraisemblances et le théorème de Bayes généralisé proposée indépendamment dans [Appriou99] et [Smets90a], et aussi celle basée sur les distances proposée dans [Denoeux95] et [Zouhal98]. Nous nous plaçons dans la perspective de la deuxième approche et nous présentons ici une proposition importante dans ce domaine, pour d'autres propositions, voir la thèse de [Lefevre01].

2.8.5 Méthode de modélisation basée sur la distance

Plusieurs travaux ont été menés sur la modélisation des fonctions de croyance à l'aide d'une distance, ils sont présentés dans [Lefevre01]. Dans [Appriou99] et [Bouchon-Meunier95], la technique d'égalisation de données basée sur la fonction de transformation qui est une distribution cumulative des valeurs de sortie des classifieurs, a été appliquée au résultat d'un système de classifieurs multiples. Les résultats du classifieur sont alors combinés en utilisant la théorie de Dempster-Shafer avec une nouvelle fonction de support, qui est en fait une fonction d'une variable de différence entre les vecteurs de référence et de sortie d'un classifieur. Cette fonction de support une fois calculée est choisie comme fonction de croyance pour une proposition de classe.

Dans son approche [Denoeux95], Denoeux a présenté la modélisation des fonctions de croyance comme une adaptation de la méthode des plus proches voisins. Chaque source d'information est basée sur un prototype. La base d'apprentissage est constituée de prototypes, et un prototype est choisi par classe. Le choix de prototypes permet la construction d'une fonction de croyance ayant l'expression suivante :

$$m_i(\{H_n\}) = \alpha_i \phi_i(d_i), \quad m_i(\Omega) = 1 - \sum \alpha_i \phi_i(d_i) \quad (2.21)$$

où $0 < \alpha_i < 1$ est une constante, $\phi_i(\cdot)$ est une fonction décroissante monotone vérifiant $\phi_i(0) = 1$ et $\lim_{d \rightarrow \infty} \phi_i(d_i) = 0$, d_i est la distance euclidienne entre le vecteur entrant et le $i^{\text{ème}}$ prototype. La fonction ϕ_i peut être une fonction exponentielle de la forme :

$$\phi_i(d_i) = \exp^{\omega_i(d_i)^2} \quad (2.22)$$

où ω_i est un paramètre négatif associé au $i^{\text{ème}}$ prototype.

Les fonctions de croyance m_i , obtenues pour chacun des prototypes, sont ensuite fusionnées avec la règle de combinaison de Dempster. On peut remarquer que cette méthode repose sur l'estimation de plusieurs paramètres :

- nombre de voisins ou nombre de prototypes par classe,
- position des prototypes,
- valeurs de ω_i , et de α_i .

On peut regretter que les décisions soient prises par les prototypes indépendamment les uns des autres. Nous présentons notre contribution à la modélisation de la fonction de croyance dans le chapitre 5.

2.9 Théorie des possibilités (approche possibiliste)

Quelques années après avoir introduit la théorie des ensembles flous [Zadeh65], en 1978, Zadeh a proposé la théorie des possibilités à partir de sa théorie des sous ensembles flous [Zadeh78], [Zadeh79]. Elle fut ensuite développée par de nombreux auteurs tels que Dubois et Prade [Dubois85], Yager [Yager82] et [Yager83b], Kacprzyk et al. [Kacprzyk85], etc. Elle

permet de manipuler des incertitudes de nature non probabiliste. Ainsi, dans le cadre de cette théorie, les connaissances imprécises et les connaissances incertaines peuvent coexister et être traitées conjointement [Dubois84], [Dubois88b].

La théorie des possibilités considère certaines situations plus ou moins possibles par rapport à d'autres. Elle modélise, non pas un degré de croyance ou de vérité, mais plutôt la préférence que l'on a pour une proposition, c'est-à-dire un moyen de dire dans quelle mesure la réalisation d'un événement est possible et dans quelle mesure on en est certain. Dans cette théorie, on formalise donc ces deux évaluations subjectives à travers une mesure de possibilité et une mesure de nécessité. Ces deux mesures prennent leurs valeurs dans l'intervalle $[0, 1]$. Un événement est tout à fait possible si la mesure de sa possibilité est égale à 1, et impossible si celle-ci est nulle. En fait, une mesure de possibilité donne une information sur l'occurrence d'un événement A relatif à un ensemble de référence fini X , mais elle ne suffit pas pour décrire l'incertitude existant sur cet événement. Pour compléter l'information sur A , on indique le degré avec lequel la réalisation de A est certaine, par l'intermédiaire d'une mesure de nécessité, grandeur duale d'une mesure de possibilité [Dubois80].

2.9.1 Principes

Nous rappelons ici quelques principes fondamentaux de cette théorie.

Mesure de possibilité

Soit un référentiel U . On définit une mesure de possibilité Π sur l'ensemble $P(U)$ des parties de U par les trois axiomes fondamentaux suivants :

i) on peut définir la possibilité d'un événement par un coefficient (degré de possibilité) compris entre 0 et 1 : $\Pi : P(U) \rightarrow [0, 1]$

ii) l'ensemble de référence U est complètement possible ou complètement compatible avec la connaissance disponible ; on lui attribue alors le degré de possibilité maximum 1. A l'inverse l'ensemble vide reçoit le degré zéro : $\Pi(U) = 1$ et $\Pi(\emptyset) = 0$

iii) la possibilité d'un événement formé par une collection d'éléments est égale au degré de possibilité de la valeur préférée parmi ses éléments, dans le sens où la valeur préférée est celle possédant le plus grand degré de possibilité : $A_i \in P(U), \Pi(\bigcup_i A_i) = \sup_i \Pi(A_i)$.

Mesure de nécessité

La mesure de nécessité N est une mesure duale de la mesure de possibilité. $N(A)$ indique le degré avec lequel la réalisation d'un événement A est certaine. En effet, la possibilité s'avère insuffisante pour représenter l'information sur un événement puisqu'elle nous informe

uniquement sur l'occurrence de cet événement. On peut constater que deux événements A et son contraire \bar{A} peuvent être tous les deux possibles, ce qui correspond à une situation d'ignorance totale. C'est pour lever cette ambiguïté que cette mesure complémentaire a été introduite. On dit qu'un événement est certain si son événement contraire est impossible, d'où le lien entre les deux mesures.

Distribution de possibilités

Pour éviter de travailler sur l'ensemble $P(U)$ des parties de U , on définit une fonction directement sur U qu'on appelle distribution de possibilité. Elle associe à chaque élément de U une valeur dans $[0, 1]$. Afin que la distribution soit normalisée, il suffit qu'il existe un élément de U qui soit complètement possible : $\exists x_0 \in U, \pi(x_0) = 1$.

La distribution de possibilité est directement liée à la notion de mesure de possibilité par :

$$\forall A \in P(U), \quad \Pi(A) = \sup \{ \pi(x), x \in A \} \quad (2.23)$$

on a :

$$\pi(x) = \Pi(\{x\}) \quad (2.24)$$

L'expression (2.23) peut être étendue au cas où A est un sous-ensemble flou (caractérisé par sa fonction d'appartenance $\mu_A(x)$) :

$$\Pi(A) = \sup_{x \in U} \min (\mu_A(x), \pi(x)) \quad (2.25)$$

On peut noter que (2.23) et (2.25) se confondent dans le cas des ensembles ordinaires. Il suffit de prendre dans (2.25) la fonction d'appartenance correspondant aux ensembles ordinaires, appelée fonction caractéristique de l'ensemble.

Relation entre mesures de nécessité et de possibilité

$$i) \quad \forall A \in P(U), \quad N(A) = 1 - \Pi(\bar{A}) \quad (2.26)$$

$$ii) \quad \Pi(A) + N(\bar{A}) = 1$$

ii) $N(A) \leq \Pi(A)$ un événement doit d'abord être possible avant d'être nécessaire.

iii) $\Pi(A) < 1 \Leftrightarrow N(A) = 0$, $N(A) > 0 \Leftrightarrow \Pi(A) = 1$ Tout événement dont on est au moins un peu certain est possible.

iv) Si la mesure de possibilité est déterminée à partir d'une distribution de possibilités,

$$N(A) = \inf\{1 - \pi(x) \mid x \notin A\} \quad (2.27)$$

v) La nécessité d'un événement flou généralisant la relation Eq. (2.25) se déduit à partir de sa distribution de possibilité en appliquant Eq. (2.26) et en utilisant la complémentation floue :

$$N(A) = \inf_{x \in X} [\max(\mu_A(x), 1 - \pi(x))] \quad (2.28)$$

2.9.2 Obtention des distributions de possibilité

La distribution de possibilité joue un rôle primordial dans la théorie des possibilités comme la fonction d'appartenance dans la logique floue. En effet, d'après [Oussalah98] la distribution de possibilité et la fonction d'appartenance sont à la base de la modélisation d'un événement plus ou moins connu, où le degré de connaissance se trouve quantifié dans l'intervalle $[0, 1]$. $\mu_A(x)$ désigne le degré avec lequel l'élément x appartient au sous-ensemble A . De la même façon, $\pi_x(u)$ exprime le degré de possibilité avec lequel la variable de discours x prend la valeur u . Pour obtenir une distribution de possibilité [Oussalah98] a cité un panorama de méthodes utilisées pour obtenir des fonctions d'appartenance à côté de méthodes spécifiques pour la distribution de possibilité. Nous présentons ici trois méthodes importantes avec la notion de distance.

2.9.2.1 Méthode basée sur le concept de distance

Dans [Zimmerman85], une méthode basée sur le concept de distance est proposée en supposant une interprétation de la fonction d'appartenance en terme de distance à un prototype idéal. Ainsi, plus l'objet x est près de ce prototype, plus la valeur de la fonction d'appartenance est proche de 1, et inversement. Le formalisme décrit est le suivant :

$$\pi(x) = \frac{1}{1 + d(x)} \quad (2.29)$$

où $d(x)$ peut être n'importe quelle fonction de distance. $\pi(x)$ prend ses valeurs dans $[0, 1]$. Dans les cas limites où $d(x) \rightarrow 0$, $\pi(x) \rightarrow 1$ et inversement, si $d(x) \rightarrow \infty$, $\pi(x) \rightarrow 0$.

2.9.2.2 Classification floue par un algorithme de *c-means*

Un moyen d'obtenir une distribution de possibilité est de procéder par classification de données [Bezdek91], [Dave91], [Krinsnapuram93]. Le but est de générer une certaine classe, représentant au mieux l'ensemble de ces données. Le prototype de la classe est choisi a priori. L'algorithme attribue à chaque point x_i de l'ensemble des données un degré (μ_{ij}) compris entre 0 et 1, avec lequel le point x_i appartient à la classe C_j . Pour une classe donnée, μ_{ij} joue le rôle d'une fonction d'appartenance où l'univers de discours représente l'ensemble des éléments x_i à classer. L'algorithme *c-means* flous introduit par Bezdek [Bezdek91], dont les μ_{ij} et C_j sont déterminés de sorte à minimiser (2.31), exige un minimum de deux classes. Ceci est dû à la contrainte (2.30) imposée :

$$\sum_{i=1}^c \mu_{ij} = 1 \quad (2.30)$$

$$\min J(u,c) = \sum_{i=1}^n \sum_{j=1}^c u_{ij}^m \cdot d_{ij} \quad (2.31)$$

où c est le nombre de classes. De plus, pour chaque élément, la valeur 1 est partagée entre toutes les classes. D'autre part, le choix de la fonction de distance et du paramètre m permet de modifier la forme de la fonction d'appartenance.

D'autres algorithmes sont capables de générer des fonctions d'appartenance unidimensionnelles comme, par exemple, ceux de la famille des « possibilistic *c-means* » [Krinsnapuram93] et les « *c-means* avec une classe de rejet » [Dave91]. Ces algorithmes permettent, même avec une seule classe, de déterminer la répartition. Cette classification correspond à une interprétation de la distribution de possibilités en termes de distance à un prototype. En effet, les points qui sont proches du centre de la classe déterminée par l'algorithme seront affectés d'un degré de possibilité élevé. Inversement, plus on s'éloigne du prototype, plus cette valeur devient petite.

Le défaut majeur de cette méthode est de conduire généralement à un résultat non normalisé, et non convexe [Oussalah98].

2.9.2.3 Méthodes heuristiques

Les méthodes heuristiques sont basées sur un choix *a priori* de la forme de la distribution, puis une détermination de paramètres, soit par expertise, soit par une certaine

procédure d'identification (tests statistiques ou autres). Evidemment, ce genre de procédure suppose que le problème à traiter est peu sensible à la forme de la distribution de possibilités (ou fonction d'appartenance). Ce genre de démarche est très répandu dans le traitement de certains problèmes de contrôle par exemple, ainsi que dans l'analyse de quantificateurs relatifs au langage humain. Par exemple, Zadeh [Zadeh71] a défini de manière empirique (heuristique) la fonction d'appartenance des quantificateurs « très », « similaire à », « proche de », etc. Les formes les plus courantes sont les formes triangulaires, trapézoïdales ou les fonctions en S. Nous présentons notre contribution à l'obtention des distributions de possibilité à partir d'une fonction d'appartenance floue dans le chapitre 5.

2.9.3 Opérateurs de fusion

De nombreux opérateurs de fusion d'informations issus de plusieurs sources sont proposés dans la littérature. Le choix d'un type d'opérateur (conjonction, disjonction, adaptatif, etc.), se base sur la fiabilité, le conflit et l'interdépendance des données fournies par les sources d'informations.

Supposons que l'information de chaque source (S_j $j = 1, \dots, L$) soit supportée par une distribution de possibilité. Les combinaisons conjonctives et disjonctives sont interprétées respectivement en termes d'intersection et d'union des distributions de possibilité des sources :

$$\pi_{\wedge}(x) = \bigcap_{j=1}^L \pi_j(x) \quad (2.32)$$

$$\pi_{\vee}(x) = \bigcup_{j=1}^L \pi_j(x) \quad (2.33)$$

L'opérateur de conjonction (t-norme) correspond à un consensus entre les informations. Il permet une satisfaction simultanée des contraintes induites par le processus de fusion. Naturellement, ce comportement se comprend seulement si les informations sont tout à fait fiables et si les sources ne sont pas conflictuelles, dans le sens qu'elles soulignent le même intérêt. Autrement, si les sources ont différentes fiabilités, alors le choix le plus fiable doit être une option plus prudente plutôt que la recherche d'un consensus. Par conséquent, sous certaines hypothèses, il n'y a aucun risque à relaxer l'information appropriée en limitant le procédé de combinaison seulement à la connaissance commune.

En revanche, l'opérateur de disjonction (t-conorme) correspond à une prétention très faible au sujet de la fiabilité des sources et suppose qu'au moins une d'entre elles soit fiable. À la différence d'un mode conjonctif, l'opération disjonctive induit le résultat le plus imprécis, et sa certitude correspond au moins à une partie certaine d'informations. Tandis que dans le cas d'une conjonction, la certitude assignée au résultat est au plus égale à une partie moins certaine parmi les informations.

Des opérateurs de conjonction et de disjonction sont souvent modélisés en tant qu'opérateurs respectivement d'intersection et d'union d'ensembles flous. Une attitude intermédiaire entre la disjonction et les modes de conjonction est un mode de compromis où le résultat se trouve entre la plus petite et la plus grande partie certaine parmi les informations initiales. Ceci inclut tous les opérateurs de moyenne, qui peuvent être employés dans la théorie des probabilités aussi bien que dans les théories des ensembles flous et des possibilités [Oussalah03].

Cependant, quand les hypothèses sont affaiblies, l'utilisation d'une combinaison conjonctive peut être remise en cause, et habituellement elle est moins significative en termes de pertinence de l'information résultante, et peut mener à des contradictions. Comme les solutions sont des pondérations de sources, considérons une source associée à la distribution π_i et supposons que l'on connaisse le degré de fiabilité w_i de cette source. Alors, on pourra représenter cette nouvelle information par la distribution π_i' :

$$\forall u, \pi_i'(u) = \max(\pi_i(u), 1 - w_i) \quad (2.34)$$

Cette formulation est en fait un cas particulier de la qualification « α -certitude » [Dubois91], [Yager92]. Dans les cas limites, on retrouve bien le cas classique. Si $w_i = 1$, la source est complètement fiable ($\pi_i'(u) = \pi_i(u)$). Si $w_i = 0$, on n'a aucune fiabilité sur la donnée de la source et on retrouve alors l'ignorance totale ($\pi_i'(u) = 1$). Ainsi, pour combiner de façon conjonctive l'ensemble des sources dont les fiabilités sont connues, dans [Dubois86] est proposée la combinaison min pondérée :

$$\forall u, \pi'(u) = \min_i \pi_i' = \min_i \max(\pi_i(u), 1 - w_i) \quad (2.35)$$

Un autre type de combinaison (adaptative), intermédiaire entre les deux précédentes, a été proposé par Dubois et Prade [Dubois92], [Dubois94]. La propriété de l'opérateur adaptatif

est intéressante dans le sens qu'il évolue progressivement d'une combinaison conjonctive à un mode disjonctif dès que le conflit entre les sources augmente.

Le degré de compatibilité (conflit) des sources est défini par :

$$h(\pi_1(x), \pi_2(x)) = \max_x(\min(\pi_1(x), \pi_2(x)))$$

Si $h(\pi_1(x), \pi_2(x)) = 0$ on a le cas de la disjonction

Si $h(\pi_1(x), \pi_2(x)) = 1$ c'est le cas de la conjonction

Si $h(\pi_1(x), \pi_2(x)) > 0$, la règle est de la forme

$$\pi_{1,2} = \max\left(\frac{\pi_1(x) \wedge \pi_2(x)}{h(\pi_1(x), \pi_2(x))}, \min(1 - h(\pi_1(x), \pi_2(x)), \pi_1(x) \vee \pi_2(x))\right)$$

Sinon, $\pi_{1,2} = \pi_1(x) \vee \pi_2(x)$ 2.36

La figure 2.4 donne des exemples de combinaison des distributions π_1 et π_2 de sources concordantes et discordantes par cette règle.

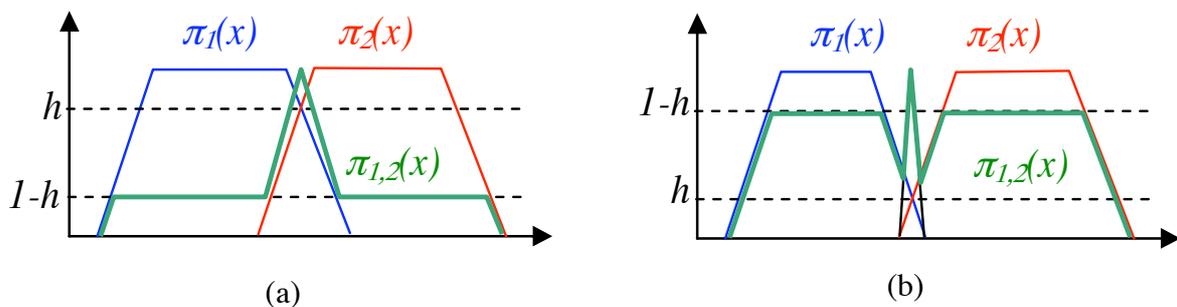


Figure 2.2 : (a) Combinaison adaptative des sources concordantes (b) Combinaison adaptative des sources discordantes.

2.10 Conclusion

Dans ce chapitre, nous avons présenté un état de l'art sur les méthodes de fusion de données. Nous avons mis l'accent sur le grand nombre de ces méthodes de fusion. Nous avons indiqué quelques points forts et faibles de chaque méthode qui mettent en évidence le

fait qu'elles ne sont pas toutes de même qualité. Les méthodes de fusion présentées ont été appliquées sur des données réelles dans divers domaines mais il n'est pas aisé non plus de prouver que telle méthode de fusion convient mieux que telle autre pour tout problème de reconnaissance. Par conséquent, les résultats obtenus restent étroitement liés à ces données et donc difficiles à généraliser pour d'autres applications. Nous avons aussi étudié ces méthodes sur nos jeux de données réelles et dans les chapitres suivants nous citons les résultats expérimentaux obtenus.

Pour appliquer les théories de l'incertain et en particulier la théorie des sous-ensembles flous, la théorie de l'évidence et la théorie des possibilités, il n'existe pas d'approches génériques pour obtenir la fonction d'appartenance floue, les fonctions de masses de croyance et les distributions de possibilité. Aussi, nous avons proposé une définition de fonction d'appartenance floue avec l'aide de l'information de distance et nous indiquons notre contribution.

Chapitre 3

La place des k-ppv en reconnaissance de formes

La reconnaissance de formes est un domaine de recherche très actif ayant une vaste diversité d'applications réelles. Dans ce chapitre, nous décrivons dans la première partie quelques principes de la reconnaissance de formes et dans la partie suivante les outils utilisés et proposés pour la classification des formes dans la littérature. Parmi ces méthodes, nous avons retenu un classifieur de distance et plus précisément le classifieur de la règle des k-plus proches voisins. Nous citons ici quelques notions fondamentales sur les classifieurs de distance et la classification basée sur la règle des k-plus proches voisins comme un exemple de méthode de classification dans un processus de reconnaissance de formes.

3.1 Reconnaissance de formes

Il ne s'agit pas pour nous de procéder à un exposé exhaustif sur ce vaste domaine, mais simplement de rappeler la problématique et ses principaux éléments afin de préciser le contexte de notre travail.

3.1.1 Introduction

La reconnaissance de formes est une capacité commune à tous les organismes vivants. Cependant, les différentes créatures reconnaissent de manières différentes. Un homme peut reconnaître une autre personne par son visage, par sa voix, ou bien par son écriture manuscrite etc. mais un chien reconnaît une personne ou un autre chien par son odorat. Un aveugle reconnaît des objets en les touchant. Tous ces exemples sont à classer dans le domaine de la *reconnaissance*. L'objet inspecté dans le processus de la reconnaissance est appelé une *forme*.

La reconnaissance de formes (Rdf) peut être définie comme une science ayant pour objectif la conception d'algorithmes permettant de mettre en évidence une structure au sein d'un ensemble de données. Les méthodes de reconnaissance de formes possèdent un vaste champ d'application. Un système peut être décrit par un ensemble d'états, correspondant chacun à une forme. Il peut posséder un ou plusieurs modes normaux, connus a priori, et un

nombre généralement inconnu de modes anormaux. En terme de reconnaissance de formes, chaque état se traduit par une classe et les mesures observées sur le système constituent le *vecteur forme* noté x .

D'après [Bow92] les étapes de la reconnaissance de formes sont au nombre de trois: acquisition des données, pré-traitement des données, et classification et décision comme indiqué dans la figure 3.1

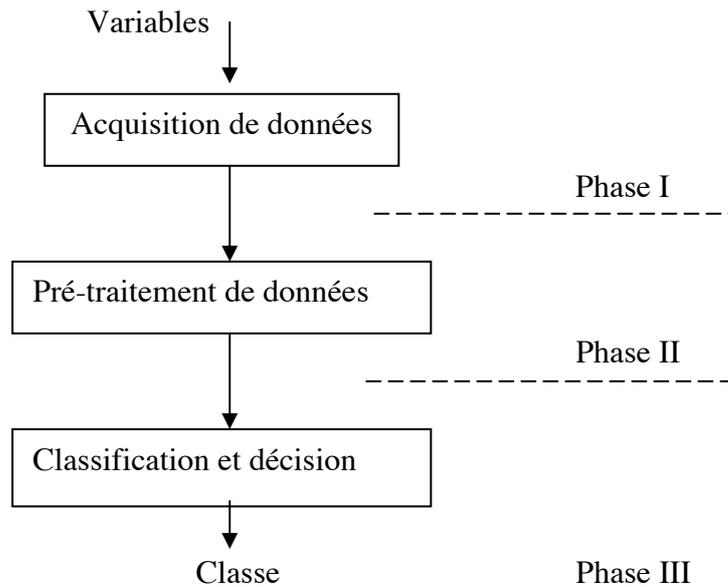


Figure 3.1 : Représentation conceptuelle d'un problème de la reconnaissance de formes.

Dans la phase d'acquisition des données, les données analogiques du monde physique sont obtenues par un transducteur (ou par un scanner) et sont converties en un format digital pour être traitées par la machine. La phase d'analyse qui consiste à concevoir un module de pré-traitement des données comporte les points suivants :

- définir le système,
- préciser les modes de fonctionnement de ce système,
- choisir une source d'information
- définir et sélectionner les caractères à extraire de l'information, c'est à dire préciser l'espace de représentation.

La phase de conception du système de décision consiste à choisir une ou plusieurs techniques de discrimination, puis à construire par apprentissage la fonction de décision à partir des données disponibles. Le choix d'une technique doit être fait selon un certain

nombre de critères (performance, temps d'apprentissage, temps de calcul de la fonction de décision, etc.). Parmi les systèmes de décision les plus couramment utilisés, on peut citer :

Les méthodes paramétriques basées sur la règle de Bayes, les méthodes non paramétriques reposant sur l'estimation des lois de probabilité (e.g. la règle des k-ppv et les méthodes à noyaux), les méthodes reposant sur le calcul direct des frontières dans l'espace de représentation, les réseaux de neurones, etc.

La phase d'exploitation au cours de laquelle le système est implanté, permet alors d'associer à toute nouvelle observation recueillie par le système, une des classes connues en appliquant la règle de décision. Le système retenu doit être capable d'adapter sa fonction de décision en tenant compte de l'enrichissement de la base de données et de l'apparition de nouvelles classes.

Un concept dominant en reconnaissance de formes est la classification. Une classe consiste en un certain nombre d'objets similaires (formes) groupés ensemble. Ici le choix des données en entrée du processus de la reconnaissance est très important. Le travail consiste à diviser les données en grands groupes (ou classes) et à établir leurs frontières. Si on connaît le nombre de groupes a priori alors la tâche est assez simple. On réalise alors un processus d'apprentissage supervisé, dans le cas contraire on fait un apprentissage non supervisé.

Analysant le processus de Rdf, on peut déduire que dans le domaine de la reconnaissance de formes, deux étapes très importantes sont l'extraction des caractéristiques et la classification [Gorman03]. Les outils et les méthodes appliqués sont nombreux. Nous allons alors en parler en détail dans les sections suivantes.

3.1.2 Caractéristiques

Un problème de reconnaissance de formes a pour objectif de placer des formes dans des classes, en fonction d'un critère. On désire atteindre la capacité de reconnaissance humaine. Pour cela, il faut exploiter et interpréter un certain nombre d'indices (ou caractéristiques) extraits d'une forme inconnue, de manière à produire une hypothèse sur sa classe d'appartenance. Ainsi, chaque vecteur forme noté x appartient à l'espace D des caractéristiques.

En pratique, d'énormes difficultés se présentent. Les problèmes concernent, en premier lieu, le choix des caractéristiques qui doivent être représentatives de l'ensemble des formes à reconnaître. Ce choix est important car il conditionne toute la méthodologie mise en œuvre pour la reconnaissance. Enfin, en supposant ces caractéristiques connues, il est souvent difficile de définir un ensemble de règles permettant de les exploiter. En d'autres termes, il est

souvent impossible de définir dans un système une méthodologie a priori permettant d'exploiter ces indices, en vue de procéder à une reconnaissance.

Pour un problème spécifique de reconnaissance, de nombreux types de caractéristiques ont pu être employés pour représenter et identifier des formes. Quelques exemples sont présentés :

- en reconnaissance des caractères, les caractéristiques utilisables peuvent venir de la densité des points, des moments, des lieux caractéristiques, des transformées mathématiques (Fourier, Walsh, Hadamard...), elles peuvent également venir des squelettes ou des contours.
- dans des applications liées à l'analyse de texture telles que télédétection et analyse des scènes, les caractéristiques utilisables peuvent venir de la matrice de co-occurrence, des descripteurs de Fourier, du spectre de puissance, des moments, aussi bien que de diverses primitives structurelles.
- dans l'analyse et la reconnaissance de formes d'ondes telles que le signal sismique, l'EEG et l'ECG, la parole aussi bien que les images de formes courbes, les caractéristiques utilisables peuvent venir du spectre de puissance, de la modélisation AR, de fonctions d'approximation, des zero crossing, et de plusieurs types de segments de traits structurels.

3.1.3 Classifieurs

Dans presque tous les domaines d'application de la reconnaissance de formes, un certain nombre d'algorithmes de classification sont disponibles. Ces algorithmes sont basés sur différentes théories. Nous distinguons deux grands groupes de méthodes, notamment, celles basées sur un vecteur de caractéristiques et les méthodes syntaxiques et structurelles. En outre, chaque groupe inclut de nombreux algorithmes basés sur une variété de méthodologies, par exemple, dans le premier groupe : les classifieurs de Bayes, différents classifieurs de distances, les k-plus proches voisins et des réseaux des neurones, etc.

On peut aussi distinguer les méthodes de classification selon qu'elles sont paramétriques ou non paramétriques. Les premières reposent sur des hypothèses strictes concernant les formalismes des probabilités conditionnelles des différentes classes. En pratique, la vérification de ces hypothèses est souvent délicate, et l'on a recours à des méthodes non paramétriques plus générales.

Selon les connaissances disponibles, on utilise différentes approches. Si on dispose d'un ensemble d'apprentissage pour lequel on connaît a priori les classes d'appartenance,

l'apprentissage est supervisé. Dans le cas contraire, il convient d'extraire cette connaissance manquante de l'ensemble d'apprentissage, en utilisant uniquement des informations de proximité entre les observations pour définir les classes.

Les méthodes usuelles de Rdf supposent généralement une connaissance complète des classes. Mais une méthode de Rdf doit être capable d'adapter sa règle de décision à l'évolution du système. Les options de rejet offrent des solutions à ce problème en permettant de différer la décision lorsque l'information disponible pour classer un nouveau vecteur n'est pas suffisante.

Dans la section suivante, nous citons quelques exemples de méthodes de classification en mettant l'accent sur leurs points forts et leurs limitations et en particulier les méthodes reposant sur un calcul des distances, plus précisément les approches des k-ppv.

3.2 Méthodes de classement

Les méthodes de classification s'appliquent dans des domaines d'application divers tels la reconnaissance de formes et l'intelligence artificielle, les statistiques, la psychologie cognitive, la vision, et la médecine. Très souvent les méthodes proposées emploient des principes statistiques tels que des classifieurs linéaires discriminants reposant sur une analyse ou une régression. D'autres algorithmes emploient les réseaux de neurones. Un des inconvénients majeurs de ces approches classiques est leur limitation à distinguer des classes de formes non convexes [Devillez04]. Ces limites sont dépassées par quelques approches bien connues comme l'algorithme des k-plus proches voisins [Cover67], [Keller85] et les fonctions radiales de base (FRB) [Broomhead88], [Belloir99]. D'autres méthodes de classification ont été développées pour la classification des données reposant sur la théorie des ensembles flous introduite par Zadeh [Zadah65]. En effet parfois, ce n'est pas possible de choisir un classement d'une forme entre des classes disjointes. L'adéquation d'une forme aux caractéristiques des prototypes qui définissent une classe peut être indiquée par un degré d'appartenance [Dubois98]. Dès sa naissance, la logique floue a été appliquée à la reconnaissance [Dubois80], [Klir95], [Yager87], [Kruse94], etc. [Baldwin99] a présenté un modèle cartésien flou de caractéristiques basé sur l'agrégation de concepts qualitatifs flous, représenté par les ensembles flous fusionnés afin d'obtenir une décision de classification. D'autres méthodes proposées sont basées sur les arbres de décision flous [Baldwin97], [Janikow96]. Des variables linguistiques sont liées avec des règles SI ALORS dans un arbre. Chaque branche de l'arbre est pondérée par une probabilité. Chaque chemin de la racine aux feuilles de l'arbre représente une règle de décision. En raison de son importance, la logique

floue est utilisée de plus en plus conjointement avec d'autres méthodes et elle a donné naissance à des méthodes hybrides.

Le choix d'une méthode pour un problème donné est très difficile. Les méthodes développées ont des performances variables selon l'application. Clairement, plus on connaît d'information a priori, plus l'algorithme peut refléter la situation réelle. Par exemple, si les probabilités a priori et les densités conditionnelles d'état de toutes les classes sont connues, l'approche bayésienne produit des résultats optimaux dans le sens qu'elle réduit au minimum le taux d'erreur de classement [Dubois90]. Cependant, dans beaucoup de problèmes effectifs de reconnaissance de formes, le classement d'une forme entrante est basé sur des données où le nombre d'éléments de l'échantillon représentatif de chaque classe est trop petit et probablement non représentatif des distributions réelles de probabilités. Dans ces cas, beaucoup de techniques se fondent sur une certaine notion de similitude ou de distance dans l'espace des caractéristiques, par exemple, par classement et analyse discriminante. Dans la littérature, les chercheurs ont comparé les différentes méthodes de classification dans divers domaines. Nous citons quelques études comparatives de ces différentes méthodes en particulier dans le domaine de la reconnaissance des formes, parfois les chercheurs ont aussi précisé les temps de calcul [Denoeux95], [Denoeux00], [Kuncheva98], [Devillez04], [Billaude199], [Gascuel98], [Klein98]. Parmi les méthodes proposées, nous avons retenu l'approche des k-plus proches voisins à cause de sa simplicité de mise en œuvre et de l'absence de complexité de l'apprentissage, car c'est une méthode non paramétrique et une approche robuste. Dans la section suivante, nous décrivons le principe de cette approche et les différentes versions proposées dans la littérature pour son amélioration.

3.2.1 Classifieur de distance

Un classifieur de distance e_i réalise la reconnaissance des formes selon une fonction de distance. La distance d_i ($i = 1, \dots, n$) est mesurée entre une forme inconnue « x » et les n centres (ou les n prototypes x_i) des classes C_j , $j = 1, \dots, M$. La fonction de distance $f(d^{e_i}(x, x_i))$ où $e(i = 1, \dots, L)$ représente un classifieur sera simplement notée $f(d(x, x_i))$. Le principe est illustré sur la figure 3.2.

Soit D le domaine de données contenant n vecteurs d'échantillons de dimension d . Dans l'espace il y a des vecteurs de caractéristiques étiquetés et d'autres inconnus. L'objectif est de les étiqueter avec l'aide de ceux qui sont actuellement étiquetés dans D . Dans la figure 3.3, nous avons deux classes de formes, une notée avec des cercles « O » et l'autre avec des croix « \times ».

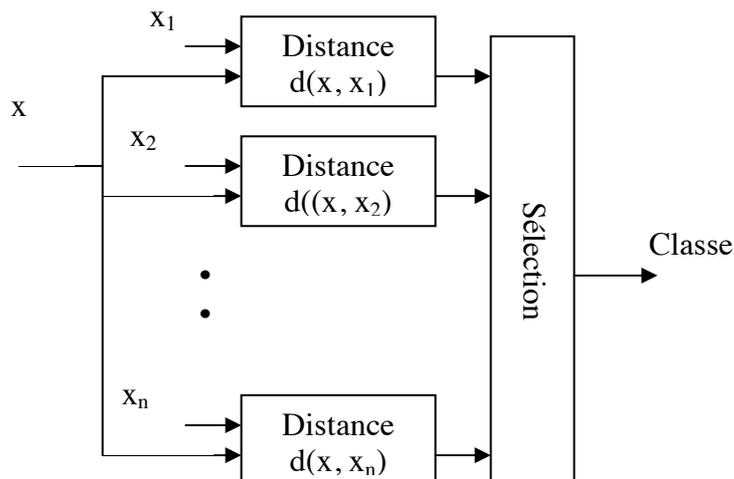


Figure 3.2 : Schéma général de sélection de la classe dans un classifieur de distance.

Nous avons aussi fait figurer un vecteur inconnu, avec le symbole « + », dont on cherche à identifier la classe d'appartenance. Une méthode consiste à déterminer le plus proche vecteur en mesurant la distance entre la forme inconnue et tous les autres cercles et croix selon une certaine métrique (par exemple Euclidienne, Manhattan, Chebychev, Minkowski, Mahalanobis, etc.). La classe contenant le maximum d'éléments avec les plus faibles distances indiquera l'étiquette. De cette façon, après avoir construit plusieurs vecteurs de caractéristiques pour les différentes formes, on calcule les distances et les résultats constituent un classifieur appelé classifieur de distance.

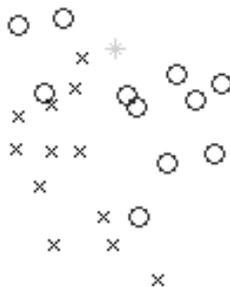


Figure 3.3 : Exemple en 2 dimensions : Les vecteurs des 2 classes étiquetés en o et x.

3.2.2 Classifieur des k-ppv

Parmi les méthodes d'analyse discriminante les plus simples et intuitivement séduisantes, l'algorithme non paramétrique des k-plus proches voisins (k-ppv) est largement utilisé. La première formulation d'une règle du type plus proche voisin semble avoir été faite par [Fix51] et depuis elle est devenue une approche bien classique dans la littérature sur la reconnaissance de formes et a pris le nom de règle des k-plus proches voisins basée sur un vote.

Un classifieur des k-plus proches voisins (k-ppv) fait une classification reposant en fait sur l'estimation de la fonction densité de probabilité. Soit, $C = \{(x_1, C_{x_1}), (x_2, C_{x_2}), \dots, (x_n, C_{x_n})\}$ un ensemble de points (formes) étiquetés. Si x_{n+1} est une nouvelle forme inconnue, le principe de la règle des k-ppv est le suivant :

x_{n+1} est affecté à la classe C_q majoritairement représentée parmi ses k plus proches voisins (k-ppv), où q représente une classe parmi les M classes présentes dans la base de données.

Initialement, la règle du plus proche voisin ne tenait compte que du plus proche voisin [Cover67]. Ensuite, cette idée a été étendue aux k-plus proches voisins. La définition de la notion de plus proche voisin est liée au choix d'une distance d. Plusieurs études ont été menées afin de réduire le temps de recherche des k plus proches voisins, notamment lorsque la base d'apprentissage est importante.

Dans le cas où une classe est majoritaire parmi les k-plus proches voisins, cette règle n'a pas de difficulté pour prendre la décision, mais il y a très souvent des cas d'égalité (ambiguïtés) entre les classes contenant les nombres maxima de voisins parmi les k-plus proches voisins. Dans un cas d'ambiguïté, plusieurs propositions ont été faites pour résoudre le problème. Une manière simple est de limiter les valeurs possibles de k ; par exemple, étant donné un problème à deux classes, si nous limitons k aux valeurs impaires seulement, l'existence d'égalité ne sera pas possible. Naturellement, quand plus de deux classes sont possibles, cette technique n'est pas utile. Parmi les moyens de traiter l'occurrence d'une égalité nous indiquons une solution possible. L'échantillon d'entrée est assigné parmi les classes d'ambiguïté à la classe pour laquelle la somme de distances de l'échantillon à chaque voisin de la classe est le minimum. Logiquement, ceci pourrait encore mener à une ambiguïté, dans ce cas là, la classe de x choisie est celle de la dernière classe rencontrée parmi les classes d'ambiguïté, mais c'est une assignation arbitraire. Clairement, il y aura des cas où la

classification d'un échantillon x devient une assignation arbitraire en suivant n'importe laquelle des procédures additionnelles qui sont incluses dans l'algorithme [Keller85].

Dans [Cover67] une étude rigoureuse exhaustive des propriétés de cette règle est faite et indique statistiquement les limites inférieure et supérieure de la probabilité d'erreur. Il a été montré que si le nombre d'échantillons n et k tendent tous les deux vers l'infini tout en vérifiant que $k/n \rightarrow 0$, le taux d'erreur de la règle des k -ppv tend vers le double de l'erreur optimale de Bayes. Au delà de cette propriété remarquable, sa simplicité de programmation et son caractère non paramétrique et, peut-être, les bons résultats obtenus dans des applications pratiques, ont toujours maintenu l'attention de la communauté des chercheurs dans le domaine de la reconnaissance de formes. On a trouvé par exemple que la classification par la règle des k -ppv convient bien aux domaines des problèmes caractérisés par des données partiellement connues seulement du système avant l'emploi. Cependant la méthode a quelques inconvénients. En particulier la même importance est attribuée à chacun des voisins de x dans l'attribution de l'étiquette de sa classe. Ceci conduit fréquemment à des difficultés dans les cas où les ensembles de caractéristiques des échantillons se chevauchent. Aux vecteurs atypiques est donné autant de poids qu'à ceux vraiment représentatifs des classes. Il n'y a aucune indication du degré d'appartenance d'un élément même connu à une classe. C'est la raison pour laquelle l'amélioration de cette règle est restée un domaine actif de recherche depuis les 40 dernières années [Denoeux95]. Ainsi, diverses versions et améliorations de la règle des k -ppv ont été proposées par beaucoup de chercheurs [Dudani76], [Keller85], [Denoeux95], [Janikow96], etc.

Maintenant, nous décrivons quelques variantes importantes des k -ppv proposées dans la littérature.

3.2.3 La règle des k -ppv avec pondération des distances

L'inconvénient principal de la règle de vote des k -ppv est qu'elle suppose implicitement que les k -plus proches voisins d'un échantillon x sont contenus dans une région de volume relativement petite, de telle sorte que les différentes densités conditionnelles soient évaluées avec une résolution suffisamment bonne. Dans la pratique, cependant, la distance entre x et un de ses plus proches voisins n'est pas toujours négligeable, et peut même devenir très grande en dehors des régions de forte densité. Ceci a plusieurs conséquences. D'abord, on peut remettre en cause qu'il soit raisonnable et justifiable de donner des poids égaux à tous les voisins indépendamment de leurs distances, dans la phase de décision concernant la classe de l'échantillon x inconnu. Ainsi, un nouveau concept a été proposé par [Dudani76] qui a suggéré

de donner plus de poids à l'évidence d'un voisin plus près d'un échantillon x inconnu qu'à un autre voisin qui est plus loin. Il a défini une fonction de pondération, dont la valeur diminue avec l'augmentation de la distance entre l'échantillon x et ses voisins. Cette règle des k -ppv a été alors appelée "la règle des k -ppv avec des distances pondérées".

Supposons que $X = \{x_1, x_2, \dots, x_n\}$ soit un ensemble de n échantillons étiquetés et utilisé comme ensemble d'apprentissage (collection d'échantillons correctement classifiés). Les éléments appartiennent à un ensemble de classes $C = \{C_1, C_2, \dots, C_M\}$. Quand un échantillon inconnu x doit être classifié, ses k -plus proches voisins (selon une métrique appropriée d) sont déterminés. Supposons que ces k -plus proches voisins de x avec leurs classes associées, soient donnés par $\{(x_i, C_j), i = 1, \dots, k \text{ et } j = 1, \dots, M\}$. Les voisins (x_i, C_j) , sont ordonnés de telle sorte que x_1 soit le plus proche de x et x_k le plus loin de l'échantillon x inconnu. Une définition possible des poids w_i attribués aux plus proches voisins est :

$$w_j = \begin{cases} \frac{d(x, x_k) - d(x, x_i)}{d(x, x_k) - d(x, x_1)} & \text{si } d(x, x_k) \neq d(x, x_1) \\ 1 & \text{si } d(x, x_k) = d(x, x_1) \end{cases} \quad (3.1)$$

Il doit être noté que la valeur de w_j varie d'une valeur maximum de 1 pour le plus proche voisin à une valeur minimum de zéro pour le plus éloigné parmi les k plus proches voisins. Après avoir calculé les poids w_j , la règle des k -plus proches voisins avec distance pondérée assigne alors l'échantillon x à une classe pour laquelle la somme des distances pondérées à ses représentants dans les k -plus proches voisins obtient la plus grande valeur. Dans le cas d'égalité de sommes des poids, l'échantillon x est classifié dans la dernière classe rencontrée parmi les classes qui présentent ambiguïté. Il peut être noté dans la définition de la fonction de pondération à base de distance donnée dans l'Equation 3.1, qu'il est préférable de considérer cette méthode pour les valeurs de k supérieures à 3.

Selon [Dudani76], cette règle fournit des taux d'erreur inférieurs à ceux obtenus en utilisant le procédé de vote des k -ppv pour certains jeux de données particuliers. Cependant, tous les avis ne sont pas aussi favorables. Certains indiquent des résultats moins optimistes [Baily78], [Morin81] arguant que la règle des k -ppv avec distances pondérées n'est pas adaptée pour des échantillons de petite taille et les problèmes d'ambiguïté doivent être résolus d'une façon judicieuse. Cependant, [MacLeod87] a donné des arguments prouvant que cette

conclusion ne s'applique pas si l'ensemble d'apprentissage est fini. [MacLeod87] a également proposé une prolongation simple de la règle de [Dudani76] tenant compte du $k^{\text{ème}}$ voisin (le dernier) plus efficacement dans la conclusion.

Indépendamment de cette discussion, dans quelques domaines d'application comme l'identification de cible ou les problèmes de diagnostic, il arrive que toutes les classes ne soient pas représentées dans l'ensemble d'apprentissage. Dans ces cas, il peut être sage de considérer qu'un échantillon d'entrée, loin des échantillons précédemment étiquetés, appartient le plus probablement à une classe inconnue pour laquelle aucune information n'a été donnée dans l'ensemble d'apprentissage, et cet échantillon devrait donc être rejeté [Hellman70]. Quelques années plus tard, [Dasarathy80] a proposé une règle des k -ppv où une option de rejet à base de distance est retenue par introduction du concept de voisin acceptable, défini comme un voisin dont la distance à l'échantillon à reconnaître est plus petite qu'un certain seuil fixé à partir de l'ensemble d'apprentissage. S'il y a moins d'un certain nombre de voisins acceptables d'une même classe prédéfinie dans les k -ppv, l'échantillon est rejeté et considéré comme un candidat pour une nouvelle classe.

3.2.4 L'approche des k -ppv floue

Une autre classe importante de règles des k -ppv est basée sur le concept de la logique floue. Les chercheurs travaillant avec les outils flous indiquent que la règle de vote des k -ppv n'offre aucune manière évidente de faire face à l'incertitude ou à l'imprécision dans l'étiquetage des formes. Ceci peut être un problème important dans certaines applications pratiques, où l'identité vraie des échantillons de l'ensemble d'apprentissage n'est pas toujours connue ou même n'est pas définie clairement, et doit être déterminée par un expert. D'un autre point de vue, les échantillons, même correctement étiquetés, ont un certain degré de « typicalité » selon leur distance aux centres des classes. Aux vecteurs atypiques devrait être donné moins de poids dans la décision [Keller85].

La théorie des ensembles flous offre un formalisme pour manipuler l'imprécision et l'incertitude dans un processus de décision, et quelques règles floues associées à la méthode des k -ppv ont été proposées [Jozwik83], [Keller85]. Dans cette approche, le degré d'appartenance d'un échantillon x à chacune des M classes est indiqué par un nombre u_i , avec les propriétés suivantes :

$$u_i \in [0, 1], \quad \sum_{i=1}^M u_i = 1. \quad (3.3)$$

Les coefficients d'appartenance u_i sont donnés en général par des experts ou calculés en utilisant les informations portées par les voisins de chaque échantillon dans l'ensemble d'apprentissage. Le degré d'appartenance d'un échantillon inconnu à chaque classe est alors déterminé en combinant les appartenances de ses voisins à chaque classe. Dans [Keller85] une règle des k-ppv floue est proposée dans laquelle le degré d'appartenance est une fonction à la fois de la distance entre l'échantillon x et ses k-plus proches voisins, et des degrés d'appartenance de ses voisins aux classes possibles. Le formalisme proposé est décrit par la formule suivante :

$$u_i(x) = \frac{\sum_{j=1}^k u_{ij} [d(x, x_j)]^{\frac{2}{(1-m)}}}{\sum_{j=1}^k [d(x, x_j)]^{\frac{2}{(1-m)}}} \quad (3.4)$$

Dans l'équation 3.4 u_{ij} est le degré d'appartenance du $j^{\text{ème}}$ plus proche voisin de x à la classe i . Comme on peut le remarquer dans l'équation 3.4, les degrés d'appartenance assignés à x sont influencés par les distances aux plus proches voisins et par leurs degrés d'appartenance aux différentes classes. La puissance sert à donner plus de poids à un échantillon si il est plus proche de x et moins si il est plus loin de l'échantillon considéré x . La variable m détermine l'importance avec laquelle la distance doit être pondérée en calculant la contribution de chaque voisin au degré d'appartenance.

Dans l'implémentation de la règle des k-ppv floue, les degrés d'appartenance de chaque échantillon étiqueté par rapport à toutes les classes doivent être initialisés, c'est-à-dire que tous les u_{ij} dans l'équation 3.4 doivent être déterminés. Selon [Keller85], plusieurs manières sont possibles :

- La première méthode, dite « étiquetage net », consiste à assigner à chaque échantillon étiqueté la valeur 1 pour la classe étiquetée et zéro comme degré d'appartenance à toutes les autres classes.
- La deuxième technique assigne les degrés d'appartenance selon le procédé présenté dans [Jozwik83]. Cette technique fonctionne seulement sur des données appartenant à deux classes. Le procédé assigne le degré d'appartenance d'un échantillon à sa

classe connue en fonction de sa distance moyenne aux échantillons étiquetés de la classe. Ces degrés d'appartenance varient d'une valeur 1 à une valeur 0,5 avec une variation exponentielle entre ces limites. Le degré d'appartenance de l'échantillon à l'autre classe est le complément à un.

- La troisième méthode que nous décrivons assigne les degrés d'appartenance des échantillons étiquetés selon une règle des k-plus proches voisins. Les k-plus proches voisins de chaque échantillon x (supposons x dans la classe i) sont déterminés, et les degrés d'appartenance à chaque classe sont calculés selon les équations suivantes :

$$u_j(x) = \begin{cases} 0,51 + 0,49 \left(\frac{n_j}{3} \right) & \text{si } j = i, \\ 0,49 \left(\frac{n_j}{3} \right) & \text{si } j \neq i, \end{cases} \quad (3.5)$$

La valeur n_j désigne le nombre des voisins de la classe C_j trouvés parmi les k-plus proches voisins. Cette méthode essaie donc premièrement de "fuzzifier" les appartenances des échantillons étiquetés qui sont dans les régions de chevauchement des classes dans l'espace des caractéristiques, et deuxièmement laisse les échantillons qui sont comparativement loin de ces zones avec une appartenance complète dans la classe connue. En conséquence, un échantillon inconnu se situant dans cette région d'intersection sera peu influencé par les échantillons étiquetés qui sont dans la zone "floue" de la frontière de classe.

Au delà d'une amélioration de la performance de classification par apport au procédé des k-ppv nets, la règle des k-ppv floue permet de prendre en compte une information plus riche lors de la décision du classifieur en fournissant les degrés d'appartenance qui peuvent servir comme mesure de confiance dans la classification. Dans la section prochaine, nous décrivons en résumé quelques travaux importants dans le domaine de la règle des k-ppv et ensuite nous détaillons notre contribution.

3.2.5 Les techniques de plus proche prototype dans la règle des k-ppv

Afin de réduire les immenses demandes de stockage et les calculs très lourds liés à la règle des k-ppv, divers efforts pour choisir un sous-ensemble optimal de référence à partir d'un jeu de données initiales sont présentés dans la littérature. Une perspective est de choisir quelques objets dans l'ensemble des échantillons, comme précisé par [Dasarathy90]. Cela doit permettre de réaliser un résultat de classification que l'on espère plus rapide plus précis et

plus fiable. De nombreuses techniques sont résumées par [Dasarathy90], [Dasarathy94], [Devijver80], [Kuncheva95], et [Bezdek01]. Dans [Kuncheva95] trois grandes catégories sont formulées. De plus des subdivisions sont envisagées en fonction de la stratégie de choix des prototypes représentatifs des classes et du niveau de la classification pré supervisée ou post supervisée. Un autre critère pour classer les méthodes est la gestion des échantillons mal classés. Il existe des propositions qui maintiennent les échantillons dans les ensembles de référence (techniques de condensation) voir [Hart68], [Dasarathy94], etc., d'autres proposent de les rejeter (techniques d'erreur), par exemple, on peut citer la méthode de Wilson [Wilson72], la méthode de Multi-edition [Devijver80], [Devijver82], il y a des techniques également avec une stratégie libre (garder ou éliminer) utilisant une recherche aléatoire [Shalak94], les algorithmes génétiques [Kuncheva95], [Kuncheva97], ou une recherche Tabou [Ferri98]. Les autres suggèrent de remplacer les échantillons mal classés par quelques nouveaux prototypes recherchant à couvrir l'espace entier de caractéristiques (techniques de remplacement). Une grande catégorie de techniques de remplacement utilise par exemple les réseaux de neurones, la quantification vectorielle (Learning vector quantization) [Kohonen95], [Odorico97], [Xie93], les surfaces de décision croissantes (Decision surface mapping) [Geva91], le bootstrap (bootstrap editing) [Hamamoto97], l'apprentissage par la quantification de vecteur généralisée-floue (Generalized Learning Vector Quantization-Fuzzy) [Karayiannis96], la classification et le ré-étiquetage (clustering and relabeling) [Bezdek99].

Une comparaison des classifieurs de plus proche prototype peut être lue dans [Bezdek01] où deux jeux de données artificielles et deux jeux de données d'applications réelles sont employés.

3.2.6 D'autres propositions

Il existe encore d'autres propositions d'améliorations de la règle des k-ppv dans la littérature depuis quelques années. Nous en mentionnons ici quelques exemples :

- ◆ Dans [Kelly91], un algorithme génétique est appliqué pour ajuster la fonction de distance pour la règle des k-ppv.

- ◆ Dans [Denoeux95] une règle des k-ppv est présentée basée sur la théorie de l'évidence de Dempster-Shafer. Dans la méthodologie proposée chaque voisin d'un échantillon inconnu x dans les k-ppv est considéré comme une source de l'évidence qui supporte des hypothèses concernant l'appartenance de x à une classe. Le degré du support est

défini comme une fonction de la distance entre deux vecteurs. Les évidences des k-plus proches voisins sont ensuite fusionnées par la règle de combinaison de Dempster.

◆ Dans [Belkasim92] un algorithme efficace appelé KNNR (K Nearest Neighbors Rule) est présenté pour la classification des formes avec une amélioration du temps de calcul des distances en réduisant le nombre des calculs.

◆ Dans [Hattori99] une règle des plus proches voisins pondérée est également proposée mais la pondération est différente de celle présentée par [Dudani76]. Dans la méthodologie proposée, les k-plus proches voisins d'un échantillon d'entrée sont obtenus dans chaque classe. Un paramètre positif est introduit dans le formalisme de pondération pour donner des poids différents aux k-plus proches voisins d'un échantillon d'entrée dans chaque classe. Cette règle est dite très flexible et pertinente si les valeurs des paramètres sont bien optimisées.

3.3 Conclusion

Dans ce chapitre, nous avons présenté les notions fondamentales de la reconnaissance de formes et de l'approche des k-plus proches voisins. Le choix d'une méthode de classification dans le domaine de la reconnaissance de formes pour un problème donné est très difficile parce que toutes les méthodes proposées pendant des années ont des points forts et faibles selon l'application traitée. Les comparaisons entre ces différentes méthodes de classification dans les divers domaines sont décrites dans la littérature. Les chercheurs ont bien souligné la simplicité de mise en œuvre et l'absence d'apprentissage dans un classifieur des k-ppv. Différentes méthodologies de classifieurs des k-ppv sont proposées dans la littérature. Nous avons aussi proposé une règle des k-ppv floue. Nous comparons les performances des méthodes existantes et celle obtenue par notre approche avec différents jeux de données dans le chapitre suivant.

Partie 2 : L'utilisation de l'information de distance

Chapitre 4

Au niveau d'un classifieur des k-ppv

Dans ce chapitre, nous décrivons notre contribution à une règle des k-plus proches voisins et plus généralement à un formalisme flou en utilisant l'information de distance. Notre contribution repose sur la définition d'une fonction d'appartenance floue basée sur les plus proches voisins de la forme inconnue. La méthode est flexible et peut avoir des utilisations multiples. Premièrement, elle est applicable aussi bien dans le cadre de la théorie des ensembles flous que dans celui de la théorie des possibilités pour modéliser un degré d'appartenance d'un objet ou d'une forme à plusieurs classes. Deuxièmement elle s'applique à tout classifieur de distance notamment ceux appliquant la règle des k-ppv et dans lesquels on peut importer le concept de flou. Il est possible de caractériser l'échantillon d'entrée « x » par différents degrés d'appartenance à chaque classe. Cela en reconsidérant l'apport de chaque prototype dans le voisinage de x en fonction des distances entre x et ses voisins et du rang des voisins parmi les k-plus proches voisins. Par conséquent un degré final d'appartenance à chaque classe peut être défini. Contrairement à la fonction floue proposée par [Keller85], notre formalisme ne pose pas de problème d'initialisation. Dans la prochaine section nous discutons en détail comment a été élaborée cette fonction et comment elle est employée dans la règle des k-ppv. Nous proposons deux possibilités de défuzzification. Une forme entrante « x » est étiquetée par une classe C_j soit sur la base du degré d'appartenance maximum à la classe C_j soit sur la base du degré d'appartenance maximum à un prototype de C_j dans le voisinage de x .

4.1 Degré d'appartenance

Dans la théorie du flou la notion de degré d'appartenance joue un rôle fondamental puisqu'elle caractérise les objets. Tous les traitements sur ces objets sont ensuite faits en fonction de ces degrés. Ainsi la détermination de cette fonction est primordiale, et c'est donc à optimiser cette fonction que nous nous attachons. De la qualité de ce modèle dépend bien souvent la qualité de tout le système. L'approche adoptée pour définir une fonction dépend

souvent de l'application visée. Bien souvent les paramètres sont choisis par des utilisateurs, à partir de leurs propres expériences ou d'essais successifs.

Dans notre travail, nous abordons la conception d'un système de reconnaissance de formes basé sur des prototypes avec des données quantitatives. On suppose qu'une forme entrante inconnue « x » a été identifiée en comparant ses caractéristiques à celles des x_i ($i = 1$ à n), les échantillons de référence des différentes classes $\{C_j$ ($j = 1$ à M)}. La décision que x appartienne à la classe C_j par un classifieur (classifieur de distance) a été prise par une règle des k -plus proches voisins floue. Nous proposons alors d'améliorer les résultats de l'identification par la combinaison de plusieurs classifieurs basés sur un certain nombre d'ensembles de caractéristiques. Pour réaliser la fusion de classifieurs, plusieurs méthodes ont été employées : la théorie des possibilités, la théorie des fonctions de croyance (ou de l'évidence) etc. Nous reviendrons sur ce sujet dans les chapitres suivants.

Les principaux avantages de notre approche par rapport aux autres sont sa simplicité de mise en œuvre, sa flexibilité et son aspect non paramétrique. Restant dans le cadre de l'information fournie par des classifieurs de distance, nous avons noté qu'un formalisme basé sur quatre variables est possible. En analysant l'influence de chacune de ces variables, nous avons dérivé le formalisme final qui est expliqué dans la section suivante.

4.2 Formalisme flou

Nous avons essayé de développer une fonction d'appartenance floue la plus générale possible pour résoudre ce problème assez délicat. Dans un premier temps, nous avons considéré les données fournies par un classifieur basé sur la règle des k -ppv. Mais notre approche est aussi applicable à tous les autres classifieurs qui fournissent des données quantitatives.

4.2.1 Proposition initiale

Précisons tout d'abord les notations que nous emploierons dans toute la présentation. Nous notons le degré d'appartenance floue de la forme entrante x à la classe des différents prototypes dans le voisinage de x par $F_{x_i}(x)$ et aux classes C_j par $F_{C_j}(x)$. $F_{x_i}(x)$ ne constitue qu'une normalisation de $f_{x_i}(x)$. On construit ainsi des fonctions sur l'espace de représentation considéré dans le problème. Les trois fonctions f_{x_i} , F_{x_i} , et F_{C_j} sont à valeurs réelles entre 1 et 0, elles respectent les propriétés suivantes :

$$f_{xi}(x) \in [0,1] \quad (4.1)$$

$$F_{xi}(x) \in [0,1] \quad (4.2)$$

$$\sum_{i=1}^k F_{xi}(x) = 1 \quad (4.3)$$

$$F_{C_j}(x) = \frac{N_x(C_j)}{\sum_{q=1}^{N_x(C_j)} F_{xq}(x)} \quad (4.4)$$

Ici, q varie de 1 à $N_x(C_j)$ qui représente le nombre des prototypes dans le voisinage de x appartenant à la classe j et dans les k -ppv.

La forme x a un degré d'appartenance à la classe C_j dépendant de sa ressemblance avec elle. Celle-ci, du point de vue de x , est exprimée par la présence des prototypes de son voisinage dans l'espace de caractéristiques. Le formalisme exprime l'influence de chaque voisin de x d'après la distance entre x et ses voisins x_i notée par $d(x, x_i)$ et le nombre d'occurrences des voisins de la même classe. Nous avons mis en évidence des variables importantes ayant une influence forte dans un tel système. Nous les précisons maintenant :

- Le nombre des plus proches voisins de x considérés (k -ppv) parmi les n prototypes ($k \leq n$) et les distances $d(x, x_i)$, i variant de 1 à k .
- Le rang des prototypes dans le voisinage, x_i , noté par $R_x(x_i)$, le rang est considéré en fonction des distances $d(x, x_i)$.
- Le nombre d'occurrences des prototypes dans le voisinage de x appartenant à une même classe C , dans les k -ppv considérés, il est noté $N_x(C)$.
- La variation $V_{xi}(x)$; le rapport entre les distances $d(x, x_i)$ et $d(x, x_z)$ où, x_z représente le voisin précédant x_i dans la suite des voisins.

La fonction que nous recherchons doit décroître quand les trois variables $d(x, x_i)$, $R_x(x_i)$, $V_{xi}(x)$ augmentent et doit donner une valeur relativement grande quand $N_{xi}(C)$ augmente. Dans un premier temps, nous avons donc étudié une combinaison linéaire des quatre variables $d(x, x_i)$, $R_x(x_i)$, $V_x(x_i)$, $N_x(C)$; les 3 premières variables sont affectées d'un poids positif et un signe négatif est affecté à la variable $N_x(C)$. Nous avons expérimenté les valeurs obtenues sur un petit jeu de données contenant 5 classes et 10 prototypes dans chaque classe, en considérant 10-ppv.

La formule proposée est donc :

$$f_{xi}(x) = d(x, x_i) + R_x(x_i) + V_x(x_i) - N_x(C) \quad (4.5)$$

De manière à illustrer l'influence de chacun des 4 termes introduits, nous traçons sur la figure 4.1 d'une part le résultat correspondant, d'autre part les résultats obtenus en omettant à chaque fois un des termes.

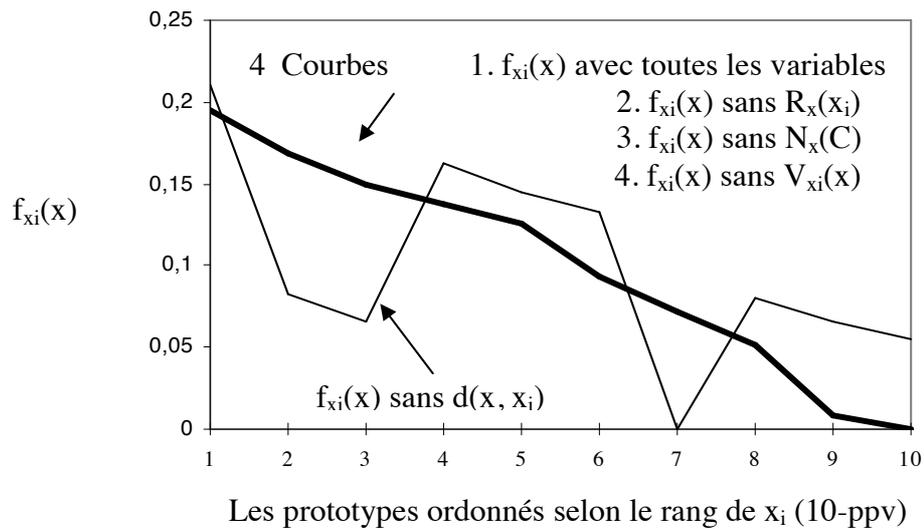


Figure 4.1 : Exemple de calcul du degré d'appartenance d'une forme à la classe d'un prototype selon l'équation 4.5 et des variantes.

Dans la figure 4.1, nous pouvons constater que 4 courbes parmi les 5 sont pratiquement identiques et on peut dire que la variable de distance $d(x, x_i)$ influe trop sur les résultats, elle lisse les résultats par rapport aux autres variables. Nous avons donc pensé à modifier la fonction en introduisant l'inverse au lieu de l'opposé et en pondérant $N_x(C)$ par le facteur $1/4$. Le résultat nous a montré que $N_x(C)$ influe énormément sur les valeurs obtenues, malgré la pondération en $1/4$ que nous avons appliquée. Par contre l'influence de $d(x, x_i)$ est minimisée, cela est dû à ses grandes valeurs. L'hétérogénéité de nos variables nous conduit à réaliser des pondérations sur toutes les variables. Donc nous avons pensé à une pondération telle que la somme de tous les termes ait une valeur constante pour avoir un même poids et permettre des comparaisons. Avec cette pondération nous avons noté que les résultats sont plus homogènes que dans les expériences précédentes. Pour atténuer les effets du rang, nous avons décidé de travailler sur l'inverse de la racine du rang, ce qui a été justifié par les résultats que nous

avons obtenus. Nos différentes expérimentations nous ont montré l'importance prépondérante de $N_x(C)$ dans les résultats où $d(x, x_i)$, $R_x(x_i)$, $V_x(x_i)$ ont presque la même allure sauf sans $N_x(C)$. C'est pourquoi nous avons considéré le carré de $N_x(C)$ avec succès. On peut remarquer que les valeurs de $f_{x_i}(x)$ ne sont pas vraiment entre 0 et 1 (plutôt entre 0 et 0,1), comme on peut le voir sur un résultat montré dans la figure 4.2 (avec le même jeu de données). Nous avons donc introduit une étape de normalisation. Voici le formalisme final élaboré dans un premier temps concernant les prototypes dans le voisinage de x :

$$F_{x_i}(x) = \frac{f_{x_i}(x)}{\sum_{i=1}^k f_{x_i}(x)} \quad (4.6)$$

où

$$f_{x_i}(x) = \left[\frac{1/d(x, x_i)}{1+4 \sum_{j=1}^k 1/d(x, x_j)} + \frac{1/\sqrt{R_x(x_i)}}{1+4 \sum_{j=1}^k 1/\sqrt{R_x(x_j)}} \right. \\ \left. + \frac{(N_x(C))^2}{1+4 \sum_{j=1}^k N_x(C)} + \frac{1/V_{x_i}(x)}{1+4 \sum_{j=1}^k 1/V_{x_i}(x)} \right] \quad (4.7)$$

En utilisant la formule (4.7), il y a un problème d'initialisation des valeurs de $V_{x_i}(x)$, puisqu'il n'y a pas de prototype précédent pour le premier voisin de x . Pour avoir une harmonisation des variables nous avons trouvé les propositions suivantes :

$$V_{x_1}(x) = \frac{1}{3}$$

$$V_{x_2}(x) = \frac{d(x, x_2)}{d(x, x_2) + 2 * d(x, x_1)} \quad (4.8)$$

Et à partir du 3ème voisin dans le voisinage de x , nous avons généralisé par :

$$V_{x_i}(x) = \frac{d(x, x_i)}{\sum_{j=1}^i d(x, x_j)} \quad (4.9)$$

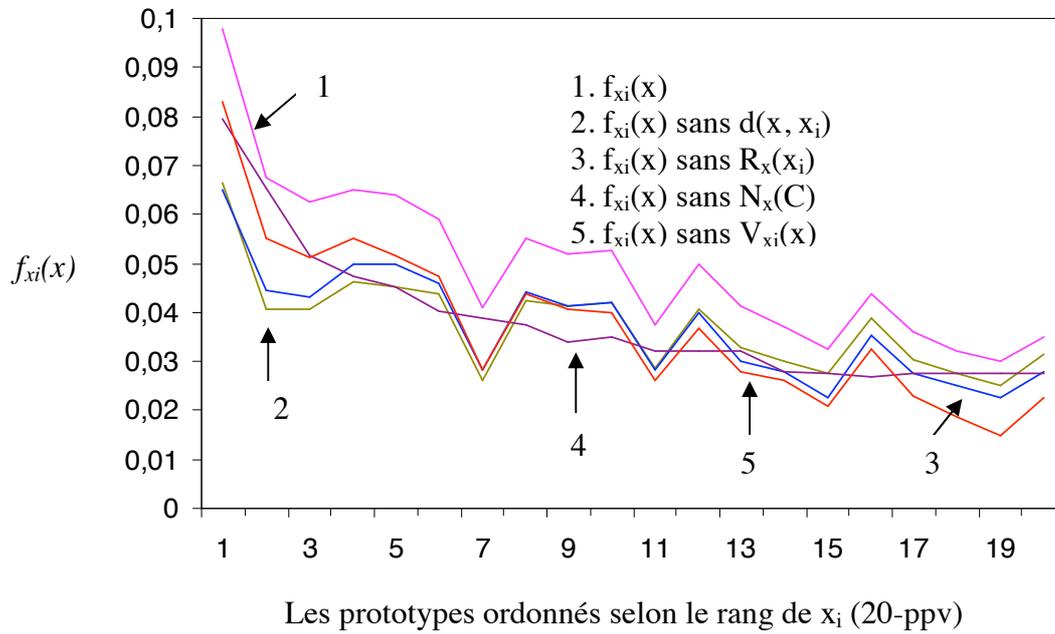


Figure 4.2 : Un résultat intermédiaire du formalisme qui montre un lissage des degrés d'appartenance sans $N_x(C)$ en considérant les 20-ppv

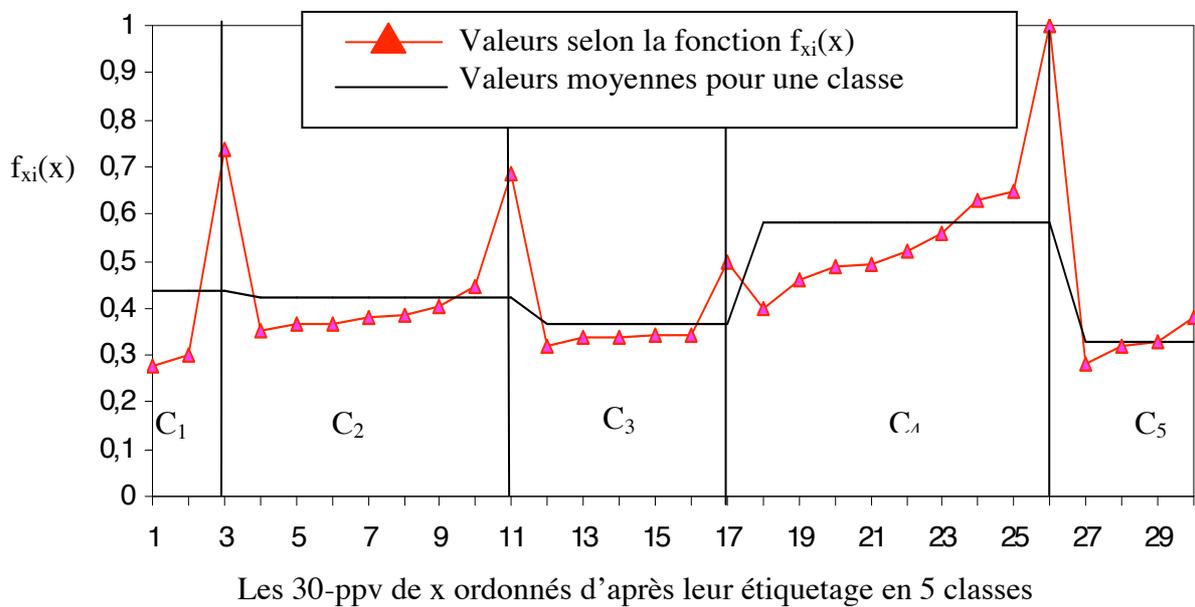


Figure 4.3 : Résultat de notre formalisme proposé dans un premier temps (où la forme entrante appartient à la classe C_4).

Dans la figure 4.3, un résultat de notre formalisme proposé dans un premier temps est montré en considérant les 30 premiers plus proches voisins d'une forme x . Le jeu de données utilisé reste le même. Le résultat dans la figure 4.3 montre que la forme appartient à la classe C_4 ayant un degré d'appartenance maximum à cette classe. Les prototypes parmi les 30 prototypes ont été réordonnés pour rassembler les prototypes appartenant à une même classe.

4.2.2 2eme tentative (amélioration)

Dans un deuxième temps, nous avons pensé grouper les quatre variables de manière géométrique plutôt que linéaire. Nous obtenons la version suivante :

$$f_{xi}(x) = \frac{N_x(C)^2 \cdot V_{xi}(x) / (\sqrt{R_x(x_i)} \cdot d(x, x_i))}{a + \{ N_x(C)^2 \cdot V_{xi}(x) / \sqrt{R_x(x_i)} \cdot d(x, x_i) \}} \quad (4.10)$$

Pour des raisons de simplicité, nous présentons l'équation précédente sous la forme :

$$f_{xi}(x) = \frac{b_i}{a + b_i} \quad (4.11)$$

$$b_i = \frac{N_x(C)^2 \cdot V_{xi}(x)}{\sqrt{R_x(x_i)} \cdot d(x, x_i)}$$

Un point important, nous avons généralisé le calcul de $V_{xi}(x)$ décrit précédemment par les équations (4.8) et (4.9) pour une formule indépendante de la valeur de « i » (les prototypes du voisinage de x) de cette manière :

$$V_{xi}(x) = \frac{d(x, x_i)}{\sum_{j=1}^i d(x, x_j)} \quad (4.12)$$

Il reste des problèmes à résoudre, comme par exemple fixer le coefficient « a » et les paramètres d'exposants de puissance ici fixés à 2, 0.5, 1 et 1 pour la pondération des quatre variables. Nous avons étudié l'influence de chaque variable séparément.

Etude du coefficient « a »

Une première étude a été réalisée en modifiant les valeurs du coefficient « a ». Nous avons fait varier ses valeurs entre zéro et 15. Les valeurs les plus raisonnables ont été trouvées proches de 1, nous avons alors fixé sa valeur égale à 1 pour étudier les autres variables.

Etude du « Rang »

La variable $R_x(x_i)$ a toujours une valeur croissante à partir du plus proche voisin jusqu'au $k^{\text{ème}}$ voisin dans les k -plus proches voisins considérés. En réalité cette variable ne porte pas une information réellement liée au système spécifique puisque dans tous les cas les mêmes chiffres entre 1 et k interviennent. Cette valeur n'est donc pas aussi importante que les autres variables. En raison de cette réalité, nous avons fixé la valeur de sa puissance en considérant toujours sa racine carrée dans l'étude de cette nouvelle version. Nous avons réalisé des tests pour fixer sa position indépendamment de l'ancienne relation de la fonction d'appartenance. Cela nous amène à penser le rang comme un coefficient et non plus comme une variable. Avec ce concept sa position a été fixée dans le terme « b » :

$$f_{xi}(x) = \frac{b_i}{1 + b_i}$$

(4.13)

$$b_i = \frac{(N_x(C))^\alpha \sqrt{R_x(x_i)} (V_{xi}(x))^\gamma}{(d(x, x_i))^\beta}$$

Etude des exposants de puissance des variables

Après l'étude du coefficient a et du rang, il reste à étudier trois variables, les distances, leur variation, et le nombre d'occurrences de chaque classe dans les k -ppv. C'est-à-dire que nous avons un espace de dimension 3 à explorer. Nous choisissons de modéliser les triplets à partir d'un triangle dont les trois arêtes sont définies respectivement par $\alpha = 15$, $\beta = 15$, et $\gamma = 15$. Pour nous, ces trois arêtes représentent les domaines de variation des exposants de chaque variable : α , β , et γ .

Différentes expérimentations sont réalisées pour étudier l'influence de chaque variable. Pour cela, on fait varier les valeurs d'un paramètre en gardant les deux autres variables avec une valeur constante de « 1 » comme nous le montrons dans le tableau 4.1 :

Tableau 4.1: Schéma de variation des paramètres dans la série des expériences.

Paramètre	α	β	γ
α	0,1-15	1	1
β	1	0,1-15	1
γ	1	1	0,1-15

Les valeurs en gras représentent l'intervalle qui a été exploré pour les puissances des trois variables. Les tests concernent un jeu de données de classification réelle. Les résultats obtenus avec ces trois paramètres ont été analysés et comparés entre eux pour trouver lequel des trois paramètres est le plus sensible et permet par ses variations d'atteindre le meilleur résultat. Plusieurs simulations nous ont donné les meilleures valeurs pour chaque paramètre. Ce sont ; $\alpha = 1$, $\beta = 1,7$, $\gamma = 1,3$. Notre critère d'efficacité est le bon classement quand la décision que $x \in C_j$ est prise en fonction du maximum de $F_{x_i}(x)$. La meilleure performance a été obtenue avec la variation de γ .

La non prise en compte de la valeur de l'exposant α de $N_x(C)$ (nombre d'occurrences des classes), comme nous l'avions pensé (c'est-à-dire $\alpha = 1$), a été justifiée. Le problème a donc été réduit à deux paramètres théoriques, c'est-à-dire β et γ . Nous avons alors étudié la variation des deux paramètres en même temps. Le temps de calcul pour régler les deux paramètres a été augmenté. Le résultat obtenu est presque le même que celui obtenu avec $\gamma = 1,3$. Néanmoins, nous pensons garder les trois paramètres provisoirement dans le formalisme proposé avant de faire des expérimentations avec d'autres jeux de données. Donc le formalisme proposé reste celui indiqué à l'équation 4.13.

Dans la prochaine partie, nous décrivons en détail comment nous avons utilisé ce formalisme pour traiter les deux jeux de données du « benchmark » (IRIS présenté dans [Ficher36] et de soudure présenté dans [Liao97]) ce qui nous permettra des comparaisons avec les autres approches.

4.2.3 Défuzzification

Dans nos expérimentations, les résultats de la classification employant la règle des k-ppv floue proposée sont défuzzifiés de deux manières différentes :

- Soit en classifiant une forme entrante x dans une classe C_j pour laquelle le degré d'appartenance est maximum c'est à dire $F_{C_j}(x)$ pour la classe C_j est maximum.

- Soit en classifiant une forme entrante x dans une classe C_j pour laquelle le degré d'appartenance est maximum par rapport aux prototypes figurant parmi les k -plus proches voisins de x , c'est-à-dire que nous considérons la classe pour laquelle $F_{x_i}(x)$ est maximum.

Nous avons étudié ces deux méthodes de défuzzification avec nos jeux de données réelles et avec celles de benchmark pour tirer une conclusion plus fiable. En général nous laissons le choix de la meilleure méthode aux utilisateurs. Ils décideront la méthode d'après la nature des données de leurs applications de classification.

4.3 Résultats

Quelques exemples de classification des formes sont présentés pour étudier la pertinence de notre formalisme d'appartenance floue. La classification est évaluée en utilisant la méthode du « leave one out ». Cette technique consiste à laisser un échantillon hors de l'ensemble de données et à le classifier en employant l'ensemble des échantillons restants comme un ensemble de référence. Ce procédé est répété jusqu'à ce que tous les échantillons des données aient été classifiés. Pour calculer une mesure de similarité entre les formes dans l'espace de leurs caractéristiques, nous avons utilisé la distance euclidienne usuelle pour déterminer la distance entre elles, elle s'écrit :

$$d(x, x_i) = \sqrt{\sum_{j=1}^n (x^j - x_i^j)^2} \quad (4.14)$$

Dans un but de comparaison, les résultats obtenus par la règle simple des k -ppv, la règle des k -ppv avec distance pondérée présentée par [Dudani76], et la règle des k -ppv floue proposée par [Keller85] ainsi que d'autres sont également présentés sur les exemples de données du benchmark.

4.3.1 Test sur les Iris de Fisher

Les données utilisées dans cet exemple sont les données classiques des Iris de Fisher [Fisher36], [Anderson35]. Les chercheurs dans le domaine de l'analyse de données et de la classification ont employé ces données particulièrement intensivement depuis 1936 [Fisher36]. Les données correspondent à 150 fleurs d'Iris, décrites par 4 primitives (longueur

des sépales, largeur des sépales, longueur des pétales, largeur des pétales), et par leur espèce. Trois espèces différentes font partie de cette étude : *setosa*, *versicolor* et *virginica*. Ainsi il y a trois classes et chaque classe inclut 50 fleurs représentées par un vecteur quadridimensionnel de caractéristiques.

Appliquant au jeu de données d'Iris la règle des k-ppv floue proposée, différents résultats de classification ont été obtenus en faisant varier les valeurs de α , β , γ , et k. Les nombres des échantillons mal classés notés par N_m sont évalués selon les valeurs de α , β , γ , et k dans la gamme de $0,1 \leq \alpha, \beta, \gamma \leq 15$, et $1 \leq k \leq 15$ respectivement. Enfin, la moyenne des N_m (Moy) et le minimum des N_m (Min) sont indiqués pour permettre des comparaisons en vision globale.

Etude de α

Les résultats obtenus en faisant varier α (en fixant à 1 les valeurs de β et γ) sont donnés dans les Tableaux 4.2 (a) et (b) pour les valeurs de k dans l'intervalle [1-15]. Les valeurs de α optimum (en moyenne) sont dans l'intervalle [0,6-15] si la défuzzification est réalisée selon le maximum de $F_{C_j}(x)$. C'est dans l'intervalle [6-15] que les résultats sont les meilleurs possibles (en moyenne) dans le cas de défuzzification par maximum de $F_{x_i}(x)$. On peut traduire cette remarque dans le premier cas de défuzzification par le fait que α n'a pas une influence importante à partir d'une valeur égale à 1. Mais par contre pour le deuxième cas de défuzzification, une valeur comparativement plus grande est à conseiller. Le minimum d'erreur de classification a été le même dans les deux cas de défuzzification, il est obtenu quand k est égal à 14.

Etude de β

En prenant α et γ égaux à 1, les résultats obtenus en faisant varier le paramètre β dans le formalisme flou proposé pour la règle des k-ppv floue sont montrés dans les Tableaux 4.3 (a), et (b) pour les deux cas de défuzzification. En moyenne, la variation du paramètre β a donné une amélioration des résultats quand le premier critère de défuzzification a été utilisé par rapport à ceux obtenus en faisant varier α mais le deuxième critère de décision est moins efficace. Ce n'est pas étonnant puisqu'on avait vu que α devait être élevé. Les valeurs optimales de β trouvées sont dans l'intervalle [11-15] pour le premier cas de décision et dans [0,2-0,3] pour le deuxième cas, les nombres minimums d'erreurs sont de 3 et 5 respectivement.

Tableau 4.2 : Nombre d'échantillons mal classés par la règle des k-ppv floue proposée pour le jeu de données des Iris en faisant varier le paramètre α (et $\beta = \gamma = 1$).

(a) Critère de décision : maximum d'appartenance à la classe : $F_{C_j}(x)$

k	α				
	0,1	0,2 – 0,3	0,4	0,5	0,6 – 15
1	6	6	6	6	6
2	6	6	6	6	6
3	6	6	6	6	6
4	6	6	6	6	6
5	5	5	5	5	5
6	6	6	6	6	6
7	5	6	5	5	5
8	5	5	5	5	5
9	4	6	6	6	5
10	6	6	6	6	6
11	6	7	7	6	5
12	5	4	4	4	4
13	4	5	5	4	4
14	4	3	3	3	3
15	4	5	5	4	4
Moy	5,2	5,47	5,4	5,2	5,07
Min	4	3	3	3	3

(b) Critère de décision : maximum d'appartenance à la même classe qu'un prototype : $F_{x_i}(x)$

k	α					
	0,1 – 1	2	3	4	5	6 – 15
1	6	6	6	6	6	6
2	6	6	6	6	6	6
3	6	6	6	6	6	6
4	6	6	6	6	6	6
5	6	5	5	5	5	5
6	6	6	6	6	6	6
7	6	6	6	5	5	5
8	6	5	5	5	5	5
9	6	5	5	6	5	5
10	6	7	6	6	6	6
11	6	5	5	7	6	5
12	6	5	4	4	4	4
13	6	5	5	5	4	4
14	6	6	4	3	3	3
15	6	6	5	5	4	4
Moy	6,00	5,67	5,33	5,40	5,13	5,07
Min	6	5	4	3	3	3

Tableau 4.3 : Nombre d'échantillons mal classés par la règle des k-ppv floue proposée pour le jeu de données des Iris en faisant varier le paramètre β (et $\alpha = \gamma = 1$).

(a) Critère de décision : maximum d'appartenance à la classe : $F_{C_j}(x)$

k	β					
	0,1 – 3,5	3,7	4 – 5	6	7	11 – 15
1	6	6	6	6	6	6
2	6	6	6	6	6	6
3	6	6	6	6	6	6
4	6	6	6	6	6	6
5	5	5	5	5	5	5
6	6	6	6	6	6	6
7	5	5	5	5	5	5
8	5	5	5	5	4	4
9	5	5	5	5	5	5
10	6	5	5	5	5	5
11	5	5	5	5	5	5
12	4	4	3	3	4	3
13	4	4	4	4	4	4
14	3	3	3	4	4	4
15	4	4	4	4	4	4
Moy	5,07	5,0	4,93	5,0	5,0	4,93
Min	3	3	3	3	4	3

(b) Critère de décision : maximum d'appartenance à la même classe qu'un prototype : $F_{x_i}(x)$

k	β				
	0,1	0,2	0,3	0,4, 0,5	0,6 – 10
1	6	6	6	6	6
2	6	6	6	6	6
3	6	6	6	6	6
4	6	6	6	6	6
5	6	6	6	6	6
6	6	6	6	6	6
7	6	6	6	6	6
8	6	6	6	6	6
9	6	5	5	6	6
10	7	7	7	7	6
11	6	6	6	6	6
12	5	5	5	6	6
13	6	6	6	6	6
14	6	6	6	6	6
15	6	6	6	6	6
Moy	6,00	5,93	5,93	6,07	6,00
Min	5	5	5	6	6

Etude de γ

On procède de même avec le paramètre γ , les résultats obtenus sont montrés dans les tableaux 4.4 (a) et (b). L'analyse des résultats (Tableau 4.4 (a), (b)) montre que ce paramètre a une plus grande influence que les deux autres (α et β).

Les tableaux 4.2, 4.3, et 4.4 montrent que les valeurs du N_m obtenues sont égales à 6 pour $1 \leq k \leq 4$ et $k = 6$, quelles que soient les valeurs de α , β , et γ dans tous les cas de défuzzification. Pour $k = 5$ et $7 \leq k \leq 15$, les valeurs de N_m varient de 2 à 6 selon les différentes valeurs de α , β , et γ et le critère de décision. Le minimum de N_m est évalué à 2 dans le tableau de variation du paramètre γ dans le cas du critère de décision du maximum de $F_{xi}(x)$. Les meilleurs résultats de classification avec $N_m = 3$ ou 4 sont obtenus en général pour $\alpha \cong \beta \cong \gamma \cong 1$ et $12 \leq k \leq 15$ dans le cas de la prise de décision par maximum de $F_{Cj}(x)$. Dans le cas ($\alpha = \beta = \gamma = 1$) cas de notre formalisme sans aucun paramètre à régler, la perte d'efficacité est tolérable. Mais ce n'est pas le cas avec le critère de décision du maximum de $F_{xi}(x)$. Les valeurs des paramètres doivent être optimisées pour avoir de bons résultats pour les valeurs de k ($2 \leq k \leq 15$). Le meilleur résultat parmi les trois tableaux est donné dans le tableau concernant γ et avec le critère de décision de maximum de $F_{xi}(x)$.

Tableau 4.4 : Nombre d'échantillons mal classés par la règle des k-ppv floue proposée pour le jeu de données des Iris en faisant varier le paramètre γ (et $\alpha = \beta = 1$).

(a) Critère de décision : maximum d'appartenance à la classe : $F_{Cj}(x)$

k	γ												
	0,1,0,2	0,3	0,4	0,5-1,2	1,3	1,4	1,5	1,6	1,7	1,8	1,9	2	3-15
1	6	6	6	6	6	6	6	6	6	6	6	6	6
2	6	6	6	6	6	6	6	6	6	6	6	6	6
3	6	6	6	6	6	6	6	6	6	6	6	6	6
4	5	5	6	6	6	6	6	6	6	6	6	6	6
5	5	5	5	5	5	5	5	5	5	6	6	6	6
6	5	5	6	6	6	6	6	6	6	6	6	6	6
7	5	5	5	5	5	6	6	5	5	5	6	6	6
8	5	4	5	5	5	5	5	5	5	5	6	6	6
9	5	5	5	5	5	6	6	6	5	5	4	5	6
10	5	4	5	6	6	6	6	6	6	6	6	7	6
11	5	5	5	5	6	6	7	7	7	6	6	5	6
12	4	4	3	4	4	4	4	4	5	5	5	5	6
13	4	4	4	4	4	5	5	5	5	4	4	4	6
14	4	4	3	3	3	3	3	3	4	4	4	4	6
15	4	4	4	4	4	4	5	5	5	5	4	4	6
Moy	4,93	4,8	4,93	5,03	5,13	5,33	5,47	5,4	5,47	5,4	5,4	5,47	6
Min	4	4	3	3	3	3	3	3	4	4	4	4	6

(b) Critère de décision : maximum d'appartenance à la même classe qu'un prototype : $F_{xi}(x)$

k	γ								
	0,1	0,2	0,3	0,4	0,50	0,6	0,7	0,8	0,9 – 10
1	6	6	6	6	6	6	6	6	6
2	6	6	6	6	6	6	6	6	6
3	6	6	6	6	6	6	6	6	6
4	5	5	5	5	6	6	6	6	6
5	5	5	5	5	5	5	5	6	6
6	6	6	6	5	6	6	6	6	6
7	5	5	5	5	5	5	6	6	6
8	5	5	5	4	5	5	5	6	6
9	5	5	5	5	5	4	5	5	6
10	4	5	6	5	6	5	6	6	6
11	5	4	5	5	4	5	5	6	6
12	3	4	4	3	4	4	5	5	6
13	4	4	4	4	3	5	6	6	6
14	2	4	4	3	3	4	6	6	6
15	4	4	4	4	3	5	6	6	6
Moy	4,73	4,93	5,07	4,73	4,87	5,13	5,67	5,87	6
Min	2	4	4	3	3	4	5	5	6

Dans presque tous les cas où N_m est égal à 6, les mêmes six fleurs sont mal classées : trois fleurs *Virginica* et trois fleurs *Versicolor* sont classées respectivement dans l'iris *Versicolor* et *Virginica*. Dans tous les cas où N_m est égal à 3, les mêmes trois fleurs sont mal classées : deux fleurs *Versicolor* et une fleur *Virginica* sont classées respectivement dans l'iris *Virginica* et *Versicolor*.

Le tableau 4.5 permet de comparer notre méthode aux méthodes décrites précédemment. Il montre les résultats, le nombre de mauvaises classifications par la règle des k-ppv, la règle des k-ppv avec distance-pondérée, la règle des k-ppv floue proposée par [Keller85] avec deux types d'initialisation (nette et 3-ppv), et la règle des plus proches voisins des k-ppv pour chaque classe proposée par [Hattori99]. Dans ce tableau, on peut noter que le minimum de N_m pour $1 \leq k \leq 15$ est 6 dans la règle des k-ppv avec pondération de distance. D'autre part le minimum de N_m est 4 dans la règle des k-ppv floue [Keller85] avec les deux techniques d'initialisation nette et 3-ppv pour $1 \leq k \leq 15$. Par contre la règle des k-ppv pour chaque classe proposée par [Hattori99] a donné comme minimum $N_m = 3$. Dans cet intervalle de k, donc, le minimum de N_m par la règle des k-ppv floue proposée est plus petit que ceux obtenus par les 4 autres approches des k-ppv. Cependant, si l'on considère la moyenne des N_m pour les valeurs de k dans l'intervalle [1-15], la règle des k-ppv floue avec initialisation par 3-ppv a un taux d'erreur légèrement inférieur.

Tableau 4.5 : Nombre d'échantillons mal classés par la règle des k-ppv, la règle des k-ppv avec distance-pondérée présentée par [Dudani76], la règle des k-ppv floue présentée par [Keller85] avec 2 techniques d'initialisation et la règle des k-ppv dans chaque classe pour le jeu de données des Iris.

k	La règle des k-ppv	k-ppv avec distance pondérée	k-ppv floue avec initialisation nette	k-ppv floue avec initialisation par 3-ppv	La méthode des k-ppv avec k-ppv pour chaque classe
1	6	6	6	6	6
2	6	6	6	6	6
3	6	6	6	5	6
4	6	6	6	5	5
5	5	6	5	4	4
6	6	6	6	4	4
7	5	6	5	4	4
8	5	6	6	4	4
9	5	6	4	4	3
10	6	6	6	4	3
11	4	6	4	4	3
12	5	6	5	4	3
13	5	6	4	4	4
14	4	6	5	4	4
15	4	6	4	4	5
Moy	5,2	6	5,2	4,4	4,27
Min	4	6	4	4	3

4.3.2 Exemple 2

Dans [Liao97] un jeu de données pour la détection des soudures dans des images radiographiques numériques est présenté. La classification des formes à l'aide de la règle des k-ppv floue [Keller85] est proposée. L'image de soudure est traitée ligne par ligne et trois caractéristiques sont extraites pour chaque objet dans la ligne de l'image. Ces caractéristiques sont la largeur, l'erreur quadratique moyenne entre l'objet et son modèle gaussien, et l'intensité maximale (niveau de gris). Ce jeu de données est constitué de deux classes représentant les caractéristiques de 36 échantillons, 36 images dont 18 contiennent des soudures et 18 sans soudures dans la base de référence. Le classifieur des k-ppv flou [Keller85] a été employé et testé avec 44 autres images avec initialisation par le 1-plus proche prototype (1-ppv). Ce jeu de données (se composant de 36 échantillons de référence et de 44 échantillons de test) est

cit  dans l'annexe. Le r sultat obtenu par [Liao97] est rapport  dans le tableau 4.9. Ce jeu de donn es est  galement utilis  par [Mitchell01] pour comparer sa m thode. Le r sultat obtenu par la m thodologie de [Mitchell01] est aussi rapport  dans le tableau 4.9.

Les r sultats par le classifieur propos 

Ici aussi l' valuation des performances selon les valeurs de nos trois param tres a  t  effectu e afin de trouver les param tres optimaux et en particulier celui qui doit constituer notre mod le final. Nous avons  galement  tudi  la phase de d fuzzification et les r sultats sont pr sent s dans les tableaux 4.6, 4.7, 4.8.

Tableau 4.6 : Nombre d' chantillons mal class s par la r gle des k-ppv floue propos e pour le jeu de donn es des soudures en faisant varier le param tre α (et $\beta = \gamma = 1$).

(a) Crit re de d cision : maximum d'appartenance   la classe : $F_{C_j}(x)$

k	α
	0,1 - 15
1	3
2	3
3	6
4	5
5	7
6	5
Moy	4,83
Min	3

(b) Crit re de d cision : maximum d'appartenance   la m me classe qu'un prototype : $F_{x_i}(x)$

k	α													
	0,1-0,3	0,4-0,5	0,6	0,7	0,8	0,9	1	1,2-1,4	1,5	1,6	1,8-1,9	2	3	4-15
1	3	3	3	3	3	3	3	3	3	3	3	3	3	3
2	3	3	3	3	3	3	3	3	3	3	3	3	3	3
3	3	3	4	4	4	3	3	4	4	5	6	6	6	6
4	3	3	2	3	3	3	4	5	5	5	5	5	5	5
5	3	3	3	3	4	4	4	4	3	4	4	5	6	7
6	3	2	3	4	4	3	4	4	4	4	4	4	4	4
Moy	3,00	2,83	3,00	3,33	3,50	3,17	3,50	3,83	3,67	4,00	4,17	4,33	4,50	4,67
Min	3	2	2	3	3	3	3	4	3	4	4	4	4	4

(b) Critère de décision : maximum d'appartenance à la classe qu'un prototype : $F_{xi}(x)$

k	γ												
	0,1	0,20	0,3	0,4	0,5, 0,6	0,7	0,8	0,9-1	1,1 - 1,2	1,3 - 1,4	1,5 - 1,9	2	3 - 20
1	3	3	3	3	3	3	3	3	3	3	3	3	3
2	3	3	3	3	3	3	3	3	3	3	3	3	3
3	4	4	4	4	4	4	4	4	4	4	3	3	3
4	6	6	5	5	4	4	4	4	3	3	3	2	3
5	6	6	6	5	4	5	5	4	4	4	4	4	3
6	5	4	4	4	4	4	4	4	3	4	4	4	3
Moy	4,5	4,33	4,17	4	3,67	3,83	3,83	3,67	3,33	3,5	3,33	3,17	3
Min	3	3	3	3	3	3	3	3	3	3	3	2	3

Tableau 4.9 : Nombre d'échantillons mal classés par la règle des k-ppv floue proposée par [Keller85], avec initialisation par 1-PPP et nette, la règle des k-ppv, la règle des k-ppv proposée par [Mitchell01] et la règle des k-ppv avec distance-pondérée proposée par [Dudani76] pour le jeu de données des soudures.

k	La règle des k-ppv avec initialisation par 1-PPP	La règle des k-ppv avec initialisation nette par 1-ppv	La règle des k-ppv	La règle des k-ppv avec soft voting scheme	La règle des k-ppv avec distance-pondérée
1	3	3	3	3	3
2		3	3	3	3
3		4	5	4	3
4		3	6	6	4
5		3	7	6	4
6		3	6	6	4
Moy	3	3,17	5,0	4,67	3,5
Min	3	3	3	3	3

Nous avons employé les données d'un problème réel à deux classes pour examiner le comportement de notre formalisme. Les résultats obtenus par d'autres méthodes avec le même jeu de données sont aussi présentés dans le tableau 4.9.

Différents résultats de classification ont été obtenus en faisant varier les valeurs de α , β , γ et k . Le nombre d'échantillons mal classés est évalué pour les différentes simulations dans les intervalles de $0,1 \leq \alpha, \beta, \gamma \leq 15$ et $1 \leq k \leq 6$. Les résultats sont mesurés par le nombre de mauvaises classifications des échantillons en test (N_m). Ils sont indiqués dans les tableaux précédents. Les observations de ces tableaux conduisent à noter que les résultats obtenus en fonction de α , β , et γ sont fortement influencés par le critère de décision de défuzzification.

Pour prendre la décision en fonction du maximum de $F_{C_j}(x)$ le paramètre γ est très clairement un meilleur choix parmi les trois paramètres. Dans le cas d'une décision basée sur le maximum de la fonction d'appartenance du prototype $F_{x_i}(x)$, les trois paramètres ont plus ou moins la même performance.

Pour $k = 1$, les mêmes échantillons sont mal classés par les cinq méthodes citées dans le tableau 4.9 et aussi par la règle des k -ppv floue proposée. Pour $k = 3$, la règle des k -ppv avec distance-pondérée [Dudani76] et la règle des k -ppv floue proposée ont le même résultat tandis que les autres méthodes, la règle des k -ppv floue nette [Keller85], la règle des k -ppv, la règle des k -ppv présentée par [Mitchell01] ont des taux d'erreur plus grands. Pour $4 \leq k \leq 6$ la règle des k -ppv floue avec initialisation nette [Keller85], la règle des k -ppv, la règle des k -ppv [Mitchell01] et la règle des k -ppv avec distance-pondérée [Dudani76] sont encore moins performantes. D'autre part, notre classifieur donne les mêmes taux de bon classement quand les paramètres sont optimisés.

4.4 Discussions

Nous avons proposé une nouvelle règle des k -ppv floue dans le domaine de la classification des formes. A l'étape de défuzzification pour prendre la décision de la classe d'une forme x , nous avons étudié deux possibilités, soit la décision est basée sur le degré d'appartenance maximum à la classe soit elle est basée sur le degré d'appartenance maximum à la même classe qu'un des voisins de x dans ses k -plus proches voisins. Dans nos expériences avec différents jeux de données, nous avons montré qu'il y a un très petit risque d'erreur entre ces deux choix et avec les données utilisées, nous constatons que le deuxième choix est meilleur que le premier. Mais, un utilisateur peut adopter une des deux méthodes selon la nature de l'application. En plus de k , dans le formalisme flou, trois paramètres positifs α , β , et γ sont présentés pour moduler les degrés d'appartenance aux classes candidates dans les k -plus proches voisins de x . Ces paramètres représentent en fait les exposants de nos trois variables qui sont le nombre d'occurrences des voisins de x parmi les k -ppv appartenant à la même classe, l'inverse de la distance entre x et x_i , et à la variation des distances à partir du plus proche voisin et jusqu'au $k^{\text{ème}}$ voisin de x . L'influence de chacun de ces paramètres est étudiée un par un et le paramètre ayant le meilleur comportement est retenu et proposé pour la recherche avancée. Deux exemples de classification sont présentés pour évaluer la règle des k -ppv floue proposée. Pour la comparaison, les résultats obtenus avec quelques autres méthodes bien connues dans le domaine de la règle des k -ppv ont été présentés.

Dans l'exemple des IRIS, la performance de la règle proposée avec des variations de α est semblable à celle de la règle des k-ppv et de la règle des k-ppv floue avec initialisation nette [Keller85]. Cependant, le minimum de N_m (le nombre d'échantillons mal classés) est plus petit que dans d'autres méthodes et il est évalué à 3. La méthode s'avère donner des résultats comparativement bons, avec de petites valeurs de N_m , pour des valeurs relativement grandes de α et de k dans les deux cas de défuzzification. Le paramètre β a donné un meilleur résultat pour les grandes valeurs de k (>12) mais seulement dans le cas du premier type de défuzzification. Le paramètre γ a donné de bons résultats comparativement aux deux autres paramètres dans les deux cas de défuzzification avec un score de N_m encore plus bas, égal à 2 (avec $k = 14$) pour la seconde méthode de défuzzification, c'est un des meilleurs résultats possibles publiés avec ce jeu de données dans la littérature. La règle des k-ppv distance-pondérée [Dudani76] donne la plus mauvaise performance parmi les six règles comparées avec ce jeu de données, avec $N_m = 6$ dans tout l'intervalle $1 \leq k \leq 15$. La règle des k-ppv floue avec initialisation par 3-ppv est une règle des k-ppv pour chaque classe [Hattori99], elle emploie plus d'information que celle portée par les k-plus proches voisins d'un échantillon x .

Dans l'exemple 2, le minimum de N_m est égal à 3 avec la règle du 1-plus proche voisin, la règle des k-ppv, la règle des k-ppv floue [Keller85] avec initialisation nette et par prototype moyen de la classe, la règle des k-ppv avec soft voting et la règle des k-ppv avec distance-pondérée [Dudani76] quand k appartient à l'intervalle [1-6]. Le minimum de N_m est égal à 3 par la règle du 1-ppv, il indique le fait que pour les deux classes, seulement un ou deux plus proches échantillons étiquetés de x est nécessaire pour réaliser une classification de qualité. La règle des k-ppv floue proposée a montré des bons résultats indépendamment des critères de décision pour k variant dans l'intervalle [1-6] si un bon paramètre est retenu et optimisé. Les variations du paramètre α pour les valeurs de 0,1 à 15 n'ont aucun effet dans le cas du premier critère de défuzzification, mais le deuxième critère a donné des bons résultats avec les valeurs relativement basses i.e. 0,4 – 0,5 et il a donné un N_m évalué à 2. Les variations du paramètre β ne fournissent aucun bon résultat avec le premier critère de défuzzification, les valeurs de β variant de 0,1 à 20, alors que dans le deuxième cas de défuzzification la meilleure performance est atteinte avec des valeurs s'approchant de 2 dans l'intervalle [1-6] pour k avec le minimum de N_m égal à 2. Le troisième paramètre γ a gardé approximativement le même type de performance pour $1 \leq k \leq 6$ dans les deux cas de défuzzification avec une valeur autour de 3 pour le premier cas et égale ou supérieure à 2 pour le deuxième cas. Il a donc aussi donné une erreur minimum de 2.

La nouvelle règle des k-ppv floue proposée est une règle flexible, car les paramètres k et α ou β ou γ peuvent être choisis selon le problème de classification. Une manière pratique d'employer la méthode proposée, est d'utiliser les échantillons étiquetés donnés dans chaque classe comme échantillons de référence. La classification des échantillons en test est alors effectuée en utilisant la technique du « leave one out » pour estimer les valeurs de k dans un intervalle et les trois paramètres proposés. Ces paramètres sont finalement déterminés pour réduire N_m au minimum. Les paramètres obtenus ainsi sont employés pour classifier des échantillons d'entrée dans la phase de classification proprement dite.

La quantité de calculs nécessaire à l'optimisation des trois paramètres α , β , γ conduit à une limite du nombre de paramètres que l'on peut introduire dans le formalisme, c'est pourquoi, nous avons réalisé l'étude expérimentale de ces trois paramètres indépendamment les uns des autres. Avec deux jeux de données classiques et bien connus dans le domaine de la classification, nous pouvons conclure que si nous voulons réduire le nombre de paramètres, γ est le meilleur paramètre à laisser à choisir aux utilisateurs pour optimiser notre formalisme avec $\alpha = \beta = 1$. Alors avec cette proposition, il ne reste que deux paramètres γ et k dont les valeurs sont à déterminer et l'équation 4.13 devient :

$$f_{xi}(x) = \frac{b_i}{1 + b_i} \tag{4.14}$$

$$b_i = \frac{(N_x(C)) \sqrt{R_x(x_i)} (V_{xi}(x))^\gamma}{(d(x, x_i))}$$

De ce point de vue, notre méthode présente la même quantité de calculs que la règle des k-ppv floue [Keller85], mais les études ne s'inquiètent pas généralement de l'étape de mise au point des paramètres d'une méthode. Supposons que N_k et N_γ soient les nombres de valeurs de k et γ différentes utilisées dans l'optimisation de k et γ respectivement. Nous devons effectuer la classification des échantillons de référence $N_k \cdot N_\gamma$ fois pour l'optimisation de k et γ . Dans la règle des k-ppv et la règle des k-ppv distance-pondérée [Dudani76] dans laquelle il y a un seul paramètre k à optimiser, la classification des échantillons de référence doit être effectuée N_k fois pour l'optimisation de k . Dans la règle des k-ppv proposée par [Hattori99], les k -plus proches voisins d'un échantillon x d'entrée dans chaque classe doivent être considérés et en

plus de k , un paramètre « ℓ » est aussi à considérer. Il s'ensuit que la quantité de calcul avec les M ensembles des k -plus proches voisins de x dans M classes sera M fois plus importante qu'avec notre règle et la règle des k -ppv floue [Keller85].

4.5 Conclusion

Nous avons proposé une nouvelle fonction d'appartenance floue. La fonction proposée est employée dans la règle des k -ppv floue pour la classification de formes. Dans cette règle proposée, nous avons donné deux choix de défuzzification, l'un ou l'autre permet d'assigner un échantillon d'entrée à une classe pour laquelle la valeur d'appartenance est maximum ou de l'assigner à la classe du prototype parmi les k -plus proches voisins à laquelle la fonction d'appartenance est maximum. En plus de k , trois paramètres positifs α , β , et γ sont introduits pour évaluer l'influence de trois variables notamment le nombre d'occurrences des prototypes dans le voisinage de x appartenant à la même classe, l'inverse de la distance d'un échantillon x aux k -plus proches voisins et finalement la variation de ces distances entre x et ses k -plus proches voisins. Deux applications de classification ont prouvé que la dernière variable devrait être pondérée avec une valeur appropriée de γ pour obtenir une meilleure performance. Le nombre d'échantillons mal classés N_m est évalué. Avec des exemples de classification classique et réelle, le minimum de N_m évalué par la règle des k -ppv floue proposée est meilleur que ceux évalués par la règle des k -ppv, la règle des k -ppv avec distance-pondérée [Dudani76], la règle des k -ppv floue [Keller85], la règle des k -ppv proposée par [Hattori99] et la règle des k -ppv proposée par [Mitchell01].

La règle des k -ppv floue proposée est une règle de décision facile à mettre en œuvre comportant 2 paramètres γ et k pouvant être choisis et modifiés selon la nature de chaque problème de classification. Les paramètres, une fois optimisés, peuvent être employés pour la classification des échantillons inconnus. La quantité de calculs pour notre règle n'est pas plus importante que dans les autres règles pertinentes, toutefois comme nous l'avons montré dans les exemples de données, le nombre d'échantillons mal classés est considérablement diminué par l'optimisation des paramètres. Quand les paramètres γ et k sont optimisés, le coût informatique pour l'étiquetage des formes inconnues ne pose pas de problème particulier.

Chapitre 5

Définition des masses d'évidence et des distributions de possibilité

Dans ce chapitre, nous décrivons une illustration d'emploi du formalisme flou proposé (décrit dans le chapitre précédent) pour définir les masses d'évidence dans le cadre de la théorie de l'évidence (chapitre 2) et les distributions de possibilité dans le cadre de la théorie des possibilités (chapitre 2). Pour réaliser cette tâche, nous allons tout d'abord nous placer dans un cadre plus général, celui des *mesures floues*, défini par Sugeno [Sugeno74].

5.1 Mesure floue

Une mesure floue attribue à tout événement ou sous-ensemble de Ω (cadre de discernement) un coefficient compris entre 0 et 1 qui indique dans quelle mesure on peut penser que l'événement se réalisera. Une mesure floue est une fonction « g » définie sur les parties de Ω à valeurs dans $[0,1]$, telle que les axiomes suivants sont vérifiés :

$$g(\emptyset) = 0 \quad (5.1)$$

$$g(\Omega) = 1 \quad (5.2)$$

$$B \subseteq A \Rightarrow g(B) \leq g(A) \quad (5.3)$$

Le premier axiome (5.1) traduit que la confiance en l'élément vide est nulle. Le second axiome (5.2) définit l'hypothèse du référentiel exhaustif. Enfin, le dernier axiome (5.3) correspond à la propriété de croissance vis-à-vis de l'inclusion, c'est-à-dire que plus l'ensemble d'hypothèses est grand, plus la croyance qu'on lui accorde est grande. Cette propriété de monotonie implique les deux propriétés suivantes :

$$g(A \cup B) \geq \max (g(A), g(B)) \quad (5.4)$$

$$g(A \cap B) \leq \min (g(A), g(B)) \quad (5.5)$$

Les fonctions de plausibilité et de crédibilité sont des cas particuliers des mesures floues. L'ajout de contraintes permet de définir les mesures de probabilité, de nécessité et de possibilité.

En effet, si les mesures floues g_1 et g_2 vérifient les axiomes de monotonie suivants :

$$g_1(A \cup B) \geq \max (g_1(A), g_1(B)) \quad (5.6)$$

$$g_2(A \cap B) \leq \min (g_2(A), g_2(B)) \quad (5.7)$$

Alors g_1 est une mesure de possibilité Π et g_2 est une mesure de nécessité N . De plus, si g est une mesure floue qui vérifie l'axiome suivant :

$$\forall A, B \subseteq \Omega \quad g(A \cup B) = g(A) + g(B) - g(A \cap B) \quad (5.8)$$

alors g est une mesure de probabilité P .

Nous présentons maintenant les relations existant entre des fonctions de croyance particulières et ces mesures floues.

Fonction de croyance bayésienne :

Une distribution de masses est dite bayésienne si tous ses éléments focaux sont des singletons. Lorsque la masse de croyance est équi-répartie sur les hypothèses singleton, on appelle alors cette distribution de masse « masse bayésienne uniforme ». les fonctions de crédibilité et de plausibilité sont alors confondues avec la mesure de probabilité P :

$$\forall H_n \subseteq \Omega \quad \text{Bel}(\{H_n\}) = \text{Pl}(\{H_n\}) = P(\{H_n\}) \quad (5.9)$$

Fonction de croyance consonante :

Une fonction de croyance m est consonante lorsque les éléments focaux sont emboîtés au sens de l'inclusion :

$$F(m) = \{A_j\}_{j=1}^J \quad A_1 \subseteq \dots \subseteq \dots \subseteq A_J \quad (5.10)$$

Ici $F(m)$ représente ensemble des éléments focaux de fonction de croyance. Nous obtenons alors pour une fonction de crédibilité Bel et de plausibilité Pl consonante :

$$\forall A, B \subseteq \Omega \quad \text{Bel}(A \cap B) = \min(\text{Bel}(A), \text{Bel}(B)) \quad (5.11)$$

$$\forall A, B \subseteq \Omega \quad \text{Pl}(A \cup B) = \max(\text{Pl}(A), \text{Pl}(B)) \quad (5.12)$$

Dans ce cas, les mesures de crédibilité et plausibilité sont strictement équivalentes respectivement aux mesures de nécessité N et de possibilité Π . Notons qu'une explication plus détaillée des relations existant entre ces mesures est présentée dans [Smets00].

On peut illustrer les relations entre ces mesures floues [Bouchon-Meunier95] par la figure 5.1.

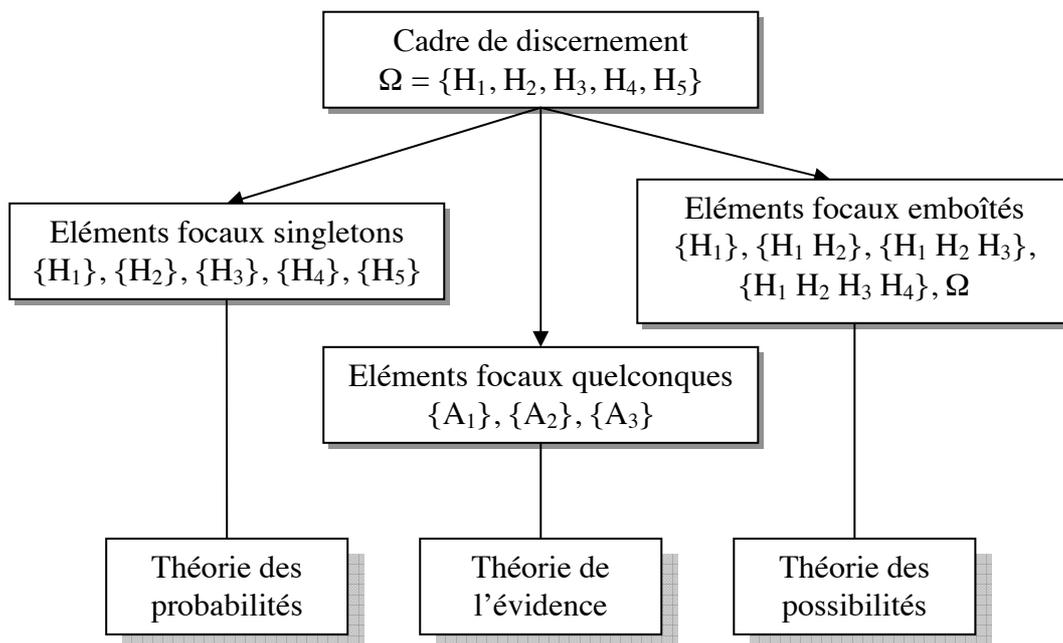


Figure 5.1 : Liens entre différentes mesures floues.

Afin de présenter la mise en œuvre de ces notions floues, nous pouvons reprendre un exemple issu de [Bouchon-Meunier95]. Considérons le jeu de roulette et un ensemble Ω

comprenant l'ensemble fini des chiffres susceptibles de sortir. On attribue des masses de croyance en plaçant une proportion x des jetons sur une case ou un groupe de cases.

Situation n°1 :

Si l'on croît que le chiffre 13 va sortir, on peut attribuer x de ces jetons à la case 13 et le reste à la case « impaire », donc $m(\{13\}) = x$ et $m(\{1,3,5,\dots\}) = 1-x$. les éléments focaux sont alors emboîtés puisque $\{13\} \subseteq \{1,3,5,\dots\}$ et on se trouve dans le cadre de la théorie des possibilités, avec :

$$\begin{aligned} N(\{13\}) &= \text{Bel}(\{13\}) = x \\ \Pi(\{13\}) &= \text{Pl}(\{13\}) = 1 - (x + 1-x) \\ N(A) &= \Pi(A) = P(A) = \text{Bel}(A) = \text{Pl}(A) = 1 \quad \text{avec } A = \{1,3,5,\dots\} \\ x &\leq P(\{13\}) \leq 1. \end{aligned} \tag{5.13}$$

Situation n° 2 :

Si l'on n'a que peu d'avis sur le chiffre qui va sortir, on peut miser par exemple 40% de ses jetons sur « impair », 10% sur « pair », 30% sur le 1 et 20% sur le 12, ce qui nous donne $m(\{1,3,5,\dots\}) = 0.4$, $m(\{2,4,6,\dots\}) = 0.1$, $m(\{1\}) = 0.3$ et $m(\{12\}) = 0.2$. Nous avons alors des éléments focaux quelconques et nous pouvons déterminer la confiance dans la sortie de chacun des chiffres à l'aide de fonctions de crédibilité ou de plausibilité. Nous obtenons alors :

$$\begin{aligned} \text{Bel}(\{1\}) &= 0,3 & \text{Pl}(\{1\}) &= 0,7 \\ \text{Bel}(\{2\}) &= 0 & \text{Pl}(\{2\}) &= 0,1 \\ &\dots & &\dots \\ \text{Bel}(\{12\}) &= 0,2 & \text{Pl}(\{12\}) &= 0,3 \end{aligned} \tag{5.14}$$

Dans ce contexte, nous avons donc :

$$\begin{aligned} 0,3 &\leq P(\{1\}) \leq 0,7 \\ 0 &\leq P(\{2\}) \leq 0,1 \\ &\dots \\ 0,2 &\leq P(\{12\}) \leq 0,3 \end{aligned} \tag{5.15}$$

Nous définissons maintenant les éléments focaux utilisés à partir de l'information de distance dans le cadre de la théorie de l'évidence et de la théorie des possibilités. Nous définissons aussi leurs masses d'évidence et les distributions de possibilité.

5.2 Eléments focaux

Pour la sélection des éléments focaux, nous considérons les k plus proches voisins d'une forme entrante x . Nous avons choisi les sous-ensembles d'après l'ordre des classes candidates dans les k -ppv. Supposons M classes dans la base de référence et n le nombre total des prototypes des M classes. La classe du plus proche voisin de x « C_q » est alors choisie comme seul membre du premier sous-ensemble des éléments focaux. Le deuxième sous-ensemble contient deux classes, la classe précédente et la classe suivante des 1^{er} et 2^{ème} plus proches voisins. Le troisième sous-ensemble comporte les deux classes précédentes et la troisième classe d'après le rang et on continue ainsi jusqu'à la dernière classe en suivant les rangs des k plus proches voisins de x considérés. On écrit $\{A_1\}, \{A_2\}, \{A_3\}, \dots, \Omega$. Où A représente une proposition contenant une ou plusieurs classes des voisins de x d'après le rang. Le nombre des éléments focaux retenus associés aux k -ppv varie d'un classifieur à l'autre. Voici un exemple dans le tableau 5.1 pour illustrer le choix des éléments focaux en prenant les sorties d'un classifieur :

Tableau 5.1 : Définition des éléments focaux

k	Classe	Eléments focaux
1	C_8	$\{C_8\}$ $\{A_1\}$
2	C_1	$\{C_1, C_8\}$ $\{A_2\}$
3	C_3	$\{C_1, C_3, C_8\}$ $\{A_3\}$
4	C_3	$\{C_1, C_3, C_8, C_3\} \Rightarrow \{C_1, C_3, C_8\}$
5	C_1	$\{C_1, C_3, C_8, C_1\} \Rightarrow \{C_1, C_3, C_8\}$

Dans cette étape, on envisage aussi le cas où il apparaît des sous-ensembles identiques. Dans ce cas, on supprime les sous-ensembles où des classes apparaissent avec des répétitions. Par exemple, si on trouve l'organisation : $\{C_1, C_3, C_8\}, \{C_1, C_3, C_8, C_3\}$, nous ne prenons pas en compte les sous ensembles où il y a des répétitions de classes.

5.3 Masses d'évidence et distributions de possibilité

Nous proposons de définir les masses d'évidence des éléments focaux à partir d'un degré d'appartenance floue de la forme entrante x , notée $F_{x_i}(x)$ et défini par l'équation 4.14 dans le chapitre précédent. Cette fonction assigne des valeurs réelles entre 1 et 0, et donne des degrés d'appartenance différents aux différentes classes C_i auxquelles appartiennent les prototypes étiquetés dans le voisinage de x .

En prenant en compte ces degrés d'appartenance floue assignés par le formalisme proposé pour un classifieur, les éléments focaux peuvent être modifiés selon les degrés d'appartenance $F_{x_i}(x)$. Les classes peuvent alors être réordonnées en fonction de valeurs décroissantes de $F_{x_i}(x)$, menant à la définition de nouveaux rangs pour les prototypes. Le tableau 5.2, établi à partir du tableau précédent (Tableau 5.1) montre la transformation :

Tableau 5.2 : Ordonnement des classes et éléments focaux selon $F_{x_i}(x)$

k	Classe	$F_{x_i}(x)$		k	Classe	$F_{x_i}(x)$	Eléments focaux	
1	C_8	0,201	→	1	C_1	0,226	$\{C_1\}$	$\{A_1\}$
2	C_1	0,226		2	C_3	0,206	$\{C_1, C_3\}$	$\{A_2\}$
3	C_3	0,206		3	C_8	0,201	$\{C_1, C_3, C_8\}$	$\{A_3\}$
4	C_3	0,190		4	C_3	0,190		
5	C_1	0,177		5	C_1	0,177		

Nous proposons de modéliser les fonctions de croyance à partir des degrés d'appartenance floue calculés par rapport à chaque élément des k -plus proches voisins de x . Nous assignons une masse de croyance à l'élément focal A_i égale à une valeur de $F_{x_i}(x)$ correspondant au positionnement de l'élément focal :

$$m(\{A_i\}) = F_{x_i}(x). \quad (5.16)$$

Si on reprend l'exemple décrit dans la section précédente des éléments focaux, nous trouvons un cas simple où $i = j$, c'est-à-dire :

$$\begin{aligned} m(\{A_1\}) &= F_{x_1}(x) = 0,226 \\ m(\{A_2\}) &= F_{x_2}(x) = 0,206 \\ m(\{A_3\}) &= F_{x_3}(x) = 0,201 \end{aligned} \quad (5.17)$$

La somme de masses des croyances n'est pas égale à 1, une étape de normalisation est nécessaire. Voici les masses de croyance après normalisation :

$$\begin{aligned} m(\{A_1\}) &= 0,226/(0,226+0,206+0,201) = 0,357 \\ m(\{A_2\}) &= 0,325 \\ m(\{A_3\}) &= 0,318 \end{aligned} \quad (5.18)$$

Nous pouvons déterminer la confiance dans le gain de chacune des classes à l'aide de fonction de crédibilité ou de plausibilité. Nous obtenons alors :

$$\begin{aligned} \text{Bel}(\{C_1\}) &= 0,357 & \text{Pl}(\{C_1\}) &= 0,357+0,325+0,318 = 1 \\ \text{Bel}(\{C_3\}) &= 0 & \text{Pl}(\{C_3\}) &= 0,325+0,318 = 0,643 \\ \text{Bel}(\{C_8\}) &= 0 & \text{Pl}(\{C_8\}) &= 0,318 \end{aligned} \quad (5.19)$$

Les crédibilités et les plausibilités pour toutes les autres classes qui n'ont pas de prototypes dans les k-plus proches voisins d'une forme entrante x sont égales à zéro.

Comme nous l'avons noté dans le chapitre 4, une décision de défuzzification basée sur le maximum de $F_{x_i}(x)$ est plus efficace que celle basée sur $F_{C_i}(x)$, c'est pourquoi nous avons retenu et utilisé le premier cas de défuzzification dans la modélisation des masses de croyance et des distributions de possibilité. Plus une classe est représentée dans le voisinage de x , plus x a de chance d'appartenir à cette classe mais la décision dépend des distances entre x et ses prototypes voisins, des variations de ces distances, et du rang comme nous l'avons déjà expliqué dans le chapitre précédent.

Maintenant nous précisons comment nous avons utilisé le formalisme flou proposé pour les distributions de possibilité. Les éléments focaux choisis sont des sous-ensembles emboîtés qui sont utilisés dans la théorie de l'évidence. En prenant le même exemple de jeu de données (tableau 5.2, et équation 5.18), nous définissons les distributions de possibilité des éléments focaux dans le cadre de la théorie des possibilités :

$$\begin{aligned} \pi(\{A_1\}) &= 0,357 \\ \pi(\{A_2\}) &= 0,325 \\ \pi(\{A_3\}) &= 0,318 \end{aligned} \quad (5.20)$$

Les possibilités et nécessités pour les classes sont décrites en 5.21 :

$$\begin{array}{ll}
 N(\{C_1\}) = 0,357 & \Pi(\{C_1\}) = 1 \\
 N(\{C_3\}) = 0 & \Pi(\{C_3\}) = 0,643 \\
 N(\{C_8\}) = 0 & \Pi(\{C_8\}) = 0,318
 \end{array} \tag{5.21}$$

Les nécessités et les possibilités pour les autres classes non représentées dans les k-ppv sont égales à zéro.

5.4 Conclusion

Les mesures floues de Sugeno offrent un cadre général de représentation dont les théories probabiliste, évidentielle et possibiliste ne sont que des cas particuliers. Cette mesure modélise l'aspect intuitif relatif à la propriété de monotonie qu'engendre une mesure de confiance sur l'occurrence d'un événement. Un corps d'évidence possibiliste représente le cas où l'information disponible est imprécise mais consonante. Dans ce cas, les degrés de crédibilité et de plausibilité associés à un événement se confondent avec les degrés de nécessité et de possibilité de cet événement. La théorie de l'évidence peut être considérée comme une généralisation des deux théories probabiliste et possibiliste dans la mesure où ces deux dernières correspondent à des situations particulières des éléments focaux. La théorie des probabilités correspond au cas où les éléments focaux sont des singletons et les possibilités correspondent au cas où ils engendrent la propriété de consonance (éléments focaux emboîtés).

Dans le cadre de la théorie de l'évidence et dans celui de la théorie des possibilités pour la reconnaissance des formes, il n'existe pas de méthodes génériques pour l'obtention des fonctions de croyance ou des distributions de possibilité respectivement. Dans la plupart des cas, les modélisations utilisées dépendent de l'application envisagée.

A partir de l'information de distance et des classes candidates d'une forme entrante fournies par un classifieur des k-ppv, nous avons défini d'une part les éléments focaux emboîtés d'après les mesures floues calculées et ordonnées par le formalisme flou proposé et d'autre part leurs masses d'évidence et leurs distributions de possibilité.

Chapitre 6

Fusion de classifieurs

6.1 Introduction

Nous présentons ici comment notre fonction du degré d'appartenance floue proposée au chapitre 4 peut être utilisée pour la reconnaissance des formes en fusionnant des classifieurs. Nous mettons en évidence une amélioration possible des résultats grâce à son emploi. La formule est déjà présentée (équation 4.14), ici nous décrivons un exemple pour montrer comment nous l'avons appliquée. Avant d'appliquer le formalisme flou proposé, nous obtenons l'information globale de distance à partir des informations de distances fournies par plusieurs classifieurs de distance. Pour calculer les distances globales nous avons utilisé plusieurs concepts de fusion, la règle de moyenne arithmétique et de somme avec ou sans pondération. Comme pondération, nous utilisons des poids fonction de la performance globale de chaque classifieur. L'emploi du formalisme flou dans le cadre de la fusion des informations en sortie des classifieurs est présenté sur la figure 6.1.

Dans la figure 6.1 et l'équation (6.1), e_j ($i = 1, \dots, L$) représente les L classifieurs, et P_{e_j} prend différentes valeurs selon les cas de fusion de distances :

- pour la règle de somme simple, P_{e_j} est égal à 1.
- pour la règle de somme pondérée, P_{e_j} est égal à la performance globale de chaque classifieur individuellement
- pour la règle de moyenne arithmétique simple, P_{e_j} est égal à $1/L$,
- pour la règle de moyenne arithmétique pondérée, P_{e_i} est égal à la performance globale de chaque classifieur individuellement divisée par le nombre de classifieurs (L).

Une fois que les classifieurs sont fusionnés selon le choix de la règle de fusion de distance, nous utilisons le formalisme flou proposé pour prendre la décision finale.

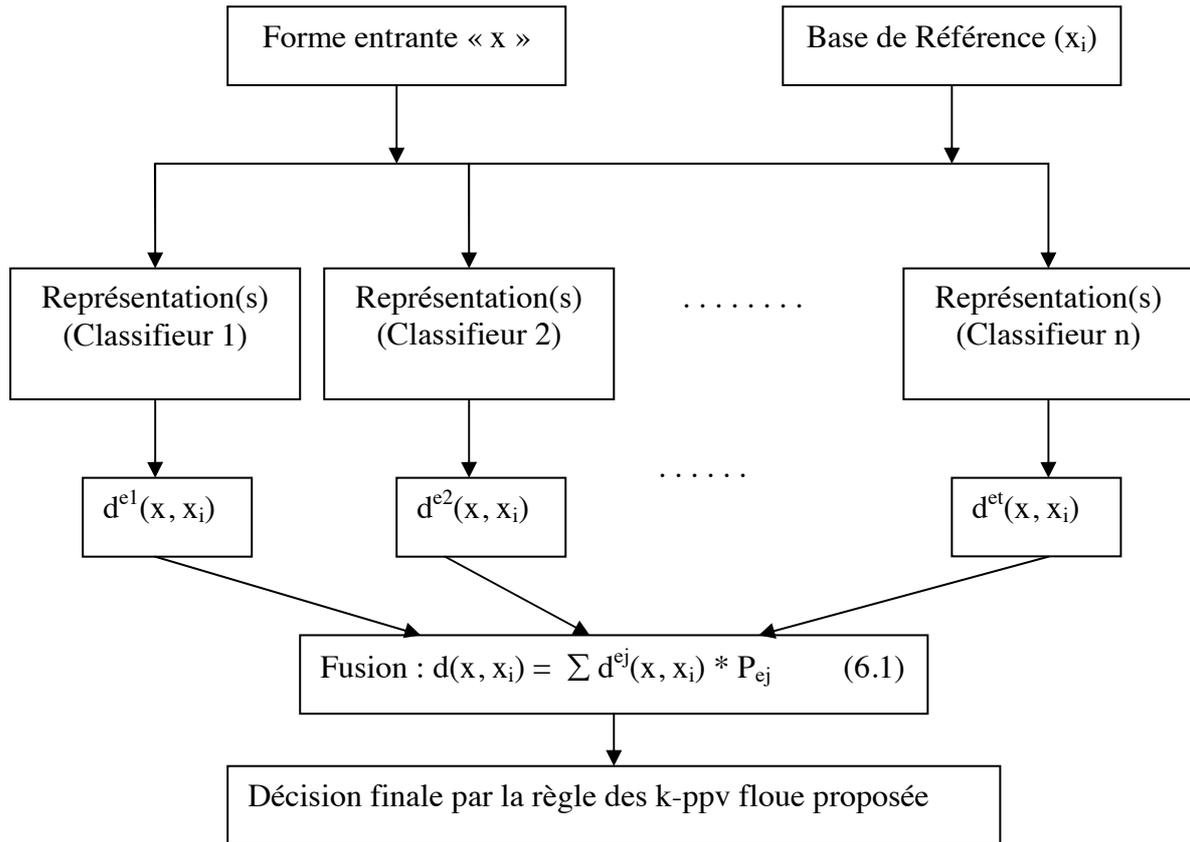


Figure 6.1 : Schéma général de fusion de données au niveau des distances (représentations) par la règle des k-ppv floue proposée.

6.2 Illustration sur un exemple

Prenons un système de reconnaissance de formes ayant quatre classifieurs de k-ppv (e1, e2, e3 et e4). Chaque classifieur de k-ppv donne l'information de distance et l'ordre des classes en fonction de ces distances. Un exemple de leurs sorties est montré dans le tableau 6.1 en limitant aux 5 premiers plus proches voisins pour mettre en évidence les décisions individuelles de chaque classifieur. Les décisions de chaque classifieur par la règle du plus proche voisin, la règle des 5-ppv classique, la règle des k-ppv floue proposée et n'importe quelle autre méthode des k-ppv sont identiques et sont indiquées en gras sur le tableau 6.1. La forme entrante x est une image de la main droite d'une personne étiquetée comme la classe numéro 26 (C₂₆). Les décisions de chaque classifieur restent les mêmes et varient en fonction de k dans un intervalle d'extrémités 1 et 5. Seulement le premier classifieur (e1) présente la bonne décision.

Tableau 6.1 : Quatre classifieurs et leurs informations en sortie dans le cas de 5-ppv

k	Classifieur (e1)		e2		e3		e4	
	Classe	$d(x, x_i)$						
1	C₂₆	0,11	C₁₂	0,18	C₁₈	0,06	C₁₉	0,29
2	C ₂₆	0,16	C ₁₂	0,20	C ₁₈	0,11	C ₁₂	0,38
3	C ₁₆	0,18	C ₁₃	0,21	C ₂₆	0,13	C ₂₆	0,40
4	C ₁₈	0,21	C ₁₃	0,23	C ₂₄	0,14	C ₉	0,41
5	C ₁₉	0,25	C ₁₁	0,24	C ₂₄	0,14	C ₂₅	0,42

Pour fusionner ces quatre classifieurs on calcule d'abord les distances globales. Pour cela nous utilisons toutes les distances entre une forme entrante x et les autres dans la base de référence c'est-à-dire que $k = n$ (n représente le nombre total des formes référence). Nous avons étudié les quatre règles de fusion de distance indiquées dans la page précédente. Nous avons noté qu'il n'y avait aucune influence de la pondération des classifieurs sur le résultat de fusion finale. En utilisant la règle de moyenne arithmétique simple voici, tableau 6.2, un jeu de données (distances et les classes):

Tableau 6.2 : L'information de distance globale et les classes candidates avec k égal à 5.

k	Classe	distance
1	C₂₆	0,225
2	C ₁₈	0,251
3	C ₂₆	0,256
4	C ₁₂	0,320
5	C ₁₉	0,329

En utilisant la formule du formalisme flou proposé dans le chapitre précédent voici le tableau contenant les calculs des éléments du formalisme :

Tableau 6.3 : Calcul des éléments de formalisme flou proposé.

k	Classe	$d(x, x_i)$	$N_x(C)$	$R_x(x_i)$	$V_{x_i}(x)$	b_i	$f_{x_i}(x)$	$F_{x_i}(x)$
1	C₂₆	0,68	2	1	1	2,92	0,75	0,29
2	C ₁₈	0,76	1	2	0,53	0,98	0,49	0,19
3	C ₂₆	0,78	2	3	0,35	1,56	0,61	0,24
4	C ₁₂	0,97	1	4	0,30	0,63	0,38	0,15
5	C ₁₉	1,00	1	5	0,24	0,53	0,35	0,13

Ici, nous avons fixé la valeur de γ égale à 1. Les distances sont normalisées par rapport au $k^{\text{ème}}$ voisin, c'est-à-dire que $d(x, x_i)$ est la distance entre x et le $i^{\text{ème}}$ prototype divisée par la distance entre x et le $k^{\text{ème}}$ prototype $d(x, x_k)$ comme indiqué dans le chapitre 4. Les variations de distances $V_{xi}(x)$ sont calculées alors par :

$$V_{xi}(x) = \frac{d(x, x_i)}{\sum_{j=1}^i d(x, x_j)} \quad (6.2)$$

et le degré d'appartenance flou normalisé est calculé par l'équation suivante (déjà présentée dans le chapitre 4) :

$$F_{xi}(x) = \frac{f_{xi}(x)}{\sum_{j=1}^k f_{xj}(x)} \quad (6.3)$$

Pour la défuzzification par un degré d'appartenance flou aux classes, nous avons déjà défini la fonction suivante :

$$F_{C_j}(x) = \sum_{i=1}^{N_x(C_j)} F_{xi}(x) \quad (6.4)$$

Ici, dans l'exemple donné, les degrés d'appartenance en fonction des classes sont :

$$\begin{aligned} F_{C_{26}}(x) &= 0,29 + 0,24 = 0,53 \\ F_{C_{18}}(x) &= 0,19 \\ F_{C_{12}}(x) &= 0,15 \\ F_{C_{19}}(x) &= 0,13 \end{aligned} \quad (6.5)$$

Comme nous l'avons déjà décrit deux étapes de défuzzification sont possibles. La décision que x appartienne à une classe C_q prend en compte soit le maximum de $F_{xi}(x)$ soit le max de $F_{C_j}(x)$. Sur notre exemple, dans les deux cas de défuzzification, nous trouvons la même décision : $x \in C_{26}$ (la bonne décision). Mais ce n'est pas toujours le cas. Nous avons

constaté avec nos jeux de données et comme nous l'avons noté dans la chapitre 4 que la décision avec le maximum de $F_{x_i}(x)$ est un peu meilleure qu'en considérant le maximum de $F_{C_j}(x)$.

Nous notons dans cet exemple d'illustration que la forme entrante x a été correctement classée par un seul classifieur et les trois autres classifieurs ont proposé des décisions différentes. En fusionnant ces quatre classifieurs, nous obtenons la bonne décision finale. Nous appliquons le formalisme proposé au niveau de chaque classifieur pour évaluer sa performance et au niveau des distances. Les résultats obtenus sont décrits dans les chapitres d'applications.

6.3 Conclusion

Dans ce chapitre, notre méthodologie de fusion de classifieurs par le formalisme flou proposé est décrite. Les informations de distance en sortie des classifieurs sont tout d'abord fusionnées à l'aide de plusieurs concepts d'opérations arithmétiques et finalement la règle des k -ppv floue proposée est employée pour prendre une décision finale. Les opérations mathématiques utilisées sont la moyenne et les sommes avec ou sans pondérations des sorties des classifieurs. Pour la pondération, nous calculons les performances globales individuelles de chaque classifieur et les poids assignés sont les valeurs de performances. Le formalisme proposé est applicable au niveau de la fusion de représentation.

Partie 3 : Applications de l'identification et de l'authentification

Nous n'avons pas voulu que l'apport présenté dans les parties précédentes reste théorique, certes un exemple ne peut pas prouver la généralité d'une approche néanmoins nous avons voulu illustrer l'efficacité de notre approche sur des problèmes concrets.

Dans cette partie nous décrivons trois applications que nous avons abordées.

- Identification et authentification par la main.
- Identification et authentification par signatures manuscrites hors ligne.
- Détection des contours dans une image couleur.

Comme on peut le noter, nos deux premiers exemples d'application sont des indicateurs biométriques. Dans cette partie nous présentons les notions fondamentales de l'identification et de l'authentification. Ensuite nous décrivons une brève introduction de la biométrie et des indicateurs utilisés dans la littérature ainsi que l'architecture générale d'un système basé sur un indicateur biométrique.

Chapitre 7

Identification et authentification

7.1 Introduction

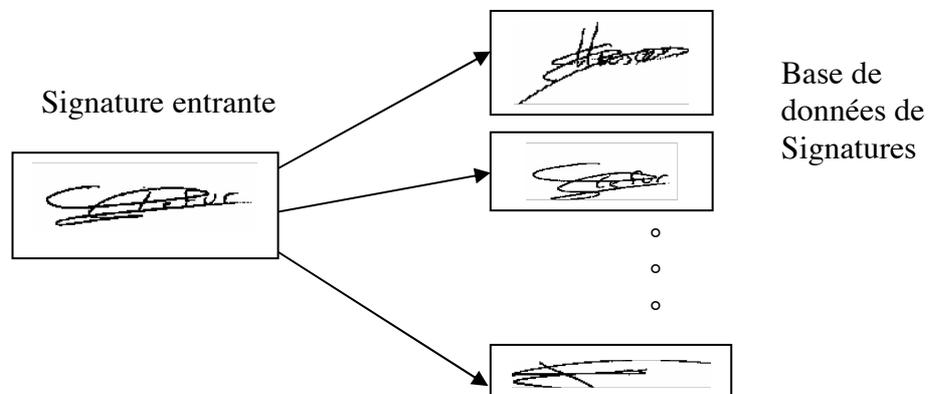
L'identification et l'authentification (ou vérification) sont des problèmes complexes, qui exigent une efficacité élevée et une robustesse à toute épreuve quand elles sont mises en œuvre dans les applications pratiques (renforcement des lois sur la sécurité, la sécurité dans les aéroports, l'accès à un bâtiment ou un serveur, le e-commerce, etc.). Les deux processus comprennent plusieurs étapes communes comme le prétraitement de l'information acquise, l'analyse et la décision.

Le but du procédé d'identification des formes est d'identifier la classe d'une forme entrante inconnue parmi une base de données des classes. Le cas de l'identification des signatures manuscrites est illustrée figure 7.1 (a). Le but du procédé de vérification est de confirmer ou de rejeter une forme concernant une classe dont on connaîtrait le nom. Un exemple de vérification des signatures manuscrites est montré dans la figure 7.1 (b).

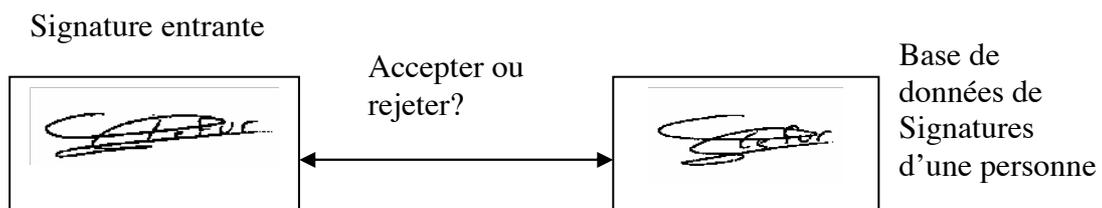
La discrimination ou distinction des formes du monde réel est toujours un problème actuel. L'identification et la vérification exigent un bon système de comparaison entre vecteurs de caractéristiques multidimensionnels. Dans ce but le choix des caractéristiques les plus pertinentes pour un système de reconnaissance des formes est une étape très importante. La sélection des caractéristiques n'est pas facile. Une solution est d'utiliser une grande diversité de caractéristiques et d'établir plusieurs classifieurs. Ensuite au lieu d'exclure l'utilisation des classifieurs pas assez robustes et de rechercher les caractéristiques à très haut pouvoir discriminant, l'augmentation de la fiabilité d'un système d'identification ou de vérification peut être réalisée par une combinaison (fusion) de classifieurs différents.

Alors, l'étape critique dans le processus de reconnaissance est la tâche de « fusion », qui combine différents avis des experts afin de prendre une décision finale. La difficulté principale dans cette tâche est due au comportement différent des experts qui peuvent, par exemple, donner des avis totalement contraires. Nous avons étudié différentes méthodes de

fusion pour la prise de décision à l'étape finale d'un processus de reconnaissance. Bien que chaque méthode ait ses propres avantages et inconvénients selon les domaines d'application nous concluerons en nous appuyant sur quelques applications réelles.



(a) comparaison avec les éléments d'une base de données



(b) comparaison avec les éléments d'une personne

Figure 7.1: Identification et vérification.

7.2 Biométrie

A l'heure où les frontières s'ouvrent, où la croissance internationale des communications et des réseaux informatiques, tant en volume qu'en diversité, explose et où la menace terroriste est présente, l'accès sécurisé et la surveillance constituent un sujet de très grande importance.

Dans nos sociétés, chaque individu doit pouvoir se faire connaître, s'authentifier et être identifié de façon sûre. Pour répondre à ces exigences, de nombreux systèmes "simples" d'identification et d'authentification ont été développés dans de très divers domaines. Les plus conventionnels étant le badge, le code, le *login* et mot de passe, la clé, la carte d'identité (contenant des informations sur l'individu)...

Toutefois, ces systèmes simples répondent de moins en moins bien aux besoins exprimés en termes de fiabilité et de sécurité. En effet le défaut commun à tous ces systèmes d'authentification est que l'on identifie un objet (carte, clé...) et non la personne elle-même. Les risques de vol, de perte, de copie sont grands et inacceptables. En ce qui concerne les systèmes à code, la technologie actuelle permet aux imposteurs dans la plupart des cas et en un temps raisonnable, de passer outre cette protection par recherche automatisée des passwords. De plus, qui n'a jamais transmis, confié ou oublié son mot de passe ?

Certains utilisateurs (mal intentionnés), appelés *imposteurs*, sont donc capables, du fait de la non identification de la personne physique, de falsifier leur identité et de pénétrer un système, ou un lieu dans lequel ils ne sont pas autorisés.

Les nouvelles technologies n'ont pas négligé le problème de la sécurité. Les différentes techniques d'authentification basées sur les caractéristiques physiques ou comportementales de l'utilisateur, ont été développées et ont donné naissance à *la biométrie*. L'avantage principal de ce qu'on appelle « *mot de passe biométrique* » est lié au fait qu'il ne pourrait pas être volé, oublié ou transmis à une autre personne. En effet, chaque membre de la population possède sa propre caractéristique biométrique et elle est relativement stable. D'où l'idée d'utiliser ces caractéristiques uniques et propres à chacun, pour l'authentification ou l'identification d'un individu.

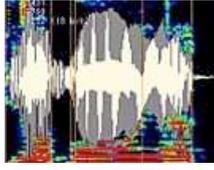
La définition de "Biométrie", est, (Petit Robert) : "Science qui étudie à l'aide des mathématiques (statistiques, probabilités), les variations biologiques, à l'intérieur d'un groupe déterminé". Notons que le terme de biométrie est un mot dérivé de l'anglais « *biometric* » définissant "La mesure des éléments morphologiques humains", il faudrait théoriquement employer le mot anthropométrie désignant "La mesure d'éléments de l'homme" (*mais ce terme n'est que très peu employé*).

7.2.1 Différents types de descripteurs biométriques

Diverses techniques biométriques ont été présentées dans la littérature et certaines d'entre elles sont employées pour les applications en temps réel. Les plus populaires sont l'identification d'empreinte digitale et l'identification de visage. Les autres biométries qui ont eu comme conséquence des systèmes commerciaux incluent le balayage de l'iris, la parole, le balayage rétinien, les thermogrammes et la géométrie de main [Jain99].

En analysant les technologies biométriques existantes, on peut les grouper en 2 catégories:

1. Les techniques d'analyse **comportementale** :

			
La signature manuscrite	La frappe au clavier d'ordinateur	Le clic sur la souris d'un ordinateur	La voix

2. Les techniques d'analyse de la **morphologie humaine** :

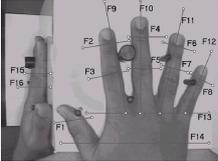
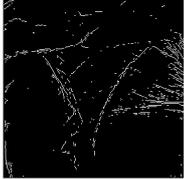
			
L'empreinte digitale	L'iris	La rétine	Le visage
			
La thermographie de la main	La thermographie du visage	La forme de la main	L'empreinte palmaire

Figure 7.2 : Différents types de descripteurs biométriques

7.2.2 Un indicateur biométrique idéal

La comparaison entre ces différentes biométries montre qu'il n'y a aucun indicateur biométrique idéal ; chaque indicateur biométrique a ses propres points forts et limitations et par conséquent chaque indicateur est utilisable pour une application particulière d'identification ou d'authentification. La fiabilité de l'identification personnelle employant le visage est actuellement faible [Yang02]. La reconnaissance d'empreinte digitale est largement utilisée dans l'identification personnelle car cela fonctionne bien dans la plupart des cas. Cependant, il est difficile d'acquérir des minuties c'est à dire des caractéristiques d'empreinte

digitale pour certaines classes de personnes telles que les personnes âgées, les travailleurs manuels, etc. Pour les applications de contrôle d'accès comme la surveillance de l'immigration aux frontières et d'accès aux lieux de repas par exemple, les approches biométriques très discriminantes comme l'empreinte digitale et l'iris ne peuvent pas être acceptables car l'intimité d'un individu n'est pas assez protégée. Un système basé sur la main et l'empreinte palmaire est mieux adapté dans ces cas.

7.3 Architecture générale

Tous les systèmes de biométrie partagent de nombreuses étapes et ont différents types d'architecture. Nous présentons une vue générale d'une architecture très souvent adoptée dans les systèmes de la littérature (figure 7.3). Il y a une possibilité de distinguer dans ces architectures, deux modules : le module d'acquisition et le module de reconnaissance, ce dernier étant divisé en deux sous modules : l'apprentissage et la décision.

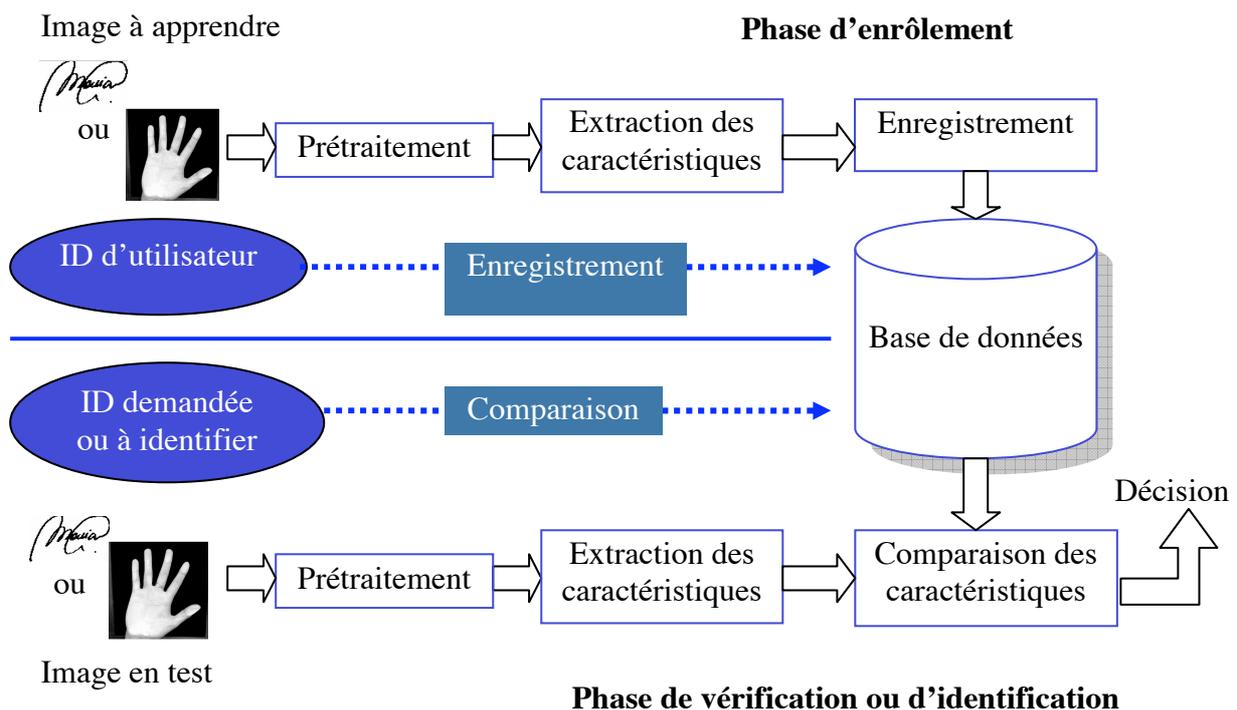


Figure 7.3 : Schéma général d'un système de reconnaissance par un indicateur biométrique.

7.4 Les caractéristiques des classifieurs étudiés

Dans cette thèse, nous avons étudié les classifieurs des k-ppv et quelques caractéristiques intéressantes dans le cas de deux applications réelles (reconnaissance de la main et de la signature manuscrite hors ligne). Notons certaines propriétés de ces classifieurs :

- (1) les classifieurs sont indépendants et assez redondants.
- (2) la robustesse des classifieurs varie selon la nature de l'application traitée, nous avons construit 4 classifieurs pour les deux applications traitées dans cette thèse. Trois classifieurs ont les performances comparables mais le quatrième classifieur est moins robuste.
- (3) les formes à reconnaître sont attribuées à une classe (les classifieurs sont sans rejet) et la classification est supervisée.
- (4) en cas d'ambiguïté en sortie du classifieur, nous avons indiqué ces cas en pourcentage, mais ils sont compris dans le pourcentage d'erreur en considérant ce cas comme une mauvaise décision.

7.5 Evaluation de la performance d'un classifieur

L'évaluation des performances d'un classifieur est une phase importante dans le processus de sa conception et de sa mise en œuvre dans la mesure où elle permet de savoir si le système est suffisamment performant pour l'application visée. Elle permet aussi de comparer les systèmes entre eux. Le plus souvent, la méthode *hold-out* est utilisée, elle consiste à diviser les données de départ en deux parties, une pour l'apprentissage et l'autre pour les tests ou l'évaluation de la robustesse du classifieur. Si les données disponibles sont limitées, l'une des deux méthodes suivantes est utilisée :

- La méthode de *leave one out* (tout sauf un) réalise autant d'essais qu'il y a de formes disponibles au départ dans la base de données.
- La méthode de cross-validation (validation croisée) consiste à découper la base de données disponible au départ en N sous-bases d'effectifs égaux. On effectue alors N essais en utilisant à chaque fois (N-1) sous-bases pour l'apprentissage du système de classification, et la sous-base restante pour le test.

Ayant une base de test, on procède généralement à l'évaluation du comportement d'un classifieur à partir de certaines mesures qui peuvent être globales, semi-globales, et/ou locales.

Performance globale : la plupart des approches globales classiques utilisées pour évaluer la performance des classifieurs reposent sur le calcul du taux de reconnaissance (TL). Un taux de reconnaissance se base sur les décisions des classifieurs : les bonnes décisions et les mauvaises décisions. En reconnaissance de formes, d'autres taux sont également définis comme le taux de confusion (TC) et le taux de rejet (TR). Ils sont définis par :

$$TL = \text{Nombre d'entités bien reconnues} / \text{Nombre total d'entités.}$$

$TC = \text{Nombre d'entités mal reconnues} / \text{Nombre total d'entités}.$

$TR = \text{Nombre d'entités rejetées} / \text{Nombre total d'entités}.$

Ces trois taux d'évaluation de performances sont liés par la relation :

$$TL + TC + TR \text{ soit } 100 \%$$

Ces mesures peuvent être utilisées pour calculer d'autres mesures permettant d'évaluer les performances comme par exemple la fiabilité. Le taux de fiabilité (TF) correspond au nombre d'entités reconnues par rapport au nombre d'entités non rejetées :

$$TF = TL / (1 - TR)$$

Dans cette thèse, nous ne considérons pas le taux de rejet comme nous l'avons déjà noté, nous indiquons les taux de reconnaissance et le taux de confusion (y compris le taux d'ambiguïté très souvent) comme celui de mauvaise classification.

Performances semi-globales : contenues dans les matrices de performances semi-globales. La matrice de performances semi-globales est une représentation quantitative des performances globales de chaque classifieur en reconnaissance et en rejet pour chacune des classes.

Performances locales : une analyse encore plus fine peut être obtenue par des mesures locales comme les matrices de confusion.

Pour évaluer **les performances d'un système de vérification**, deux taux d'erreur sont généralement calculés : le taux de vrais rejetés (TVR) et le taux de faux acceptés (TFA). Ces deux taux d'erreur sont aussi appelés dans la littérature : type I ou FRR (False rejection Rate) pour le TVR et type II ou FAR (False Acceptance Rate) pour le TFA. Dans certains travaux de la littérature un autre taux d'erreur est utilisé, le taux pour lequel TVR est égal à TFA dit Taux d'Erreur Egales (Equal Error Rate : EER). Le choix d'un seuil de décision joue un rôle important dans les calculs de ces erreurs, il peut être défini selon différents critères, soit minimiser la moyenne de TFA et de TVR, soit assurer que l'un des deux taux soit inférieur à un certain taux désiré (par exemple inférieur à 2%) voir la figure 7.4 :

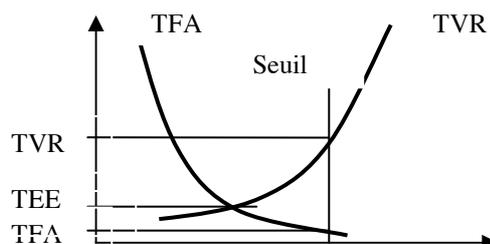


Figure 7.4 : Choix d'un seuil de décision suivant un critère.

Chapitre 8

Reconnaissance des personnes par leur main

8.1 La reconnaissance de la main

8.1.1 Introduction

Les systèmes d'identification de la main sont maintenant considérés très appropriés parce qu'ils ne causent pas d'anxiété aux utilisateurs comme des systèmes d'empreinte digitale et d'iris. La principale supériorité des systèmes basés sur la géométrie de main est la facilité des personnes à les accepter en raison de leur ergonomie et de leur installation facile et peu chère. D'ailleurs il est possible d'extraire deux types d'indicateurs biométriques à partir des images de main ; (i) les caractéristiques de la géométrie de main qui incluent la longueur de la main, la largeur, l'épaisseur, la composition géométrique, la forme et la géométrie des doigts, la forme de la paume, etc., et (ii) les caractéristiques de l'empreinte palmaire, qui se composent des lignes principales, rides, minuties, points de delta, etc.

Dans les systèmes conventionnels, des plots sont employés pour fixer le placement de la main pendant l'acquisition de l'image. Néanmoins, les systèmes basés sur des plots ont quelques inconvénients; les plots déforment certainement la forme de la main, deuxièmement, quoique les plots soient fixes, les doigts peuvent être placés différemment à différents instants, et cela cause une variabilité dans le placement de la main. Ces problèmes réduisent la performance du système global dans l'extraction de caractéristiques et l'analyse suivante. C'est pourquoi les nouvelles tendances sont les systèmes sans plots et nous proposons aussi d'utiliser notre méthodologie dans ce cadre. Dans cette thèse, nous présentons l'extraction de caractéristiques et une méthodologie basée sur la fusion qui emploie une acquisition d'image de la main simple, sans plots. Dans la littérature, des combinaisons de ces caractéristiques sont étudiées avec des degrés de succès variables. Notre contribution présente une comparaison entre les caractéristiques qui ont pour la plupart été proposées par d'autres chercheurs avant nous.

8.1.2 La biométrie de la main : état de l'art

Les systèmes d'identification de main ne sont pas nouveaux; un travail initial dans ce domaine peut être trouvé dans les années 70 avec l'existence de systèmes commerciaux [Miller71], [Ernst71], [Jacoby72]. Depuis lors, plusieurs méthodes ont été proposées dans la littérature et aussi dans le commerce. [HaSIS97], [Jain99], [Reillo00a], [Reillo00b], [Oden03], [Goh03], [Han04], [Ouhaddi98], [Kumar03], [Adan03], [Wong02]. Toutes les méthodes proposées utilisent diverses caractéristiques géométriques de la main (la taille, la largeur et la longueur des doigts, la taille de la main, le profil de hauteur etc.). Voici en bref quelques systèmes de reconnaissance de la main proposés dans la littérature et sur le marché.

8.1.2.1 Systèmes proposés dans la littérature

Méthode de segmentation de l'image d'une main [Ouhaddi98]

Cette méthode de segmentation, utilisée par [Ouhaddi98], a été mise en œuvre dans le cadre de la conception d'un modèle 3D articulé de la main. Elle permet d'extraire de l'image d'une main, sa silhouette, puis de réaliser une segmentation des doigts.

La détection des mains est basée sur l'information couleur. Un apprentissage de la distribution des couleurs de la peau est effectué à partir de l'histogramme des teintes et des saturations (peu sensible aux conditions d'éclairage). Une région de cet espace est définie par des seuils. La silhouette de la main sera considérée comme correspondant à la plus grande composante connexe des couleurs sélectionnées.

L'extraction des doigts est réalisée grâce à un opérateur morphologique : chapeau haut-de-forme avec un élément structurant de type disque dont le diamètre est légèrement supérieur à la largeur des doigts. Les 5 plus grandes composantes connexes correspondent aux 5 doigts. Le poignet peut être approximativement localisé comme étant le centre de gravité des points d'intersection de l'axe d'inertie de la main et de ceux des 4 plus grands doigts. La paume correspond au complément des doigts et de l'avant bras.

Méthode de reconnaissance de la main par un « modèle gaussien mixte » [Reillo00]

L'acquisition de l'image est réalisée grâce à un appareil photo numérique. La main est placée sur une plateforme munie de « plots » permettant un positionnement correct de la main et des doigts. La face dorsale est photographiée. La plateforme est munie, sur son côté, d'un miroir permettant également d'acquérir lors de la photographie, une vue de profil de la main.

Des mesures sont effectuées sur les deux vues (face et profil : analyse en 3D). Suite à une détection des contours par l'opérateur de Sobel, 25 caractéristiques sont extraites :

- largeurs des 4 plus grands doigts (annulaire, auriculaire, majeur, index)
- largeur de la paume
- longueurs du majeur et de l'auriculaire
- Angles et distances entre les « fourchettes interdigitales »

Pour éviter les variations dues aux prises ou pertes de poids, chaque valeur (sauf les angles) est normalisée par la première mesure de la largeur du majeur.

Le vecteur à 25 composantes est traité par un algorithme de modélisation par mélange de gaussiennes usuellement désigné par l'acronyme GMM (Gaussian Mixture Model).

GMM est une méthode statistique de reconnaissance de formes généralement utilisée pour la reconnaissance vocale. Cette technique est ici utilisée, sur des caractéristiques morphologiques, dans le but d'améliorer les résultats obtenus indépendamment par d'autres méthodes (distance de Hamming).

Les tests ont été effectués sur 20 utilisateurs fournissant chacun 10 images de leur main. Le tableau suivant présente les résultats. Il met en évidence les taux suivants :

- taux de succès d'identification
- EER (Equal Error Rate) pour l'authentification.

Les taux sont présentés pour 2 méthodes :

- Méthode reposant sur l'algorithme GMM
- Méthode reposant sur des calculs de Distance de Hamming (DH)

De plus chaque résultat est présenté en fonction du nombre d'images utilisées pour l'apprentissage (5 semble être une limite encore acceptable pour l'utilisateur).

Tableau 8.1 : Tableau de performances [Reillo00]

Nombre d'images de référence	3	4	5
Identification (GMM)	88 %	93 %	96 %
Authentification : ERR (GMM)	9,2 %	7,0 %	4,9 %
Identification (HD)	75 %	82 %	87 %
Authentification : ERR (HD)	14,8 %	10,4 %	8,3 %

Méthode de reconnaissance bimodale utilisant la géométrie et les lignes de la main [KUMAR03]

Cette méthode de reconnaissance se base sur l'analyse simultanée de deux caractéristiques biométriques. Elle entre donc dans le cadre des méthodes bimodales. Mais à la différence des méthodes biométriques bimodales classiques utilisant deux « organes » différents (empreintes digitales et visage...), la technique présentée ici, peut être mise en œuvre à partir d'une unique photo de main. Les deux caractéristiques biométriques étudiées sont : la géométrie de la main et les empreintes palmaires (lignes de la main).

L'acquisition de l'image (1280 x 960 pixels) est réalisée grâce à un simple appareil photo numérique. L'utilisateur place sa main dans le champ de l'appareil, sans aucune contrainte de position ou d'orientation. La face palmaire est photographiée (Analyse en 2D).

Prétraitements : L'image de la main (niveaux de gris) subit une binarisation avec seuil automatique grâce à la méthode de Otsu [Otsu78] .

L'orientation initiale de la main étant libre, il est nécessaire d'effectuer une rotation de l'image de façon à la « redresser ». L'angle de rotation est défini par le plus grand axe de l'ellipse englobant la main binarisée.

Géométrie de la main : 16 primitives issues de la géométrie de la main en sont extraites :

- Longueurs des 4 plus grands doigts
- Largeurs des 2 articulations des 4 plus grands doigts
- Largeur de la paume
- Hauteur de la paume
- Aire de la main
- Hauteur de la main (paume + majeur).

Empreintes palmaires : La zone d'intérêt (zone palmaire) subit une normalisation des niveaux de gris. Cette normalisation permet d'obtenir la moyenne et la variance souhaitées de façon à éliminer les imperfections dues au bruit et à la non-uniformité de l'illumination.

Les empreintes sont extraites grâce à différents masques permettant de faire apparaître les lignes d'orientation 0°, 45°, 90°, 135°.

Résultats : Deux types de fusion de classifieurs sont mis en œuvre :

- « fusion « au niveau de la représentation » (les vecteurs de caractéristiques des différents systèmes biométriques sont concaténés pour former un vecteur de caractéristiques uniques)
- « fusion au niveau de la décision » (les scores des systèmes biométriques sont combinés pour générer un score de décision finale).

La base d'images contient 1000 images issues de 100 personnes (10 images par personne). Pour chaque utilisateur, les 5 dernières images sont utilisées pour le test. Voici (tableau 8.2) les performances pour un test sur 472 images.

Tableau 8.2 : Les performances du système étudié par [Kumar03].

	FAR	FRR
Empreintes palmaires	4,49 %	2,04 %
Géométrie de la main	5,29 %	8,34 %
« Fusion au niveau représentation »	5,08 %	2,25 %
« Fusion de décision »	0 %	1,41 %

La reconnaissance de la géométrie de la main [Jain99]

C'est une méthode d'authentification. La main est placée sur une plateforme munie de plots permettant un positionnement fixe. Le processus d'enregistrement d'un utilisateur, se réalise par la saisie de 5 images (640 x 480) de la même main. 16 axes sont placés sur l'image (les plots servent de points de contrôle et de repère pour le placement des axes), permettant d'extraire différentes caractéristiques de la main : longueur et hauteur des doigts, hauteur de la main...

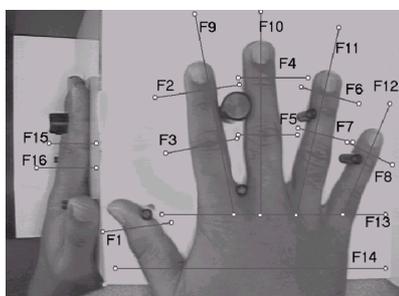


Figure 8.1 : Configuration du système et placement des axes [Jain99].

Chaque mesure est extraite de l'analyse de la couleur des pixels constituant chaque axe. Le profil de la couleur des pixels de chaque axe est assimilé à un profil idéal de façon à pouvoir identifier (sur l'axe) les points P_s et P_e constituant la frontière entre la main et le fond (plateforme). Les points caractéristiques P_s et P_e du profil idéal sont extraits du profil.

La phase d'authentification compte deux acquisitions fournissant deux supports pour extraire des caractéristiques. Un vecteur de la moyenne des caractéristiques F est généré. Ce vecteur F est ensuite comparé au vecteur Y de la base de données correspondant à la personne déclarée. La vérification d'identité est considérée comme positive, si la distance entre les

vecteurs F et Y est inférieure à un seuil prédéterminé. Quatre distances sont utilisées : la distance absolue, la distance absolue pondérée, la distance euclidienne, la distance euclidienne pondérée ; chacune d'entre elles ayant son propre seuil. Les tests ont été effectués sur 360 images, issues de 50 personnes. Les résultats sont présentés sur un graphe.

La reconnaissance de la main par sa géométrie et son positionnement naturel [Adan03]:

Cette méthode de reconnaissance de la main se base sur deux types de caractéristiques : sa géométrie et son tracé naturel. L'analyse se réalise sur les deux mains. Les mains sont placées sur une plate-forme, avec l'unique contrainte d'un écartement maximum des doigts (pas de plot de positionnement). Les images (640 x 480 pixels) sont acquises grâce à 2 appareils photo numériques. Le dispositif dispose de sa propre source de lumière.

La main étant positionnée librement, il est dans un premier temps nécessaire de réaliser un alignement de la main. Dans un deuxième temps, il est possible de déterminer le système de référence de la main, défini par les deux points extrêmes du majeur et du pouce.

Le processus d'analyse commence par une extraction de contours. L'utilisation d'une méthode d'interpolation par β -spline, permettant la détection des points clés suivants : 5 extrémités des doigts et 4 points correspondant aux fourchettes interdigitales (repères anatomiques de la main). On réalise ensuite une segmentation des différents doigts reposant sur des masques. Chaque doigt pourra donc être isolé et permettra une détection de la position des phalanges. Soixante dix caractéristiques sont extraites de la géométrie de la main. D'autres caractéristiques sont extraites du positionnement des doigts. En effet, le positionnement des doigts d'une personne, lors d'un écartement maximal, est inhérent à la personne elle-même et peut être considéré comme invariant au cours du temps. Les comparaisons sont réalisées grâce à des calculs de distances. Cette méthode semble, d'après les auteurs de l'article, donner de bons résultats mais ceux-ci ne sont pas quantitativement mesurés.

HaSIS : Hand Shape Identification System [HaSIS97]

Ce système est similaire à ceux décrits précédemment. Il utilise une image contenant la face dorsale de la main et une vue de côté (3D). La main est placée correctement sur une plate-forme, grâce à des plots. Dix sept caractéristiques géométriques sont extraites d'une image. Un test du système a été réalisé avec une base de 800 images (100 personnes, 8 images par personne) dont voici les résultats : Taux de Fausse Acceptation = 0,6 %, Taux de Faux

rejetés = 0,7 %, temps de traitement (hardware 486-50Mhz) = 0,5 sec, et le temps d'enrôlement (hardware 486-50Mhz) = 1,5 sec.

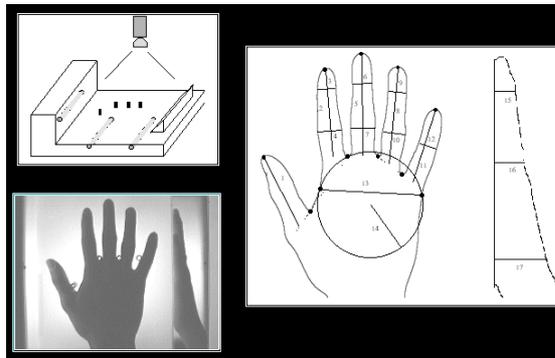


Figure 8.2 : Configuration d'un système de [HaSIS97].

La géométrie de la main par géométrie hiérarchique et « shape matching » [Wong02]

Cette méthode repose sur un positionnement libre de la main, aucun plot de positionnement n'est utilisé. De plus, l'écartement des doigts n'est pas imposé dans une configuration maximale, la seule contrainte posée est une séparation claire des doigts.

L'image est acquise par un scanner avec une résolution de 150 dpi. Suite à une binarisation, le contour de la main est facilement détecté. Les points caractéristiques de la main (extrémités des doigts et fourchettes inter-digitales) sont détectés en utilisant la courbure de la ligne de contours. L'axe défini par le point extrémité du majeur et le point milieu de la base du majeur sert d'axe de référence. Une rotation de l'image est effectuée pour obtenir un axe référence vertical (alignement de la main). Les caractéristiques extraites de la main sont présentées sur la figure 8.4.

Avec L_i ($i = 1 \dots 5$) : longueur de chaque doigt, W_j ($j = 1 \dots 8$): largeur des doigts, S_k ($k = 1..3$) : région extrême respectivement de l'index, du majeur et de l'annulaire. Les S_k sont des séries de points ordonnés issus du contour des doigts.

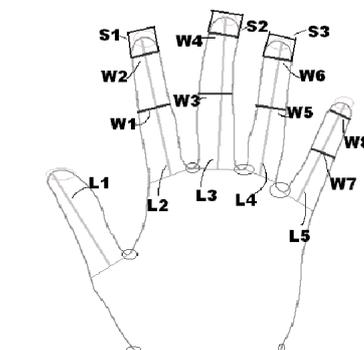


Figure 8.3 : Les caractéristiques extraites par [Wong02].

Les caractéristiques extraites sont séparées en deux groupes. Le groupe #1 contient 13 caractéristiques (longueurs et largeurs des doigts), le groupe #2 contient les 3 régions extrêmes. Un schéma séquentiel de reconnaissance est adopté. Un modèle de mélange de Gaussiennes (GMM : Gaussian mixture model) est utilisé sur le groupe #1 pour obtenir les paramètres caractéristiques de chaque personne. La probabilité d'appartenance de l'image considérée à une classe u est estimée. Si cette probabilité est supérieure à un seuil fixé à 0,5 alors l'image sera ensuite traitée avec le groupe #2.

Une comparaison, entre les points des régions extrêmes du groupe #2 et les points du modèle mémorisés dans la base, est effectuée grâce à un calcul de distance Euclidienne. Un test du système a été effectué sur 288 images issues de 22 personnes différentes (de 12 à 15 images par personne). Voici les résultats obtenus (tableau 8.3).

Tableau 8.3 : Les résultats de performances de [Wong02].

	Groupe #1 seulement	Groupe #1 + Groupe #2
Hit Rate	100%	88,89%
FAR	12,22%	2,2%

8.1.2.2 Systèmes développés par le secteur privé

De nombreux dispositifs de reconnaissance de la main sont disponibles sur le marché. Toutefois, ces appareils restent l'exclusivité de sociétés privées. Il est donc très difficile d'obtenir des informations sur leurs fonctionnements et les méthodes utilisées. Les seules sources d'informations disponibles sont les communiqués de presse et les fiches techniques des matériels. La plupart des systèmes disponibles sur le marché sont extérieurement très semblables.



Figure 8.4 : Un dispositif de Time & Attendance Terminal [HandPunch4000]

Le plus souvent ces systèmes présentent les caractéristiques suivantes :

- Système dont l'objectif est l'authentification
- Analyse tridimensionnelle de la main
- Saisie d'une image de la face dorsale de la main
- Positionnement de la main grâce à des guides (plots)
- Analyse d'une main en moins d'une seconde

De manière générale l'authentification semble reposer sur un code personnel (analogue à l'identifiant) et une analyse biométrique (analogue au *password*). Certains systèmes peuvent analyser jusqu'à 90 caractéristiques de la main. Le système prend une image de la main et examine la forme tridimensionnelle de la main, la longueur et la largeur des doigts, la forme des articulations...

Des lumières infrarouges et un appareil photo digital sont souvent employés pour capturer les images de la main. Aucune vérification d'empreinte palmaire n'est utilisée. Un descripteur mathématique de la géométrie de la main est créé à partir de ces informations et est enregistré dans le lecteur ou sur un PC relié à un réseau. Un stockage typique de la géométrie de la main exige approximativement 9 octets de mémoire. Les performances semblent être raisonnables, mais certaines difficultés apparaissent lorsqu'il s'agit de différencier de vrais jumeaux et parfois même, des membres d'une même famille.

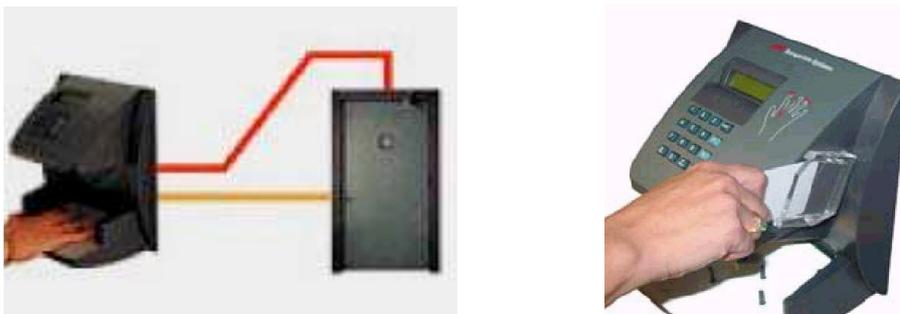


Figure 8.5 : Un système d'ouverture de porte, main + carte

Certains système utilisent la double authentification. Ils utilisent une carte personnelle sur laquelle est stocké le gabarit de la main de l'utilisateur. Aucune base de données d'empreintes n'est présente dans le lecteur.

Remarques :

- Les lecteurs de géométrie de la main sont de grande taille, causant des restrictions d'utilisation, pour certaines applications.
- Le lecteur de reconnaissance du gabarit de la main effectue, à chaque passage, de nouvelles mesures pour prendre en compte des modifications de la forme dues à l'ajout d'une bague, un régime ou la croissance d'une main d'enfant.

Le laboratoire de recherche de Fujitsu a mis au point un système biométrique capable de lire les lignes de la main, sans contact physique. Le taux d'erreur serait de 0,8%. Lors d'un essai portant sur 700 personnes de 10 à 70 ans, 99 % des personnes testées ont été reconnues par le système.

8.1.3 Conclusion

Les travaux dans le domaine de la reconnaissance de la main présentent différentes méthodes utilisées pour l'identification ou l'authentification par la biométrie de la main. Chacun présente une méthode de reconnaissance originale, toutefois, certains procédés ou paramètres sont communs à plusieurs approches. Les systèmes utilisés sont le plus souvent constitués d'une plate-forme munie d'un module de saisie de l'image. Ce module produit clichés de tailles variées (de 480 x 640 à 1280 x 960).

Deux types de plate-forme sont les plus utilisés :

- Plate-forme munie de plots permettant un positionnement correct et stable de la main. Ce type de plate-forme nécessiterait un certain entraînement de la part de l'utilisateur et engendrerait des déformations de la main. Toutefois cette technique présente l'avantage d'éliminer les mauvais positionnements (doigts non séparés, par exemple).
- Plate-forme sans plots, laissant une plus grande liberté à l'utilisateur. Cette technique pose tout de même la contrainte de présenter sa main avec les doigts clairement séparés (problème de non respect de cette contrainte). Un alignement de l'image est nécessaire.

Deux types d'analyse sont étudiés : Analyse en 2D : l'image contient la face dorsale ou palmaire de la main. Analyse en 3D : la face dorsale ou palmaire et le profil de la main sont saisis. Un miroir est communément employé.

Le nombre de caractéristiques extraites de la main est variable (de 16 jusqu'à 70), toutefois un nombre proche de 16 est souvent utilisé. Le nombre d'images saisies pour chaque personne est variable (de 5 jusqu'à 15), toutefois un nombre de 5 images semble

communément être un maximum pour que le système soit accepté par l'utilisateur. Les caractéristiques extraites sont le plus souvent :

- Les longueurs des doigts
- Les largeurs des doigts
- La largeur de la paume
- Les hauteurs des doigts (système 3D, vue de côté)
- L'aire de la main
- La hauteur globale de la main

Remarque : le pouce est souvent mis à l'écart des mesures.

Les procédés de comparaison d'une image avec celles de la base de données sont variés, les calculs de différentes distances sont très souvent mis en œuvre. La notion de fusion de classifieurs apparaît parfois. Les résultats FRR et FAR sont variables suivant les méthodes et les paramètres utilisés. Une comparaison des résultats n'aurait pas grand intérêt parce que les jeux de données sont différents. Mais en général il y a de meilleurs résultats dans le domaine de l'authentification que pour les systèmes basés sur les signatures manuscrites.

8.2 Empreinte palmaire (Palmprint)

8.2.1 Introduction

L'identification ou l'authentification employant des caractéristiques de l'empreinte palmaire est une biométrie relativement nouvelle. Un système d'empreinte palmaire comporte plusieurs avantages par rapport à l'utilisation d'autres caractéristiques biométriques actuellement disponibles comme l'a noté par [Kumar04]. Les empreintes palmaires contiennent plus d'information que les empreintes digitales, ainsi elles sont plus discriminantes ; les sources de capture d'empreintes palmaires sont beaucoup moins chères que celles de capture des iris; les empreintes palmaires contiennent des caractéristiques distinctives additionnelles telles que les lignes principales et les ridules (wrinkles), qui peuvent être extraites à partir des images à basse résolution; et le dernier avantage, en combinant toutes les caractéristiques d'une paume, telles que la géométrie de la paume, les caractéristiques des ridules ou des plis, et des lignes principales, il est possible d'établir un système robuste de biométrie. En raison de ces avantages, ces dernières années, l'empreinte palmaire a attiré une attention considérable et diverses méthodes ont été proposées. Cependant, une étude de l'empreinte palmaire est plus lente qu'une étude d'empreinte digitale en raison de l'information supplémentaire stockée dans une empreinte palmaire. Par

conséquent des systèmes d'identification de l'empreinte palmaire sont généralement configurés avec des unités de traitement plus puissantes et plus rapides. La taille du disque dur doit également être optimisée pour le traitement des grandes images de l'empreinte palmaire, ces images ne sont pas plus grandes que pour la main.

Une paume est la surface intérieure de la main entre le poignet et les doigts. Une empreinte palmaire est définie comme une empreinte sur une paume, elle se compose principalement des lignes, des ridules (wrinkles), des minuties, des crêtes (ridges), etc.

Il y a trois lignes principales en général sur une paume. Ces lignes sont claires. Les ridules sont des lignes plus minces que les lignes principales et plus irrégulières. Les lignes autres que les lignes principales, et des ridules, sont appelées des crêtes, et elles existent partout sur la paume (figure 8.6).

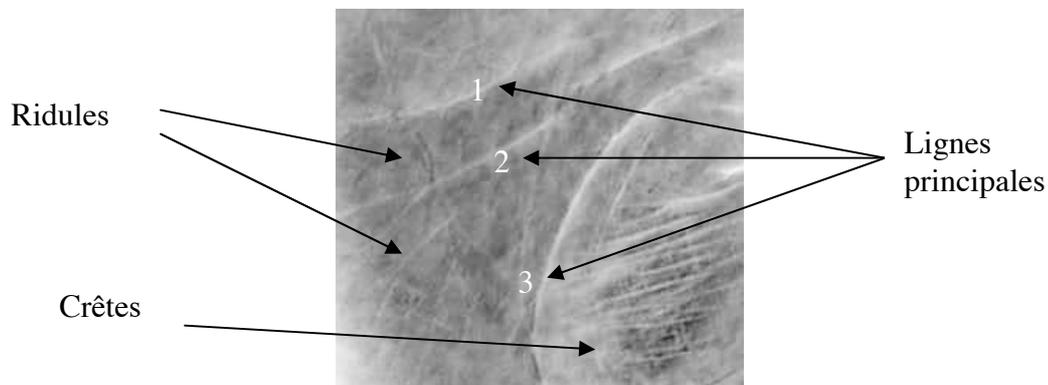


Figure 8.6 : La forme des lignes sur une paume. Trois lignes principales sur une paume : 1- ligne de cœur, 2- ligne de tête et 3- ligne de vie.

Un système automatique d'identification d'empreinte palmaire, souvent nommé un APIS (Automatic Palmprint Identification System), est employé typiquement dans des applications légales criminelles, plutôt que pour l'authentification en temps réel [Survey03]. Le nombre des systèmes d'empreinte palmaire va continuer à augmenter. Naturellement la police ne peut que remarquer les avantages qu'une telle technologie peut apporter. L'identification d'empreinte palmaire est sans doute le prochain grand domaine d'investigation dans le cadre des lois sur la sécurité [Survey03].

8.2.2 Etat de l'art

Considérant les empreintes palmaires en tant qu'images texturées, propres à chaque individu quelques techniques ont été proposées dans la littérature. L'analyse des images

d'empreintes palmaires peut reposer par exemple sur des filtres de Gabor [Kong02], [Kong03], [Zhang03], ou des ondelettes [Kumar02], ou la transformée de Fourier [Li02], ou l'énergie locale de texture [You02].

Par référence aux empreintes digitales, d'autres auteurs ont concentré leur attention sur la présence et l'importance des plis, des points extrémaux de quelques lignes principales, des arêtes et des minuties ressemblant aux formes des empreintes digitales. [Wu02] a caractérisé ces plis par des caractéristiques de la ligne directionnelle d'énergie et les ont employées pour l'identification de l'empreinte palmaire.

Les propositions de traitement de quelques auteurs indiquent que les points extrémaux des 3 lignes principales sont invariants à rotation. [Shu98], [Zhang99] ont employé ces points terminaux et certains points intermédiaires pour le calcul des caractéristiques géométriques et structurelles des lignes principales et la mise en correspondance des empreintes palmaires. D'autres chercheurs comme [Duta01] ont suggéré que les connections entre lignes extraites de la paume ne soient pas importantes. Par conséquent, dans [Duta02] est employé un ensemble de points caractéristiques le long des lignes importantes de la paume, plutôt que sur des lignes extraites dans [Zhang99] et [Duta02] a proposé des points adaptés pour l'authentification de l'empreinte palmaire. Dans [Kumar03] les auteurs ont utilisé des masques directionnels de taille 9 par 9 pour l'extraction de caractéristiques des lignes (orientées à 0° , à 45° , à 90° , et à 135°).

La forme de l'empreinte palmaire contient également des arêtes et des minuties ressemblant à une forme d'empreinte digitale. Cependant, dans les empreintes palmaires les plis et les arêtes se recouvrent et se croisent souvent. Par conséquent, dans [Funada98] les auteurs ont suggéré l'extraction de caractéristiques locales, les arêtes. Mais leur travail est limité à l'extraction sans analyse des arêtes. Ces auteurs n'indiquent pas le taux de succès de l'identification des empreintes palmaires du système reposant sur ces arêtes extraites. [Chen01] a essayé d'estimer des points de pliure des empreintes palmaires en produisant un plan tangent en niveaux de gris local. Ces points de pli sont reliés ensemble pour isoler le pli sous forme de lignes droites employées dans le processus de mise en correspondance. Aucun détail n'est donné pour suggérer la robustesse de l'extraction de ces plis partiellement extraits pour la mise en correspondance des empreintes palmaires.

Dans [Han03], l'utilisation des caractéristiques morphologiques et de contours par filtre de Sobel pour caractériser des empreintes palmaires avec l'aide d'un classifieur de réseau de neurones a été présentée. Un scanner est utilisé pour capturer des images d'empreintes

palmaires. Tandis qu'un dispositif CCD dans un appareil photo saisit les images de la main et de l'empreinte palmaire dans [Han04].

Tableau 8.4 : Résumé des bases de données et des erreurs obtenues dans quelques systèmes.

Référence	Bases de données (individus totaux × images par individu)	Images apprises/test pour chaque individu	TVR (%)	TFA (%)
[Connie05]	75 × 6 × 2	3 / 3	1,49	1,36
[Han04]	50 × 30	10 / 20	4,0	9,1
[Wu03]	300 × 10	6 / 4	1,22	0,18
[You02]	200	-	9	-
[Duta02]	3 × 30	-	EER = 5 %	
[Connie05b]	50 × 6 × 2	3 / 3	0	0
[Kong03]	120 × 20 × 20	19 / 1	-	-
[Zhang99]	100	-	5 %	-
[Li03]	100 × 2	-	6 %	-
[Lu03]	191×8×2	4 / 4	0,85	-
[Han03]	50 × 30	10 / 20	2	2

8.2.3 Systèmes en ligne et hors ligne basés sur l'empreinte palmaire

En plus du procédé de sélection des caractéristiques, la méthode d'acquisition des images est un autre facteur à prendre en compte. Les systèmes automatiques d'identification d'empreinte palmaire sont alors classifiés en deux catégories [Zhang03] : *en ligne et hors ligne*. Un système d'identification d'empreinte palmaire hors ligne traite les images d'empreintes palmaires capturées précédemment, souvent obtenues à partir des paumes de mains encrées digitalisées par un scanner numérique. Les méthodes d'identification d'empreinte palmaire proposées par [Li03], [You02], [Funada98], [Zhang99], [Duta01], [Chen01] et [Wu02] utilisent des images de la trace d'encre constituant l'empreinte palmaire. Ces approches peuvent fournir des images à haute résolution et conviennent aux méthodes qui exigent des images de résolution fine pour extraire des lignes, des points caractéristiques (datum points) et des minuties. Cependant, ces méthodes ne sont pas appropriées aux systèmes de sécurité en ligne car deux étapes sont nécessaires : encrer les mains pour obtenir les images d'empreinte palmaire sur des papiers et puis les scanner pour obtenir des images numériques. Quelques travaux récents présentés par [Kong02], [Wu02], [Zhang03], ont employé un appareil photo numérique CCD pour capturer des images d'empreinte palmaire. Les images numériques acquises sont traitées en temps réel. Une autre approche proposée par [Han03] utilise un scanner comme dispositif d'acquisition. L'avantage du scanner est qu'il est

équipé d'un verre plat permettant aux utilisateurs d'aplatir leur paume correctement sur le verre pour réduire les arêtes pliées et les erreurs de ridule. Certains auteurs comme [Li03] et [Wu02] ont fixé quelques plots sur la plateforme du capteur pour limiter le décalage et la rotation de la paume. Quelques utilisateurs peuvent se sentir inconfortables quand leurs images de main sont acquises dans la position imposée à la main. En outre, cette approche exige un algorithme additionnel pour enlever les traces de plots dans l'image de main acquise. Les travaux présentés par [Zhang03] et [Connie05] n'emploient pas de plots fixes afin d'augmenter la flexibilité et la facilité d'emploi du système.

8.2.4 Conclusion

L'étude des systèmes d'identification d'empreinte palmaire proposés montre que les caractéristiques employées peuvent être groupées en deux catégories principales : les caractéristiques statistiques et structurelles [Connie05]. Dans une approche d'identification d'empreinte palmaire basée sur les caractéristiques statistiques, l'image d'empreinte palmaire est traitée dans son ensemble pour l'extraction, la représentation et la comparaison. Ainsi, le processus d'identification est très clair. Cependant, comme des détails de texture abondants sont ignorés, l'information normale et structurale d'empreinte palmaire ne peut pas être caractérisée. D'autre part, une approche structurale peut clairement représenter les caractéristiques structurelles d'empreinte palmaire. En outre, une image de basse résolution peut être employée pour l'approche structurale puisque des lignes peuvent être détectées à basse résolution. Cependant, cette méthode est limitée par la difficulté de déterminer les éléments primitifs et les placements relatifs des structures de ligne. Une puissance de traitement plus élevée est exigée pour la mise en correspondance des segments de ligne avec les échantillons stockés dans la base de données. Chaque approche comporte ses points forts et ses points faibles, et le choix dépend de l'application : le mode opérationnel, la vitesse de traitement, la mémoire de stockage et la qualité des images acquises. Une de solution d'amélioration d'un système serait de fusionner différents types de caractéristiques, mais pour le moment, il y a très peu de travaux qui aient réalisé cet aspect ; nous allons décrire quelques travaux trouvés dans la littérature dans la section suivante.

L'analyse des méthodes utilisées pour la décision montre que la plupart des travaux dans le domaine de l'empreinte palmaire sont basés sur l'extraction de caractéristiques et leur comparaison par la mise en correspondance. C'est-à-dire que des propositions faites dans ce domaine mettent l'accent sur la recherche des caractéristiques les plus discriminantes. Les avantages de la combinaison (ou fusion) de classifieurs ne sont pas encore vraiment explorés.

Récemment il y a des travaux qui combinent les scores de correspondance au niveau des caractéristiques et les décisions au niveau de la décision. De plus, comme l'empreinte palmaire peut aussi être extraite à partir de l'image de la main, on peut combiner les deux modalités dans le processus de reconnaissance. Il y a encore très peu de travaux réalisés c'est pourquoi nous nous intéressons à ce domaine.

8.3 L'intérêt de la fusion

Dans cette section, nous présentons quelques travaux que nous avons trouvés dans la littérature. Ils ont proposé et étudié l'influence de la fusion dans leurs méthodologies.

Reconnaissance par la géométrie de la main et par l'empreinte palmaire [Han04]

Le système inclut deux protocoles. Le premier protocole est à deux niveaux. La géométrie de la main est employée dans un premier niveau pour vérifier grossièrement l'identité. Les échantillons possédant les formes de main ambiguës sont re-vérifiés dans un deuxième niveau par les caractéristiques (50-500 en nombre) de l'empreinte palmaire, qui sont extraites à partir d'une région d'intérêt en employant des approches de décomposition basées sur des ondelettes. Dans le deuxième protocole, les deux indicateurs biométriques sont fusionnés. Des appareils photo numériques avec capteur CCD sont utilisés pour saisir les images. Les divers résultats obtenus avec des résolutions différentes sont intégrés pour réaliser une meilleure décision en employant la fonction booléenne positive (PBF) et la méthode de bootstrap. Une base de données a été construite rassemblant 1500 images de main de 50 personnes pendant un an. Dix images d'une personne ont été aléatoirement choisies et employées pour l'apprentissage du modèle lors de la phase d'enrôlement, et les 20 autres images ont été employées lors de l'évaluation de leurs approches. La géométrie de la main (11 caractéristiques) seule a donné un résultat : TVR = 1,6% et TFA = 36,3%, l'empreinte palmaire (50 caractéristiques) seule TVR = 4,0 et TFA = 9,1%, quand les deux ont été combinées TVR = 5,3% et TFA = 3,7%.

L'authentification d'empreinte palmaire par classifieurs multiples [Kumar04]

Selon [Kumar04], une combinaison de différentes approches de l'extraction des caractéristiques peut être employée pour atteindre une performance plus élevée. Extrayant des caractéristiques de la forme, de la ligne, et de la texture de l'empreinte palmaire simultanément à partir d'une analyse en composantes principales (ACP), à partir de détecteurs de ligne et de filtres de Gabor, les scores ont été comparés ainsi que leurs combinaisons. Les

performances comparatives des règles simples de combinaison et de stratégie hybride de fusion ont aussi été étudiées. L'utilité d'une telle approche par rapport à celles basées sur différents classifieurs individuels a été montrée par des résultats expérimentaux sur une base de données de 100 utilisateurs.

Fusion au niveau des caractéristiques d'empreinte palmaire [Kong04]

Pour améliorer l'efficacité de l'identification, une approche de fusion au niveau des caractéristiques est proposée dans [Kong04]. Dans leur travail, de multiples filtres de Gabor sont utilisés pour extraire des informations de phase à partir d'une image de l'empreinte palmaire, ces informations sont ensuite fusionnées pour produire une caractéristique simple appelée le code de fusion. La similarité entre deux codes de fusion est mesurée par leur distance de Hamming normalisée. Une base de données contenant 7752 images d'empreintes palmaires de 386 paumes différentes a été employée pour valider la performance de la méthode. La comparaison avec les résultats obtenus avec leur approche précédente sans fusion montre une amélioration de la vérification en faveur de la fusion.

Identification et vérification par la fusion de représentations d'empreinte palmaire [Poon04]

Les auteurs précisent l'efficacité et la robustesse des systèmes d'identification ou de vérification de l'empreinte palmaire quand la fusion a été réalisée aux différents niveaux. Dans leur méthodologie, trois représentations différentes de l'empreinte palmaire ont été fusionnées au niveau des scores par la règle de la somme, et au niveau de la décision par des poids ou par la règle de vote majoritaire. Selon leurs conclusions, les résultats ont prouvé qu'il est plus facile de formuler et de justifier une étape de fusion au niveau des scores. C'est aussi une approche plus pertinente que la fusion au niveau de la décision. Sur une base de données de 340 utilisateurs (10 prototypes / classe), un taux de réussite 99,8 % en identification et un FAR = 0,68%, FRR = 5 % en vérification sont cités.

8.4 Fusion multimodalité : systèmes multiples biométriques

Aujourd'hui les indicateurs de la biométrie sont assez nombreux, ils sont déclarés plus ou moins fiables. Les critères de performance ne sont pas les seuls à prendre en compte mais aussi les critères de coûts et d'acceptation par le public. Ainsi, selon les situations d'usage et les buts recherchés, chaque biométrie a ses points forts et ses inconvénients. La multimodalité est une solution pour tenter de pallier ce problème. A chaque modalité peut être associé un

classifieur qui fournit un score concernant l'acceptation ou non d'une personne dont on souhaite vérifier l'identité. Le problème est alors de définir des stratégies pour combiner ces scores de décision, considérés indépendants. Les chercheurs ont employé différentes modalités et différentes stratégies pour montrer l'intérêt de la fusion multimodalité et des résultats montrent une très nette amélioration des performances. Nous nous limitons aux travaux les plus importants qui ont employé la géométrie de la main ou l'empreinte palmaire :

- Un système avec deux modalités : empreinte palmaire et visage [Feng04].
- Un système avec cinq modalités ; empreinte digitale, signature, forme de la main, visage et voix [BIOMET].
- Empreinte palmaire et géométrie de la main [Kumar03], et [Ong03].
- Empreinte digitale et géométrie de la main [Toh03].

8.5 Notre système

8.5.1 Introduction

Le système que nous nous proposons de concevoir est un système « en ligne » d'analyse biométrique de la main. Il doit être capable d'identifier et d'authentifier un individu préalablement enregistré par ses caractéristiques de la géométrie de la main et de l'empreinte palmaire. L'acquisition de données utilise un scanner et laisse à l'utilisateur la plus grande liberté possible quant au positionnement de sa main. Aucun plot ou guide de positionnement de la main n'est utilisé. Nous disposons alors d'une image numérique.

Les images capturées font l'objet de différents traitements pour extraire les caractéristiques discriminantes de la main et de l'empreinte palmaire. Ensuite le système doit réaliser un apprentissage et enfin être capable de décider, dans le cas d'une identification, quelle est l'identité exacte de l'utilisateur à identifier en fusionnant les informations en sortie des différents classifieurs de représentations. Et dans le cas d'une authentification, le système doit décider si l'identité réelle de l'utilisateur est conforme à l'identité proclamée grâce à une étape ultime de fusion.

Les caractéristiques que nous avons choisies d'extraire (pour la géométrie de la main et pour l'empreinte palmaire) sont:

- a) Longueurs des doigts
- b) Chaînes de mesure de la largeur des doigts (vecteur de largeurs)
- c) Largeurs de la base des doigts

- d) Largeur du « poignet »
- e) Aire de la partie supérieure de la main
- f) Largeur de la paume
- g) Aires des doigts
- h) Aire de la paume
- i) Lignes de la main (l’empreinte palmaire)

Ces neuf types d’ensembles de caractéristiques s’inspirent de celles évoquées dans l’état de l’art et semblent être les plus classiques. Toutefois il est envisageable d’en rajouter de nouvelles. Nous avons étudié séparément ces neuf vecteurs de représentation et la classification a été réalisée individuellement à partir de chaque ensemble de caractéristiques. Ainsi ont été définis neuf classifieurs de distances. L’évaluation de ces neuf classifieurs a été réalisée indépendamment et les résultats sont indiqués dans la section concernée. Enfin nous étudions l’influence d’une étape ultime concernant le processus de prise de décision i.e. la fusion des classifieurs. Maintenant nous allons étudier en détail chaque phase de façon à mettre en évidence les différents traitements et méthodes mis en œuvre dans notre travail.

8.5.2 Module d’acquisition

Dans notre système, l’acquisition porte sur la main droite de la personne à reconnaître. L’utilisateur place sa main comme il le souhaite sur la plateforme du scanner, la seule contrainte posée est de ne pas joindre les doigts. Voici la procédure détaillée :

- L’utilisateur place sa main droite sur le scanner, doigts non joints.
- Ne pas fermer le « couvercle » du scanner de façon à obtenir un fond noir
- Scanner la main de façon à ce qu’elle soit centrée sur l’image et qu’aucun doigt ne soit coupé.
- A chaque nouvelle acquisition l’utilisateur retirera puis replacera sa main sur le scanner.

Détail de la configuration du logiciel d’acquisition utilisé (HP DeskScan II) :

- Type : Photo en noir et blanc affinée (c'est-à-dire en niveaux de gris)
- 80dpi x 80dpi
- Luminosité : 150
- Contraste : 170
- Cadrage 100%
- 615 x 615 pixels

Remarque : L'image obtenue est en niveaux de gris, ce qui facilitera les traitements ultérieurs. Toutefois il est tout à fait envisageable d'utiliser, dans une continuation du projet, une image en couleur de façon à obtenir des informations supplémentaires. Voici quelques exemples des images obtenues lors de l'acquisition (figure 8.8).

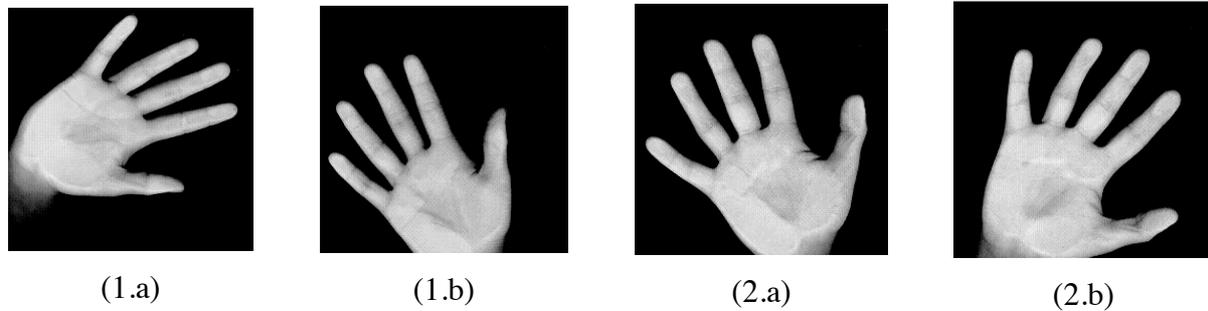


Figure 8.7 : Les images de deux mains scannées en niveaux de gris.

8.5.3 Prétraitements

Avant de segmenter l'image, nous définissons de nombreux prétraitements. Ces prétraitements vont permettre de configurer et de modifier l'image de façon à la préparer, à l'extraction des caractéristiques. Nous détaillons chaque prétraitement effectué sur l'image issue de l'étape d'acquisition.

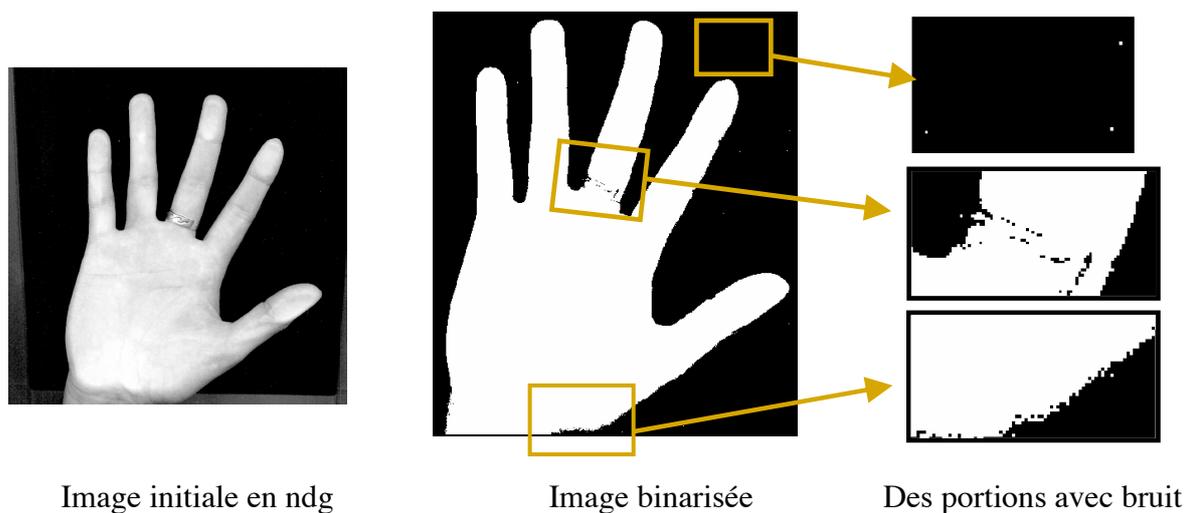


Figure 8.8: Binarisation de l'image.

8.5.3.1 Binarisation

Cette étape va permettre de segmenter l'image en repérant les pixels constitutifs de la main. Il s'agit ici d'être capable de faire la différence entre la main et le fond de l'image. La

binarisation va permettre de transformer l'image initiale (ici 256 niveaux de gris) en une image binaire. Pour réaliser cette transformation, il est nécessaire de fixer une valeur seuil S ($0 \leq S \leq 255$). Le seuil utilisé dans notre travail est fixé de façon automatique, grâce à la méthode de Otsu [Otsu78]. La binarisation appliquée à l'image obtenue, lors de la phase d'acquisition, donne le résultat montré sur la figure 8.9:

8.5.3.2 Fermeture et ouverture

Comme nous l'avons vu précédemment la binarisation fait apparaître un bruit plus ou moins important suivant la qualité de l'image. Pour éliminer le bruit, des filtres morphologiques peuvent être utilisés: la fermeture et l'ouverture. Ces filtres reposent sur un élément structurant (figure 8.10) de type disque dont le rayon est fixé en fonction du nombre de composantes connexes obtenues après la binarisation.

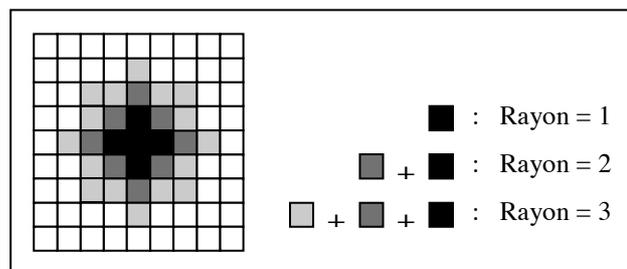


Figure 8.9 : Élément structurant

Grâce à la fermeture, il est possible de combler les « trous » d'une surface, ou de préciser les contours d'une forme (dans la mesure où la taille de l'élément structurant le permet). L'ouverture permet d'éliminer le bruit apparaissant ici, sous forme de pixels blancs et de lisser les contours d'une forme. Voici l'image obtenue après l'opération de fermeture et d'ouverture (figure 8.10) :

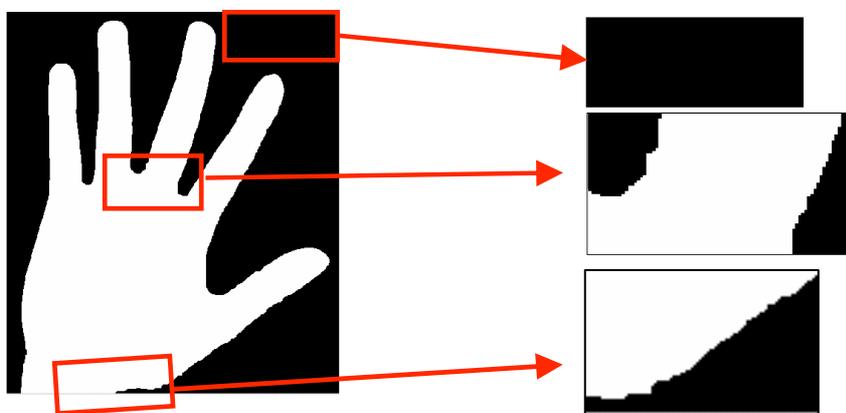


Figure 8.10 : Fermeture et Ouverture

8.5.3.3 Elimination des plus petites composantes connexes

Il est possible que les opérations de binarisation, d'ouverture et fermeture conduisent à la présence de plusieurs composantes connexes (régions isolées composées de pixels blancs). Dans l'exemple utilisé, une seule région est détectée.

Plusieurs petites régions peuvent, sur certaines images, se former au niveau du poignet. Dans le système ici développé, la région du poignet en lui-même n'est pas utilisée pour l'extraction des caractéristiques. On peut éliminer ces petites régions pour ne s'intéresser qu'à la région correspondant à la main. Seule la plus grande composante connexe est conservée.

8.5.3.4 Rotation

Du fait du placement libre de la main de l'utilisateur lors de l'acquisition de l'image, une normalisation est nécessaire de façon à obtenir des séries d'images les plus homogènes possible. Cette normalisation consiste en un alignement vertical (rotation) de la silhouette de la main grâce à son axe d'inertie.

L'axe d'inertie de la silhouette de la main est déterminé grâce au plus grand axe de symétrie de la plus petite ellipse englobant la forme (axe rouge sur la figure 8.11). Cet axe d'inertie forme un angle θ avec l'axe des ordonnées du repère de l'image (axe bleu). Une fois l'angle θ déterminé, on effectue une rotation de l'image d'un angle de mesure θ° , afin d'aligner l'axe d'inertie de la silhouette avec l'axe des ordonnées de l'image.

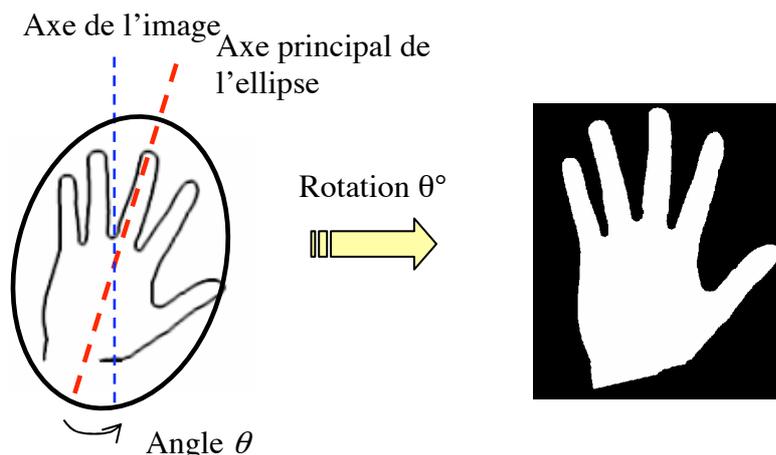


Figure 8.11 : Rotation de l'image (normalisation)

Grâce à cette normalisation on obtient une position correcte de la main sans avoir recours à des guides de positionnement. La rotation est suivie d'un lissage, comme précédemment. Notons que la relative lenteur de la rotation (temps proportionnel à la taille de

l'image) présente un certain inconvénient. De plus, il est important de noter que cette méthode ne permet pas à l'utilisateur de placer sa main avec un angle supérieur à $+ 90^\circ$ par rapport à l'axe vertical du scanner. Cette technique d'alignement serait à améliorer de façon à obtenir un système plus robuste.

8.5.4 Extraction des caractéristiques

Dans cette section, nous décrivons les étapes suivies pour l'extraction des caractéristiques de la main et de l'empreinte palmaire à partir de l'image de la main.

8.5.4.1 Segmentation

La segmentation est une étape essentielle dans le processus d'extraction de caractéristiques. Elle permet de repérer différents éléments de l'image et de les isoler de façon à pouvoir réaliser les mesures des caractéristiques choisies. Une mauvaise segmentation entachera, de façon évidente, les mesures et par extension les résultats de la reconnaissance.

8.5.4.1.1 Les points clés

Pour réaliser les mesures souhaitées, il est nécessaire de rechercher, sur l'image prétraitée, certains points clés caractéristiques de la forme d'une main. Ces points sont présentés sur le schéma suivant. La recherche de ces points clés se base sur une segmentation préalable des doigts.

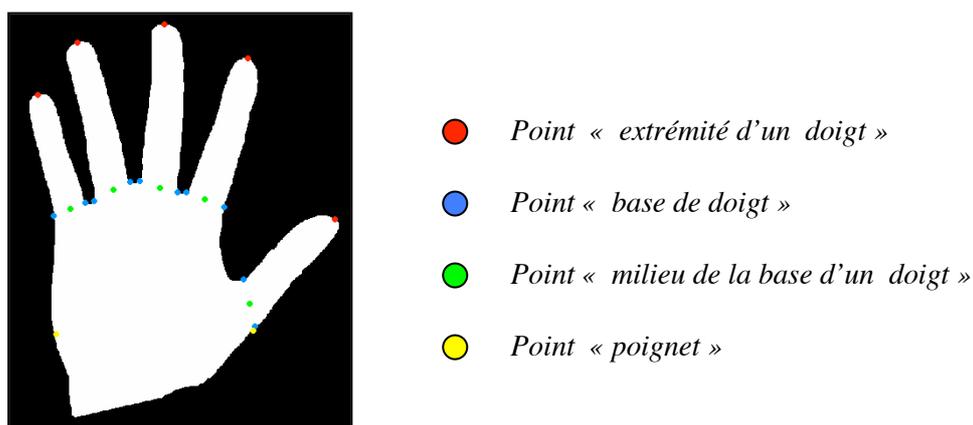


Figure 8.12 : représentation des points clés de la main.

8.5.4.1.2 Segmentation des doigts

La segmentation des doigts permet de repérer certains points clés, ainsi que de traiter chaque doigt indépendamment des autres. La technique de segmentation utilisée repose sur

une propagation d'étiquettes comme dans une détection de composantes connexes. L'image est parcourue de haut en bas de gauche à droite. Au fur et à mesure de l'avancement du parcours, apparaissent 4 composantes connexes assimilées à l'auriculaire, l'annulaire, le majeur et l'index puis une 5^{ème} composante assimilée au pouce. Chacune de ces composantes connexes sera colorée d'une couleur différente de façon à pouvoir simplement les identifier. La coloration d'une composante s'arrête lors d'une fusion potentielle avec une autre composante (fourchette interdigitale). Le processus est décrit par les images suivantes (figures 8.14, 8.15, 8.16).



Figure 8.13 : Segmentation des doigts par propagation d'étiquette

A partir de l'image segmentée, il est maintenant possible de repérer certains points clés au niveau des fourchettes interdigitales. Ces points correspondent en fait aux points délimitant une fusion de composantes. Ces points sont mis en évidence sur le schéma suivant (figure 8.14):

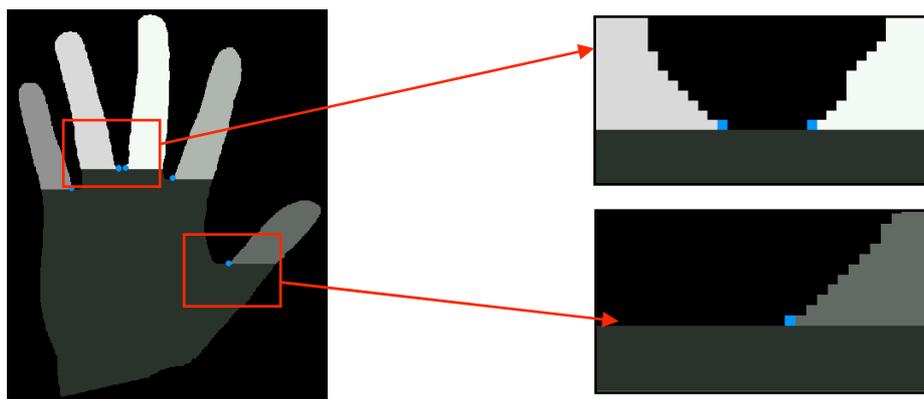


Figure 8.14 : Points limites de fusion de composantes

Grâce à la segmentation, chaque doigt est détecté. Il est aussi possible de déterminer certains points importants utilisés lors de la mesure des caractéristiques. Toutefois nous constatons sur l'image dans la figure 8.14 que la « coupure », au niveau de la base des doigts,

est réalisée de façon horizontale. Cette segmentation ne représente pas la réalité, elle est donc insuffisante et doit être améliorée. C'est l'objet du paragraphe suivant.

8.5.4.1.3 Amélioration de la segmentation des doigts

La technique utilisée pour améliorer la segmentation des doigts permet d'ajuster la détection de la base de chaque doigt en fonction de sa position et de son orientation. Elle s'appuie sur la zone étiquetée du doigt lui-même, mais aussi, sur les points précédemment localisés. La première étape consiste à déterminer l'axe d'inertie de chaque doigt. Pour cela nous allons utiliser la même méthode que précédemment. Chaque doigt est totalement englobé dans la plus petite ellipse possible. L'axe d'inertie de chaque doigt est assimilé au plus grand axe de symétrie de l'ellipse englobante. Pour obtenir un meilleur résultat, l'ajustement se réalise de façon différente suivant les doigts, d'une part l'auriculaire, l'index et le pouce, d'autre part l'annulaire et le majeur.

Pour l'auriculaire, l'index et le pouce, à partir de l'axe d'inertie de ces derniers et des points précédemment détectés, la base des doigts est délimitée par le segment perpendiculaire à l'axe d'inertie de chaque doigt. Ce segment doit passer par le point associé au doigt traité. On effectue alors une propagation de l'étiquette du doigt dans la zone créée.

Pour l'annulaire, les points de base des doigts (précédemment détectés), annulaire et auriculaire sont reliés. Pour le majeur, les points de base des doigts majeur et index sont reliés.

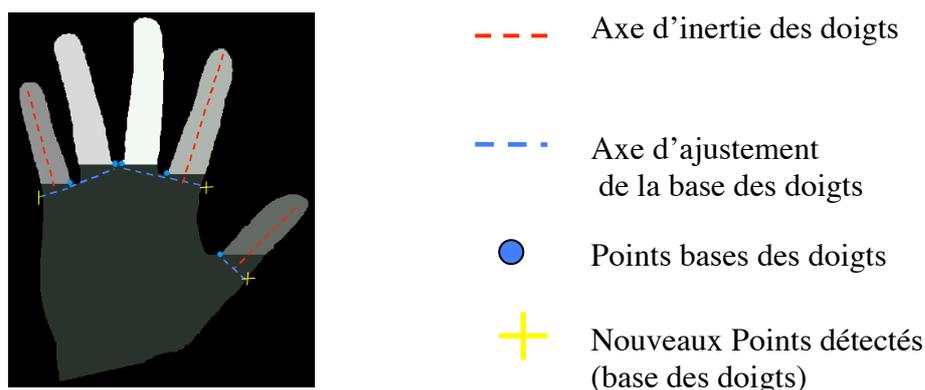


Figure 8.15 : Ajustement de la segmentation des doigts

Une fois les axes d'ajustement placés, un remplissage des zones formées est effectué avec la même couleur que les doigts correspondants. On obtient donc des zones de couleur

homogène définissant chaque doigt. L'ajustement permet également de localiser les points manquant à la base des doigts (croix jaune sur la figure 8.15).

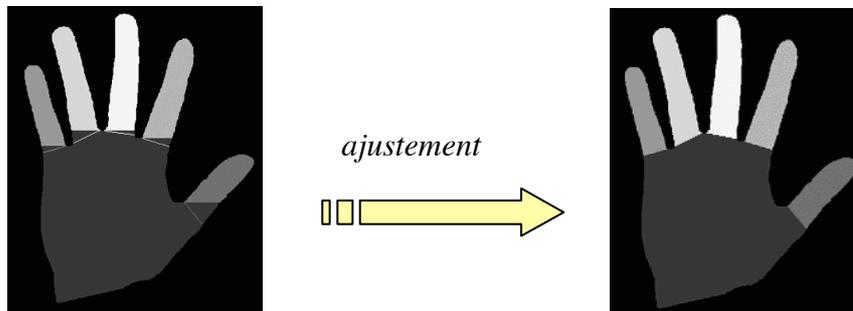


Figure 8.16 : Ajustement de la segmentation des doigts (résultats)

Trois autres types de points peuvent être maintenant localisés : les extrémités des doigts, le milieu de la base des doigts et les points du « poignet » (figure 8.17) :

Les extrémités des doigts et les milieux des bases des doigts correspondent aux points d'intersection de l'axe d'inertie des doigts avec respectivement les extrémités supérieures des doigts et les axes d'ajustement. Le poignet est localisé grâce au deuxième point de la base du pouce (point A dans la figure 8.17) et à l'intersection entre l'axe horizontal passant par ce point « A » et la frontière de la main (le deuxième point jaune « B » dans la figure 8.17).

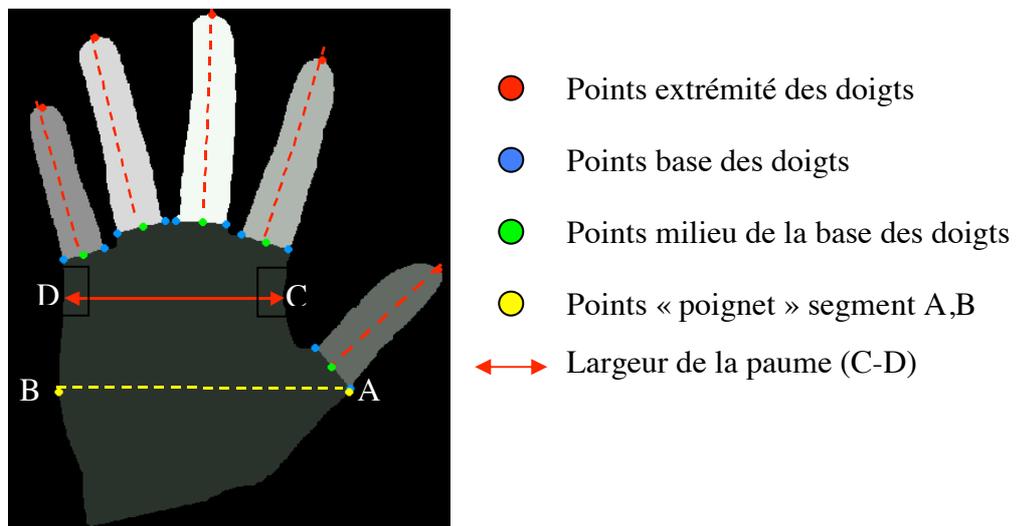


Figure 8.17 : Mise en évidence de caractéristiques

La largeur de la paume de la main est la longueur du segment horizontal de longueur minimum ayant pour extrémité un point « D » (figure 8.17) localisé proche de la base de

l'auriculaire et le point « C » de la fourchette interdigitale formée par le pouce. Chaque point caractéristique de la main est maintenant localisé.

8.5.4.2 Caractéristiques de main

Certaines distances sont, grâce aux points localisés, directement calculables.

- Longueur des doigts : calcul de distance entre les points « extrémité des doigts » et les points « milieu de la base des doigts ».
- Largeur de la base des doigts : calcul de distance entre les 2 points correspondant à la « base des doigts ».
- Largeur du « poignet » : calcul de distance entre les 2 points au « poignet ».
- La mesure des chaînes correspondant à la largeur des doigts nécessite d'isoler et de faire pivoter chaque doigt. Nous disposons, suite aux traitements effectués auparavant, des axes d'inertie de chaque doigt et donc de leur angle d'inclinaison par rapport à l'axe des ordonnées de l'image. Chaque silhouette est isolée et redressée.

En parcourant les images de bas en haut, il est possible de mesurer différentes largeurs des doigts. Un pourcentage fixé par l'utilisateur permet de déterminer le nombre de mesures à effectuer sur chaque image. (Exemple : une mesure tous les 25% de la hauteur de l'image entraîne 5 mesures, la première étant réalisée à 0%). Les chaînes mesurant l'évolution de la largeur des doigts sont donc maintenant déterminées.

- L'aire de la partie supérieure de la main est mesurée directement au-dessus de la largeur de la paume de la main (segment CD, figure 8.17) et la limite inférieure des doigts.

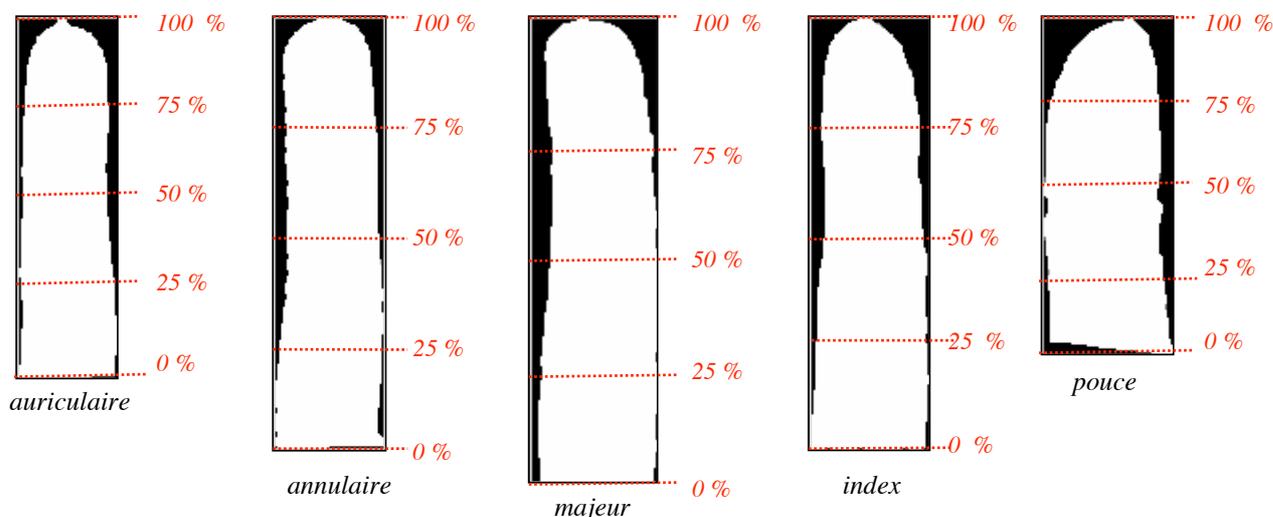


Figure 8.18 : Chaînes (vecteur) de largeurs des doigts

8.5.4.3 Les caractéristiques de l’empreinte palmaire

Le but est ici de faire apparaître les lignes de la main de façon à pouvoir étudier leurs orientations. Le cadrage de la zone à étudier est défini grâce aux différents points détectés. Le découpage est illustré sur la figure 8.19 :

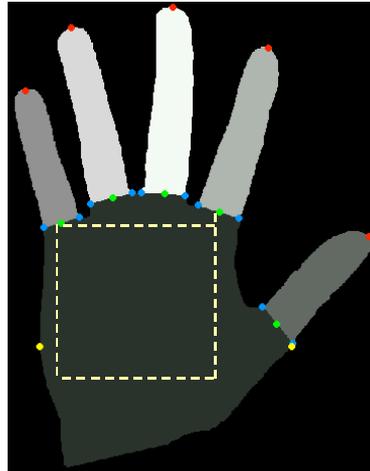


Figure 8.19 : Mise en évidence de la zone de l’empreinte palmaire pour les lignes de la main

La largeur de la zone d’étude correspond à la distance entre les points milieux de la base de l’auriculaire et de l’index. Le point le plus bas des deux est le point référence pour le découpage de la zone d’étude (ici le point gauche milieu de la base de l’auriculaire). La zone contenant les lignes de la main étant définie, différents traitements peuvent être réalisés.

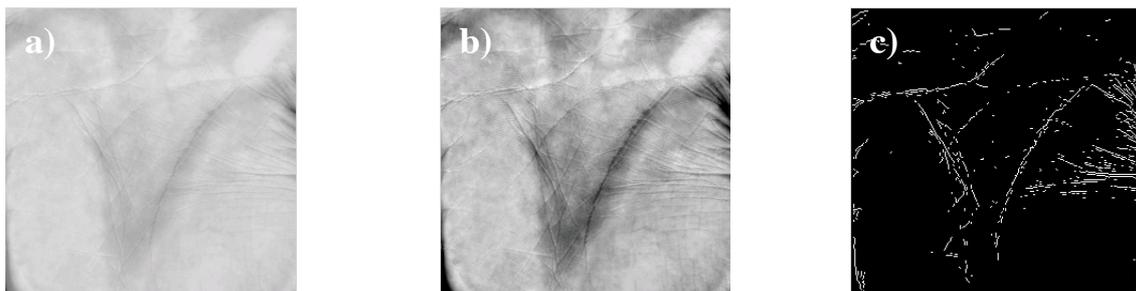


Figure 8.20 : Prétraitements, (a) ligne de la main (image originale), (b) égalisation de l’histogramme, (c) détection de contours selon le gradient de Sobel

L’extraction de caractéristiques concerne l’orientation générale des lignes de la main. Un découpage de l’image est réalisé de façon à constituer un ensemble de 25 zones auxquelles nous allons affecter une direction. Quatre directions sont possibles (Nord/Sud, Est/Ouest, Nord-Ouest/Sud-Est, Nord-Est/Sud-Ouest).

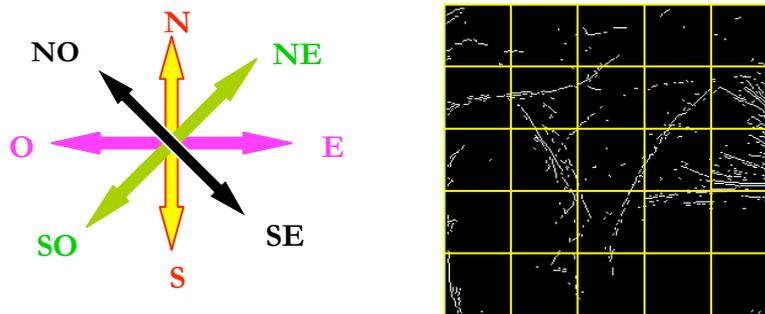


Figure 8.21 : Découpage en zones de la fenêtre contenant les lignes de la main

Pour attribuer une direction à chaque sous-zone, nous calculons en tout point la direction du gradient de Sobel et sur chaque sous-zone le nombre de pixels où le gradient est supérieur à un seuil, et cela dans chaque direction. Nous attribuons alors une direction à chaque sous-zone parmi les quatre directions possibles en fonction du nombre de pixels blancs maximum trouvés dans cette sous-zone (figure 8.22). Un score de ressemblance est défini par comparaison zone à zone de deux images.

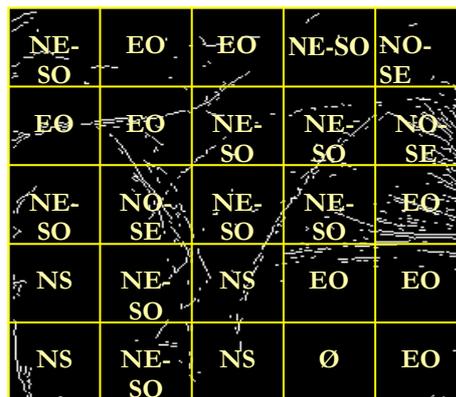


Figure 8.22 : Attribution des directions

8.6 Classification

Une fois les caractéristiques de la main et de l'empreinte palmaire extraites grâce aux primitives présentées dans les sections précédentes, nous avons réalisé la classification des images basée sur des classifieurs de distance (k-ppv). Un classifieur est basé sur une primitive soit une valeur comme la largeur du poignet, l'aire de la partie supérieure de la main, la largeur de la paume, l'aire de la paume, le score des lignes de l'empreinte palmaire, soit un vecteur des valeurs comme les longueurs des doigts, le vecteur de mesures des largeurs des doigts, les largeurs de la base des doigts, l'aire des doigts. Pour classifier une nouvelle image entrante inconnue, chaque classifieur (sauf celui basé sur les lignes de la main) réalise un

calcul de similarité entre cette image et toutes les images dans la base de référence. Pour calculer la similarité la distance euclidienne simple a été utilisée. Entre $pt1(x1,y1)$ et $pt2(x2,y2)$, par exemple elle s'exprime par :

$$d(pt1, pt2) = \sqrt{(x1 - x2)^2 + (y1 - y2)^2}$$

Comme indiqué avant, le classifieur basé sur les lignes de la main calcule un score, traduisant la mise en correspondance entre des images. Ce score est normalisé entre 0 et 1 et pour avoir une harmonie avec les sorties des autres classifieurs de distance, la distance entre l'image entrante x et les images existantes x_i dans l'espace des caractéristiques est calculée par : $d(x, x_i) = 1 - \text{score}(x, x_i)$.

Pour prendre la décision concernant la classe de l'image entrante « x » chaque classifieur considère les k plus proches voisins (k -ppv) de « x ». Ici les voisins de x sont aussi des images de la main étiquetées dans la base de référence c'est-à-dire que chacun des k -ppv retenus appartient à une classe connue. Avec ces informations chaque classifieur prend la décision selon la stratégie choisie. Nous avons considéré plusieurs approches dans le chapitre sur la classification. Dans cette application nous avons étudié trois approches différentes:

- La règle de vote majoritaire
- La règle des k -ppv avec distance pondérée
- L'approche floue proposée

Dans un problème de vérification, la tâche de chaque classifieur est de vérifier si l'image entrante x accompagnée d'une identité proclamée, correspond réellement à l'identité proclamée. Dans ce cas, après l'extraction des caractéristiques de x , la similarité entre x et l'ensemble des images de la classe proclamée est calculée avec la distance euclidienne. Un seuil est ensuite appliqué pour prendre la décision d'accepter ou de rejeter. Notons que chaque représentation de chaque classe possède un seuil propre. Pour prendre la décision concernant l'acceptation ou le rejet d'une image entrante x , plusieurs méthodologies sont possibles, quelques unes peuvent être précisées, par exemple :

- L'image x est acceptée si la distance entre x et le plus proche prototype de la classe proclamée est inférieure au seuil.
- x est acceptée si la distance moyenne à tous les prototypes de la classe proclamée est inférieure au seuil.
- x est acceptée si elle est acceptée par la majorité des prototypes dans les k -plus proches voisins considérés.

Les deux premières méthodologies sont assez claires, nous discutons la 3ème plus en détail. Nous fixons tout d'abord un seuil S et calculons les distances entre x et tous les prototypes (des images de la classe proclamée) dans la base de référence. Si la distance entre x et le premier prototype est inférieure à S , ce prototype donne sa décision d'acceptation, x est donc étiqueté classe C_1 , dans un cas contraire, il est rejeté et étiqueté dans une classe de rejet C_2 . De cette façon, chaque prototype, en fonction de la distance entre x et chaque prototype, conduit à une étiquette C_1 ou C_2 . Le classifieur prend une décision finale C_1 ou C_2 selon l'étiquette majoritaire assignée par les k -ppv de la classe proclamée.

8.7 Résultats expérimentaux

Chaque classifieur doit être testé afin d'évaluer ses performances pour avoir une vision claire de la robustesse de la phase de fusion. En effet, nous ne pouvons pas obtenir en sortie d'un classifieur des résultats totalement fiables. Cependant étant donné que les résultats seront fusionnés, il est important qu'ils soient « relativement » corrects.

8.7.1 Première évaluation : données de [HaSIS97]

Pour évaluer notre système, dans un premier temps nous avons réalisé une expérimentation avec un jeu de données téléchargé à partir de [HaSIS97]. Il se compose de données relatives à huit personnes avec 8 ou 9 images de la main par personne. Les caractéristiques de l'empreinte palmaire ne sont pas extraites de ces images car les images contiennent la face supérieure de la main. Nous avons donc utilisé et évalué les classifieurs de la géométrie de la main seulement. Le taux de succès (en terme de bonne classification) est de 100 % dans le cas de l'identification par un seul meilleur classifieur et aussi en fusionnant (par la règle du vote majoritaire) les classifieurs relatifs à la géométrie de main avec seulement 2 images de la main par personne dans la base de référence, et les 6 ou 7 images restantes dans la phase d'essai. Ce résultat évidemment nous a encouragé pour continuer notre travail.

8.7.2 Deuxième évaluation : notre base de données

N'ayant pas une base d'images de la main et d'empreintes palmaires communes dans la littérature, nous avons alors créé notre propre base de données en prenant cinq images de la main de 26 individus. Les individus sont des étudiants et professeurs de notre école, leur âge varie entre 20 et 45 ans. Après une étape d'extraction de caractéristiques, plusieurs classifieurs de distance (k -ppv) ont été développés comme expliqué dans les sections précédentes. La méthode de *leave-one-out* a été utilisée pour évaluer la performance de

chaque classifieur et celle de fusion des classifieurs. En effet le nombre d'échantillons de la main des individus est limité dans notre base. Le taux de bonne classification dans le cas d'identification et le taux de faux rejet (FRR) et le taux de fausse acceptation (FAR) dans le cas de vérification sont calculés. Dans un système de signatures manuscrites, plusieurs types de fausses signatures sont possibles. Mais dans une application de la main et empreinte palmaire, on ne dispose pas des différents types de faux sauf les faux aléatoires. Nous avons donc utilisé toutes les images d'autres personnes (faux aléatoires) pour l'évaluation du taux de faux acceptés. Pour évaluer le taux de faux rejets la méthode de *leave-one-out* permet de maximiser l'utilisation des échantillons authentiques disponibles. Cinq séries ont été réalisées globalement pour chaque classe (130 au total) avec toute la base de données créée. Le taux de succès en identification et les FRR et FAR en vérification ont été notés.

8.7.3 Résultats d'identification

Au départ de nos travaux nous avons retenu et testé notre système en identification avec les neuf classifieurs décrits dans les sections précédentes. Deux méthodologies des k-ppv, comme décrit dans le chapitre 3, ont été employées en parallèle avec notre approche proposée pour prendre la décision finale par un classifieur. Nous avons étudié la règle de vote majoritaire et la règle des k-ppv avec distance pondérée introduite par Dudani [Dudani76]. Les résultats obtenus en terme de taux de bonne classification avec différentes valeurs de k sont notés et les plus intéressants sont indiqués dans les tableaux 8.6 (a) et (b) où des résultats avec 1-ppv, 3-ppv, 5-ppv et 8-ppv sont présentés. Un point à noter, comme il n'y a que 5 images par classe, il semble de n'être pas raisonnable de présenter les résultats avec 8-ppv. Nous justifions ce point par la suite.

Tableau 8.6 (a) : Les performances des classifieurs individuellement

Classifieur	La règle des k-ppv floue proposée			
	1-ppv	3-ppv	5-ppv	8-ppv
Longueur des doigts (e1)	86,92	90,77	88,46	89,23
Chaîne de mesure de la largeur des doigts (e2)	93,85	94,62	93,85	92,31
Largeur de la base des doigts (e3)	42,2			
Largeur du « poignet » (e4)	20,7			
Aire de la partie supérieure de la main (e5)	12,6			
Largeur de la paume (e6)	20,7			
Aire des doigts (e7)	83,9	83,9	82,3	84,6
Aire de la paume (e8)	22,2			
Lignes de la main (e9)	41,5			

Tableau 8.6 (b) : Les performances des classifieurs individuellement

Classifieur	La règle de vote à la majorité				La règle de distance pondérée			
	1-ppv	3-ppv	5-ppv	8-ppv	1-ppv	3-ppv	5-ppv	8-ppv
e1	86,9	86,4	81,4	67,6	86,9	84,4	87,4	85,9
e2	93,8	87,6	77	68	93,8	93,3	94	93,3
e3	42,2	38,3	33,8	38,5	42,2	42,2	39,3	38,5
e4	20,7	19,3	17,8	21,4	20,7	22,2	18,9	17,6
e5	12,6	13,8	13,2	17,1	12,6	12,6	11,1	11,1
e6	20,7	23	20,6	16,4	20,7	20,7	21	20
e7	83,9	74,8	70,6	50,8	83,9	82,2	80	77,8
e8	22,2	22,5	26	24,2	22,2	22,2	19,3	22,6
e9	41,5	33,1	30,4	23,5	41,5	41	43,2	42,2

Dans ces deux tableaux nous pouvons observer que les différents classifieurs ont des performances variables. La meilleure performance est obtenue par le classifieur basé sur les mesures de largeur des doigts (classifieur e2). C'est compréhensible car ce classifieur comporte le plus grand nombre de caractéristiques (25 sur 45 au total). De plus, ces caractéristiques sont plus stables que les autres dans un système sans plots. Les classifieurs e1, et e7 semblent donner un rendement comparable. Les performances des autres classifieurs indiquent une faible qualité de leurs comportements qui provient soit de caractéristiques moins performantes soit de la faiblesse d'acquisition des données. Nous rediscuterons la deuxième raison dans la section 8.7.6.

Parmi les trois règles des k-ppv étudiés, la règle des k-ppv floue proposée semble la plus performante et elle montre une performance assez consistante en faisant varier le nombre des k-ppv quand le paramètre γ est optimisé. La règle du vote majoritaire a donné un bon résultat en général en considérant seulement le premier plus proche voisin ou les trois plus proches voisins ($1 \leq k \leq 3$). Nous constatons que les taux de bonne classification baissent avec l'augmentation du nombre des ppv utilisés avec cette méthodologie. La règle des k-ppv avec la distance pondérée [Dudani76] a donné les meilleurs résultats pour un nombre de ppv un peu plus « élevé ».

Chaque classifieur fournit une décision en sortie, nous disposons donc de 9 décisions supposées indépendantes les unes des autres et les informations de distances avec les rangs des classes. Il est maintenant possible de fusionner ces différentes sorties de classifieurs de façon à obtenir une décision finale. Différentes méthodes de fusion ont été testées et leurs résultats sont présentés ci-après.

Fusion par la règle de vote majoritaire

La fusion est réalisée au niveau des décisions prises par les 9 classifieurs et une méthode de vote à la majorité est utilisée. En observant les résultats des 9 classifieurs, nous pouvons mettre en évidence 3 d'entre eux donnant les meilleurs résultats. Ces 3 classifieurs sont les classifieurs e1 (longueur des doigts), e2 (vecteur de largeur des doigts) et e7 (aire des doigts). Considérant ces 3 meilleurs classifieurs, il est possible de fusionner les sorties des décisions des 6 autres classifieurs moins robustes, de façon à créer un nouveau classifieur nommé Cfus (contenant e3, e4, e5, e6, e8, e9) pour avoir une performance comparable aux 3 autres classifieurs.

Une fois le classifieur Cfus créé, il est possible de fusionner les classifieurs e1, e2, e7 et Cfus, pour obtenir une décision finale. La fusion entre les décisions des classifieurs se réalise grâce à une méthode de vote majoritaire. Nous pouvons observer que la fusion permet d'améliorer la performance des classifieurs « moins pertinents ». Nous pouvons observer une amélioration significative des résultats, par rapport à la méthode précédente. Les meilleurs résultats sont obtenus avec 1ppv.

Tableau 8.7 : Fusion au niveau de la décision

Classifieurs	La règle du vote				La règle de la distance pondérée			
	1-ppv	3-ppv	5-ppv	8-ppv	1-ppv	3-ppv	5-ppv	8-ppv
Tous les e1-e9	89,6	88,7	82,7	81,2	89,6	87,9	87	87,1
e3,e4,e5,e6,e8,e9 (Cfus)	45,9	50,3	46,4	42,4	45,9	47,5	43,9	43
e1, e2, e7, Cfus	93,5	91,4	87,5	81,4	93,5	92,9	92,5	91,1

La fusion présentée ici porte les deux mêmes étapes que la méthode précédente, c'est à dire qu'elle utilise une fusion des sorties des classifieurs e3, e4, e5, e6, e8 et e9 tout d'abord donnant un classifieur Cfus et ensuite la fusion de sorties des e1, e2, e7, Cfus. La différence apparaît au niveau de la fusion. La méthode précédente utilise une fusion des décisions, ici la fusion se réalise au niveau des distances. Les caractéristiques étant différentes, une normalisation s'impose pour réaliser la fusion à ce niveau. La décision du classifieur Cfus est réalisée sur une moyenne des distances normalisées. Nous observons une très nette amélioration des performances du classifieur Cfus. Malgré la nette amélioration du classifieur Cfus, nous n'obtenons pas d'amélioration significative grâce à la fusion des 4 classifieurs considérés (une différence de 0,4 seulement pour le taux de bonne classification). Les résultats obtenus par notre méthode figurent dans le tableau 8.9 du prochain paragraphe.

Tableau 8.8 : Fusion au niveau représentation

Classifieurs	La règle du vote				La règle de la distance pondérée			
	1-ppv	3-ppv	5-ppv	8-ppv	1-ppv	3-ppv	5-ppv	8-ppv
e3, e4, e5, e6, e8, e9 (Cfus)	78,5	72,3	67	60,9	78,5	78,5	78,5	77
e1, e2, e7, Cfus	93,9	93,1	87,6	82,6	93,9	93,9	94,1	93

Tableau 8.9 : Etude de performance du système de fusion par le formalisme flou proposé en prenant en compte différents classifieurs.

Classifieurs fusionnés	γ	1-ppv	3-ppv	5-ppv	8-ppv
Cfus		78,5	80,0	78,5	76,9
e1, e2	3	96,9	96,9	96,9	96,2
e1, e3	3	93,8	93,8	93,8	93,8
e1, Cfus	3	93,8	93,8	93,8	93,8
e2, e3	2,5-3	96,2	96,2	96,2	96,2
e2, Cfus	2,5-3	93,1	93,1	93,1	93,1
e3, Cfus	2,5-3	90,8	90,8	90,8	90,8
e1, e2, e3	2,8-3	97,7	97,7	97,7	97,7
e1, e2, Cfus	3	96,9	96,9	96,9	96,9
e2, e3, Cfus	2,5-3	96,2	96,2	96,2	96,2
e1, e2, e3, Cfus	2,6-3	97,7	97,7	97,7	97,7

L'influence du nombre de classifieurs par le formalisme flou proposé

Pour étudier l'influence du nombre de classifieurs, en fait de la contribution d'information apportée par des classifieurs, nous avons employé le formalisme flou proposé. L'emploi de cette approche floue proposée dans le cadre de la fusion de données est déjà expliqué dans les chapitres précédents. Nous avons étudié toutes les combinaisons possibles de quatre classifieurs ; deux classifieurs différents, trois classifieurs différents et quatre classifieurs. Dans l'étude de la fusion de ces classifieurs différents, la valeur optimum du paramètre γ du formalisme flou proposé a été trouvée assez grande, vers sa limite supérieure (égale à 3 en général).

La fusion de deux classifieurs a apporté une amélioration par rapport au seul meilleur classifieur mais cela dépend des classifieurs pris en compte. Dans le tableau 8.9 par exemple,

la performance du système en fusionnant les classifieurs e1 et e2, et e2 et e3 a été améliorée mais ce n'est pas le cas avec quatre autres combinaisons $\{(e1, e3), (e1, e4), (e2, e4), (e3, e4)\}$. Toutes les combinaisons de trois classifieurs ont bien montré une amélioration de la fusion mais la fusion de quatre classifieurs ensemble n'est pas meilleure que celle du système en prenant en compte les trois meilleurs classifieurs. Ce n'était pas le cas quand nous avons utilisé la règle du vote majoritaire.

D'autres méthodes de fusion

Nous avons également étudié d'autres méthodes de fusion pour comparer. Nous avons étudié la robustesse de chaque méthode en faisant varier les valeurs de k dans l'intervalle [1-8]. Pour les valeurs de k entre 1 et 3, chaque méthode a été confrontée à des problèmes d'ambiguïté ou de conflit total. La performance de plusieurs méthodes a varié selon la manière de résoudre ce problème d'ambiguïté ou de conflit.

La méthode de l'évidence (Dempster-Shafer)

La théorie de l'évidence a été employée en utilisant le formalisme flou proposé pour définir les masses d'évidence. Les éléments focaux retenus par chaque classifieur ont varié en fonction de l'information de distance et des degrés d'appartenance floue. La décision a été prise en fonction du maximum de plausibilité. En cas de conflit total ($K = 1$), la théorie ne propose aucune solution, les mauvaises décisions et le taux de bonne classification sont indiqués dans le tableau 8.10. Dans cette théorie, l'importance est donnée aux croyances des informations des classifieurs mais pas au point de vue du vote. C'est pourquoi, si deux classifieurs ont des confiances de 100 % sur deux classes différentes, cette théorie alors ne donne aucune décision.

Tableau 8.10 : Performance de la théorie de l'évidence en faisant varier k

k-ppv	Conflit ou ambiguïté (%)	Taux de mauvaise décision (%)	Taux de bonne décision (%)
3	10,77	0,77	88,46
4	5,38	1,54	93,08
5	2,31	3,08	94,62
6	1,54	3,85	94,62
7	0	4,62	95,38
8	0	4,62	95,38

Dans la littérature, il existe plusieurs approches pour résoudre les problèmes de conflit, nous avons fait varier le nombre des k-ppv considérés. Dans ce cas, nous avons trouvé que pour k égal à 7 ou 8, il n'y a aucun problème de conflit.

La théorie des possibilités

Dans cette théorie, l'opérateur adaptatif proposé par Dubois et Prade [Dubois85] a donné une meilleure performance que les opérateurs classiques comme T-norme et T-conorme. Les résultats obtenus par l'opérateur adaptatif sont indiqués dans le tableau 8.11.

Tableau 8.11 : Performance de l'opérateur adaptatif (théorie des possibilités) en faisant varier k.

k-ppv	Ambiguïté (%)	Taux de mauvaise décision (%)	Taux de bonne décision (%)
3	1,54	3,85	93,85
4	0,77	4,62	94,62
5	2,31	3,85	93,85
6	0,77	6,15	93,08
7	2,31	3,85	93,85
8	2,31	3,08	94,62

La méthode de Borda count

La méthode de Borda count a aussi été employée dans les mêmes conditions, en faisant varier k dans l'intervalle [1-8]. Voici les résultats obtenus par cette méthode (Tableau 8.12) :

Tableau 8.12 : Performance de la méthode de Borda Count en faisant varier k

k-ppv	Ambiguïté (%)	Taux de mauvaise décision (%)	Taux de bonne décision (%)
3	1,54	3,08	95,38
4	1,54	3,85	94,62
5	0,77	4,62	94,62
6	0,77	5,38	93,85
7	0	5,38	94,62
8	0	5,38	94,62

L'approche bayésienne (matrice de confusion)

L'approche bayésienne a été employée avec les calculs des probabilités *a posteriori* basés sur la matrice de confusion. Pour créer la matrice de confusion, nous avons utilisé notre

formalisme flou indépendamment pour chaque classifieur en optimisant les paramètres k et γ . Les résultats comme indiqués dans la section précédente ont été obtenus avec k égal à 3 et le γ a été optimisé pour chaque classifieur. Le résultat obtenu par l'approche bayésienne est un taux de bonne classification égal à 96,92 %.

8.7.4 Conclusion

Dans cette section, nous avons indiqué les résultats expérimentaux obtenus en cas d'identification des images de la main par chaque classifieur et en fusionnant les classifieurs par plusieurs approches. Dans un premier temps, nous avons établi plusieurs classifieurs des k -ppv basés sur différents vecteurs de caractéristiques de la géométrie de la main et d'empreinte palmaire. L'évaluation des performances des classifieurs nous a conduit à considérer 4 classifieurs. Les performances de ces classifieurs ont montré une dépendance à la valeur du paramètre k . Dans un classifieur des k -ppv, il existe plusieurs méthodologies pour prendre la décision. Dans ce chapitre, nous avons étudié la règle des k -ppv avec vote majoritaire, la règle des k -ppv avec pondération de distance et la règle des k -ppv floue proposée. Les performances évaluées de ces trois règles varient en fonction de k . En effet, avec $k = 1$, les décisions prises par un classifieur quelle que soit la méthodologie ne présentent pas de problème d'ambiguïté, mais en faisant varier la valeur de k , égal à 3 et plus, il y a des problèmes d'ambiguïté qui font varier l'efficacité de chaque méthodologie en fonction de la manière de résoudre ces problèmes. Un exemple de résultat obtenu avec 5-ppv par la règle des k -ppv avec vote majoritaire classique est décrit dans le tableau ci-dessous :

Tableau 8.13 : Performances des classifieurs évaluées par la règle des k -ppv avec vote majoritaire classique et k égal à 5 (5-ppv).

	e1	e2	e3	e4
Taux de bonne classification (%)	85,38	84,62	75,38	84,62
Ambiguïté en Top_2 (%)	6,92	10	10	6,15
Ambiguïté en Top_5 (%)	0	0	3,85	0,77
L'erreur absolue (%)	7,69	5,38	10,77	8,46

Dans ce tableau (8.13), nous pouvons noter qu'il y a un pourcentage important de cas d'ambiguïté qui demande une méthodologie efficace. La règle des k -ppv floue proposée a montré une amélioration par rapport à d'autres méthodologies étudiées dans ce chapitre.

Un exemple des résultats est indiqué dans le tableau 8.14 pour montrer comment la performance du système en fusionnant les quatre classifieurs a été améliorée (ici la main est de la classe 18).

Tableau 8.14 : Les décisions prises par les quatre classifieurs (la règle des k-ppv du vote majoritaire) et la décision finale par fusion.

Classifieur	Décision	Fusion
e1	C_{18}, C_{19}	C_{18}
e2	C_{26}	
e3	$C_{12}, C_{18}, C_{19}, C_{24}, C_{26}$	
e4	C_9, C_{18}	

Dans ces résultats, il y a un seul classifieur (e2) qui a donné une décision précise, sans ambiguïté, mais qui est une mauvaise décision, les trois autres classifieurs (e1, e3, e4) ont rencontré des cas d'ambiguïté mais leurs décisions comportent quand même la bonne classe en confusion avec une ou plusieurs autres classes.

Des informations de natures complémentaires ont servi à améliorer la pertinence de chaque méthode de fusion. En effet, cela dépend dans chaque méthode comment ces informations ont été exploitées. Pour une vue générale des résultats obtenus par plusieurs méthodes de fusion, nous indiquons les meilleurs résultats trouvés avec les informations de type décision (classe) ou rang ou les mesures (distance) en faisant varier k dans l'intervalle [1-8] (tableau 8.15). En analysant ce tableau, nous notons que la meilleure robustesse est donnée par le formalisme flou proposé.

Tableau 8.15 : Les meilleurs résultats obtenus par les méthodes de fusion.

Méthode	Reconnaissance (%)
Le formalisme flou proposé	97,70
La méthode du vote avec $\lambda \geq 0,5$	93,90
La méthode du vote pondéré	96,15
La méthode du vote à la pluralité	93,85
La théorie de l'évidence	95,38
La théorie des possibilités	94,62
La méthode de Borda Count	95,38
L'approche bayésienne	96,92

8.7.5 Résultats en vérification

Dans cette étape, le jeu de données est le même que celui utilisé précédemment. (26 personnes ou classes et 5 prototypes par classe). Tout d'abord le taux de faux rejet (FRR) et le taux de fausse acceptation (FAR) de nos quatre classifieurs sont calculés individuellement et ils sont indiqués dans le tableau 8.16. Nous avons utilisé l'idée de la méthode de « leave one out » comme expliqué avant. Le seuil de décision pour chaque classe (personne) a été calculé pendant la phase d'apprentissage en utilisant les 4 prototypes de chaque classe, c'est en fait la plus grande valeur des distances minimums entre chacun des 4 échantillons et les autres avec en plus une tolérance. L'un des prototypes en test a été utilisé pour calculer le taux de faux rejets dans les différents tests comme expliqué avant. Par contre tous les autres prototypes de toutes les autres classes sont employés comme faux aléatoires pour calculer le taux de fausse acceptation.

Au contraire de l'identification nous notons que les performances des classifieurs e1, e2 et e3 sont assez proches et que la qualité du classifieur e1 est légèrement meilleure que les autres. Ce résultat montre que le meilleur classifieur (ou un ensemble de caractéristiques) pour un problème d'identification peut ne pas l'être pour un problème de vérification. Une fois les deux taux d'erreur pour chaque classifieur notés, nous avons réalisé une étape de fusion de ces classifieurs aux différents niveaux.

Tableau 8.16 : Les performances des classifieurs

Classifieur	FRR (%)	FAR (%)
e1	2,3	1,8
e2	2,3	2,0
e3	2,3	2,3
e4	3,9	3,1

Fusion de classifieurs au niveau représentation

Dans un premier temps, pour étudier l'intérêt de la fusion de données au niveau représentation, nous avons utilisé la règle de la moyenne arithmétique pour fusionner les distances des quatre classifieurs. Puis nous avons noté les performances de trois méthodologies comme nous l'avons indiqué dans une section précédente pour prendre la décision finale concernant l'acceptation ou le rejet d'une forme entrante. Pour une forme entrante x et un seuil donné S , on applique :

- Si la distance minimum entre la forme entrante x et un des 4 prototypes est inférieur à S , alors x est acceptée sinon rejetée.
- Si les distances minimums entre la forme entrante x et deux des 4 prototypes sont inférieur à S , alors x est acceptée sinon rejetée.
- Si les distances minimums entre la forme entrante x et trois des 4 prototypes sont inférieur à S , alors x est acceptée sinon rejetée.
- Si les distances entre la forme entrante x et tous les 4 prototypes sont inférieur à S , alors x est acceptée sinon rejetée.
- Si la distance moyenne de la forme entrante x aux 4 prototypes est inférieur à S , alors x est acceptée sinon rejetée.

Tableau 8.17 : Performances de différentes méthodologies de prise de décision en fusionnant les quatre classifieurs

Méthodologie	FRR (%)	FAR (%)
1-prototype	1,54	0,57
2-prototypes	3,08	1,54
3-prototypes	2,31	2,03
4-prototypes	3,85	3,72
Moyenne-prototype	2,31	1,13

Fusion par la règle de vote

La règle de vote majoritaire a été utilisée au niveau des décisions des classifieurs. En cas d'égalité (ambiguïté), le problème a été résolu en donnant une pondération aux classifieurs selon leurs performances individuelles. Il est évident dans le tableau 8.18 que le résultat de la fusion au niveau de la décision des classifieurs a augmenté la performance globale de notre système par rapport à la fusion au niveau représentation. Le résultat a été assez amélioré par rapport à celui de chaque classifieur (tableau 8.18).

Tableau 8.18: Performances de la méthode du vote majoritaire

	FRR (%)	FAR (%)
Fusion par la règle de vote majoritaire (au niveau décision)	0,77	0,43

Fusion par le formalisme flou proposé

En appliquant le formalisme flou proposé à la fusion de classifieurs dans le problème de vérification, les résultats obtenus sont présentés dans le tableau 8.19. La méthodologie

d'emploi du formalisme flou proposé est déjà décrite dans le chapitre 6. Nous avons étudié l'influence de trois paramètres, le seuil de distance, la valeur du paramètre du formalisme, noté γ , et la valeur de la fonction d'appartenance $f_{x_i}(x)$. Le choix des valeurs du paramètre γ a conduit vers la limite supérieure de son intervalle défini dans le chapitre 4, en fait entre 2,5 et 3. Nous avons alors fixé sa valeur égale à 2,5 dans toutes les phases de tests. Ensuite, au lieu de faire varier le seuil de distance nous avons fait varier les valeurs des seuils de $f_{x_i}(x)$ pour prendre la décision finale parce que pendant la phase d'évaluation de performance de différentes méthodologies un seuil optimal pour une classe a déjà été désigné. Ces seuils de distances ont été retenus et les valeurs de $f_{x_i}(x)$, reste un seul paramètre à étudier, les seuils varient entre 0,51 et 1. Pour une classe (personne) un seuil optimal en fonction de $f_{x_i}(x)$, a été trouvé.

Tableau 8.19 : Performance par le formalisme flou proposé

k-ppv	FRR (%)	FAR (%)
3-ppv	0,77	0,30
4-ppv	0,77	0,43

La différence importante entre les résultats montrés dans les tableaux 8.17 et 8.19 est que dans le tableau 8.17, nous prenons en compte le nombre de prototypes 1, ou 2, ou 3, ou 4 par exemple parmi les quatre prototypes de l'ensemble de référence qui sont d'accord pour accepter ou rejeter une forme entrante. L'avis d'un prototype (C_1 ou C_2) est à la base d'un seuillage de distance. Dans le tableau 8.19, nous prenons en compte les quatre variables indiquées dans le chapitre 4 (sur le formalisme flou), le nombre de prototypes de C_1 et C_2 ($N_x(C)$), les rangs, les distances, les variances de distances, le paramètre γ optimisé du formalisme. Enfin en faisant varier les valeurs de $f_{x_i}(x)$, tous ces facteurs ont montré globalement un bon comportement de notre formalisme.

Les résultats indiquant 0,3 % de taux de fausse acceptation avec seulement 0,77 % de taux de faux rejet montrent le potentiel d'un système de vérification basé sur la reconnaissance de la main.

8.7.6 Problèmes et discussion

Dans notre système, nous avons utilisé les caractéristiques de la géométrie et de l'empreinte palmaire. Nous avons montré qu'une étape de fusion a apporté une amélioration de la performance du système.

En développant ce système nous avons rencontré certains problèmes. La performance d'un système est basée en principe sur la robustesse des classifieurs. Ces robustesses sont liées à plusieurs critères comme la qualité des images et du prétraitement par exemple. Dans notre système, pour créer la base de données des images de la main sans encre, un scanner ordinaire a été utilisé avec les lumières normales internes, dans une salle de l'école. Des images de l'empreinte palmaire ont été extraites à partir de ces images. En analysant les images, nous avons noté que quelques utilisateurs n'ont pas mis en contact leur paume/doigts et la plateforme du scanner correctement et certains ont placé leur main avec des forces d'écrasement différentes (figure 8.23).

Ainsi, il y avait des problèmes de qualité des images notamment pour l'extraction des caractéristiques de l'empreinte palmaire, c'est pourquoi des classifieurs basés sur l'extraction des lignes de l'empreinte palmaire et des caractéristiques de paume ont obtenu des performances faibles par rapport à celles basées sur la géométrie de la main. Ayant une petite base de données, nous n'avons pas enlevé les images de mauvaise qualité de notre base de données. D'autres chercheurs ont aussi indiqué le même type de problème pendant l'acquisition de leur propre base de données [Travieso04], [Kumar03], [Connie05]. Ils ont supprimé les images de mauvaise qualité de leur base de données. Dans ces cas, les chercheurs ont souligné le problème de la coopération sérieuse des personnes lors de l'acquisition des images de main et d'empreinte palmaire en particulier.

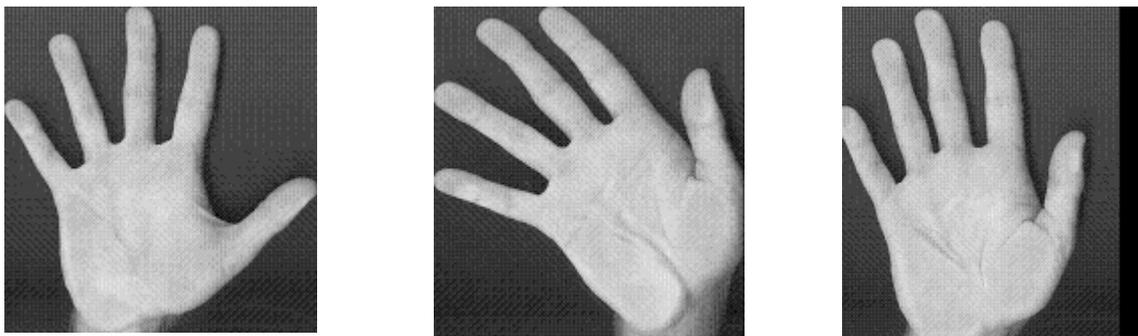


Figure 8.23: Trois images par la même personne

Nous avons dans un deuxième temps capturé les images de la main en basse résolution, 80 dpi seulement pour une taille d'image de 615 par 615 pixels en général. Ces caractéristiques sont jugées suffisantes pour la géométrie de la main mais probablement pas pour des caractéristiques de l'empreinte palmaire. Nous étudions en détail ce problème dans l'avenir.

8.8 Conclusion

Nous avons présenté un système de reconnaissance des mains basé sur les caractéristiques de la géométrie de la main et sur l’empreinte palmaire. Le but principal a été de montrer l’intérêt de la fusion de données. Les caractéristiques de la main et de l’empreinte palmaire sont extraites à partir de la même image et sont employées pour réaliser plusieurs classifieurs. La performance de chaque classifieur a été évaluée avec deux jeux de données réelles. Un petit jeu de données trouvé sur internet a été employé dans un premier temps dans un problème d’identification. Le résultat obtenu était très encourageant. Le deuxième jeu de données a été créé par nous-même, il a été utilisé pour des problèmes d’identification et d’authentification. La liberté donnée aux utilisateurs au niveau du positionnement de la main ne pose aucun problème sérieux pour l’extraction des caractéristiques de la main mais ce n’est pas idéal pour l’extraction des caractéristiques de l’empreinte palmaire. Nous continuerons notre travail sur cet aspect dans l’avenir. Le classifieur basé sur les caractéristiques de l’empreinte palmaire exige d’ajouter des informations plus locales et fiables.

Au niveau d’un seul classifieur, le formalisme flou proposé a augmenté les performances des classifieurs par rapport aux deux autres approches employées également à des fins de comparaison. Le meilleur classifieur pour un problème d’identification n’est pas toujours le meilleur pour un problème d’authentification du point de vue des performances. Plusieurs méthodes de fusion proposées dans la littérature ont été étudiées pour ces deux problèmes. L’influence du nombre de classifieurs à prendre en compte dans le processus de fusion a été aussi étudiée. La méthodologie proposée basée sur le formalisme flou a montré un pouvoir de discrimination important. En effet, la performance en fusionnant trois classifieurs a été notée exactement la même que celle en fusionnant quatre classifieurs. Ce n’était pas le cas avec toutes les autres méthodes étudiées.

Chapitre 9

Identification et authentification par signatures manuscrites hors ligne

Dans la littérature, parmi les systèmes reposant sur les signatures manuscrites, de plus en plus, l'accent est mis sur les systèmes de vérification de signature tandis que l'identification automatique de signatures a été délaissée. Ici, nous nous intéressons à ces deux types de systèmes qui comportent des phases communes mais en différenciant les solutions pouvant être apportées à certaines étapes indépendantes. Nous étudions l'importance de la fusion de données dans ces deux systèmes séparément. De notre point de vue, le système d'identification aussi bien que le système de vérification basé sur les signatures manuscrites peut trouver sa place dans la vie pratique. Un système plus pertinent avec une étape de fusion de données dans le processus de décision est l'objectif de notre recherche.

9.1 Introduction

Les hommes ont différents styles d'écriture, plus ou moins caractéristiques. Les signatures forment une classe spéciale d'écritures dans laquelle des lettres ou les mots lisibles ne peuvent être extraits. Néanmoins elles fournissent des moyens fiables pour l'authentification, l'identification, l'attestation et l'autorisation dans le domaine du droit, le domaine bancaire ou d'autres environnements de sécurité élevée. Elles sont acceptées en tant qu'évidence légale. Une signature peut être produite presque n'importe où et au contraire des mots de passe ou des cartes d'identité, elle ne peut pas être oubliée ou perdue. Elles constituent également une solution avantageuse en terme de facteurs psychologiques en comparaison avec d'autres méthodes biométriques. L'identification de signature semble ne pas gêner les personnes, peut-être parce que la signature est une activité commune de presque tous les jours. Cependant, l'accomplissement d'une identification de signature ou d'un système automatique de vérification pose beaucoup de problèmes. L'identification et en particulier la vérification de signature sont très sensibles à la stabilité de la signature d'un individu. La

variabilité des signatures dépend des lieux géographiques, de l'âge, de l'époque, des habitudes psychologiques ou de l'état mental et des conditions physiques et pratiques. Deux types de variabilité de signature doivent être clairement distingués. Premièrement, la variabilité intra-classe ou intra-scripteur c'est à dire la variation observée à l'intérieur d'un ensemble de vraies signatures d'un individu. Deuxièmement, la variabilité interclasses ou interpersonnes c'est à dire les différences qui existent entre les vraies classes de signatures représentant des auteurs différents. En plus, d'après [Pavlids98] et [Ismail00], le problème d'identification de signature est plus complexe que celui de la vérification de signature.

9.2 Types de signatures

Il existe deux types distincts de signatures, d'après [Cardot93], qui dépendent de la situation géographique. Les signatures américaines sont proches de l'écriture cursive classique. Il est rarement impossible de reconnaître le nom d'une signature américaine. La reconnaissance d'une signature américaine s'apparente donc plus à la reconnaissance d'écriture. En effet, généralement le nom est écrit et simplement souligné.


 A rectangular box containing the handwritten signature "Katherine Paul" in a cursive script. The letters are connected, and the overall style is characteristic of American cursive handwriting.

Figure 9.1 : Exemple de signature cursive américaine

Les signatures européennes sont plus variées et souvent plus éloignées de l'écriture cursive. Elles possèdent une composante graphique non négligeable qui nous oblige à les traiter dans leur globalité et non caractère par caractère. Le système que nous voulons développer doit s'intéresser aussi à ce type de signatures ; voir quelques exemples dans le tableau 9.1. Certains chercheurs ont proposé des méthodes de classification [Boulétreau97].

9.3 Méthodes d'analyse des signatures

Un système de signatures peut être classifié en tant que système en ligne ou hors ligne selon le matériel d'acquisition. Un système en ligne [Ammar88] utilise un stylo avec un environnement électronique qui fournit des informations dynamiques liées au mouvement du stylo, généralement sa position, vitesse, ou accélération en fonction du temps. Les systèmes en ligne présentent généralement une meilleure performance que les systèmes hors ligne mais exigent la présence de l'auteur pendant l'acquisition des données de référence et pendant le procédé de vérification, limitant son utilisation à certaines applications. Dans un système hors

ligne, des signatures écrites sur une facture, un chèque bancaire ou n'importe quel document officiel, sont converties sous forme électronique avec l'aide d'un scanner ou d'un appareil photo. Comparés aux systèmes en ligne, les systèmes hors ligne ne disposent d'aucune information temporelle directe et le procédé de vérification se fonde sur les caractéristiques qui peuvent être extraites à partir de la luminance de la trace seulement. De plus, les systèmes hors ligne n'exigent l'utilisation d'aucun appareil complexe autre qu'un scanner mais exigent une étape de prétraitement en général plus complexe, ainsi que la création d'une plus grande base de données [Zimmer03].

9.4 Les fausses signatures

Dans un système automatique de signature, on doit distinguer différents types de fausse signature (aléatoire, simple et simulé, etc.) [Cardot93], [Sabourin97], [Justino01]. Le faux aléatoire est habituellement représenté par un échantillon d'une vraie signature mais appartenant à un auteur différent pas nécessairement inscrit dans la base de signatures connues. Le faux simple est représenté par un échantillon de signature qui utilise le même nom que l'auteur sans imiter une signature originale. Le faux simulé est représenté par une imitation raisonnable d'une vraie signature. Le tableau 9.1 montre des exemples d'échantillons vrais et de faux simulés pour différents auteurs. Pour les faux simples et aléatoires le tracé est spontané, les caractéristiques pseudo dynamiques sont donc peu discriminantes, par contre la ressemblance est faible et les caractéristiques statiques sont assez discriminantes [Cardot93]. Ces faux sont considérés comme les plus faciles à détecter car ils ne nécessitent pas d'expertise très élevée. Pour les faux simulés, qui ressemblent aux vraies signatures, il est nécessaire d'utiliser des caractéristiques pseudo dynamiques et un système plus évolué. Pour d'autres types de fausse signature voir la thèse de [Cardot93].

Tableau 9.1. Les vraies signatures et les faux simulés [Demos]

Signataire	Vraies signatures		Faux simulés par des imposteurs	
1				
2				
3				

9.5 Etat de l'art

Nous nous intéressons dans cette thèse aux systèmes n'utilisant que l'information statique de la signature. C'est pourquoi, nous ne citons pas les travaux effectués à partir de l'information dynamique. Les premiers travaux à remarquer dans ce domaine sont cités dans les états de l'art jusqu'en 1987 par [Plamondon89], pour la période de 1989-1993 par [Leclerc94] et [Issue spéciale de revue IEEE-PR&MI 94], et finalement jusqu'en 1999 en bref dans [Plamondon00]. Nous pouvons remarquer dans les différents travaux présentés que beaucoup utilisent des signatures cursives [Cardot93]. Nous citons dans cette thèse les publications plus récentes dans ce domaine.

Pendant la dernière dizaine d'années, l'attention s'est portée sur les réseaux de neurones. La plupart des études emploient des approches conventionnelles : perceptrons multicouches, architecture de reconnaissance coopérative, et réseaux adaptatifs de théorie de résonance (ART en anglais). D'autres approches utilisent les classifieurs de distance minimale, le plus proche voisin, la programmation dynamique, les Chaînes de Markov Cachées (CMC), des classifieurs à base de seuils, et la logique floue.

Pendant les 5 dernières années, les articles de recherche insistent principalement sur des techniques floues et des classifieurs par machine à support de vecteur (SVM) pour la vérification de signatures hors ligne en parallèle avec les réseaux de neurones artificiels et les chaînes de Markov cachées (CMC).

9.5.1 Caractéristiques pour la représentation des signatures

Beaucoup de caractéristiques utiles ont été proposées depuis la naissance de ce domaine pour différencier les signatures d'une personne et celles d'autres personnes. Un travail de recherche sur un système d'extraction de caractéristiques plus robustes est toujours d'actualité. Les caractéristiques proposées dans les systèmes hors ligne peuvent être groupées selon leur nature globale, géométrique, structurelle ou statistique. Dans la représentation globale des signatures, les caractéristiques sont extraites à partir de chaque pixel qui se trouve dans un rectangle entourant la signature. Bien qu'elles soient faciles à extraire et peu sensibles au bruit, elles varient sous l'effet d'une déformation significative ou quand une variation de style apparaît. Alors un alignement satisfaisant de position ne peut pas être réalisé. Les caractéristiques statistiques sont dérivées de la distribution statistique des pixels de la signature. L'approche statistique est plus tolérante que des méthodes globales aux variations de déformation et de style puisqu'elle incorpore une certaine quantité de l'information

topologique et dynamique [Ammar88]. Les caractéristiques géométriques et topologiques représentent la géométrie et la topologie particulières d'une signature. Ces caractéristiques peuvent tolérer un degré élevé de variations dans les déformations et dans le style, et elles peuvent même tolérer jusqu'à un certain degré les variations de translation et de rotation [Lee92].

L'utilisation des représentations basées sur une transformation et sur des points critiques dans une image de signature hors ligne a été rapportée par [Sabourin97] et [Lee92]. Dans [Qi94], la combinaison des caractéristiques géométriques globales et de la grille est présentée. La mesure de moments et des caractéristiques d'enveloppe sont décrites dans [Bajaj97]. Quatre types de représentations de formes *via* des caractéristiques géométriques, des représentations basées sur les moments, des caractéristiques d'enveloppe et des caractéristiques à structure arborescente d'ondelette ont été utilisés par [Ramesh99]. Dans [Huang02] une combinaison des caractéristiques statiques des pixels de l'image et des caractéristiques structurelles pseudo dynamiques a été utilisée. Dans [Fang03] les déplacements de position dans les profils unidimensionnels de projection aussi bien que les déplacements de la place de certaines portions de trait dans la forme de la signature bidimensionnelle sont proposés. Les méthodes proposées ont été comparées à deux méthodes existantes basées sur les caractéristiques globales de forme proposées par [Ammar91] et le code basé sur l'ombrage (extended shadow code) proposé par [Sabourin94] avec la même base de données.

9.5.2 La nouvelle tendance : combinaison

Une vue d'ensemble des publications récentes de la décennie passée ne montre pas une unicité des techniques de vérification de signature ou du genre d'analyse et de choix des caractéristiques [Plamondon00]. Tous les systèmes développés jusqu'ici, en dépit de la variété des caractéristiques, ne produisent pas des résultats assez bons, bien que les cas où la robustesse de chaque approche est mise en défaut ne soient pas nécessairement identiques. Un autre concept est développé, il cherche à utiliser la nature complémentaire des ensembles de plusieurs caractéristiques pour augmenter la performance des différents vecteurs individuels de caractéristiques. La tendance vers l'intégration de plusieurs vecteurs de caractéristiques semble être la meilleure solution possible. Quoique plusieurs caractéristiques ou descripteurs apportent des informations complémentaires, ils peuvent être en conflit. Tandis que la combinaison est un but souhaitable, la réalisation de celle-ci n'est pas une tâche facile. Plusieurs méthodes sont étudiées pour la combinaison, notons par exemple les réseaux de

neurones artificiels [Bajaj97], [Cardot94] les réseaux bayésiens [Xiao02], les Chaînes de Markov Cachées [Justino01], et la méthode de vote [Allgrove00].

Un système de signature hors ligne se composant de l'identification et de la vérification des signatures est proposé par [Ismail00]. Dans cet article, la phase d'identification est basée sur un classifieur multi niveaux et une combinaison des caractéristiques globales et locales tandis que la vérification est faite en utilisant des concepts de la logique floue. Une approche basée sur les CMC présentée par [El-Yacoubi00] dérive dynamiquement et automatiquement les paramètres dépendant de l'auteur pour installer une règle optimale de décision pour le procédé de vérification des signatures. Ici le principe de validation croisée (cross validation) est employé pour dériver non seulement les meilleurs modèles de CMC, mais également un seuil optimal d'acceptation/rejet pour chaque auteur. Ce seuil mène à une discrimination élevée entre les auteurs et les imposteurs dans le contexte des faux aléatoires. Dans [Fang01] une méthode basée sur le critère de lissage est proposée. Selon leur observation, les segments cursifs des fausses signatures sont généralement moins lisses et moins normalisés que les vrais, particulièrement pour les signatures qui se composent de formes graphiques cursives. Deux approches sont alors utilisées pour extraire une caractéristique de lissage: une méthode d'étude des croisements et une méthode de calcul de dimension fractale. Pour obtenir de meilleurs résultats, la caractéristique de lissage a été combinée avec d'autres caractéristiques globales de forme.

Dans [Baltzakis01], le système proposé est basé sur les caractéristiques globales, de grille et de texture. Pour chacun des ensembles de ces caractéristiques une structure spéciale de classification de Perceptron UCUN (une classe, un réseau) à deux niveaux a été mise en œuvre. Dans la première étape, le classifieur combine les résultats de décision des réseaux de neurones et de la distance euclidienne obtenus en utilisant les trois ensembles de caractéristiques. Les résultats du classifieur du premier niveau servent alors à alimenter une structure de réseau de neurones en deuxième niveau basée sur les fonctions de base radiale (RBF) qui prend la décision finale. Dans [Fang03] les variations dans la forme ou les positions relatives des caractéristiques des signatures sont étudiées. Deux méthodes sont proposées pour suivre ces variations. La première méthode mesure les variations de position des profils unidimensionnels de projections de la signature ; et la deuxième méthode détermine les variations des positions relatives des traits dans le plan. Dans [Quek02], une approche basée sur les réseaux de neurones flous est proposée pour un système de vérification de signatures incluant des faux simulés.

Dans [Hanmandlu05], une modélisation floue utilisant le modèle de Takagi-Sugeno est proposée pour un système de détection de fausses signatures. Quelques caractéristiques structurales incluant des angles sont extraites en utilisant l'approche des boîtes et sont employées pour la discrimination. Dans [Justino05] une comparaison entre le classifieur de SVM et celui basé sur les CMC est présentée avec des fausses signatures aléatoires, simples et simulées. Un ensemble de caractéristiques sur les graphèmes (statiques et pseudo dynamiques) a été employé pour démontrer les capacités de discrimination de ces deux classifieurs (SVM et CMC). Des résultats se sont montrés en faveur des SVM.

Les différences principales entre ces études tiennent aux caractéristiques employées pour représenter une signature donnée. Il est difficile de comparer les performances de différents systèmes de vérification de signature puisque les différents systèmes emploient des bases de données différentes. L'existence d'une base de données internationale standard de signatures est un grand problème pour la comparaison des performances.

9.6 Notre système

9.6.1 Introduction

Notre contribution s'inscrit dans cette tendance à combiner les classifieurs. D'une part nous présentons des caractéristiques traditionnelles et des caractéristiques plus spécifiques à un système de biométrie (globales, statistiques, et géométriques). D'autre part nous avons segmenté l'ensemble de caractéristiques selon chaque type de caractéristiques pour accentuer l'information qu'elles peuvent apporter à la résolution des problèmes et puis nous avons réalisé la fusion. Nous avons donc pris en compte une grande variété de caractéristiques. Dans notre méthodologie plusieurs classifieurs basés sur différents ensembles de caractéristiques sont d'abord réalisés. Enfin deux systèmes, l'un pour l'identification et l'autre pour la vérification, sont proposés en combinant ces classifieurs. Ici nous étudions certaines méthodes comme la théorie d'évidence de Dempster-Shafer, la théorie des possibilités, l'approche bayésienne basée sur la matrice de confusion, les chaînes de Markov cachées, les opérateurs d'agrégation, comme outils de combinaison. Le protocole général de notre méthodologie a été présenté dans le chapitre 6. Dans le cas de l'identification, comme nous l'avons déjà dit, les classifieurs utilisés sont des classifieurs de distance qui indiquent trois types d'informations relatives à la signature étudiée :

- (i) les classes des k -plus proches voisins avec leurs distances,
- (ii) les classes des k -plus proches voisins et leurs rangs,

(iii) la sélection d'une classe comme décision.

Dans le cas d'un système de vérification, les classifieurs donnent deux types d'informations en sortie selon la signature étudiée :

(i) deux classes en fonction des k-plus proches voisins selon un seuil de distance (C_1 si la signature est acceptée par un prototype dans les k-ppv et C_2 quand elle est rejetée par un prototype parmi les k-ppv) et les distances des k-ppv.

(ii) leur décision d'acceptation ou de rejet (soit C_1 , soit C_2). Différentes approches de fusion sont ensuite employées pour étudier l'influence de la fusion aux trois niveaux, c'est à dire, au niveau des représentations, des rangs et des décisions.

9.6.2 Prétraitement des signatures

N'importe quelle application en traitement d'images souffre de la présence de bruit comme la déformation des segments de ligne, la présence des pixels isolés et des images floues. Ce bruit peut causer des déformations graves et par conséquent les caractéristiques deviennent ambiguës et le taux d'identification ou de vérification est faible. C'est pourquoi une étape de prétraitement est utilisée pour enlever le bruit. Les techniques de prétraitement éliminent une partie de la variabilité des données de signatures.

En effet, un système parfait de prétraitement rendrait les signatures d'une même personne identiques, enlevant autant que possible le bruit et préparant les données résultantes pour l'extraction et la classification de caractéristiques, de ce fait améliorant la robustesse du système d'identification et de vérification. Le souci principal est la stabilité des caractéristiques des signatures. Puisque les techniques existant pour séparer la signature d'un fond bruité ont montré leur efficacité [Ammar88a] nous supposons que les signatures ont été déjà extraites à partir du fond. C'est pourquoi pour générer notre base de données nous avons utilisé des feuilles blanches et nous décrivons quelques étapes de prétraitement illustrées dans les figures 9.2, et 9.3.

Lissage

Il arrive fréquemment que lors de la numérisation de la signature, les pixels entourant les traits soient imparfaits. Nous pouvons en voir un exemple sur l'image d'une signature dans la figure 9.2. Pour lisser ces irrégularités, nous utilisons d'abord une méthode de dilatation-érosion. L'élément structurant choisi a une taille de 3x3 pixels.

Après avoir effectué cette opération, nous opérons un lissage d'un autre type. Pour chaque pixel, nous observons ses 8 voisins immédiats. Si parmi ceux-ci, plus de 5 sont noirs, alors nous noircissons le pixel testé.

En effet il existe parfois des « trous » dans le trait qui sont dus à l'outil d'écriture quand le scripteur n'appuie pas assez. Ces « trous » ne sont pas corrigés par le lissage car ils sont plus larges que les petites imperfections dues à la numérisation. De plus ils n'apparaissent pas sur toutes les signatures d'une même personne. Nous pouvons voir ces « trous » sur l'exemple de signature dans la figure 9.3.

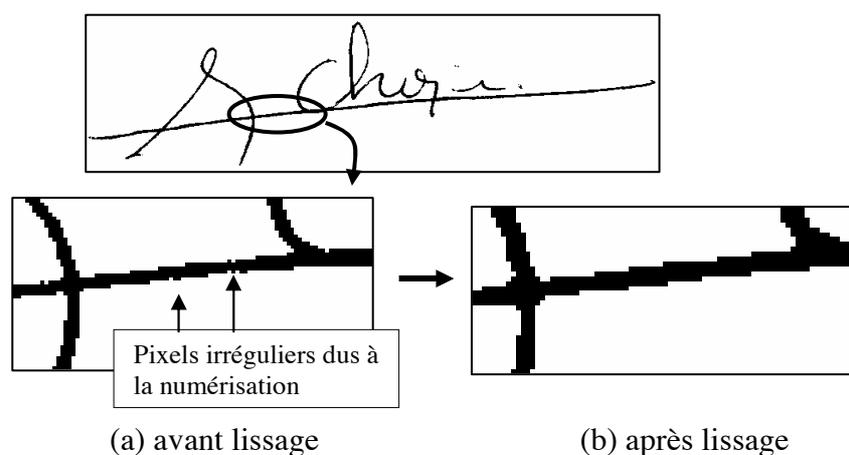


Figure 9.2 : Exemple d'image comportant des pixels irréguliers (a) et après lissage (b).

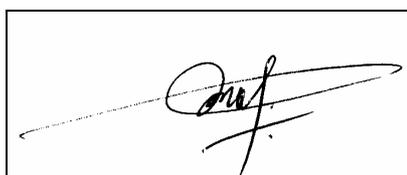


Figure 9.3 : Exemple de signature où le trait comporte des trous.

Nous constatons que le grand trait sur la gauche de la signature est en pointillé (figure 9.3). Le remplissage de ces trous est important en particulier pour le calcul du paramètre de contour. Par la suite nous verrons que nous appliquons des dilations aux contours de la signature. Ces dilations vont dans un premier temps remplir les contours et par la même occasion grossir les contours de sorte que les traits en pointillé ne forment plus qu'un trait classique. Cette première phase de dilatation n'étant pas prise en compte pour le calcul de la dimension fractale, nous pourrons étudier l'évolution des dilations suivantes de la signature où les trous seront remplis.

9.6.3 Extraction des caractéristiques

Afin d'étudier les signatures sous différents aspects, nous extrayons plusieurs types de caractéristiques des signatures. Ces différentes caractéristiques donneront lieu à quatre classifieurs :

- Trois classifieurs utilisent des histogrammes (projections des signatures selon plusieurs axes).
- Le dernier utilise des caractéristiques géométriques et fractales.

Nous décrirons en détail dans les sections suivantes ces caractéristiques utilisées et leur intérêt.

9.6.3.1 Les histogrammes

Evidemment, une même personne ne peut réaliser 2 fois sa signature à l'identique. En effet, on peut toujours y constater quelques déformations. Cependant, la forme globale de la signature reste toujours la même. Nous pouvons donc en déduire qu'en nous intéressant à l'analyse « approximative » d'une signature, nous pourrions l'identifier. Ceci rend importante l'utilisation d'histogrammes. Ceux-ci ne porteront pas attention à la signature dans ses détails mais dans sa forme globale, en négligeant les petites imperfections, suivant un axe de projection bien déterminé.

Cette première méthode de reconnaissance de signatures repose sur une approche assez simple. Le but est d'analyser la répartition des points dans la signature. Le principe est d'effectuer une projection des points constituant la signature sur un axe et de compter le nombre de pixels ayant même projection. Ceci nous permettra de constituer un histogramme de la signature. La confrontation des signatures se réduira ensuite à une simple comparaison par distances entre les histogrammes de différentes signatures suivant un même axe.

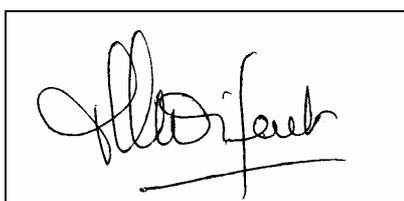
Nous étudierons d'abord les signatures grâce à des histogrammes horizontaux et verticaux. Puis nous adapterons la définition des histogrammes à la pente de la signature en les réalisant suivant les axes principaux de l'ellipse d'inertie associée à la signature. Enfin nous détaillerons les résultats des différents classifieurs réalisés à partir de ces informations.

9.6.3.1.1 Histogrammes horizontaux et verticaux

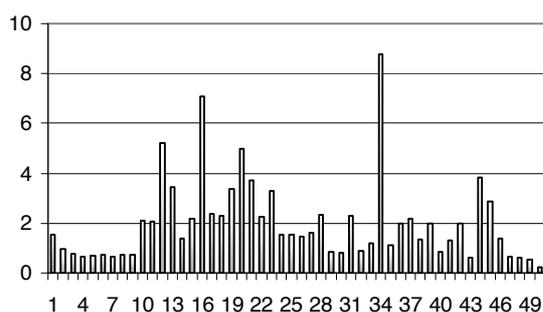
Ces histogrammes sont les plus simples à construire. Ils permettent d'étudier les variations du nombre de pixels suivant l'axe horizontal ou vertical. Nous pouvons ainsi différencier les signatures suivant la répartition des pixels.

La projection se fait suivant l'axe horizontal ou vertical. La projection sur l'axe horizontal de l'image nous permet de voir si les points de la signature sont répartis plutôt sur la gauche ou sur la droite de la signature. La projection sur l'axe vertical donne une indication sur la répartition en hauteur des points de la signature.

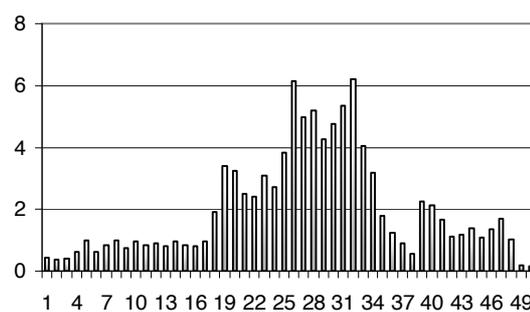
Une fois la projection effectuée suivant un axe, on normalise l'histogramme en divisant par l'effectif total. Cela nous permet de n'être sensible ni à la résolution, ni à la taille de l'image d'origine. Il est maintenant possible de les comparer sans biais dus à la résolution ou à la taille de l'image.



(a) Image de la signature A



(b) Histogramme horizontal de la signature A



(c) Histogramme vertical de la signature A

Figure 9.4: Une image de signature (a) et ses histogrammes selon deux directions (b), (c).

9.6.3.1.2 Histogrammes suivant les axes de la signature

Le calcul de ces histogrammes suit le même principe que les histogrammes horizontaux et verticaux. Seulement dans ce nouveau cas, nous devons d'abord chercher les deux axes définissant la direction de la signature et nous en déduisons deux types d'histogrammes suivant l'axe principal de la signature et suivant l'axe perpendiculaire à l'axe principal (2^{ème} axe de la signature). Le calcul de l'ellipse d'inertie de la signature nous permet de connaître l'axe principal de la signature. Afin de calculer les paramètres définissant l'ellipse d'inertie, nous devons calculer les directions propres de la matrice de variances covariances de l'image de la signature, dans un repère $(0,x,y)$ orthonormé :

- Les variances et la covariance de x et y , les coordonnées des points :

$$\text{Var}(x) = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n} \quad (9.1)$$

avec n le nombre de points de la signature.

$$\text{Var}(y) = \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n} \quad (9.2)$$

$$\text{CoVar}(x, y) = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n} \quad (9.3)$$

- Nous pouvons en déduire les valeurs propres λ_0 et λ_1 de la matrice de variances et covariances :

$$\lambda_0 = \frac{\text{Var}(x) + \text{Var}(y) + \sqrt{D}}{2} \quad (9.4)$$

$$\lambda_1 = \frac{\text{Var}(x) + \text{Var}(y) - \sqrt{D}}{2} \quad (9.5)$$

$$\text{Avec } D = (\text{Var}(x) - \text{Var}(y))^2 - 4 \cdot \text{CoVar}(x, y)^2 \quad (9.6)$$

- Ainsi nous déduisons la valeur de la pente de l'axe principal de l'ellipse considérée:

$$P = \cos^{-1} \left[\frac{1}{\sqrt{1 + \frac{\text{CoVar}(x, y)^2}{(\lambda_0 - \text{Var}(y))^2}}} \right] \quad (9.7)$$

- et les longueurs des axes de l'ellipse :

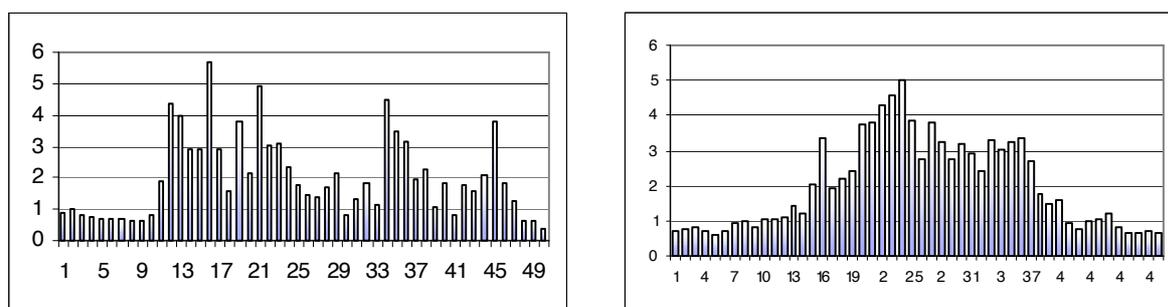
$$r_0 = \sqrt{\lambda_0}, \quad r_1 = \sqrt{\lambda_1}.$$

Nous pouvons maintenant calculer 2 nouveaux histogrammes. Les points de la signature sont projetés suivant les deux axes de l'ellipse. Ainsi nous pouvons analyser la répartition des

traits de la signature sans avoir de biais dû à la pente de la signature. Les résultats sont souvent proches des histogrammes horizontal et vertical classiques, tout en étant plus stables surtout en ce qui concerne l'histogramme suivant le grand axe de l'ellipse.

Exemples

Les histogrammes suivants ont été calculés à partir de la même image de la signature A.



(a) Histogramme suivant le grand axe de l'ellipse de la signature A.

(b) Histogramme suivant le petit axe de l'ellipse de la signature A.

Figure 9.5 : Deux histogrammes selon les deux axes de l'ellipse d'inertie

Nous pouvons facilement voir les petites variantes qui existent par rapport à la figure 9.4. Par exemple un grand trait barrant la signature verticalement engendrerait un pic très distinct dans l'histogramme horizontal (en abscisse 34). Sur l'histogramme selon le grand axe, ce trait n'étant pas perpendiculaire au grand axe de l'ellipse, nous ne voyons plus un grand pic mais une bosse sur l'histogramme suivant le grand axe (en abscisses 34 à 36).

Une signature sera dite « bien formée » si ses histogrammes ne comportent pas de pic non homogène avec ses voisins. Nous pouvons donc voir en analysant un histogramme de la signature, si celle-ci est harmonieuse ou non.

9.6.3.1.3 Calcul de distances entre histogrammes

Une fois les histogrammes établis, nous pouvons les utiliser pour comparer les signatures entre elles afin d'établir un classifieur. Il existe de nombreuses définitions de distances entre deux histogrammes, nous avons choisi une distance classique. Elle est égale à la somme des distances entre chacune des 50 classes des deux histogrammes. Ce calcul de distance est certes très simple mais reflète parfaitement les variations pouvant exister entre deux signatures.

Il peut arriver que 2 signatures de la même personne ne possèdent pas tout à fait les mêmes proportions. Prenons l'exemple d'une signature à partir de laquelle on fabrique un

histogramme horizontal. Il se peut, comme nous l'avons constaté sur la signature analysée précédemment, qu'un pic apparaisse dans l'histogramme indiquant un grand trait vertical. Si, sur 2 signatures de la même personne, ce trait se trouve sur 2 colonnes différentes mais très proches, alors le calcul de la distance entre les 2 histogrammes donnera une distance très grande alors qu'un trait est juste un peu décalé. Pour remédier à ce problème, nous ne calculons pas qu'une seule fois la distance. Nous pouvons choisir une proportion de décalage de l'histogramme. Généralement cette proportion doit rester faible (de l'ordre de $< 10\%$) pour ne pas fausser complètement les résultats. Si nous choisissons une proportion de 10% avec un histogramme de 50 colonnes, nous calculerons cinq distances entre les histogrammes décalés à chaque fois de plus ou moins une colonne. Cela peut permettre de réajuster les pics qui seraient éventuellement légèrement déplacés. Une fois que toutes les distances sont calculées, nous conservons la plus faible comme distance entre les deux histogrammes.

9.6.3.2 Paramètres géométriques et fractals

Dans cette partie nous présentons les différents paramètres pouvant être extraits des signatures. La signature étant un motif d'écriture tout à fait particulier et propre à chacun, nous avons essayé d'en tirer des caractéristiques particulières. Celles-ci sont différentes de celles étudiées avec les histogrammes car elles ne représentent pas la répartition du trait dans la signature mais la complexité de la signature et la forme globale de celle-ci.

Nous nous intéresserons tout d'abord aux contours de la signature. Il en existe plusieurs définitions et nous verrons comment ils peuvent être caractéristiques d'une signature. Ensuite nous étudierons les paramètres fractals qui donnent un indice de complexité ou de « lisibilité » de la signature. Puis nous aborderons la dimension fractale locale qui permet de détecter les zones irrégulières dans l'image et donc de les extraire pour les comparer. Ensuite nous verrons la dimension de masse qui donne un indice sur la forme de l'image et qui paraît être complémentaire de la dimension fractale. Le dernier paramètre que nous étudierons sera la pente de la signature qui apparaît assez stable chez une personne. Finalement, nous verrons comment utiliser ces paramètres dans le cadre de la reconnaissance de signatures et les résultats que nous obtenons.

9.6.3.2.1 Extraction de contours

Les contours ou l'enveloppe de la signature sont des éléments qui ont déjà été utilisés pour la reconnaissance de signatures. Nous nous intéresserons particulièrement à leur proportion par rapport à l'ensemble de la signature. Ainsi nous pourrions comparer le

« périmètre » de la signature et sa « surface ». En effet 2 objets ayant la même surface n'ont pas forcément le même périmètre (et inversement) et il est intéressant de voir dans quel rapport ils sont. Les 2 types d'extraction de contours que nous allons présenter offrent chacun des renseignements particuliers. Pour chaque type de contours utilisé, nous calculerons le rapport : *Nombre de pixels de contours / Nombre de pixels du longueur de la signature*.

Contours « classiques »

Les contours classiques sont faciles à extraire dans une image en noir et blanc. Nous parcourons l'image ligne par ligne puis colonne par colonne. Un pixel contour est caractérisé par le passage d'un pixel blanc à un pixel noir ou inversement. Nous pouvons voir sur l'exemple de signature ci-dessous (figure 9.6) le résultat de l'extraction de contours.

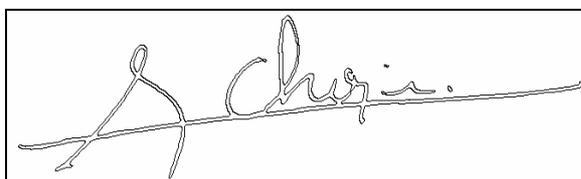


Figure 9.6 : Un exemple d'extraction de contours « classiques »

Contours « extérieurs »

Ce type de contour correspond à une partie seulement des contours classiques. Comme pour les contours classiques, nous parcourons l'image ligne par ligne et colonne par colonne. Seulement, dès que nous atteignons un pixel noir, donc un contour, nous arrêtons la recherche. Le parcours de l'image se fait en partant des quatre bords : haut, bas, gauche et droit.



Figure 9.7 : Un exemple d'extraction de contours « extérieurs ».

9.6.3.2 La pente

Généralement, les signatures d'une personne sont toujours réalisées avec un même angle par rapport à l'horizontale. On peut le constater visuellement sur la plupart des signatures. Nous avons donc pensé à utiliser cette mesure comme paramètre car elle paraît être stable.

De plus, presque tous les autres paramètres que nous utilisons dans ce classifieur sont totalement indépendants de la pente. En effet, la dimension fractale, l'indice d'application et la dimension de masse donnent un indice sur la complexité de l'écriture. Cet indice sera le même quel que soit l'angle de la signature. Les contours classiques et les zones rugueuses sont également indépendants de l'angle. Ces paramètres peuvent toutefois être légèrement modifiés si l'angle change mais cette constatation viendrait davantage d'approximations dues à la numérisation de l'image, ce qui semble négligeable. Le seul paramètre qui pourrait être modifié si l'on changeait l'angle de la signature serait celui reposant sur les contours extérieurs. En effet, comme nous nous intéressons aux premiers contours rencontrés lorsque l'on parcourt l'image en partant des bords de l'image, d'autres contours pourraient être atteints ou certains ignorés. La proportion de contours extérieurs par rapport à l'ensemble de l'image est donc le seul paramètre corrélé avec la pente. En conséquence, nous pensons pouvoir discriminer plus facilement les classes représentant les signatures des personnes en utilisant la pente de la signature. Nous avons vu lors de l'étude des signatures par histogrammes qu'il nous fallait calculer cette pente pour construire les histogrammes suivant l'axe principal de l'ellipse d'inertie associée à la signature. Nous utiliserons donc la même valeur que celle décrite précédemment comme indice de la pente.

9.6.3.2.3 La dimension fractale

Nous présenterons ici les différents paramètres fractals que nous avons utilisés pour la classification de signatures. Nous présenterons d'abord le principe de calcul de la dimension fractale. Ensuite nous expliquerons comment nous l'avons adapté aux signatures. Nous définirons les calculs de trois paramètres : la dimension fractale, la dimension fractale secondaire et l'indice d'implication.

Principe

Le but est ici de trouver un indice permettant de quantifier la forme globale de la signature. Plusieurs méthodes existent pour déterminer la dimension fractale. Toutes permettent d'approximer la formule de définition. Nous allons présenter la définition théorique de la dimension fractale.

La notion de fractales permet de déterminer la longueur d'une courbe complexe (comme les côtes maritimes ou l'écriture). Benoît Mandelbrot [Mandelbrot83] a formalisé ces objets mathématiques. Pour cette définition, il a pris l'exemple d'un arpenteur voulant mesurer la longueur des côtes anglaises. Cet arpenteur dispose d'une jauge de longueur η qu'il va

reporter $N(\eta)$ fois sur toute la longueur de la côte. En restant dans une perspective euclidienne, il peut ainsi en déduire la longueur de la côte $L(\eta)$: $L(\eta) = \eta \cdot N(\eta)$.

Nous pouvons facilement constater que si la longueur η de la jauge est très grande, les longueurs mesurées ne correspondront pas à la côte et les détails de celle-ci ne seront pas pris en compte. La longueur mesurée $L(\eta)$ de la côte sera donc plus petite. Par contre, plus la longueur de la jauge est petite, plus celle-ci pourra représenter les petits détails qui constituent la côte et par conséquent $L(\eta)$ sera plus grande.

Dans de nombreux cas nous obtenons une représentation linéaire de $N(\eta)$ en fonction de η suivant une échelle logarithmique :

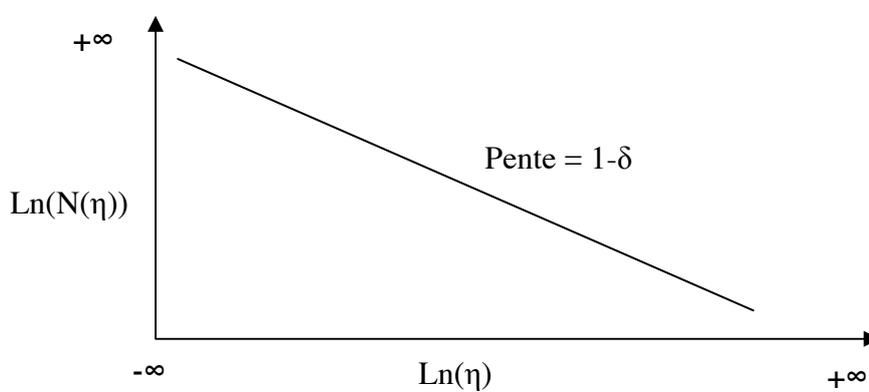


Figure 9.8 : Exemple simplifié d'un graphe d'évolution

Cette courbe est appelée graphe d'évolution. Sa pente représente la complexité de l'ensemble étudié. En effet, la variation de η entraîne une mesure différente de $L(\eta)$. C'est cette pente qui nous permet de trouver la dimension fractale de la courbe. La dimension fractale est égale à $\delta = 1 - \text{pente}$.

Construction du graphe d'évolution

Le graphe d'évolution va nous permettre de calculer la dimension fractale, la dimension secondaire et l'indice d'implication. Il est donc important de le construire avec précision de manière à avoir des résultats les plus corrects possibles. Nous choisissons d'étudier l'aire de la signature en fonction de l'échelle d'observation.

La première étape consiste à extraire les contours de la signature. Cette étape nous permet de ne pas traiter le « trait » définissant la signature mais les contours de ce trait. Nous utilisons pour cela la méthode décrite précédemment pour extraire les contours « classiques ». Cela complique quelque peu le calcul de la dimension fractale, nous le verrons dans l'étude du graphe d'évolution, mais évite d'autre part certains inconvénients.

Les dilatations successives de l'image constituent le point de départ de la construction du graphe d'évolution. Afin d'avoir un graphe d'évolution complet, il faut effectuer des dilatations jusqu'à ce que l'image soit totalement noyée, c'est à dire qu'elle ressemble à une « tache » noire.

A chaque dilatation, nous calculerons le nombre de pixels noirs dans l'image. Ainsi nous pourrons analyser de quelle façon l'image se modifie. Le principe de base de la dilatation est simple, il faut parcourir l'image pixel par pixel et agir suivant la couleur du pixel : si le pixel est blanc : ne rien faire ; si le pixel est noir : noircir ses voisins immédiats.

La construction du graphe se fait ensuite comme décrit dans [Boulétreau97]. A chaque dilatation d'ordre n , nous associons un point de coordonnées $\{\ln(n), \ln(A(X_n))\}$. $A(X_n)$ étant l'aire de la dilatation de la signature, à l'itération n . Elle est représentée par le nombre de pixels noirs de l'image.

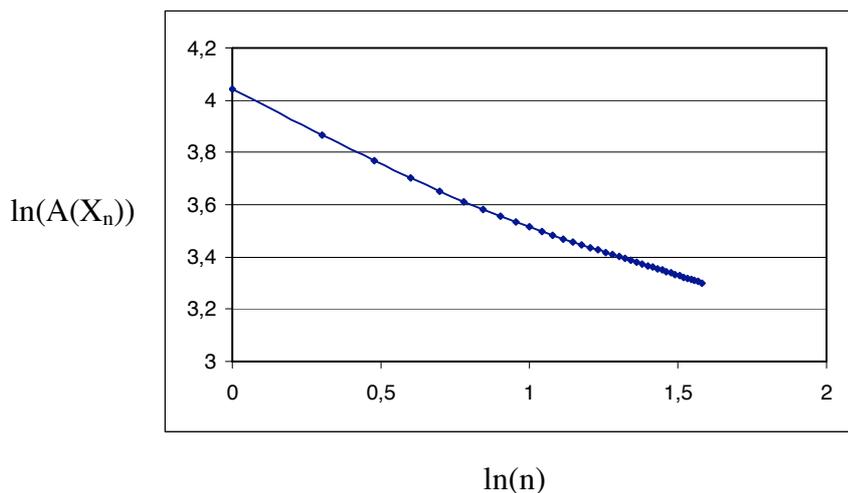


Figure 9.9 : Exemple de graphe d'évolution

Ré-échantillonnage

Le graphe d'évolution est défini par des points qui sont espacés suivant une distribution logarithmique. Dans la suite de la méthode de détermination de la dimension fractale, nous devons pouvoir trouver des droites de régression correspondant à des parties du graphe. Mais le calcul de ces droites de régression par la méthode des moindres carrés risque d'être faussé par la répartition des points. Il faut donc procéder à un rééchantillonnage qui nous permettra d'avoir des points bien répartis sur l'ensemble du graphe.

Après avoir défini un pas p qui représentera l'intervalle entre deux abscisses de points sur le nouveau graphe, nous parcourons l'ensemble de l'axe des abscisses en partant de 0 et

en avançant à chaque fois d'un pas p . L'ordonnée correspondant à cette abscisse $x_{\text{re-ech}}$ est calculée par interpolation linéaire. Finalement, nous obtenons un graphe ré-échantillonné utilisable pour l'analyse suivante.

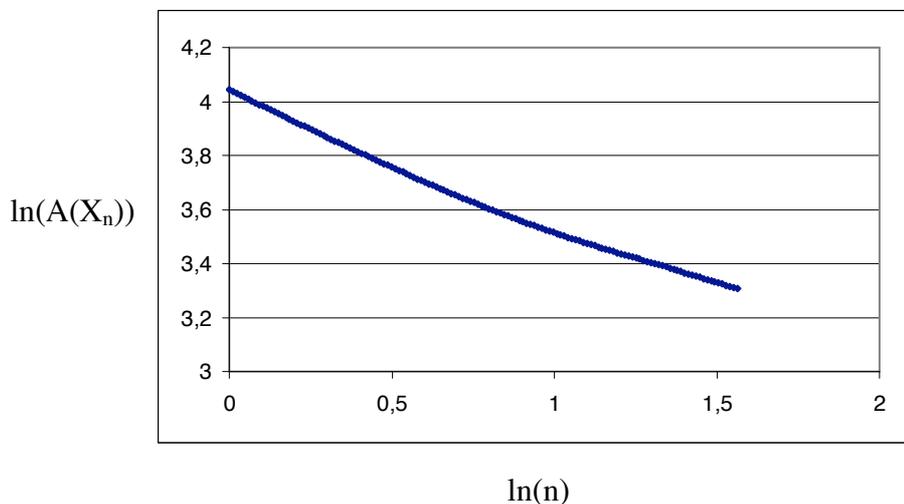


Figure 9.10 : Graphe ré échantillonné correspondant au graphe précédent

Analyse du graphe d'évolution

Le graphe d'évolution est composé de trois zones, chacune correspondant à un effet des dilatations sur l'image de la signature.

Zone 0 : cette zone correspond aux 3 ou 4 premières dilatations de l'image. Elle correspond au remplissage du contour de la signature. Le nombre de dilatations nécessaires pour cette zone est relativement stable car il dépend de la résolution et de l'épaisseur du trait. Etant donné que toutes les signatures ont été réalisées avec un stylo du même type et scannées à une même résolution, l'influence de cette zone n'est pas réellement significative. En effet, elle donne un indice sur la forme de la signature à l'échelle de l'épaisseur du trait. Nous pourrions comparer cet indice à une observation de la signature de « très près », sans pouvoir distinguer sa forme générale. Cette zone ne sera donc pas prise en compte dans la suite du traitement.

Zone 1 : celle-ci correspond aux dilatations suivant le remplissage du contour. Elle est par conséquent plus intéressante à étudier. En effet elle correspond à une étude de la signature vue à une distance de lecture « normale ». C'est cette zone qui nous permettra de déterminer la dimension fractale de l'écriture car elle renseigne sur l'allure générale de la signature. La dimension fractale nous donne un indice sur la « lisibilité » de la signature.

Zone 2 : cette dernière zone a une pente légèrement différente de celle de la zone 1. Elle correspond à des dilatations d'ordre assez élevé quand la signature commence à être « noyée ». Par conséquent, elle traduit l'observation de la signature à une distance assez grande pour qu'on ne puisse plus distinguer les petits détails de la signature mais en discerner une vague allure générale. Cette zone nous servira à définir la dimension fractale secondaire de la signature. Elle nous indiquera si la signature est encore « lisible » à une plus grande distance.

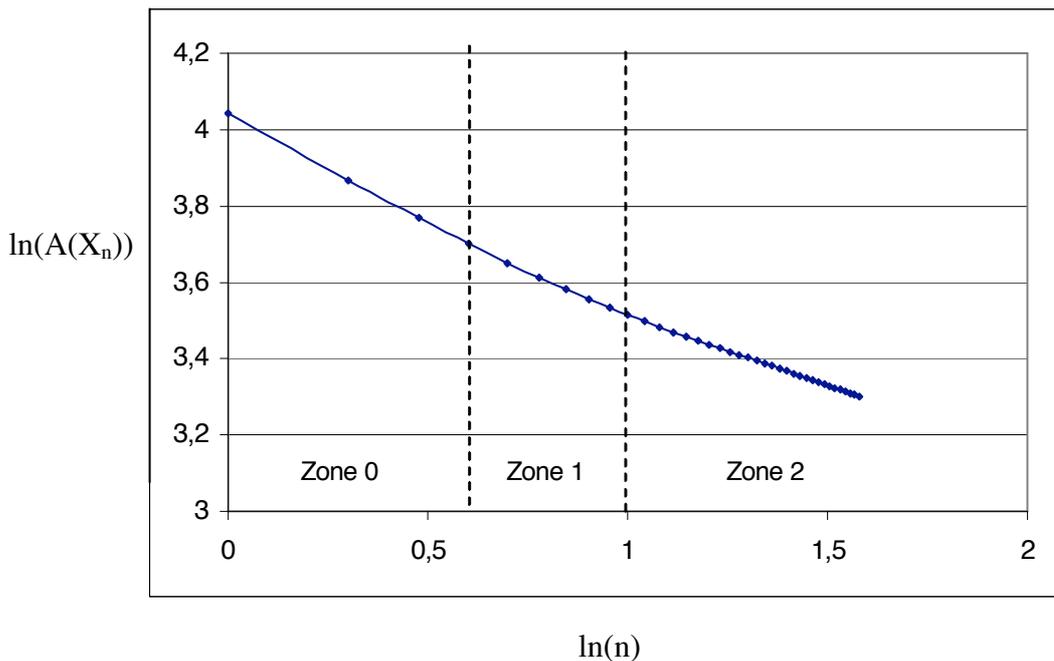


Figure 9.11 : Définition des zones du graphe d'évolution.

Comme nous l'avons précisé, la zone 0 ne nous sert pas. Elle peut être éliminée assez facilement. Elle concerne en effet les 3 ou 4 premières dilatations. Nous considérerons donc que la zone 1 commence à la 5^{ème} dilatation.

Il faut maintenant séparer les zones 1 et 2. Plusieurs méthodes existent [Boulétreau97], nous avons opté pour une méthode assez simple, rapide et présentant des résultats satisfaisants. Nous cherchons le point de la courbe rééchantillonnée qui est le plus éloigné de la droite passant par le premier point de la zone 1 et le dernier de la zone 2.

Calcul des différents paramètres

Les zones trouvées vont nous permettre de calculer la dimension fractale. Pour ce faire, nous devons calculer les équations des droites de régression associées aux points de la zone 1 puis de la zone 2 (en nous basant sur les points rééchantillonnés).

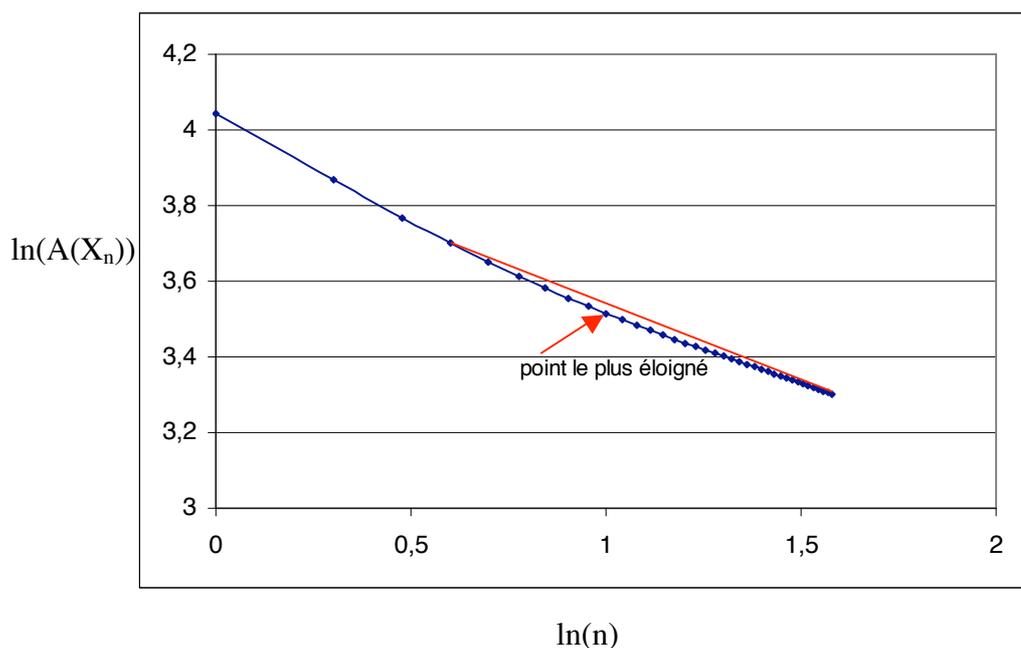


Figure 9.12 : Recherche de la frontière entre les zones 1 et 2

Nous trouvons donc les équations $y_1(x) = p_1(x) + b_1$ et $y_2(x) = p_2(x) + b_2$. C'est en particulier les pentes p_1 et p_2 qui nous intéressent car elles représentent l'évolution du graphe pour les dilatations successives.

Nous pouvons maintenant déterminer la dimension fractale, la dimension secondaire et l'indice d'implication. La dimension fractale DF1 est égale à $1 - p_1$. Elle mesure la complexité de l'écriture à une échelle d'observation normale. Une écriture mal formée aura une dimension fractale faible, alors qu'une écriture plus cursive aura une dimension fractale plus élevée. Une signature très enjolivée avec des boucles aura une dimension fractale très élevée, tout en restant dans l'intervalle $[1,2]$.

De même, la dimension fractale secondaire DF2 est égale à $1 - p_2$. Elle correspond, comme la dimension fractale, à la complexité de l'écriture mais vue de plus loin. Les détails ne sont alors pas tous visibles. Ce paramètre est évidemment lié à la dimension fractale, mais permet une autre appréciation de la complexité de l'écriture.

Finalement, l'indice d'implication Delta est égal à $DF1 - DF2$. Cet indice permet de mesurer l'application du scripteur. En effet, si ce dernier s'applique à bien libeller sa signature, la complexité doit être semblable quelle que soit l'échelle d'observation. Par conséquent un Delta proche de 0 indiquera une signature appliquée alors qu'un Delta plus éloigné de 0 traduira une signature moins bien formée.

9.6.3.2.4 La dimension fractale locale et l'extraction de zones rugueuses

La dimension fractale locale se démarque de la dimension fractale au sens classique. En effet le calcul de la dimension fractale, dans le cas de l'analyse d'image, s'intéresse généralement à la globalité d'une image. Elle indique ainsi le degré d'irrégularité de l'image. Cependant, il est aussi possible de mesurer l'irrégularité sur une partie de l'image seulement [Beaves95]. Cette approche rejoint les études sur les exposants de Hölder. Nous avons préféré garder une unité à notre approche.

Nous nous intéresserons donc à la dimension fractale du voisinage de chaque pixel d'une image de signature. Nous en déduirons une dimension fractale locale pour chaque pixel. La définition d'un seuil nous permettra ensuite d'extraire les pixels ayant une dimension fractale locale révélant une forte irrégularité locale.

Calcul de la dimension fractale locale

Parmi les nombreuses méthodes de calcul de la dimension fractale, nous avons choisi celle proposée par [Beaves95], qui permet une analyse de l'image relativement rapide. Cette méthode permet de détecter les parties rugueuses ou inégales de l'image. Une surface régulière aura une dimension fractale de valeur 2 alors qu'une surface très rugueuse aura une dimension fractale se rapprochant de 3.

Ce procédé est destiné à des images en 256 niveaux de gris, ce qui ne nous pose pas de problème car nos images sont en noir et blanc. Les pixels blancs se voient donc attribués une valeur de 255 et les pixels noirs une valeur de 0. Le calcul est effectué pour chaque pixel de l'image. Pour chaque pixel le calcul s'effectue sur une matrice M de dimension 16×16 entourant le pixel (ce dernier ayant les coordonnées (9,9) dans la matrice).

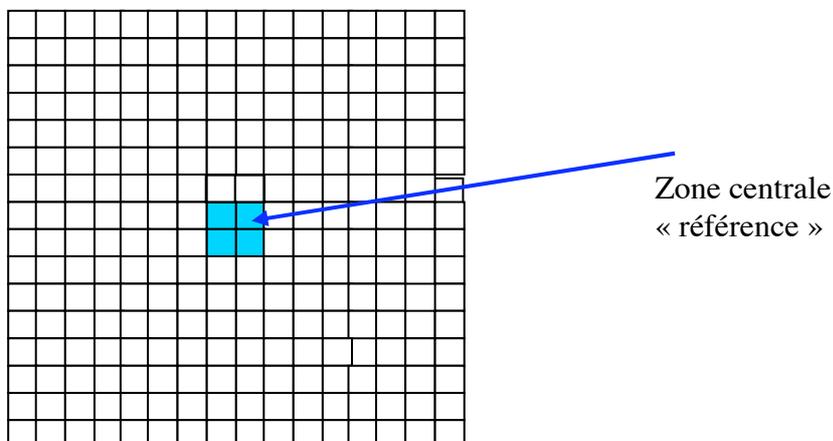


Figure 9.13 : Représentation de la matrice d'analyse M et de la zone de référence.

Nous allons étudier l'ensemble la matrice en la comparant à son centre, qui ne sera pas seulement représenté par le point de coordonnées (9,9), mais par les quatre pixels centraux de l'image (de coordonnées (8,8), (8,9), (9,8) et (9,9)). La moyenne des valeurs en niveaux de gris de ces quatre points sera utilisée comme référence.

Tout d'abord nous calculons l'écart maximum Δ qui existe entre chaque point de la matrice et la valeur moyenne de la zone centrale. La suite du calcul dépend de la valeur de cet écart maximum. Celui-ci est comparé à un seuil epsilon fixé. Deux cas peuvent se produire ensuite :

L'écart maximum Δ est petit (inférieur ou égal à epsilon) : cela signifie que les valeurs de la matrice sont suffisamment proches et que la zone de l'image étudiée est assez régulière. Dans ce cas, nous ne poursuivons pas les calculs pour cette matrice et la dimension fractale locale est fixée à la valeur 2.

L'écart maximum Δ est grand (supérieur à epsilon) : la zone étudiée est irrégulière, il est donc nécessaire de mesurer son irrégularité. Afin de simplifier l'étude, nous créons une matrice d'écart échantillonnée M' prenant ses valeurs entre -8 et 8 . Chaque valeur $M'(i,j)$ est calculée comme suit :

$$M'(i,j) = 8 \times \frac{M(i,j) - \bar{M}}{\Delta} \quad (9.8)$$

Nous utilisons la méthode « Box counting » pour analyser la matrice M' . Cette méthode utilise différentes sous-matrices carrées de tailles 2×2 , 4×4 et 8×8 et leur associe une valeur. Les différentes valeurs nous permettront ensuite de calculer la dimension fractale locale.

Intéressons nous d'abord aux sous-matrices 2×2 . Toutes les sous-matrices 2×2 de la matrice M' sont analysées afin de calculer une valeur N_8 (il y a 4 sous-matrices de dimension 2×2). Nous cherchons pour cela les valeurs minimum et maximum de chaque sous-matrice. N_8 est égal à la somme globale des valeurs de la fonction f suivantes :

Si $\text{Max} = 0$, alors $f(.) = 1$,

Si $\text{Max} \in]2(k-1), 2k]$ avec $k \in \{1,2,3,4\}$, alors $f(.) = k$,

Si $\text{Min} \in]-2k, -2(k-1)]$ avec $k \in \{1,2,3,4\}$, alors $f(.) = k$.

Ensuite, nous traitons les sous-matrices 4×4 . Nous procédons d'une manière similaire. Toutes les sous-matrices 4×4 de M' sont parcourues afin de calculer une valeur de somme globale N_4 (ici, il y a 2 sous-matrices à analyser). Après que le minimum et le maximum de chaque sous-matrice soient calculés, la fonction prend les valeurs suivantes :

Si $\text{Max} = 0$, alors $f(.)=1$,

Si $\text{Max} \in]4(k-1), 4k]$ avec $k \in \{1,2\}$, alors $f(.) = k$,

Si $\text{Min} \in]-4k, -4(k-1)]$ avec $k \in \{1,2\}$, alors $f(.) = k$.

Nous procédons maintenant de la même manière pour analyser les sous-matrices 8×8 afin de calculer la valeur de somme globale N_2 . La fonction prend les valeurs :

Si $\text{Max} \in [0,8]$, alors $f(.) = 1$,

Si $\text{Min} \in]-8,0]$, alors $f(.) = 1$.

Les trois variables vont nous permettre de calculer la dimension fractale locale grâce à la formule suivante :

$$DF_{\text{Loc}} = \frac{3\ln(N_8) + \ln(N_4) - \ln(N_2)}{10\ln(2)} \quad (9.9)$$

En appliquant cette méthode à l'ensemble de l'image, nous associons une dimension fractale locale à chaque pixel. Nous pouvons ainsi connaître les zones très irrégulières qui représentent les contours de la signature.

Application à l'extraction de zones rugueuses

Chaque pixel de l'image se voit attribué une valeur indiquant l'irrégularité de son voisinage. Afin d'extraire les contours de la signature dont l'irrégularité est forte, nous utilisons un seuil.

Tout d'abord nous cherchons la valeur de dimension fractale locale la plus élevée : $DF_{\text{Loc_Max}}$. Ensuite, comme nous voulons extraire les pixels des zones irrégulières, nous devons choisir les pixels dont la dimension fractale est proche de $DF_{\text{Loc_Max}}$. Après plusieurs tests, nous nous sommes aperçu que pour avoir les contours correctement extraits, il fallait garder les pixels dont la dimension fractale locale était supérieure ou égale à $0,956 \times DF_{\text{Loc_Max}}$.

Il est possible d'extraire des zones plus irrégulières que les contours dans une image de signature. En effet, cela serait plus utile à notre étude car nous avons déjà une méthode pour extraire les contours. En augmentant le seuil de détection à $0,975 \times DF_{\text{Loc_Max}}$, par exemple, nous obtenons un nombre inférieur de zones. Celles-ci correspondent généralement aux zones d'intersection entre des traits. A partir de la même signature que celle présentée auparavant, la figure 9.14 présente le résultat obtenu.

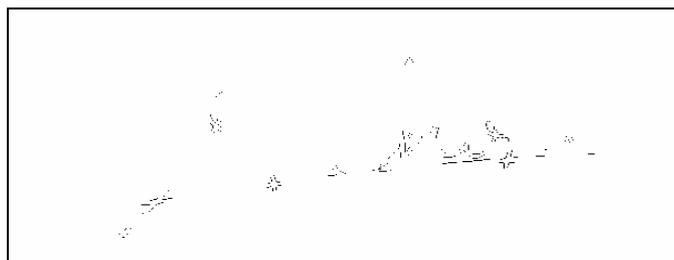


Figure 9.14 : Exemple d'extraction de zones rugueuses, seuil = $0.975 \times \text{DFLoc_Max}$.

Il peut être intéressant d'utiliser comme paramètre pour notre classifieur la proportion de ces zones par rapport à la surface totale de la signature. En effet le nombre d'intersections varie suivant les signatures et reste globalement le même pour une même personne.

9.6.3.2.5 La dimension de masse

Ce paramètre permet de mesurer la répartition des pixels définissant l'écriture. Sa méthode de calcul est relativement simple. Nous sélectionnons d'abord un certain nombre de points appartenant à la signature. Nous choisissons de tirer aléatoirement 10 % des points de la signature. Nous allons ensuite calculer la dimension de masse en étudiant chaque point sélectionné. Pour cela, nous observons le voisinage du point. Nous calculons le nombre de pixels noirs (appartenant donc au trait de la signature) dans des voisinages de diamètres 3, 5, 7, etc.

Nous obtenons 3 valeurs par exemple correspondant aux nombres de pixels : nb_pix_v3 , nb_pix_v5 et nb_pix_v7 etc. Ces valeurs vont nous permettre de constituer un graphe.

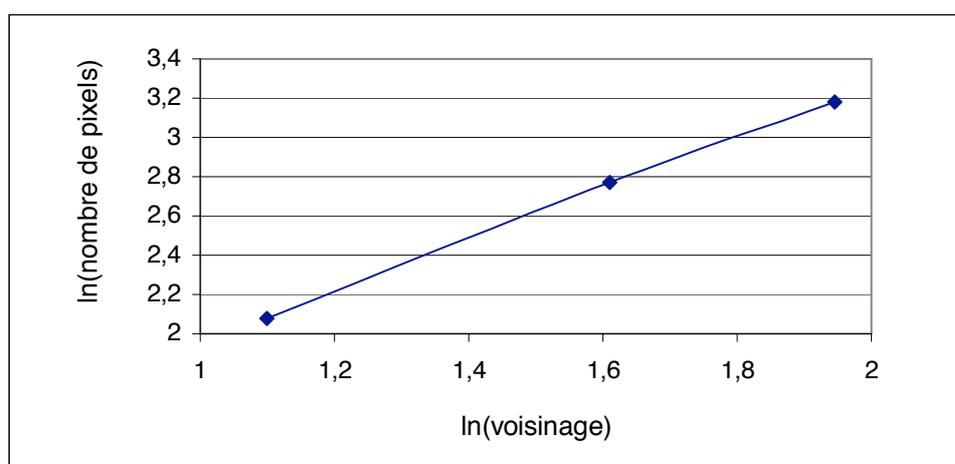


Figure 9.15 : Exemple de graphe de dimension de masse.

Nous constatons que ces trois points sont relativement alignés dans un repère logarithmique et peuvent définir une droite. Nous cherchons alors l'équation de la droite de régression de ce graphe. Le calcul nous donne une équation du type : $y(x) = ax + b$ où la pente a est la dimension de masse associée au point étudié. Ainsi en répétant cette méthode sur $1/10^{\text{ème}}$ des points de la signature nous obtenons une série de n valeurs a_1 à a_n .

La moyenne A de ces valeurs ($A = \frac{1}{n} \sum_{i=1}^n a_i$) nous donne une approximation de la dimension de masse de la signature. Bien sûr, la valeur serait un peu plus affinée si la méthode était appliquée à l'ensemble des points de la signature. Cependant, le tirage aléatoire des points dans la signature nous laisse penser qu'ils seront suffisamment bien placés à différents endroits de la signature. La dimension fractale est étudiée pour la classification de signatures dans [Boulétreau97]. Cependant, ce paramètre semble insuffisant. Il est donc proposé d'utiliser la dimension de masse qui serait assez complémentaire de la dimension fractale. Nous nous servons donc de ce paramètre pour notre classifieur.

9.7 Classement

Les classifieurs de distance et plus précisément le concept du classifieur des k -ppv ont été utilisés pour la classification des signatures comme nous avons écrit dans le chapitre précédent. D'après l'évaluation des performances de chaque primitive, nous avons établi les 4 classifieurs suivants :

Un classifieur à base des histogrammes horizontaux.

Un classifieur à base des histogrammes verticaux.

Un classifieur à base des histogrammes selon l'axe principal d'inertie.

Un classifieur géométrique et fractal prenant en compte les paramètres suivants :

La proportion : *Contours classiques* / *Longueur de la signature*,

La proportion : *Contours extérieurs* / *Longueur de la signature*,

La pente de la signature,

La dimension fractale,

L'indice d'implication,

La proportion : *Zones irrégulières* / *Longueur de la signature*,

La dimension de masse.

L'histogramme des signatures selon l'axe secondaire de l'ellipse d'inertie (axe 2) prend du temps beaucoup plus que celui d'une projection selon l'axe horizontal ou vertical mais

bien sûr égal à celui de la projection selon l'axe principal de l'ellipse d'inertie mais il a donné de mauvais résultats de classification par rapport aux autres. C'est pourquoi nous ne l'avons pas pris en compte pour établir un classifieur.

Afin d'avoir un classifieur offrant d'assez bons résultats, nous utilisons l'ensemble des dimensions fractales et des paramètres géométriques. En effet, l'utilisation individuelle de chaque paramètre pour la classification ne peut que donner de mauvais résultats car les informations sont trop partielles.

9.8 Les bases de données

Dans le cadre de l'expérimentation menée dans notre étude, nous avons utilisé deux bases de données différentes. La première base de données a été créée par nous même et elle a été employée pour étudier plusieurs méthodes de fusion dans le cas d'identification. Pour un système de vérification, nous avons besoin de fausses signatures imitées par des imposteurs.

Dans la littérature, beaucoup d'études incorporent des faux simulés non sérieux, et dans quelques cas rares des faux vraiment simulés sont employés. Les définitions de toutes ces terminologies, imitations aléatoires, simulé par expert, et simulé simple, sont véritablement discrétionnaires et changent énormément d'un benchmark à l'autre aussi bien que d'une équipe de recherche à l'autre. En plus, la meilleure solution serait de pouvoir évaluer des systèmes travaillant sur une base de données commune. Malheureusement, en raison des problèmes de confidentialité et aussi du coût important lié à la saisie des données, une base de données commune est peut être très difficile à gérer. Heureusement, une équipe de recherche espagnole a mis en œuvre une base de données de vraies et fausses signatures sur le web. Nous avons utilisé cette base de données par souci de comparaison.

9.8.1 La première base de données

Pour montrer l'intérêt de la fusion de données, nous avons créé notre propre base de données consistant en 525 images réelles de signatures obtenues auprès de 35 personnes qui ont signé chacune une quinzaine de fois. La saisie des signatures est réalisée en « off-line ». Les signataires doivent signer sur une feuille blanche ce qui diminue le bruit, dans des cadres limitant les variations de taille (les cadres sont des rectangles de taille 9,5x3,5 cm). Les signatures sont obtenues dans une seule session avec un stylo fourni aux signataires. Ensuite les signatures sont numérisées en noir et blanc avec un scanner. La résolution choisie pour l'image est de 300 ppp (pixels par pouce). Cette résolution offre une bonne précision sur la forme de la signature sans être trop élevée, ce qui allongerait le temps d'exécution des

différentes analyses d'images que nous effectuerons. Cette base de données a été utilisée pour l'identification et pour servir de faux aléatoires dans la phase de vérification.

9.8.2 La deuxième base de données

La deuxième base de données de signatures utilisée dans nos expériences a été téléchargée d'un site Web [Demos], qui contient des données de 39 individus : 24 signatures vraies pour chaque individu, plus 30 faux de sa signature. Les signataires ont signé sur du papier blanc dans des cadres de deux tailles différentes (les uns de 2,5×5,5 centimètres et l'autre moitié de 3,5×5 centimètres). Les 24 vrais spécimens de chaque signataire ont été obtenus en sessions d'écriture pendant une seule journée. Les faux ont été produits à partir de l'image statique de la vraie signature. Chaque imposteur volontaire a pris son temps pour pratiquer la signature autant de fois que nécessaire pour obtenir des graphies satisfaisantes. Un volontaire a imité 3 fois les signatures de 5 signataires en sessions d'écriture pendant la journée. La vraie signature montrée à chaque imposteur est choisie aléatoirement parmi les 24 vraies. Par conséquent pour chaque vraie signature il y a 30 faux simulés faits par 10 imposteurs à partir de 10 vrais spécimens différents. À l'étape finale, les pages de signatures ont été scannées avec une résolution basse d'environ 70-80 dpi et un prétraitement (élimination de bruit, correction de l'inclinaison, séparation, centrage et réduction des images) a été effectué. Nous avons employé cette base de données prétraitée dans le but de comparer les résultats de la tâche de vérification.

9.9 Résultats expérimentaux

9.9.1 Identification des signatures

Pour réaliser un système d'identification des signatures, nous avons étudié plusieurs méthodes de fusion et différentes combinaisons de nos quatre classifieurs. La performance de chaque classifieur a été calculée individuellement (tableau 9.2) tout d'abord pour souligner l'amélioration de la qualité du système global par rapport à celle de chaque classifieur. La performance des systèmes en fusionnant plusieurs classifieurs a été certainement améliorée en réalisant la fusion à plusieurs niveaux. Les méthodes étudiées sont : la théorie de l'évidence de Dempster-Shafer, la théorie des possibilités, l'approche bayésienne, les chaînes de Markov Cachées (CMC), la règle de vote à la majorité, La méthode de Borda Count, les opérateurs d'agrégation OWA, AWFO, le formalisme flou proposé. Les résultats obtenus avec la première base de données par ces méthodes sont montrés dans le tableau 9.3.

Tableau 9.2

(a): Performance de nos 4 classifieurs d'après la règle des k-ppv avec vote à la majorité

Classifieur	Taux de reconnaissance (TL) (%)				
	1-ppv	3-ppv	5-ppv	10-ppv	15-ppv
Histogramme Horizontal (e1)	73,3	70,8	67,9	62	58,7
Histogramme Vertical (e2)	53,2	56,0	55,8	50,1	49,4
Histogramme selon l'axe d'inertie (e3)	78,3	74,8	71,8	67,8	63,7
Fractale + Géométrie (e4)	68,9	69,4	69,3	65,7	65,1

(b) : Performance de ces classifieurs d'après la règle des k-ppv floue proposée.

Classifieur	Taux de reconnaissance (TL) (%)				
	1-ppv	3-ppv	5-ppv	10-ppv	15-ppv
Histogramme Horizontal (e1)	73,3	74,4	72,5	71,6	70,5
Histogramme Vertical (e2)	53,2	56,2	56,6	53,5	54,5
Histogramme selon l'axe d'inertie (e3)	78,3	76,1	77,3	77,5	78,6
Fractale + Géométrie (e4)	68,9	70	71,1	72,1	70,6

(c) : Un résultat montrant pourquoi la règle des k-ppv avec vote a des performances faibles quand les valeurs du k sont élevées ($k = 10$) dont $x \in C_{15}$.

k-ppv	Classe	$d(x, x_i)$	$f_x(x_i)$	Décision
1	C_{15}	0,8775	0,7737	D'après la règle des k-ppv floue proposée : $x \in C_{15}$ pour k égal à 1-10 (toujours la bonne décision). D'après la règle des k-ppv avec vote, pour k égal à 1-6, $x \in C_{15}$: bonnes décisions mais pour $k = 7-10$, $x \in C_7$: mauvaise décision.
2	C_{15}	0,9219	0,6735	
3	C_7	0,9243	0,7545	
4	C_{15}	0,9502	0,5548	
5	C_7	0,9600	0,6788	
6	C_7	0,9840	0,6487	
7	C_7	0,9847	0,6217	
8	C_9	0,9869	0,1986	
9	C_7	0,9939	0,5767	
10	C_7	1	0,5575	

L'observation du tableau 9.2 (a) indique que la meilleure performance des classifieurs est obtenue en général pour $k = 1$ avec la règle des k-ppv. Par contre, avec la règle des k-ppv floue proposée, les performances sont peu variées (tableau 9.2 b) et même elles sont

améliorées en augmentant la valeur de k dans l'intervalle de (1-15). Voici un exemple du résultat (tableau 9.2 c) pour montrer pourquoi les résultats obtenus avec la règle de vote à la majorité sont diminués par rapport la règle des k -ppv floue proposée en augmentant la valeur du k .

Tableau 9.3: La performance de plusieurs méthodes de fusion de données.

No.	Méthodes de fusion	Taux de bonne classification %		
		2 classifieurs	3 classifieurs	4 classifieurs
1	La théorie de l'évidence de D-S	90,1	94,3	95,3
2	La théorie des possibilités T-norme		91,4	87,1
	T-conorme		82,3	73,1
	Opérateur adaptatif		91,6	93,9
3	L'approche bayésienne (matrice de confusion)	93,2	95,4	95,6
4	La méthode de comptage de Borda	87,8	94,1	95,4
5	La règle de vote à la majorité (i) avec un seuil de $\lambda \geq 0,5$ (ii) avec la pondération des classifieurs		78,9	85,8
				87,6
6	Chaîne de Markov Cachée (CMC)			90,0
7	Ordered Weighted Aggregator (OWA)			98,3
8	AWFO			98,7
9	Le formalisme flou proposé ($\gamma = 1-1,05$)	91,6	96,4	97,0

L'influence du nombre de classifieurs

Tout d'abord, nous avons étudié le nombre de classifieurs à fusionner. Nous avons fusionné les deux meilleurs classifieurs, ensuite les trois meilleurs classifieurs et finalement tous les classifieurs avec différentes méthodes de fusion. La robustesse du système a été la meilleure avec les quatre classifieurs.

Les méthodes de fusion

Pour la fusion au niveau de la décision nous avons appliqué l'approche bayésienne et la règle du vote à la majorité avec et sans pondération des classifieurs. Pour la fusion au niveau des rangs et de la représentation, nous avons étudié la fusion avec l'influence de k dans l'intervalle de 1 à 15. Pour la fusion au niveau des rangs, nous avons étudié la méthode de Borda Count et la méthode des Chaînes de Markov Cachées. Pour la fusion au niveau de

représentation, nous avons mis en œuvre la théorie de l'évidence de Dempster-Shafer, la théorie des possibilités, l'opérateur OWA, AWFO, et le formalisme flou proposé.

L'approche bayésienne a été employée pour fusionner les décisions des classifieurs à l'aide de la matrice de confusion fournie par chaque classifieur. En utilisant les informations plus nombreuses, cette approche a donné une performance modérée.

La règle du vote à la majorité prend la décision finale parmi les quatre réponses de nos quatre classifieurs soit en fixant un seuil si deux ou plus que deux classifieurs ($\lambda \geq 0,5$) sont d'accord parmi les quatre classifieurs soit avec la pondération des classifieurs. Dans les deux cas, cette approche a donné une efficacité moins performante car nous avons noté qu'il y avait beaucoup de cas d'ambiguïté, il y a donc beaucoup de rejets. C'est pour cela que le taux de bonne classification est diminué. Avec la pondération des classifieurs, les problèmes d'ambiguïté ont été résolus mais l'amélioration des résultats n'est pas significative.

La méthode de Borda Count a été étudiée en faisant varier le k dans l'intervalle entre 1 et 15. Le résultat indiqué dans le tableau 9.3 est la meilleure performance de cette méthode dans cet intervalle de k. Avec cette méthode aussi, quand k était égal à 1-3, il y avait des ambiguïtés qui ont baissé la robustesse de cette méthode. Il semble que la méthode doit être considérée à partir de k supérieur à 3.

Pour l'approche par **Chaîne de Markov Cachée**, en faisant varier k, un des meilleurs résultats de l'algorithme est cité dans le tableau 9.3.

La théorie de l'évidence de Dempster-Shafer est étudiée pour réaliser la fusion au niveau de la représentation en faisant varier le k entre 1 et 15. La décision concernant la classe d'une forme entrante a été prise en fonction du maximum de plausibilité. En cas de conflit des sources d'information, il y a plusieurs propositions qui sont faites dans la littérature, nous n'avons pas étudié ces propositions mais choisi d'augmenter la valeur de k pour lever l'ambiguïté, si par exemple, avec k égal à 3 ou 4 il y a un conflit total des classifieurs (i.e. $K = 1$), nous avons continué de chercher une décision avec k égal à 5 ou 6 ou jusqu'au 15. Si le conflit persiste avec k égal à 15, la décision prise a été le rejet.

La théorie des possibilités a été étudiée avec l'aide de 3 opérateurs, T-norme, T-conorme, et la règle adaptative présentée par Dubois et Prade [Dubois88]. Les résultats obtenus avec ces trois opérateurs sont indiqués dans le tableau 9.3. Ces résultats soulignent l'importance d'un raisonnement ni optimiste ni pessimiste mais plutôt entre les deux réalisé par l'opérateur adaptatif.

L'opérateur OWA peut avoir deux comportements selon la situation et le choix du décideur ; ce sont un comportement *or-like* ou bien *and-like*. Ces deux notions représentent la

notion du degré de risque qui influence sur la décision finale. Comme déjà présenté dans le deuxième chapitre et comme mentionné dans [Carlesson97] les poids sont calculés par la relation : $w_i = Q(i/n) - Q(i-1/n)$ avec Q un quantificateur linguistique. $Q_\alpha(r) = r^\alpha/\alpha \geq 0$. Dans notre cas, afin de minimiser le risque, nous avons choisi un comportement andlike s'éloignant d'un comportement orlike (soit $Q_\alpha < 0,5$) ce qui nous a imposé de choisir $\alpha > 1$, aussi conseillé par [Kelman95]. Nous avons également étudié l'influence de la normalisation des distances fournies par chacun des classifieurs par deux approches différentes (division de distances $d(x, x_i)$ par le maximum des distances et par une autre formule. Dans ce dernier cas, la distance normalisée est égale à :

$$\frac{d(x, x_i) - \text{Min}(d(x, x_i))}{\text{Max}(d(x, x_i)) - \text{Min}(d(x, x_i))} \quad (9.10)$$

Le dernier point important que nous avons étudié a été la valeur de k définissant les k -ppv, les k -ppv de chaque classifieur mais aussi les k -ppv par rapport à chaque classe. Quelques résultats intéressants obtenus en prenant en compte ces trois aspects de notre étude sont indiqués dans les tableaux 9.4 (a), (b), (c) et (d).

Tableau 9.4

(a) : Performance de OWA avec différentes valeurs de α et k -ppv par classe, et la normalisation des distances réalisée par la max de distance

α	Taux de bonne classification %			
	1-ppv	5-ppv	10-ppv	15-ppv
1,1	98,3	97,7	94,1	90,5
1,2	98,3	97,7	93,7	89,5
1,5	98,3	95,6	92,7	87,2

(b) : Performance de OWA avec différentes valeurs de α et k -ppv par classe, et la normalisation des distances réalisée par la formule (Equation (9.10))

α	Taux de bonne classification %			
	1-ppv	5-ppv	10-ppv	15-ppv
1,1	98,1	97,1	93,5	89,9
1,2	98,0	97,3	93,3	89,5
1,5	98,0	96,7	92,7	87,2

(c) : Performance de OWA avec différentes valeurs de α et k-ppv du classifieur, et la normalisation des distances réalisée par la max de distance

α	Taux de bonne classification %			
	1-ppv	5-ppv	10-ppv	15-ppv
1,1	88,4	93,5	92,7	93,9
1,2	88,4	93,5	92,7	93,9
1,5	88,4	93,5	92,9	93,9

(d) : Performance de OWA avec différentes valeurs de α et k-ppv du classifieur, et la normalisation des distances réalisée par la formule (Equation (9.10))

α	Taux de bonne classification %			
	1-ppv	5-ppv	10-ppv	15-ppv
1,1	85,5	95,0	92,9	94,3
1,2	85,5	95,0	92,5	94,3
1,5	85,5	95,0	92,9	94,3

Nous remarquons dans ces tableaux (9.4 (a,b,c,d)) que les résultats obtenus sont les meilleurs en considérant les k-ppv par rapport à chaque classe et sont légèrement mieux avec normalisation des distances en les divisant par le maximum de distances. Un des meilleurs résultats obtenus par cet opérateur est indiqué dans le tableau 9.3.

Pour l'opérateur **AWFO**, nous avons étudié deux comportements du raisonnement, pessimiste et optimiste. En utilisant un comportement optimiste nous avons obtenu les meilleurs résultats, nous avons choisi une fonction h croissante. Ici, nous avons étudié deux cas. Dans le premier cas les k-plus proches voisins d'une signature entrante fournis par chaque classifieur sont utilisés. Dans le deuxième cas, chaque classifieur fournit les k-plus proches voisins pour chaque classe C_i ($i = 1$ à M) ici M représente le nombre total des classes (personnes). Les résultats obtenus montrent une amélioration de la reconnaissance des signatures manuscrites plus évidente dans la deuxième configuration comme l'opérateur OWA. C'est-à-dire que la fusion avec une information égale (sélection du nombre de représentants des signatures manuscrites de chaque classe) pour toutes les classes dans le voisinage d'une signature manuscrite entrante a amélioré la robustesse de cet opérateur. Le résultat présenté dans le tableau 9.3 est alors celui obtenu dans ce deuxième cas.

Tableau 9.5

(a) : Performance de AWFO avec différentes valeurs de k-ppv des classes, et la normalisation des distances réalisée par le max et la formule (Equation (9.10))

Normalisation	Taux de bonne classification %			
	1-ppv	5-ppv	10-ppv	15-ppv
max	98,7	97,5	94,7	89
formule	98,4	97,3	93,5	88,8

(b) : Performance de AWFO avec différentes valeurs de k-ppv du classifieur, et la normalisation des distances réalisée par le max et la formule (Equation (9.10))

Normalisation	Taux de bonne classification %			
	1-ppv	5-ppv	10-ppv	15-ppv
max	88,8	93,1	93	93,3
formule	85,8	92	92,3	94,3

La méthodologie pour mettre en œuvre **le formalisme flou proposé** pour la fusion des classifieurs a déjà été décrite dans le chapitre 6. Nous avons étudié toutes les combinaisons possibles de quatre classifieurs ; deux classifieurs différents, trois classifieurs différents et quatre classifieurs. Les résultats obtenus en faisant varier les paramètres k et γ sont indiqués en détail dans l'annexe. Ici les meilleurs résultats obtenus en fusionnant deux, trois et quatre classifieurs sont présentés dans le tableau 9.3.

9.9.2 Vérification de signatures

Pour la phase de vérification, nous avons utilisé les deux jeux de données présentés dans les sections précédentes. Tout d'abord nous avons étudié un système avec une base de signatures de faux aléatoires, c'est-à-dire la première base de données. Pour l'évaluation de notre système, nous avons utilisé la méthode de « leave-one-out ». Dans notre base de données, comme il y a 15 signatures par personne, 14 signatures sont utilisées pour l'apprentissage et la dernière est testée. Les signatures de tous les autres signataires sont aussi testées par rapport à une personne donnée.

Ici, nous avons étudié les quatre classifieurs comme dans l'étape d'identification mais nous avons noté un grand problème de performance de chaque classifieur. Les 3 classifieurs

basés sur les 3 histogrammes sont moins pertinents comme on peut le constater dans le tableau suivant :

Tableau 9.6 : les résultats obtenus par nos 4 classifieurs dans le cas de vraies et fausses signatures aléatoires :

Classifieur	Erreurs de vérification (%)	
	TVR	TFA
Fractale + Géométrique	10,00	4,83
Histogramme Horizontal	17,33	5,17
Histogramme selon l'axe principal d'inertie	14,09	5,06
Histogramme vertical	28,57	9,46
Trois histogrammes ensemble	5,52	1,91

Les résultats obtenus indiquent la pertinence du classifieur reposant sur l'ensemble des 3 histogrammes (Horizontal, Vertical, et selon l'axe principal d'inertie). Le résultat obtenu avec le classifieur basé sur la dimension fractale et quelques paramètres géométriques a été meilleur que ceux des 3 classifieurs d'histogramme, mais les résultats obtenus ne sont pas satisfaisants car les taux d'erreurs sont très élevés. En analysant les signatures des faux aléatoires acceptées, nous avons noté l'influence de la ressemblance des signatures de petite dimension par rapport aux signatures de grande dimension à cause de la normalisation. Un exemple de deux signatures différentes ayant des histogrammes horizontaux très ressemblants mais avec une grande différence de taille, est donné dans la figure 9.16 (la différence entre les tailles des images de signatures présentées est de l'ordre de 30 %) :

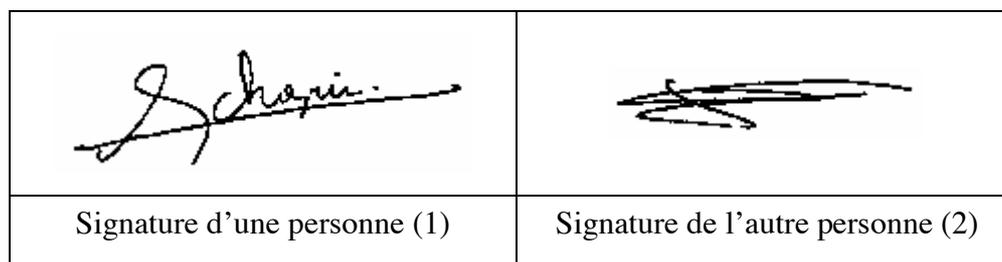


Figure 9.16 : Deux signatures ayant des dimensions différentes mais presque le même histogramme.

Nous avons donc pensé à adapter une méthodologie simple pour améliorer la performance de chaque classifieur. Le rapport entre la hauteur et la largeur d'une signature donnée est calculé. Des valeurs limite (i.e. avec une grande tolérance) ont été fixées pour

chaque signataire. Si une signature en test par rapport à une classe donnée ne passe pas ces seuils, elle est rejetée, sinon elle est traitée alors par les 4 classifieurs comme avant. Voici les résultats obtenus après mise en œuvre de ce filtre (tableau 9.7) :

Tableau 9.7 : les résultats obtenus par nos 4 classifieurs dans le cas de vraies signatures et faux aléatoires (avec $k = 1$).

Classifieur	Taux d'erreurs (%)	
	TVR	TFA
Fractale + Géométrie	5,90	3,59
Histogramme horizontal	5,90	4,06
Histogramme selon l'axe principal d'inertie	4,57	3,12
Histogramme vertical	10,67	6,54
Trois histogrammes ensemble	2,48	0,87

Tableau 9.8 : Les résultats obtenus avec la théorie de l'évidence

k-ppv	Taux d'erreurs (%)	
	TVR	TFA
3	0,76	0,58
4	0,76	0,53
5	0,76	0,48
6	0,76	0,58
7	0,95	0,65
8	1,14	0,64

Parmi $1 \leq k \leq 8$, le résultat avec un minimum des taux d'erreur est obtenu quand $k = 5$.

Nous avons fusionné ces classifieurs avec l'aide de plusieurs méthodes de fusion comme dans la phase d'identification. Pour réaliser une étude de la fusion de classifieurs, il y a des problèmes à résoudre au départ. Le plus grand problème tout d'abord est le choix des seuils, ensuite celui de la sortie de la décision des classifieurs. Pour limiter ce problème, dans un premier temps, nous avons étudié deux classifieurs, le premier, comme avant, repose sur la dimension fractale et les paramètres géométriques et le deuxième repose sur l'ensemble des

trois histogrammes. Ensuite nous avons fusionné ces deux classifieurs avec des seuils différents qui ont donné les performances différentes. Ensuite nous avons étudié les différentes valeurs de k . La variation des seuils peut se faire pour un classifieur ou pour les deux en même temps. Nous avons noté que la variation du seuil d'un seul classifieur est satisfaisante. En faisant varier le seuil d'un classifieur et en gardant celui de l'autre, les résultats obtenus dans le cas de vraies et de fausses signatures aléatoires avec la théorie de l'évidence sont montrés dans le tableau 9.8.

La deuxième base de données

Pour tester notre système avec des fausses signatures réalisées par des experts, au lieu de créer notre base de données, nous avons utilisé la base espagnole décrite dans la section précédente.

Les expérimentations ont été conduites en suivant le même protocole que les chercheurs qui ont utilisé cette base de données. Douze échantillons choisis aléatoirement parmi les vraies signatures de chaque signataire ont été employés pour l'apprentissage du système et les 12 restants pour l'évaluation. Aucune fausse signature n'est employée dans la phase d'apprentissage. Une dizaine de simulations sont effectuées pour chaque signataire et un taux d'erreur moyen a été calculé. Dans l'article de référence, les chercheurs ont indiqué l'erreur de leur système sous forme de TEE (taux d'erreur égal ou EER en anglais), ainsi, nous avons aussi calculé cette erreur. Le taux d'erreur est la moyenne (en cas de différence) entre le TFR et le TFA pour un seuil particulier avec une différence minimum possible entre eux. Les résultats obtenus sont montrés dans le tableau 9.9.

Dans l'article de référence des chercheurs espagnols, un système basé sur les SVM est proposé pour le problème de vérification de signature. Leur modèle est basé sur des caractéristiques géométriques telles que la mesure de contour (mesure des hauteurs et des largeurs du contour des images de signatures de 60 et 40 points respectivement); suivi de contour (mesure de contour des images de signatures en coordonnées polaires); le groupement de région (groupant tout d'abord le trait de signature dans les régions selon un critère de connexité (4-C), et ensuite le centre de gravité est calculé pour chaque région); et finalement un vecteur de caractéristiques à partir de l'image directe.

Contrairement aux résultats précédents avec des faux aléatoires, notre classifieur de distance basé sur les trois histogrammes a été moins performant que le classifieur basé sur les caractéristiques fractales et géométriques. Les fausses signatures simulées ont une ressemblance forte et beaucoup plus importante que les faux aléatoires, aux vraies signatures,

c'est pour cela qu'un classifieur des histogrammes n'est pas aussi robuste que les autres. Pour augmenter la performance de notre système, nous avons utilisé plusieurs méthodes de fusion de données comme dans la phase d'identification. Dans un premier temps nous avons pensé à fusionner les deux classifieurs par des outils les plus simples. Nous avons donc établi un classifieur avec un opérateur de moyenne des distances et étudié l'influence du k dans la règle des k -ppv en faisant varier le seuil. Le meilleur résultat, comme dans la phase d'identification, est obtenu avec $k = 1$ (un classifieur de distance minimum). Puis nous avons utilisé la méthode de vote majoritaire et la règle de Borda count pour combiner ces deux classifieurs. La performance de la règle à la majorité n'est pas remarquable par rapport à celle d'un classifieur fusionné avec la moyenne de distance (comme montré dans le tableau 9.9) en raison de nombreuses égalités. Ces ambiguïtés ont été résolues en donnant des poids différents aux décisions des classifieurs selon leur performance globale. La méthode de Borda Count est meilleure dans la majorité des cas d'ambiguïté mais comme elle ne tient pas compte des valeurs de distance et de leurs variations, elle aussi n'a pas produit une amélioration significative. Ainsi, finalement la théorie de Dempster-Shafer a été utilisée.

Tableau 9.9 : Les résultats obtenus dans le cas de signatures fausses réalisées par des experts

Technique	Taux d'Erreur Egal (TEE) %
Mesure de contour	25,1
Suivi de contour	25,9
Groupement de régions	25,8
Image directe	18,8
Classifieur basé sur 3 histogrammes (e1)	26,6
Fractale + géométrique (e2)	9,5
Combinaison par moyenne de distance	7,3
Fusion par la règle du vote majoritaire	7,2
Fusion par la théorie de l'évidence	5,9

Comme on peut le noter dans le tableau 9.9, des résultats bien meilleurs ont été obtenus par rapport à un classifieur de distance minimum. L'influence du paramètre k lui-même a été étudiée pour $3 \leq k \leq 12$ comme dans l'étude faite avec la première base de données. Ici, le meilleur résultat a été trouvé quand $k = 8$ (ainsi les résultats montrés dans le tableau 9.9 pour

la théorie de l'évidence sont avec cette valeur de k). Le choix de k est différent parce que dans la base de données, les imposteurs volontaires ont imité les signatures avec une certaine expertise. La ressemblance importante avec les vraies signatures a posé problème. Ces fausses signatures acceptées nécessitent d'augmenter le nombre de plus proches voisins considérés pour diminuer leur influence.

Nous avons noté que très peu de signataires donnaient lieu à des taux d'erreur élevés, diminuent ainsi la performance du système. En examinant les faux qui ont été acceptés on constate que les vraies signatures ont des niveaux faibles de complexité et une faible variabilité intra-classe. Tandis que les signatures donnant lieu à un taux de faux rejets (TRF) élevé correspondent à des signatures très complexes et instables avec une variabilité intra-classe élevée comme représenté sur la figure 9.17. La raison de la valeur élevée de TFA est qu'il est vraiment facile d'imiter ces signatures, et pour le haut TVR on constate que les faux sont moins variables que les vraies signatures. Ces signatures montrent généralement un TEE élevé. Ce résultat a une analogie avec l'idée généralement admise qu'une signature fortement instable (variabilité intrinsèque élevée) et les signatures facilement imitées sont parmi les causes principales de la détérioration de la performance d'un système de vérification de signature manuscrite [Brault93a], [Brault93b].

		
Peu complexes et peu de variabilité	Très complexes et instables	

Figure 9.17 : Exemples de deux types de signatures

9.10 Conclusions

Dans ce chapitre, un système d'identification et de vérification des signatures manuscrites off-line est présenté. Un état de l'art des travaux dans le domaine des signatures manuscrites off-line est présenté en mettant l'accent sur la nouvelle tendance où on privilégie

l'amélioration de la performance du système au lieu d'augmenter la discrimination des caractéristiques, ce qui conduit à une fusion des classifieurs.

Nous avons pris en compte une grande variété de caractéristiques : des caractéristiques traditionnelles (des projections de distributions des pixels d'une image de signature selon plusieurs axes) et des caractéristiques plus spécifiques à un système de signatures (fractales et géométriques). Nous avons segmenté l'ensemble de caractéristiques selon chaque type de caractéristiques pour accentuer l'information qu'elles peuvent apporter à la résolution des problèmes. Ensuite nous avons établi plusieurs classifieurs de distance (quatre décrits dans la section 9.9). Les classifieurs de distance employés ont des performances différentes selon la variabilité des caractéristiques des signatures, la nature du système i.e. l'identification ou la vérification et finalement les types de fausses signatures utilisées.

Dans la phase d'identification, les informations issues des quatre classifieurs établis sont utilisées dans le processus de fusion pour étudier plusieurs méthodes proposées dans la littérature. Selon des besoins d'information d'une méthode de fusion, les trois niveaux de fusion (représentation, rangs, décision) sont étudiés et les résultats obtenus sont analysés. Si plus d'informations que les décisions (l'information des distances) sont fournies, l'approche bayésienne, la méthode de Borda, la chaîne de Markov cachée etc. ne sont pas plus pertinentes que les opérateurs d'agrégation AWO, AWFO, qui sont les plus pertinents dans l'identification des signatures. Le formalisme flou proposé a aussi donné une performance remarquable. La théorie de l'évidence et la théorie des possibilités ont montré une amélioration des performances, ces méthodes n'utilisent que les informations fournies par des classifieurs en cas des k-ppv. La méthode de Borda Count en cas de fusion au niveau des rangs a donné une robustesse meilleure que les chaînes de Markov cachées.

Dans la phase de vérification, les performances des classifieurs sont influencées par les types de fausses signatures. La qualité des trois classifieurs basés sur les projections de signatures selon trois axes différents, séparément, a été très mauvaise quand on considère les signatures fausses expertes. C'est pour cela qu'ici, les trois vecteurs de caractéristiques de projections sur trois axes différents sont combinés par un opérateur de moyenne simple et un seul classifieur est établi. De cette façon, notre système de vérification des signatures devient un système à deux classifieurs. Un classifieur, le plus pertinent pour un type de fausses signatures, est remarqué moins robuste pour un autre type de fausses signatures, ce qui limite l'utilisation des méthodes reposant sur des informations plus précises. Dans le cas des signatures fausses aléatoires le classifieur basé sur trois histogrammes a été plus pertinent que le deuxième classifieur (avec les caractéristiques fractales et géométriques) en donnant un

comportement de discrimination meilleur entre les vraies et les fausses signatures. Pour les fausses signatures imitées avec un certain temps d'imitation, l'approche s'appuyant sur la forme globale des signatures a été moins efficace. De bons résultats ont été obtenus en fusionnant ces deux classifieurs, meilleurs qu'avec le meilleur classifieur élémentaire avec les deux jeux de données. Une approche basée sur une pondération simple des classifieurs a été moins robuste parce qu'elle n'a pu améliorer l'efficacité du meilleur classifieur. Un poids adaptatif est en fait la meilleure solution dans ce cas. C'est pour cela que la théorie de l'évidence qui donne un poids indépendant de la performance globale de chaque classifieur a amélioré la robustesse du système.

Chapitre 10

Détection de contour dans une image couleur

L'idée la plus intéressante dans ce chapitre est que nous ne présentons pas un nouveau détecteur de contour mais une méthodologie fondée sur la fusion pour la détection de contour en utilisant les résultats de quelques détecteurs de contour déjà existants. Notre travail concerne deux problèmes principaux indiqués par d'autres chercheurs, (a) quelle méthode employer pour différentes images et (b) quelles valeurs choisir pour les paramètres. Nous proposons d'utiliser l'information complémentaire fournie par chaque méthode individuelle pour améliorer les résultats globaux. Dans notre méthodologie, les structures de contour d'une image sont d'abord détectées par certaines méthodes classiques comme Sobel, Canny, Roberts, LoG, Prewitt et Zero-crossing ou par une même méthode avec différentes valeurs de ses paramètres. Puis, en utilisant une méthodologie de fusion pour fusionner l'état des pixels un par un, nous construisons une image finale. Nous expliquons en détail la méthodologie proposée et les résultats obtenus dans les sections suivantes.

10.1 Introduction

La détection de contour est une partie importante de l'étape de prétraitement dans la plupart des systèmes de vision par ordinateur, de traitement d'image, et de reconnaissance des formes. La précision et la fiabilité de la détection de contour sont critiques à la pertinence globale de ces systèmes [Hou03]. Les caractéristiques de contours identifiées comme un aspect important de la perception visuelle humaine, sont généralement employées dans l'analyse de forme [Marr80]. Les contours dans une image sont généralement reliés aux changements rapides de quelques propriétés physiques, telles que la géométrie, l'illumination, ou le nombre fini de niveaux d'intensité.

10.2 Méthodes de détection de contour

Il y a beaucoup de méthodes différentes proposées pour résoudre le problème de détection de contour [Pal93]. Parmi des méthodes classiques, les détecteurs dérivatifs sont des

méthodes simples pour la détection de contour [Klette94]. Les opérateurs différentiels de premier ordre tels que Roberts, opérateurs de Sobel, sont convolués avec des images pour mettre en évidence les changements spatiaux d'intensité, et finalement un seuil est appliqué pour obtenir des points de contour. Canny [Canny86] a formulé la détection de contour comme un problème d'optimisation et a défini un filtre optimal. L'opérateur différentiel de second ordre tel que l'opérateur de Laplacien, indique des points de contour par la propriété de zero crossing [Klette94]. Quelques problèmes communs à ces méthodes sont la sensibilité au bruit, l'anisotropie et le problème des lignes épaisses. D'autres méthodes plus sophistiquées ont été développées pendant ces dernières années. Quelques modèles mathématiques de EDP (Equation Dérivée Partielle) ont été employés dans les ensembles de niveaux [Sethian99]. Dans [Liang03] quelques approches floues sont conçues. Ces dernières années, des méthodes hybrides ont été présentées comme les réseaux de neurones flous [Looney02].

En fait, la diversité des images empêche une méthode de détection de contours avec une confiance de 100%. D'après [Salotti92], et [Munoz03], toutes les techniques développées jusqu'ici ne produisent pas des résultats précis, bien que les endroits où chaque méthode échoue ne soient pas nécessairement identiques. En particulier, si une image est bruitée ou si ses attributs diffèrent un peu seulement entre les régions, la détection de contour peut avoir comme conséquence de faux contours et des contours cassés si la méthode se fonde entièrement sur l'information locale. Les techniques de suivi de contour peuvent être utilisées pour établir des liens courts, bien que ce soit une tâche très difficile. Les approches souffrent parfois de l'utilisation des seuils durs mal définis. Des architectures complexes ont été élaborées afin de trouver le meilleur détecteur de contour à appliquer.

10.3 Une solution récente : la fusion de données

Une autre approche est d'employer la nature complémentaire de plusieurs méthodes de détection de contour pour réduire les problèmes surgissant dans chaque méthode individuelle. La tendance vers la fusion de plusieurs techniques semble être la meilleure manière de résoudre ce problème. Quoique plusieurs approches rapportent l'existence d'informations complémentaires et une amélioration des résultats, néanmoins, elles impliquent des conflits. Ainsi, comme précédemment observé par [Pavlidis90], bien que la fusion de l'information soit depuis longtemps un but souhaitable dans ce domaine, la réalisation de celle-ci n'est pas une tâche facile.

10.4 La méthodologie proposée

Nous avons aussi tenté de résoudre ce problème avec les outils développés dans les chapitres précédents. Dans un premier temps, nous proposons une méthodologie automatique pour l'intégration de plusieurs méthodes sur la base de la théorie de l'évidence de Dempster-Shafer. Dans notre stratégie, l'information de contour est extraite d'abord par chacune des méthodes en construisant des cartes de contour. Ensuite, en utilisant l'information de l'intensité on peut étiqueter tous les pixels de l'image de contour selon leur appartenance au contour ou au fond. Pour chaque méthode, quelques pixels (u nombre de pixels par exemple) sont choisis comme pixels de référence de la région de contour et de la région de non-contour respectivement. Nous avons donc un problème à deux classes C_1 et C_2 . La classe C_1 représente la classe des pixels appartenant au contour et la classe C_2 est la classe de pixels non contour. Pour n'importe quel pixel « x », nous prenons la décision se fondant sur une distance mesurée entre le pixel x et chacun des pixels de référence (2u en nombre total). Ainsi, pour chacun des pixels d'image, 2u valeurs de distance sont obtenues et selon une règle de décision on peut classer x parmi une des deux classes C_1 et C_2 et ainsi on peut établir un classifieur. Les informations obtenues de cette façon sont alors combinées en utilisant la théorie de l'évidence. Les deux éléments focaux possibles dans un problème à deux classes sont : le premier $\{C_1\}$ ou $\{C_2\}$ et le deuxième $\{C_1 C_2\}$. Les masses d'évidences sont définies comme nous avons expliqué dans le chapitre 5 et aussi dans un problème de vérification. Un algorithme expliquant la méthodologie proposée est expliqué dans la section suivante.

10.5 Algorithme de fusion

La méthodologie de fusion pixel par pixel proposée est réalisée par l'algorithme suivant.

1. Charger une image I en couleur (RGB).
2. Obtenir une image en niveaux de gris I_GL (dans ce cas, intensité de niveau de gris = $a.R + b.G + c.B$, où $a = 0.299$, $b = 0.587$, $c = 0.114$, ces valeurs de trois paramètres a, b, c sont des valeurs par défaut de Matlab) et/ou extraire trois images I_R, I_G, I_B c.-à-d. les trois composantes couleur de l'image initiale I.
3. Détecter les contours avec plusieurs méthodes ou par la même méthode avec différentes valeurs de seuil. Nommer la carte de contour I_i_e_j où i indique GL, R, G, B, et e dénote le contour (edge), tandis que j représente la méthode utilisée.

4. Choisir un certain nombre u de pixels ($u \ll N_t$, où N_t représente le nombre total des pixels, i.e. x_1, x_2, \dots, x_u) à partir de $I_{i_e_j}$ avec les valeurs d'intensité les plus grandes en commençant par la valeur maximale.
5. Sélectionner les autres u pixels ($x_{u+1}, x_{u+2}, \dots, x_{2u}$) à partir de $I_{i_e_j}$ ayant les valeurs d'intensité minimum en commençant avec la valeur minimale.
6. Noter ces $2u$ pixels sélectionnés comme les pixels de référence.
7. Exécuter le processus de fusion en prenant en compte un par un tous les pixels de $I_{i_e_j}$.
 - a. Calculer les distances entre chaque pixel x et les $2u$ nombre de pixels de référence de $I_{i_e_j}$ et assigner les masses d'évidence selon l'équation (5.16).
 - b. Employer la théorie de Dempster-Shafer pour fusionner les données de distance en prenant la décision finale pour établir une carte de contour finale I_{e_f} (où f représente l'image de contour fusionnée).
8. Afficher l'image finale fusionnée I_{e_f} .

10.6 Résultats

En cas de détection de contour, nous avons un problème à deux classes, un pixel x appartient soit au contour ($x \in C_1$) soit à la région de non contour ($x \in C_2$). D'une manière simple, le corps de discernement $\Omega = \{C_1, C_2\}$ et 2^Ω est $\{\emptyset, C_1, C_2, \Omega\}$. Pour les deux classes nous avons étudié l'influence du nombre de pixels (prototypes) « u » dans la base de référence et nous l'avons fixé égal à 10. Nous avons effectué différentes expériences étudiant six détecteurs de contour classiques y compris le choix de leurs valeurs de paramètre. Quelques exemples de résultats obtenus sont montrés sur les figures 10.1, 10.2, 10.3. Comme toujours, il est difficile d'évaluer les résultats. Sur un exemple réel, l'utilisation des seuils standards donne différents résultats. Les différentes expériences effectuées sont décrites plus loin.

Catégorie 1 : le problème de seuillage

L'image couleur initiale a été convertie en niveaux de gris et alors différentes images de contour ont été obtenues en appliquant plusieurs détecteurs de contour bien connus. Ici la première partie consiste à étudier l'effet de la valeur du seuil d'intensité pour chaque détecteur de contour. Un seuil T peut être défini comme une probabilité minimum pour un pixel d'être un vrai contour. Avec une seule méthode la variation du seuil d'intensité donne différents résultats comme représentés sur la figure 10.1 (c), (d), (e), (f) pour l'opérateur de Sobel avec

quatre valeurs du seuil différentes. La structure finale de contour a été obtenue en utilisant notre méthodologie de fusion. Nous pouvons noter que l'image finale fusionnée (figure 10.1 b) est meilleure que deux images de contour de faible qualité (10.1 c et f) et comparable aux autres. L'image finale fusionnée (10.1 b) et l'image de contour (I_GL_e_Sobel (10.1 e)) semblent pareilles, en fait il existe des différences mais visibles seulement quand les images ont leurs vraies dimensions.

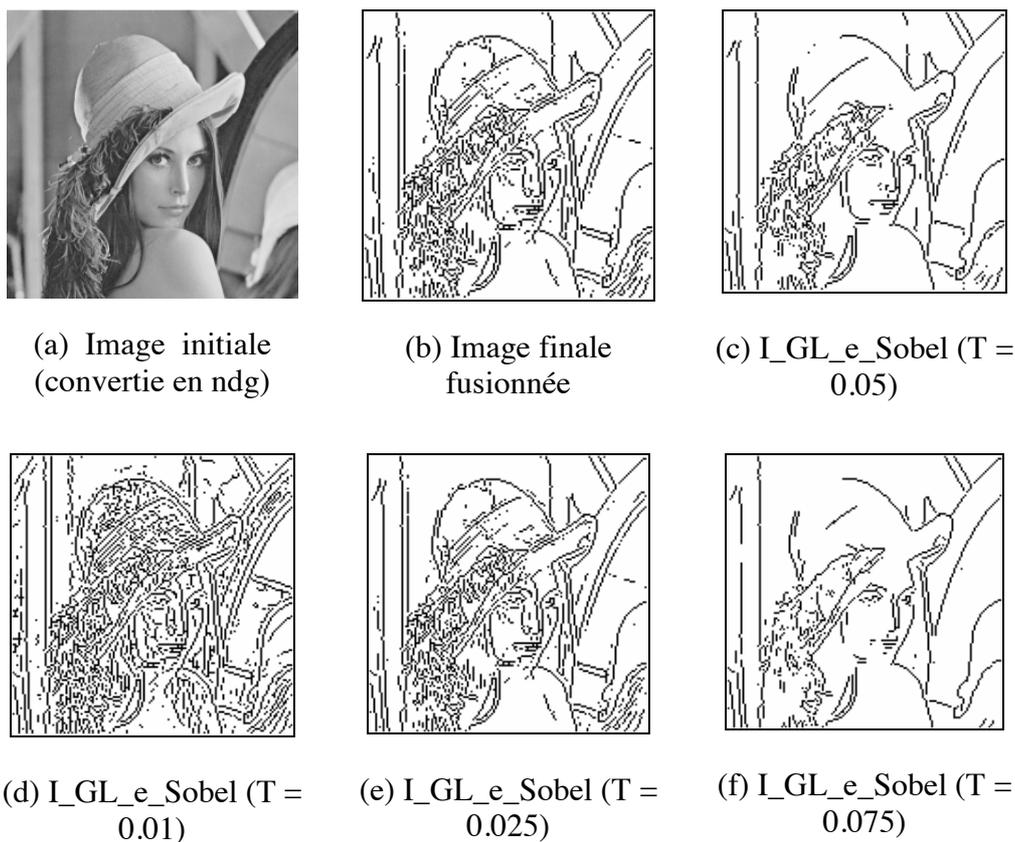


Figure 10.1: une image et les quatre images de contour par l'opérateur de Sobel en faisant varier les seuils d'intensité et l'image finale fusionnée.

Nous pouvons dire que la méthode permet de choisir un pixel de contour pour lequel la confiance évaluée par les masses d'évidence avec l'information de l'approche des k-ppv est grande. Alors la fausse détection dans l'image finale fusionnée est moins importante que dans les autres images qui contiennent des informations de contour soit trop faibles soit trop grandes. Les informations complémentaires sont prises en considération. L'essai conduit avec une seule méthode et différentes valeurs des seuils montre que le problème du choix de seuil peut être résolu par une méthodologie de fusion d'une manière automatique en réalisant une

étape de fusion (figure 10.1 (b)). Les résultats obtenus utilisant d'autres détecteurs de contour en vue du choix d'une valeur du seuil d'intensité ont donné les mêmes tendances que celle représentée sur la figure 10.1, c'est-à-dire que l'image finale fusionnée est assez proche d'une image avec des informations de contour optimales.

Catégorie 2 : plusieurs méthodes

Dans cette seconde catégorie des expériences nous continuons de travailler avec une image en niveau de gris mais en prenant en compte plusieurs méthodes de détection de contour quelles que soient les valeurs de leurs paramètres. Un des résultats est montré sur la figure 10.2.

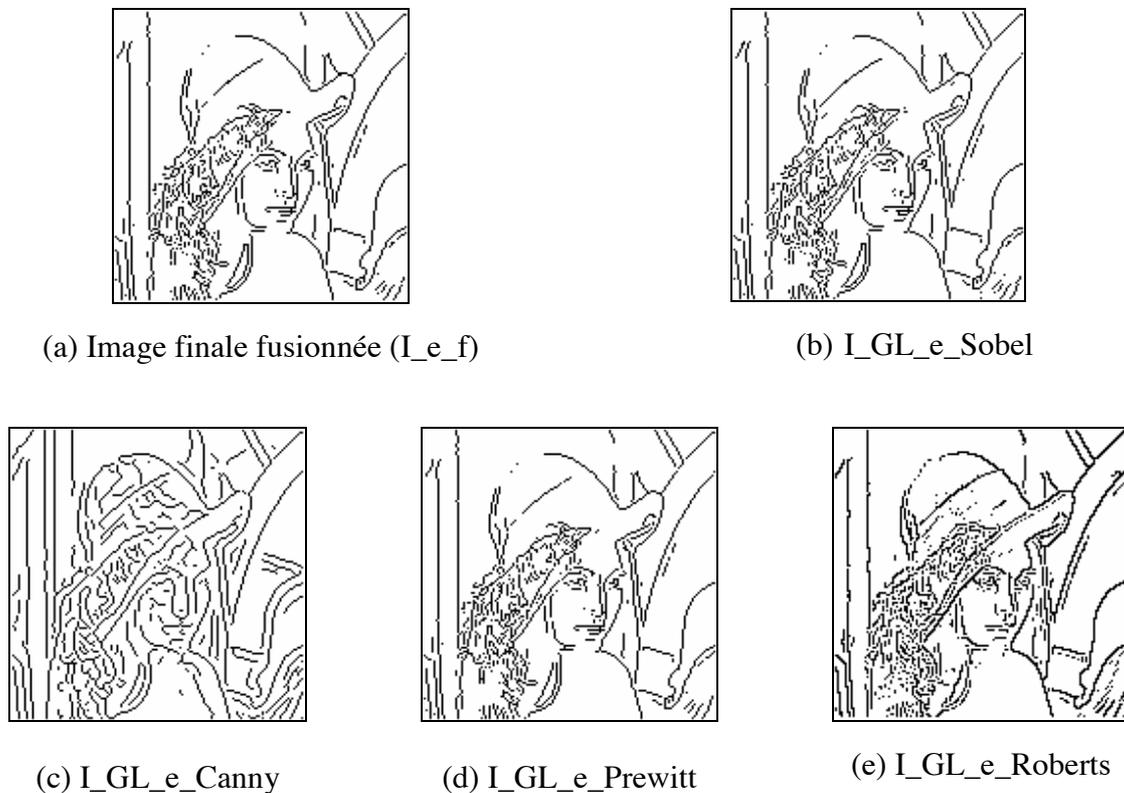


Figure 10.2 : les images de contour par plusieurs méthodes avec un même seuil global pour toutes les méthodes ($T = 0.05$) et l'image finale fusionnée.

Catégorie 3 : Avec les composantes de l'image couleur

Dans la troisième catégorie des expériences, trois composantes (rouge, vert et bleu) d'une image de couleur ont été extraites et étudiées avec l'image en niveaux de gris. Nous obtenons les images de contour en utilisant une méthode de détection de contour pour l'image en ndg et les composantes couleur. Nous avons observé une variation d'information de

contour obtenue à partir de ces quatre images en appliquant un détecteur de contour selon la nature de l'image couleur initiale. On peut conclure à partir des résultats obtenus dans cette catégorie comme dans la première catégorie que pour n'importe quelle méthode avec une valeur du seuil d'intensité fixe, l'image finale fusionnée est très proche de l'image contenant l'information de contour la meilleure.



(a) Image finale fusionnée (I_e_f)



(c) I_R_e_Sobel



(c) I_G_e_Sobel



(d) I_B_e_Sobel



(e) I_GL_e_Sobel

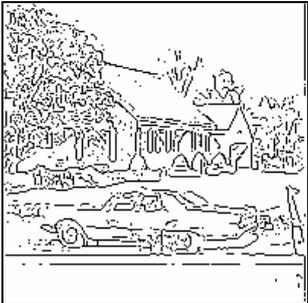
Figure 10.3 : les images de contour par Sobel et avec un même seuil ($T = 0.05$) pour les composantes (R,G,B) et l'image en ndg, et l'image finale fusionnée.

Un point important

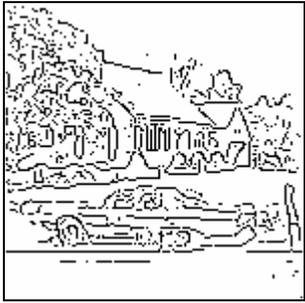
La fusion des contours des images en niveaux de gris semble ici donner un résultat comparablement meilleur par rapport à ceux obtenus en combinant de l'information de contour liée à chaque couleur. Néanmoins, nous avons montré les résultats obtenus par seulement une méthode (Sobel) pour la détection des contours dans la 3ème catégorie. Quelques autres résultats sont montrés dans la figure10.4, où une comparaison est faite entre les résultats obtenus avec la composante verte de l'image couleur et ceux de l'image en niveaux de gris (obtenue à partir de la même image couleur) sous les mêmes valeurs de paramètres pour différentes méthodes utilisées. Ici la composante verte montre un comportement meilleur que l'image en ndg.



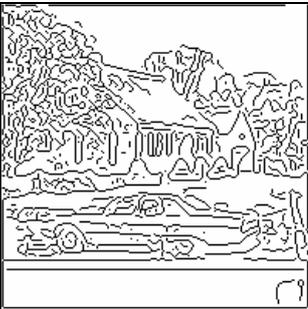
(a) Image initiale (I) en ndg.



(b) Image finale I_e_f



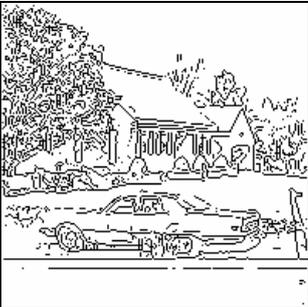
(b') Image finale I_e_f



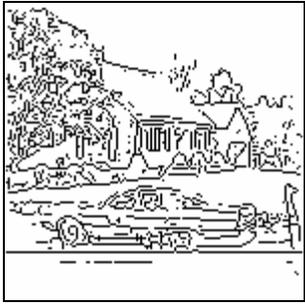
(c) I_G_e_Canny



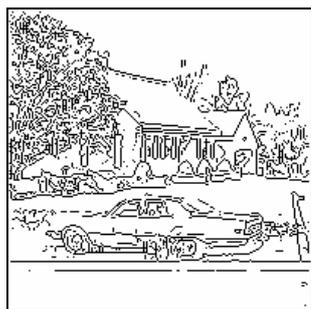
(c') I_GL_e_Canny



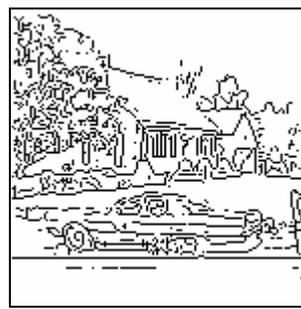
(d) I_G_e_Sobel



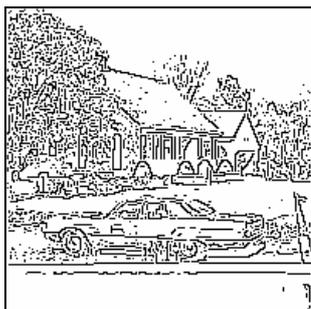
(d') I_GL_e_Sobel



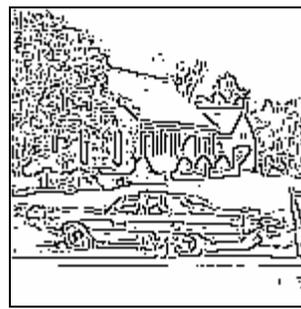
(e) I_G_e_Prewitt



(e') I_GL_e_Prewitt



(f) I_G_e_Roberts



(f') I_GL_e_Roberts

Détection de contour à la base
de la composante Verte

Détection de contour à la base
de l'image en ndg

Figure 10.4 : Deux résultats de détection de contour pour une comparaison entre l'image en ndg et une des composantes de couleur.

10.7 Une comparaison avec une autre méthode (CED)

Sur internet, nous avons trouvé des images de synthèse et des images réelles et avec quelques résultats présentés, comme par exemple le site de CED une méthode de détection de contour [CED : <http://graphics.stanford.edu/~jowens/223b/index.html>]. Nous avons utilisé les mêmes images pour faire une comparaison et voici quelques résultats intéressants :

Image réelle

Image réelle « prague.ppm » obtenue par un appareil CCD. Nous montrons la plus intéressante partie de l'image pour voir la différence entre plusieurs méthodes, c'est-à-dire les traits du visage d'une personne. Nous notons dans la figure 10.5 que le résultat donné par notre méthodologie apporte plus d'information de contour que les deux autres méthodes (Canny, CED) au niveau des yeux, du menton, des cheveux, et surtout de l'expression faciale globale.

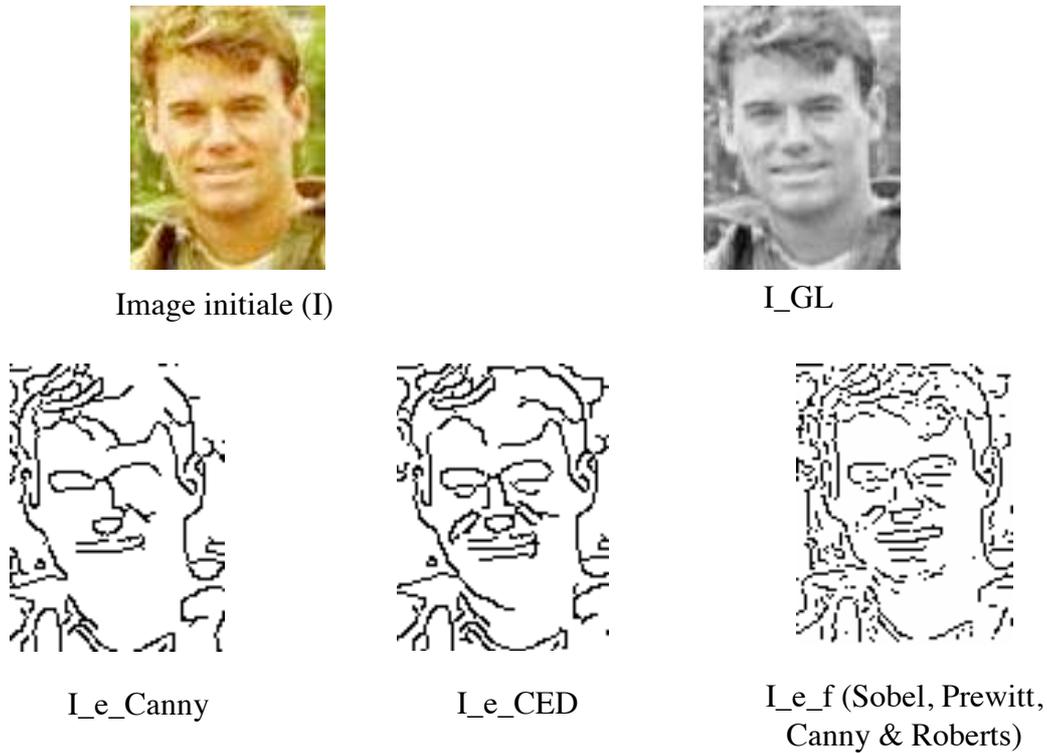


Figure 10.5 : Une image réelle et détection de contour par plusieurs méthodes.

Image artificielle

Image artificielle (squares.ppm) est une image de grille avec trois carrés de couleurs différentes mais ayant même intensité. L'image en ndg à partir de l'image initiale est une image blanche, comme il n'existe pas de niveaux d'intensité, nous avons donc pris en compte les trois composantes couleur pour fusionner les contours obtenus avec chaque composante couleur. Le résultat donné (figure 10.6) par notre méthodologie de fusion a montré que la forme exacte de l'image initiale c'est-à-dire que les contours sont bien en carré mais ils ne sont pas continus et homogènes comme donnés par la méthode CED.

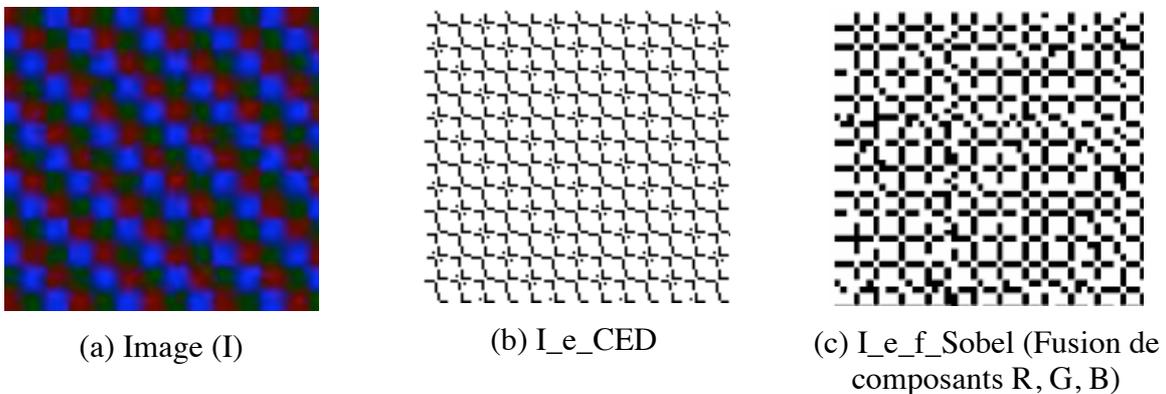


Figure 10.6 : Une image artificielle et la détection de contour par deux méthodes.

10.8 Conclusion

Dans ce chapitre, notre but n'était pas d'élaborer une nouvelle méthode de détection de contour mais de profiter des nombreuses méthodes déjà existantes et de présenter une méthodologie pour les combiner d'une manière automatique. Nous avons prouvé que la méthodologie fondée sur la fusion peut résoudre des problèmes dans ce domaine. Naturellement notre approche est limitée aux méthodes qui donnent pour un pixel une mesure quantitative d'appartenir à la région de contour. Les résultats finals de détection de contour améliorent les résultats moyens des méthodes impliquées.

En outre, la méthodologie de fusion est capable, d'une manière intelligente, de pallier le choix délicat d'un seuil pour tous les détecteurs de contour. En effet, le processus de fusion permet de combiner différentes valeurs du seuil et de décider d'une manière satisfaisante. Nous avons l'intention de continuer à améliorer les résultats de la méthode en modifiant la définition de la distance utilisée dans l'approche des k-ppv. Ici nous avons considéré une seule caractéristique, le seuil, nous devons impliquer d'autres paramètres qui peuvent mieux caractériser les pixels utilisés comme les prototypes. Une phase d'apprentissage contextuelle pourrait alors être présentée.

Conclusion générale

Une étude sur la fusion de données est réalisée dans cette thèse. La fusion de données peut être employée comme une étape dans le processus de la reconnaissance des formes, suit l'étape d'extraction de caractéristiques et de classification, par exemple par plusieurs classifieurs des k-plus proches voisins. Ces classifieurs des k-ppv fournissent en sortie des informations à différents niveaux comme leurs propres choix (décisions ou les classes privilégiées) ; les rangs des classes (celles correspondant aux k-plus proches voisins) ; les mesures de distances des représentants des formes. Les différentes méthodes de fusion sont étudiées selon la nature de ces trois niveaux de l'information disponible.

Nous avons commencé notre travail en rappelant certaines approches des k-ppv employées pour la classification des formes dans le domaine de reconnaissance des formes. Nous avons proposé, dans le cadre de la logique floue, un nouveau formalisme flou pour classer les formes dans les différentes classes selon leurs degrés d'appartenance aux classes.

En utilisant ce formalisme proposé, dans le cadre des règles des k-ppv, nous avons proposé une nouvelle règle de classification qui peut généraliser certaines approches déjà existantes en modifiant les paramètres des variables introduites dans la version générale. Ces paramètres sont au nombre de trois. Le premier représente la puissance du nombre d'occurrences des classes dans les k-plus proches voisins considérés. En mettant les valeurs des deux autres paramètres égales à 1, ce paramètre peut varier avec une valeur supérieure dans l'intervalle [6-10] caractérisant le comportement de notre règle floue comme une règle des k-ppv du vote majoritaire. La méthode résout aussi le problème de l'ambiguïté des votes dans l'algorithme des k-ppv comme nous le montrons dans le chapitre 3. Le deuxième paramètre représente l'influence de la distance entre la forme entrante et les formes dans la base d'apprentissage. En mettant les valeurs de deux autres paramètres égales à 1 et en faisant varier la valeur de ce paramètre, on retrouve le comportement de la règle floue proposée comme une règle des k-ppv avec distance pondérée proposée par Dudani. Le troisième paramètre, l'influence des variations de distance, caractérise le comportement de la règle comme une règle des k-ppv floue proposée par Keller. Les variations de ce paramètre donnent un comportement de la règle des k-ppv floue proposée meilleur que les variations des deux

autres paramètres. Cela a été mis en évidence lors des utilisations avec les différents jeux de données réelles et classiques, c'est pourquoi nous avons proposé de ne conserver que ce seul paramètre à optimiser lors de l'utilisation de la règle proposée.

Dans l'ensemble de notre thèse, nous considérons comme classifieur tout système d'extraction des caractéristiques avec l'aide de certains descripteurs de la forme entrante qui donne des informations de distance et éventuellement des classes possibles. Plusieurs classifieurs des k-plus proches voisins sont ainsi choisis. La décision prise par un classifieur est une étape cruciale, plusieurs approches classiques et celle proposée ont été étudiées à cet égard et les résultats obtenus ont montré la pertinence de notre approche floue proposée. Les performances de ces classifieurs évaluées ont montré une variabilité selon la nature de l'application traitée. Nous avons traité deux applications, l'identification et l'authentification des personnes par les mains et par les signatures manuscrites hors ligne. La robustesse d'un classifieur noté comme le meilleur pour un problème d'identification n'a pas forcément la même efficacité pour un problème d'authentification. En plus, pour un problème d'authentification de signature manuscrite, le classifieur le plus pertinent pour les signatures fausses aléatoires a été noté moins robuste pour les signatures fausses réalisées par experts.

Une fois la robustesse de chacun des classifieurs évaluée, nous avons employé différentes méthodes de fusion de classifieurs aux différents niveaux de fusion, représentation (mesure), rang, et classe ou décision. Les méthodes étudiées sont : méthode de vote, méthode de Borda Count, méthode bayésienne, méthode de la théorie des possibilités, méthode de la théorie de l'évidence, méthodes d'agrégation de données (OWA, AWFO). Nous avons ensuite présenté la méthode de fusion de classifieurs de type mesure basée sur la notion de distance. Le formalisme flou développé et proposé a été aussi employé pour définir les masses d'évidence et les distributions de possibilités des éléments focaux emboîtés.

Nous avons utilisé les jeux de données publiques disponibles et nous avons aussi créé des jeux de données. Nous avons étudié les trois différents niveaux de fusion ; décision (de type classe), rang, et représentation (mesure). Les classifieurs fournissant les sorties de distances et les classes concernées sont trouvées être les plus riches en information et les méthodes combinant ces classifieurs sont par conséquent les plus robustes. Nous avons proposé la méthode basée sur l'information de distance qui est très simple à mettre en œuvre et très pertinente. La méthodologie proposée a donné une performance remarquable dans les deux applications traitées (identification et vérification par la reconnaissance de main et de signature).

Nous avons également étudié une autre application « la détection de contour » pour montrer l'intérêt de la fusion de données dans ce domaine. Ici, notre but n'était pas de définir un nouvel opérateur mais d'utiliser les points forts des méthodes existantes pour améliorer les résultats. Ainsi nous pouvons aussi résoudre les problèmes de choix des valeurs des paramètres d'une méthode par le biais d'une fusion des résultats.

L'étendue des domaines où notre proposition peut être mise en œuvre est si grande que nous avons dû faire des choix. Ainsi les perspectives de notre travail, dans le prolongement de la thèse, pourront concerner les points importants les suivants :

- Continuation de travail sur le degré d'appartenance proposé pour le justifier plus clairement avec des outils mathématiques.
- Diminution ou suppression du nombre de paramètres à régler, par exemple au moyen de plans d'expérience pour la découverte de dépendances.
- Réglage automatique des paramètres retenus par un algorithme génétique.
- Comparaison de notre approche avec d'autres propositions de la modélisation de la masse d'évidence dans la théorie de l'évidence de Dempster-Shafer et pour la distribution des possibilités dans la théorie des possibilités.
- Généralisation de notre approche par l'étude d'autre type de classifieurs de distance et leur fusion.
- Etude des autres approches Bayésiennes pour la fusion.
- Amélioration des résultats obtenus par les chaînes de Markov cachées, la théorie de l'évidence, la théorie des possibilités en utilisant les autres propositions peut être possible.
- Passage à l'échelle des méthodes en utilisation de très grands jeux de données.
- Etude d'autres approches de normalisation, d'autres vecteurs des caractéristiques pour améliorer la classification dans le domaine de la reconnaissance par la main et par la signature.
- Un système de fusion de biométrie multimodal est déjà à l'étude. Nous continuons d'augmenter le nombre des sources biométriques en prenant en compte les classifieurs basés sur les caractéristiques extraites à partir de l'iris et le visage d'une personne.
- Un système de fusion multi-méthodologies est aussi considéré en fusionnant les décisions de plusieurs méthodes de fusion étudiées ici.

Annexe

Annexe A1 : Données de soudure

(a) pour l'apprentissage

Caractéristique ≠1	Caractéristique ≠2	Caractéristique ≠3	Classe
0,6471	0,0171	0,2039	Soudure
0,6471	0,0156	0,3059	Soudure
0,8824	0,0279	0,302	Soudure
0,7647	0,0169	0,1843	Soudure
0,7647	0,0179	0,1961	Soudure
0,5294	0,0238	0,0353	Soudure
1	0,0195	0,0392	Soudure
0,6471	0,0104	0,149	Soudure
0,8824	0,0229	0,3059	Soudure
0,8824	0,0147	0,149	Soudure
0,7647	0,0111	0,1569	Soudure
0,8824	0,018	0,2941	Soudure
0,7647	0,0155	0,1373	Soudure
0,6471	0,0122	0,1686	Soudure
0,8824	0,0121	0,4784	Soudure
1	0,0169	0,3098	Soudure
0,7647	0,0133	0,302	Soudure
0,4118	0,0689	0,1255	Soudure
1	0,021	0,2314	Sans soudure
0,2941	0,1068	0,0863	Sans soudure
0,7647	0,0374	0,0667	Sans soudure
1	0,0139	0,5843	Sans soudure
0,2941	1	0,3569	Sans soudure
0,2941	0,5581	0,698	Sans soudure
0,7647	0,04765	0,6353	Sans soudure
1	0,0157	0,5353	Sans soudure
0,2941	0,0174	0,0235	Sans soudure
0,2941	0,0539	0,0157	Sans soudure
0,2941	0,0441	0,1216	Sans soudure
0,5294	0,0164	0,1137	Sans soudure
0,4118	0,0459	0,0314	Sans soudure
0,5294	0,0662	0,1216	Sans soudure
0,2941	0,0468	0,0314	Sans soudure
0,2941	0,3766	1	Sans soudure
0,2941	1	1	Sans soudure
0,5294	0,011	0,0431	Sans soudure

(b) pour les tests

Caractéristique ≠1	Caractéristique ≠2	Caractéristique ≠3	Classe
0,6471	0,0341	0,349	Soudure
0,8824	0,0279	0,302	Soudure
0,7647	0,0124	0,2588	Soudure
0,7647	0,0145	0,4784	Soudure
1	0,0238	0,0394	Soudure
0,5294	0,0362	0,1608	Soudure
0,6471	0,0305	0,0235	Soudure
1	0,0211	0,1922	Soudure
1	0,0176	0,1882	Soudure
0,7647	0,0238	0,2	Soudure
0,8824	0,0217	0,3059	Soudure
0,7647	0,0222	0,2902	Soudure
0,7647	0,0222	0,1882	Soudure
0,6471	0,0356	0,3255	Soudure
1	0,0217	0,3333	Soudure
0,6471	0,0372	0,2267	Soudure
0,6471	0,017	0,2078	Soudure
0,5294	0,0181	0,0353	Soudure
0,7641	0,015	0,4745	Soudure
1	0,0109	0,4588	Soudure
0,8824	0,0114	0,5098	Soudure
0,8824	0,0134	0,4314	Soudure
0,2941	0,0238	0,1451	Sans soudure
0,5294	0,0109	0,0431	Sans soudure
0,4118	0,0687	0,1255	Sans soudure
0,2941	1	1	Sans soudure
0,5294	0,0372	0,1412	Sans soudure
0,7647	0,077	1	Sans soudure
0,5294	0,3409	0,1216	Sans soudure
0,2941	0,0176	0,0235	Sans soudure
0,2941	0,0537	0,0157	Sans soudure
0,4118	0,0692	0,1059	Sans soudure
0,5294	0,015	0,1725	Sans soudure
0,4118	0,0573	0,102	Sans soudure
0,2941	0,0465	0,0314	Sans soudure
0,7647	0,0439	0,0314	Sans soudure
0,5294	0,0475	0,0353	Sans soudure
0,2941	0,0233	0,1255	Sans soudure
0,2941	0,0274	0,1177	Sans soudure
0,4118	0,2764	1	Sans soudure
0,6471	0,1545	1	Sans soudure
0,5294	0,0129	0,2118	Sans soudure
0,2941	0,0269	0,1059	Sans soudure
0,5294	0,0212	0,1804	Sans soudure

Annexe A2 : Résultat de l'identification des personnes par leur main par le formalisme flou proposé

Tableau A.2 : Performance du formalisme flou proposé en fusionnant les 4 classifieurs sur la base des caractéristiques de la main et de l'empreinte palmaire en faisant varier k et γ .

γ	k-ppv								
	1	3	4	5	6	7	8	9	10
1	97,7	96,2	95,4	95,4	94,6	95,4	95,4	95,4	95,4
1,05	97,7	96,2	95,4	95,4	94,6	95,4	95,4	95,4	95,4
1,1	97,7	96,2	95,4	95,4	95,4	95,4	95,4	95,4	95,4
1,15	97,7	96,2	95,4	95,4	95,4	95,4	95,4	95,4	95,4
1,2	97,7	96,2	95,4	95,4	95,4	95,4	95,4	95,4	95,4
1,3	97,7	96,9	96,2	95,4	95,4	95,4	95,4	95,4	95,4
1,4	97,7	96,9	96,2	95,4	95,4	95,4	95,4	95,4	95,4
1,5	97,7	97,7	96,9	95,4	95,4	95,4	95,4	95,4	95,4
1,6	97,7	97,7	96,9	95,4	95,4	95,4	95,4	95,4	95,4
1,7	97,7	97,7	96,9	95,4	95,4	96,2	96,2	96,2	96,2
1,8	97,7	97,7	96,9	95,4	95,4	96,2	96,2	96,2	96,2
2	97,7	97,7	96,9	95,4	95,4	96,2	96,2	96,2	96,2
2,5	97,7	97,7	97,7	96,9	96,2	96,9	96,9	96,2	96,2
2,6	97,7	97,7	97,7	97,7	96,9	97,7	97,7	96,9	96,9
2,7	97,7	97,7	97,7	97,7	96,9	97,7	97,7	96,9	96,9
2,8	97,7	97,7	97,7	97,7	96,9	97,7	97,7	96,9	96,9
2,9	97,7	97,7	97,7	97,7	96,9	97,7	97,7	96,9	96,9
3	97,7	97,7	97,7	97,7	96,9	97,7	97,7	97,7	97,7

Annexe A3 : Résultats de l'identification de signatures manuscrites par le formalisme flou proposé

Classifieurs

e1 : Un classifieur à base des histogrammes horizontaux (Histo-Horiz)

e2 : Un classifieur à base des histogrammes verticaux (Histo-Vert)

e3 : Un classifieur à base des histogrammes selon l'axe principal d'inertie (Histo-Axe1)

e4 : Un classifieur fractal et géométrique (Fractal&Géo).

I : Fusion de deux classifieurs

I.1. Histo-Axe1 et Fractal&Géo (e3, e4)

γ	k													
	1	3	4	5	6	7	8	9	10	11	12	13	14	15
1	91,2	90,5	90,9	90,1	91,2	91,2	90,7	90,7	90,3	89,7	89,9	90,3	90,3	89,7
1,05	91,2	90,5	91,0	90,1	91,4	91,6	90,9	90,9	90,7	90,3	90,1	90,1	90,1	89,5
1,1	91,2	90,5	91,2	90,5	91,2	91,6	90,7	91,2	91,4	90,3	90,3	90,5	90,3	89,7
1,15	91,2	90,5	91,2	90,5	91,2	91,6	90,7	91,2	91,4	90,3	90,3	90,3	90,3	89,9
1,2	91,2	90,5	91,2	90,7	91,4	91,6	90,7	91,0	91,4	90,5	90,5	90,7	90,5	89,9
1,25	91,2	90,5	91,2	90,7	91,4	91,6	90,9	91,2	91,2	90,3	90,7	90,7	90,7	90,1
1,3	91,2	90,5	91,2	90,7	91,2	91,4	90,9	91,2	91,2	90,3	90,7	90,7	90,7	90,1
1,35	91,2	90,7	91,4	90,9	91,2	91,4	90,9	91,2	91,2	90,7	90,7	90,7	90,7	90,5
1,4	91,2	90,7	91,4	90,9	91,2	91,4	90,9	91,2	91,2	90,7	90,7	90,7	90,7	90,5
1,45	91,2	90,7	91,8	90,9	91,2	91,2	91,2	91,6	91,4	90,9	91,0	90,7	90,5	90,5
1,5	91,2	90,3	91,6	90,5	90,9	91,0	91,0	91,6	91,8	90,7	91,2	91,0	90,9	90,9
1,6	91,2	90,3	91,6	90,5	90,9	91,0	91,0	91,6	91,8	90,7	91,2	91,0	90,9	90,9
1,7	91,2	90,3	91,6	90,5	90,9	91,0	91,0	91,6	91,8	90,7	91,2	91,2	90,9	91,0
1,8	91,2	90,3	91,6	90,5	90,9	91,0	91,2	91,6	92,0	91,0	91,0	91,2	90,9	91,0
1,9	91,2	90,3	91,6	90,5	90,9	90,9	91,0	91,2	92,0	91,2	91,0	91,0	90,9	90,9
2	91,2	90,3	91,6	90,5	90,9	90,9	91,0	91,2	92,0	91,2	91,2	91,2	91,0	91,0
2,1- 2,5	91,2	90,3	90,9	90,7	90,9	91,0	91,0	91,0	91,6	91,4	91,6	91,4	91,0	91,2

I.2. Histo-Horiz et Histo-Axe1 (e1, e3)

γ	k													
	1	3	4	5	6	7	8	9	10	11	12	13	14	15
1	80	79	78,9	78,5	77,0	77,3	78,3	77,5	77,0	76,4	75,4	76,6	77,1	77,0
1,05	80	79	78,9	78,1	76,8	77,3	78,5	77,5	77,0	76,4	75,6	76,8	77,1	77,0
1,1	80	79	78,9	78,5	77,3	77,7	78,5	77,7	77,3	77,0	76,4	77,0	77,5	77,1
1,15	80	79	78,9	78,5	77,3	77,5	78,7	77,7	77,3	77,0	76,4	77,0	77,5	77,3
1,2	80	79	78,9	78,5	77,3	77,5	78,7	77,9	77,3	77,0	76,4	77,1	77,5	77,3
1,25	80	79	78,9	78,5	77,3	77,5	78,3	78,5	77,7	77,5	77,0	77,5	77,7	77,5
1,3	80	79	78,9	78,5	77,5	77,5	78,3	78,5	77,7	77,5	76,8	78,1	78,1	77,9
1,35	80	79	78,9	78,5	77,5	77,5	78,3	78,7	77,7	77,5	76,8	78,1	78,3	77,9
1,4	80	79	78,9	78,5	77,5	77,5	78,3	78,7	77,7	77,5	76,8	78,1	78,5	77,9
1,45	80	79,6	78,9	78,5	77,9	77,9	78,3	78,5	77,9	77,7	76,8	78,3	78,9	77,9
1,5	80	79,8	79,2	78,7	78,1	78,3	78,1	78,3	78,1	77,7	76,6	78,3	78,7	77,7
1,6	80	79,8	79,2	78,7	78,1	78,3	78,1	78,3	78,1	77,7	76,6	78,3	78,7	77,7
1,7	80	79,8	79,2	78,7	78,1	78,3	78,1	78,3	78,1	77,9	77,0	78,1	78,7	78,3
1,8	80	79,8	79,2	78,7	78,1	78,5	78,5	78,3	77,9	77,9	77,0	77,9	78,5	77,9
1,9	80	79,8	79,2	78,7	78,1	78,3	78,5	78,5	78,3	78,1	77,1	78,1	78,1	77,9
2	80	79,8	79,2	78,7	78,1	78,3	78,5	78,5	78,3	77,9	77,3	78,1	78,1	78,1
2,1	80	79,8	79,2	79,2	78,5	78,7	79,2	79,2	78,9	78,5	77,5	78,5	78,7	78,5
2,5	80	79,8	79,2	79,2	78,5	78,7	79,2	79,2	78,9	78,5	77,5	78,5	78,7	78,7
2,6	80	79,8	79,2	79,4	78,9	78,7	79,2	79,2	79,0	78,5	77,3	78,5	78,7	78,7
2,7	80	79,8	79,2	79,4	78,9	78,7	79,2	79,2	79,0	78,5	77,3	78,5	78,7	78,7
2,8	80	79,8	79,2	79,4	78,9	78,7	79,2	79,2	79,0	78,5	77,5	78,7	78,9	78,9
2,9	80	79,8	79,2	79,4	78,7	78,7	79,2	79,2	79,0	78,5	77,5	78,5	78,9	78,9
3	80	79,8	79,2	79,4	78,9	78,7	79,2	79,2	79,0	78,5	77,5	78,5	78,9	78,9
Max	80	79,8	79,2	79,4	78,9	78,7	79,2	79,2	79,0	78,5	77,5	78,7	78,9	78,9

I.3. Histo-Vert et Histo-l'Axe1 (e2, e3)

γ	k													
	1	3	4	5	6	7	8	9	10	11	12	13	14	15
0,3	82,5	81,7	81,7	82,5	81,5	82,7	82,9	81,3	80,0	80,4	78,3	80,0	79,4	79,2
0,5	82,5	82,7	83,2	83,4	83,2	83,8	84,2	83,8	82,7	82,7	80,6	81,0	81,3	80,4
0,6	82,5	82,7	83,2	83,4	83,2	83,8	84,4	84,4	83,2	82,9	81,0	81,9	82,1	81,3
0,7	82,5	82,7	83,2	83,4	83,2	84,0	84,2	84,4	84,4	83,6	81,5	82,5	83,2	82,7
0,8	82,5	82,7	83,2	83,4	83,4	83,6	83,8	84,0	84,2	84,2	82,7	83,4	83,6	82,9
0,9	82,5	82,7	83,2	82,9	83,2	83,4	83,2	83,8	84,4	84,6	82,7	83,6	83,6	82,9
1	82,5	82,7	83,2	83,0	83,2	83,4	82,9	83,6	84,4	84,4	82,3	83,6	83,4	83,2
1,05	82,5	82,7	83,2	82,7	83,0	83,6	82,7	83,4	83,8	84,4	82,3	83,4	83,4	83,2
1,1	82,5	82,7	82,9	82,9	82,7	83,6	82,9	83,6	84,0	84,6	83,2	84,0	83,8	83,4
1,15	82,5	82,7	82,9	82,9	82,9	83,6	83,0	83,8	84,0	84,6	83,2	84,0	83,4	83,0
1,2	82,5	82,7	82,9	82,9	82,9	83,6	82,7	83,4	83,8	84,6	83,2	84,0	83,6	82,9
1,25	82,5	82,7	82,9	82,9	82,9	83,6	82,9	83,2	83,4	84,4	83,2	83,8	83,8	83,0
1,3	82,5	82,7	82,9	82,9	82,9	83,6	82,9	83,2	83,2	84,2	83,0	83,4	83,8	83,0
1,35	82,5	82,7	82,9	82,9	82,9	83,6	82,9	83,2	83,2	84,2	83,0	83,4	84,0	83,2
1,4	82,5	82,7	82,9	82,9	82,9	83,6	82,9	83,2	83,2	84,2	83,0	83,4	84,0	83,2
1,45	82,5	83,0	83,0	82,9	82,9	83,6	83,0	83,2	83,0	84,0	83,0	83,4	84,0	83,2
1,5	82,5	81,7	83,2	83,2	82,7	83,6	83,0	83,2	82,9	83,6	82,9	82,7	83,6	83,6
1,6	82,5	81,7	83,2	83,2	82,7	83,6	83,0	83,2	82,9	83,6	82,9	82,7	83,6	83,6
1,7	82,5	81,7	83,2	83,2	82,7	83,6	83,0	83,2	82,9	83,4	82,5	82,7	83,4	83,0
1,8	82,5	81,7	83,2	83,2	82,5	83,4	83,0	83,2	82,9	83,4	82,1	82,5	82,7	82,3
1,9	82,5	81,7	83,2	83,2	82,5	83,0	82,5	83,0	82,9	83,2	82,3	82,7	82,7	82,5
2	82,5	81,7	83,2	83,2	82,5	83,0	82,5	83,0	82,9	83,2	82,1	82,7	82,9	82,5
2,1	82,5	81,7	82,1	82,7	82,7	83,0	82,3	82,5	82,7	83,2	81,7	82,7	82,9	82,7
2,5	82,5	81,7	82,1	82,7	82,7	83,0	82,3	82,5	82,3	82,9	81,5	82,5	82,7	82,7

I.4. Histo-Horizontal et Dimension Fractale+Géométrique (e1, e4)

γ	k													
	1	3	4	5	6	7	8	9	10	11	12	13	14	15
0,3	88,8	87,4	88,4	88,6	88,0	87,0	85,7	85,1	85,1	85,7	85,0	84,2	84,6	84,4
0,4	88,8	88,6	89,5	89,1	89,0	87,8	86,9	85,5	85,1	86,9	86,1	85,0	85,3	85,3
0,5	88,8	89,3	90,1	89,3	89,1	88,6	88,0	87,0	87,2	88,0	87,4	86,3	86,3	86,3
0,6	88,8	89,3	90,1	89,3	89,1	89,0	88,4	87,6	87,6	88,2	87,8	86,9	87,0	87,2
0,7	88,8	89,3	90,1	89,5	89,1	89,1	88,4	88,4	88,2	88,8	88,4	88,0	87,4	88,0
0,8	88,8	89,3	90,1	89,5	89,1	89,3	88,6	89,0	89,0	89,1	88,8	89,0	88,0	88,4
0,9	88,8	89,3	90,1	89,3	89,1	89,7	89,0	89,1	89,1	89,7	89,0	89,3	89,1	88,6
1	88,8	89,3	90,1	89,7	89,5	89,9	89,5	89,3	89,3	90,1	89,1	89,5	89,5	89,3
1,05	88,8	89,3	90,1	89,9	89,7	89,9	89,7	89,7	89,5	90,3	89,1	89,5	89,5	89,3
1,1	88,8	89,3	90,1	90,1	89,9	90,1	89,7	89,5	89,7	90,5	89,7	89,5	89,9	89,7
1,15	88,8	89,3	90,3	90,1	89,9	90,3	89,9	89,7	89,9	90,7	89,9	89,5	89,9	89,7
1,2	88,8	89,3	90,5	90,1	89,9	90,3	90,1	89,7	89,9	90,7	89,9	89,5	89,9	89,9
1,25	88,8	89,3	90,5	90,1	89,9	90,3	89,9	89,9	90,1	90,7	89,9	89,5	89,9	89,9
1,3	88,8	89,3	90,5	90,1	89,9	90,3	89,9	89,9	90,1	90,7	90,1	89,5	89,9	89,9
1,35	88,8	89,3	90,5	90,1	89,9	90,3	89,9	89,9	90,1	90,7	90,1	89,5	89,9	89,9
1,4	88,8	89,3	90,5	90,1	90,1	90,3	89,9	89,9	90,1	90,7	90,1	89,5	89,9	89,9
1,45	88,8	89,3	90,3	90,1	89,9	90,3	89,9	90,1	90,1	90,7	90,1	89,5	89,9	89,9
1,5	88,8	89,0	89,7	89,5	89,7	90,3	89,5	89,5	89,5	90,3	89,7	89,7	90,3	90,1
1,6	88,8	89,0	89,7	89,5	89,7	90,3	89,5	89,5	89,5	90,3	89,7	89,7	90,3	90,1
1,7	88,8	89,0	89,7	89,5	89,7	90,3	89,5	89,7	89,7	90,3	89,7	89,5	90,1	90,1
1,8	88,8	89,0	89,7	89,5	89,7	90,3	89,7	89,9	89,7	90,5	89,7	89,5	90,3	90,3
1,9	88,8	89,0	89,7	89,5	89,7	90,3	89,9	89,9	90,1	90,7	89,3	89,1	89,9	89,7
2	88,8	89,0	89,7	89,5	89,7	90,3	89,9	89,9	90,1	90,5	89,5	89,3	89,9	89,9
2,1	88,8	89,0	89,5	89,5	89,3	89,9	89,7	89,7	89,7	90,7	90,1	89,5	89,5	89,5
2,5	88,8	89,0	89,5	89,5	89,3	89,9	89,7	89,7	89,7	90,5	90,1	89,9	89,7	89,7
3	88,8	89,0	89,5	89,5	89,1	89,3	89,3	89,5	89,5	90,3	89,7	89,5	89,7	89,7

I.5. Histo-Vertical et Dimension fractale+Géométrique (e2, e4)

γ	k													
	1	3	4	5	6	7	8	9	10	11	12	13	14	15
0,3	86,1	85,9	86,3	85,1	85,5	85,1	85,0	85,5	85,0	83,8	85,0	83,8	83,0	84,4
0,5	86,1	85,7	87,2	86,7	86,7	85,7	86,1	86,3	85,7	85,3	86,1	85,1	84,2	84,4
0,8	86,1	85,7	87,2	87,0	86,7	86,5	86,5	86,7	86,1	86,1	86,5	85,9	86,1	86,1
1	86,1	85,7	87,2	86,9	86,7	86,9	86,5	86,7	85,9	85,9	86,5	86,1	86,5	86,1
1,05	86,1	85,7	87,2	87,0	86,9	86,9	86,3	86,5	86,1	85,9	86,5	86,1	86,5	86,1
1,1	86,1	85,7	87,2	86,9	87,2	87,0	87,2	87,0	86,9	86,5	87,0	86,3	86,3	86,1
1,15	86,1	85,7	87,2	86,9	86,9	87,0	87,2	87,2	86,9	86,5	87,0	86,3	86,3	86,3
1,2	86,1	85,7	87,2	86,9	86,9	87,0	87,0	87,0	87,0	86,7	87,0	86,3	86,3	86,3
1,25	86,1	85,7	87,2	86,9	86,9	87,0	87,2	87,0	87,0	86,9	87,0	86,3	86,5	86,5
1,3	86,1	85,7	87,2	86,9	86,9	87,2	87,2	87,0	87,0	86,9	87,0	86,3	86,5	86,5
1,35	86,1	85,9	87,2	86,9	87,0	87,4	87,2	87,2	87,2	86,9	87,0	86,1	86,3	86,3
1,4	86,1	86,1	87,0	86,9	87,0	87,4	87,2	87,2	87,2	86,9	87,0	86,3	86,5	86,5
1,45	86,1	86,1	87,0	86,9	87,0	87,4	87,2	87,2	87,2	86,9	87,0	86,3	86,5	86,5
1,5	86,1	86,3	87,0	86,9	87,4	87,6	87,2	87,4	87,4	87,0	87,0	86,5	86,5	86,5
1,6	86,1	86,3	87,0	86,9	87,4	87,6	87,2	87,4	87,4	87,0	87,0	86,5	86,7	86,5
1,7	86,1	86,3	87,0	86,9	87,4	87,6	87,2	87,4	87,6	87,2	87,2	86,5	86,7	86,7
1,8	86,1	86,3	87,0	86,9	87,4	87,8	87,4	87,4	87,2	87,0	87,0	86,5	86,9	86,7
1,9	86,1	86,3	87,0	86,9	87,4	87,8	87,2	87,4	87,2	87,0	87,0	86,7	86,9	86,7
2	86,1	86,3	87,0	86,9	87,4	87,8	87,2	87,6	87,2	86,9	87,0	86,7	86,9	86,7
2,1	86,1	86,3	87,2	87,0	87,6	87,8	87,6	87,6	87,6	87,2	87,4	87,0	87,2	87,2
2,5	86,1	86,3	87,2	87,0	87,6	87,8	87,6	87,6	87,4	87,2	87,6	87,2	87,4	87,4
3	86,1	86,3	87,2	87,2	87,4	87,6	87,8	87,6	87,4	87,4	87,6	87,2	87,4	87,4

I.6. Histo-Horiz et Histo-Vert (e1, e2)

γ	k													
	1	3	4	5	6	7	8	9	10	11	12	13	14	15
0,3	85,5	83,8	83,6	83,8	83,2	83,0	83,0	83,2	82,9	82,7	82,3	82,5	82,3	82,1
0,5	85,5	85,7	86,9	85,9	85,9	84,8	85,0	85,1	85,3	85,1	84,4	85,0	84,4	83,4
0,8	85,5	85,7	86,9	85,9	86,1	85,7	86,3	86,7	85,9	85,9	85,5	86,1	85,5	85,9
1	85,5	85,7	87,0	85,9	85,9	85,9	86,5	87,0	86,3	86,3	86,1	86,5	85,9	86,1
1,05	85,5	85,7	87,0	85,9	85,9	85,9	86,5	86,9	86,3	86,3	86,3	86,5	86,3	86,5
1,1	85,5	85,7	86,9	86,5	86,3	86,1	86,7	87,2	87,0	86,5	86,5	86,7	86,3	86,3
1,15	85,5	85,7	86,7	86,5	86,1	86,1	86,7	87,0	86,9	86,5	86,5	86,5	86,1	86,3
1,2	85,5	85,7	86,7	86,5	86,1	86,1	86,7	87,0	86,9	86,5	86,5	86,7	86,3	86,5
1,25	85,5	85,7	86,7	86,5	86,1	86,1	86,7	87,0	86,9	86,7	86,5	87,0	86,7	87,0
1,3	85,5	85,7	86,7	86,5	86,1	85,9	86,5	87,0	86,9	86,9	86,7	87,2	86,9	87,0
1,35	85,5	85,9	86,9	86,5	86,1	85,9	86,5	87,2	86,9	86,9	86,7	87,2	86,9	86,9
1,4	85,5	85,9	86,9	86,7	86,1	85,9	86,5	87,2	86,9	86,9	86,7	87,2	87,0	87,0
1,45	85,5	85,9	87,0	86,7	86,1	85,9	86,5	87,2	86,9	86,9	86,7	87,2	87,0	87,2
1,5	85,5	86,3	86,7	86,3	86,1	86,1	86,9	87,8	87,4	87,4	87,0	87,6	87,4	87,4
1,6	85,5	86,3	86,7	86,3	86,1	86,1	86,9	87,8	87,4	87,4	87,0	87,6	87,4	87,4
1,7	85,5	86,3	86,7	86,3	86,1	86,1	86,9	87,8	87,4	87,4	87,0	87,6	87,4	87,4
1,8	85,5	86,3	86,7	86,3	86,1	86,1	86,9	87,8	87,4	87,4	86,9	87,6	87,6	87,6
1,9	85,5	86,3	86,7	86,3	86,1	86,3	86,7	87,4	87,4	87,6	87,0	87,6	87,4	87,4
2	85,5	86,3	86,7	86,3	86,1	86,3	86,7	87,4	87,4	87,6	87,0	87,6	87,2	87,2
2,1	85,5	86,3	86,7	86,3	86,1	86,1	86,3	86,9	87,0	87,2	87,0	87,8	87,4	87,4
2,5	85,5	86,3	86,7	86,3	86,1	86,1	86,3	87,0	87,0	87,2	87,0	87,8	87,4	87,4
3	85,5	86,3	86,7	86,1	86,1	86,1	86,3	86,9	86,9	86,9	86,9	87,4	87,2	87,2

II. Fusion de trois classifieurs

II.1. Histo-Horiz, Histo-Axe1, Fractal&Géo (e1, e3, e4)

γ	k													
	1	3	4	5	6	7	8	9	10	11	12	13	14	15
0,3	94,7	94,3	93,1	93,9	94,9	95,0	92,6	92,8	92,4	90,9	90,5	90,5	90,3	90,5
0,5	94,7	95,2	95,6	95,0	95,8	95,2	94,1	93,7	93,7	92,2	92,8	92,2	91,8	92,4
0,8	94,7	95,2	95,6	95,2	95,8	95,6	94,7	94,3	94,5	93,7	94,3	94,5	94,1	93,9
1	94,7	95,2	95,6	95,4	96,0	96,0	95,2	94,7	94,9	94,1	94,5	94,5	94,1	94,3
1,05	94,7	95,2	95,6	95,4	96,0	96,0	95,2	94,7	94,9	94,5	94,9	94,5	94,1	94,3
1,1	94,7	95,2	95,6	95,4	96,0	96,0	95,6	95,4	95,2	94,7	95,0	94,7	94,1	94,5
1,15	94,7	95,2	95,6	95,4	96,0	96,0	95,8	95,6	95,4	94,9	95,2	94,7	94,1	94,5
1,2	94,7	95,2	95,6	95,4	96,0	96,0	95,8	95,8	95,4	94,9	95,2	94,7	94,3	94,7
1,25	94,7	95,2	95,6	95,4	96,0	96,0	95,6	95,8	95,6	95,0	95,2	94,9	94,3	94,7
1,3	94,7	95,2	95,6	95,4	96,0	96,0	95,6	95,8	95,6	94,9	95,2	95,0	94,5	94,7
1,35	94,7	95,2	95,6	95,4	96,0	96,0	95,6	95,8	95,6	94,9	95,2	95,0	94,7	94,7
1,4	94,7	95,2	95,8	95,4	96,0	96,0	95,6	95,8	95,6	94,9	95,4	95,0	94,7	94,7
1,45	94,7	95,2	96,0	95,6	96,2	96,2	95,8	96,0	95,8	94,9	95,4	95,0	94,7	94,7
1,5	94,7	95,0	95,6	95,8	96,2	96,4	95,8	95,8	96,0	95,0	95,4	95,4	95,0	95,2
1,6	94,7	95,0	95,6	95,8	96,2	96,4	95,8	95,8	96,0	95,0	95,4	95,4	95,0	95,2
1,7	94,7	95,0	95,6	95,8	96,2	96,4	95,8	95,8	96,0	95,0	95,4	95,4	95,0	95,2
1,8	94,7	95,0	95,6	95,8	96,2	96,4	95,8	95,8	95,8	95,0	95,4	95,4	95,0	95,2
1,9	94,7	95,0	95,6	95,8	96,2	96,2	95,8	95,8	95,8	95,0	95,4	95,4	95,2	95,2
2	94,7	95,0	95,6	95,8	96,2	96,2	95,8	95,8	95,8	95,0	95,4	95,4	95,2	95,2
2,1	94,7	95,0	95,2	95,6	95,8	96,2	96,0	96,0	96,0	95,6	95,8	95,8	95,6	95,6
2,5	94,7	95,0	95,2	95,6	95,8	96,2	96,0	96,0	96,0	95,6	95,8	95,8	95,6	95,6
2,6	94,7	95,0	95,2	95,2	96,0	96,0	96,0	96,0	96,0	95,4	95,6	95,6	95,6	95,8
2,7	94,7	95,0	95,2	95,2	96,0	96,0	96,0	96,0	96,0	95,4	95,6	95,6	95,6	95,8
2,8	94,7	95,0	95,2	95,2	96,0	96,0	96,0	96,0	96,0	95,4	95,6	95,6	95,6	95,8
2,9	94,7	95,0	95,2	95,2	95,6	96,0	95,8	95,8	96,0	95,4	95,6	95,6	95,4	95,8
3	94,7	95,0	95,2	95,2	95,6	96,0	95,8	95,8	96,0	95,4	95,6	95,6	95,4	95,8

II.2. Histo-Vert, Histo-Axe1, et Fractal&Géo (e2, e3, e4)

γ	k													
	1	3	4	5	6	7	8	9	10	11	12	13	14	15
0,3	90,5	91,8	90,9	90,7	90,3	90,7	90,5	90,7	89,3	89,5	87,6	87,4	88,4	88,4
0,5	90,5	92,4	92,2	92,0	92,0	91,8	91,6	91,6	91,4	91,0	89,9	89,9	89,7	89,3
0,8	90,5	92,4	92,2	92,0	92,4	92,6	92,6	92,4	92,2	92,0	92,0	92,0	92,2	91,4
1	90,5	92,4	92,2	92,6	92,6	92,8	92,8	92,6	92,4	92,4	92,4	92,4	92,6	92,2
1,05	90,5	92,4	92,4	92,6	92,6	93,0	93,0	92,6	92,2	92,6	92,6	92,4	92,6	92,2
1,1	90,5	92,4	92,4	92,2	92,8	93,1	93,0	92,6	91,8	92,8	92,4	92,4	92,4	92,4
1,15	90,5	92,4	92,4	92,2	92,8	93,1	93,0	92,6	92,0	92,8	92,4	92,4	92,6	92,4
1,2	90,5	92,4	92,4	92,2	92,8	93,1	92,8	92,6	92,0	92,8	92,4	92,4	92,4	92,0
1,25	90,5	92,4	92,4	92,2	92,8	93,1	92,4	92,6	92,0	92,4	92,6	92,4	92,4	92,0
1,3	90,5	92,4	92,4	92,2	93,0	93,3	92,6	92,6	92,0	92,6	92,6	92,0	92,2	91,8
1,35	90,5	92,4	92,4	92,2	93,0	93,3	92,8	92,6	92,0	92,4	92,2	92,0	92,2	91,6
1,4	90,5	92,4	92,4	92,2	93,0	93,3	92,8	92,6	92,0	92,4	92,2	92,2	92,4	91,6
1,45	90,5	92,2	92,4	92,4	93,1	93,3	92,8	92,6	92,0	92,4	92,2	92,2	92,4	91,6
1,5	90,5	91,4	91,8	92,4	92,2	93,3	92,6	92,2	92,2	92,4	92,0	92,0	92,2	91,6
1,6	90,5	91,4	91,8	92,4	92,2	93,3	92,6	92,2	92,2	92,4	92,0	92,0	92,2	91,6
1,7	90,5	91,4	91,8	92,4	92,2	93,3	92,6	92,2	92,2	92,4	92,0	92,0	92,0	91,6
1,8	90,5	91,4	91,8	92,4	92,2	93,3	92,6	92,2	92,0	92,2	91,8	92,0	92,0	91,6
1,9	90,5	91,4	91,8	92,4	92,2	92,6	92,6	92,2	92,0	92,2	91,8	92,0	92,2	91,8
2	90,5	91,4	91,8	92,4	92,2	92,6	92,6	92,2	92,0	92,2	91,8	92,0	92,2	91,6
2,1	90,5	91,4	91,0	92,0	92,0	92,6	92,2	92,4	92,2	92,4	92,0	92,2	92,2	91,6
2,5	90,5	91,4	91,0	92,0	92,0	92,6	92,2	92,2	92,2	92,2	92,0	92,0	92,0	91,6
2,6	90,5	91,4	91,0	91,2	91,8	92,4	92,2	92,2	92,0	92,2	92,0	92,0	92,0	91,6
2,7	90,5	91,4	91,0	91,2	91,8	92,4	92,2	92,2	92,0	92,2	92,0	92,0	92,0	91,6
2,8	90,5	91,4	91,0	91,2	91,8	92,4	92,2	92,2	92,0	92,0	92,0	92,0	92,0	91,6
2,9	90,5	91,4	91,0	91,2	91,4	92,0	92,0	92,2	92,0	92,0	91,8	92,0	92,0	91,6
3	90,5	91,4	91,0	91,2	91,4	92,0	92,0	92,2	92,0	92,0	91,8	92,0	92,0	91,6

II.3. Histo-Horiz, Histo-Vert, et Fractal&Géo (e1, e2, e4)

γ	k													
	1	3	4	5	6	7	8	9	10	11	12	13	14	15
0,3	94,1	92,6	93,7	93,1	91,8	92,2	93,1	92,2	92,2	92,6	92,6	92,4	91,2	91,4
0,5	94,1	93,7	94,5	94,1	93,7	93,1	93,7	93,3	93,3	92,8	92,8	93,0	92,8	92,6
0,8	94,1	93,7	94,5	94,3	93,7	93,9	93,9	93,9	94,1	93,5	93,5	93,9	93,5	93,7
1	94,1	93,7	94,5	94,3	93,9	93,9	94,5	94,1	93,7	93,7	93,5	93,7	93,7	94,1
1,05	94,1	93,7	94,5	94,3	94,1	93,9	94,7	94,3	93,7	93,7	93,5	93,7	93,7	94,1
1,1	94,1	93,7	94,5	94,3	94,1	93,9	94,7	94,5	93,9	93,9	93,9	94,1	93,9	94,3
1,15	94,1	93,7	94,3	94,3	94,1	93,9	94,7	94,5	93,9	93,9	93,9	94,1	93,9	94,3
1,2	94,1	93,7	94,3	94,3	94,1	93,9	94,7	94,5	93,9	93,9	93,9	94,1	94,1	94,3
1,25	94,1	93,7	94,3	94,3	94,1	93,9	94,5	94,5	94,1	93,9	93,9	94,1	94,3	94,3
1,3	94,1	93,7	94,3	94,3	94,1	93,9	94,5	94,5	94,1	93,9	94,1	94,1	94,3	94,3
1,35	94,1	93,7	94,3	94,3	94,1	93,9	94,5	94,5	94,1	93,9	94,1	94,1	94,3	94,3
1,4	94,1	93,7	94,3	94,3	94,1	93,9	94,5	94,5	94,1	94,1	94,1	94,3	94,5	94,3
1,45	94,1	94,1	94,5	94,5	94,1	94,1	94,5	94,5	94,3	94,3	94,3	94,5	94,7	94,5
1,5	94,1	93,7	94,5	94,5	94,1	94,1	94,3	94,5	94,5	94,5	94,5	94,7	94,9	94,5
1,6	94,1	93,7	94,5	94,5	94,1	94,1	94,3	94,5	94,5	94,5	94,5	94,7	94,9	94,5
1,7	94,1	93,7	94,5	94,5	94,1	94,1	94,3	94,5	94,5	94,5	94,5	94,7	94,9	94,7
1,8	94,1	93,7	94,5	94,5	94,1	93,9	94,3	94,5	94,5	94,7	94,5	94,7	94,9	94,9
1,9	94,1	93,7	94,5	94,5	94,1	93,9	94,3	94,1	94,3	94,5	94,3	94,9	94,9	94,9
2	94,1	93,7	94,5	94,5	94,1	93,9	94,3	94,1	94,3	94,5	94,5	94,9	94,9	94,9
2,1	94,1	93,7	94,3	94,5	94,5	94,3	94,7	94,3	94,3	94,5	94,7	94,9	95,0	95,0
2,5	94,1	93,7	94,3	94,5	94,5	94,3	94,7	94,5	94,5	94,5	94,5	94,7	94,7	94,9
2,6	94,1	93,7	94,3	94,1	94,1	94,3	94,9	94,7	94,5	94,5	94,5	94,5	94,5	94,5
2,7	94,1	93,7	94,3	94,1	94,1	94,3	94,9	94,7	94,5	94,5	94,5	94,5	94,5	94,5
2,8	94,1	93,7	94,3	94,1	94,1	94,3	94,9	94,7	94,5	94,5	94,5	94,5	94,5	94,5
2,9	94,1	93,7	94,3	94,1	93,9	93,7	94,5	94,7	94,5	94,5	94,5	94,5	94,5	94,5
3	94,1	93,7	94,3	94,1	93,9	93,7	94,5	94,7	94,5	94,5	94,5	94,5	94,5	94,5

III. Fusion de quatre classifieurs

γ	k													
	1	3	4	5	6	7	8	9	10	11	12	13	14	15
0,3	94,5	95,0	94,3	95,4	95,2	94,1	94,5	94,9	94,7	93,7	93,7	93,9	91,8	92,4
0,5	94,5	95,6	95,8	96,0	96,6	95,2	95,0	95,2	95,8	94,3	94,3	94,5	93,3	93,0
0,8	94,5	95,6	95,8	96,0	96,4	95,6	95,8	95,8	96,2	95,6	95,8	95,4	94,3	94,1
1	94,5	95,6	95,8	96,4	97,0	96,6	95,8	96,2	95,6	95,4	95,4	95,4	95,0	94,9
1,05	94,5	95,6	95,8	96,4	97,0	96,6	95,8	96,2	95,6	95,4	95,4	95,4	95,2	95,0
1,1	94,5	95,6	95,8	96,6	96,8	96,6	96,2	96,2	95,4	95,4	95,6	95,4	95,4	95,4
1,15	94,5	95,6	95,8	96,6	96,8	96,6	96,2	96,2	95,6	95,4	95,6	95,4	95,4	95,4
1,2	94,5	95,6	95,8	96,6	96,8	96,6	96,4	96,4	95,6	95,4	95,6	95,4	95,4	95,4
1,25	94,5	95,6	95,8	96,6	96,8	96,6	96,6	96,2	95,6	95,4	95,6	95,6	95,2	95,4
1,3	94,5	95,6	95,8	96,6	96,8	96,6	96,6	96,2	95,6	95,4	95,6	95,6	95,2	95,4
1,35	94,5	95,6	95,8	96,6	96,8	96,6	96,6	96,2	95,6	95,4	95,6	95,6	95,2	95,4
1,4	94,5	95,6	95,8	96,6	96,6	96,6	96,6	96,2	95,6	95,4	95,6	95,6	95,4	95,6
1,45	94,5	96,0	95,8	96,6	96,6	96,8	96,8	96,2	95,6	95,4	95,6	95,6	95,4	95,6
1,5	94,5	95,2	95,2	96,2	96,4	96,4	96,6	96,2	95,8	95,4	95,6	95,6	95,4	95,4
1,6	94,5	95,2	95,2	96,2	96,4	96,4	96,6	96,2	95,8	95,4	95,6	95,6	95,4	95,4
1,7	94,5	95,2	95,2	96,2	96,4	96,4	96,6	96,2	95,8	95,4	95,6	95,6	95,4	95,4
1,8	94,5	95,2	95,2	96,2	96,4	96,4	96,6	96,4	96,0	95,8	95,8	95,8	95,6	95,4
1,9	94,5	95,2	95,2	96,2	96,4	96,2	96,4	96,4	96,0	95,8	95,8	95,8	95,6	95,4
2	94,5	95,2	95,2	96,2	96,4	96,2	96,4	96,4	96,0	95,8	96,0	95,8	95,6	95,6
2,1	94,5	95,2	95,0	96,2	96,6	96,2	96,0	96,2	96,2	95,8	96,0	96,0	95,6	95,6
2,5	94,5	95,2	95,0	96,2	96,6	96,2	96,0	96,0	96,2	96,0	96,2	96,0	95,8	95,8
2,6	94,5	95,2	95,0	95,8	96,4	96,0	96,0	96,0	96,0	96,0	96,2	96,2	96,0	95,6
2,7	94,5	95,2	95,0	95,8	96,4	96,0	96,0	96,0	96,0	95,8	96,2	96,2	96,0	95,6
2,8	94,5	95,2	95,0	95,8	96,4	96,0	96,0	96,0	96,0	95,8	96,2	96,2	96,0	95,8
2,9	94,5	95,2	95,0	95,8	96,0	96,0	96,0	96,0	96,0	95,8	96,0	96,2	96,0	95,8
3	94,5	95,2	95,0	95,8	96,0	96,0	96,0	96,0	96,0	95,8	96,0	96,0	96,0	95,8
Max	94,5	96,0	95,8	96,6	97,0	96,8	96,8	96,4	96,2	96,0	96,2	96,2	96,0	95,8

Bibliographie

- [Abidi92] M. Abidi and R. Gonzales, Editors, *Data Fusion in Robotics and Machine Intelligence.*, Academic Press, New York, 1992.
- [Achermann96] B. Achermann, H. Bunke, *Combination of classifiers on the decision level for face recognition.* Technical report, University of Bern, 1996.
- [Aezel66] J. Aczel, *Lectures on Functional Equations and Applications*, Academic Press, New York, 1966.
- [Allgrove00] C. Allgrove, M.C. Fairhurst, “Majority voting for improved signature verification” *IEE Colloquium on Visual Biometrics*, London, (Ref No. 2000/018), pp. 9/1-9/4, 2000.
- [Ammar88] M. Ammar, Y. Yoshida, T. Fukumura, Description of signature images and its applications to their classification. In: Proc. 9th *Int. Conference on Pattern Recognition (ICPR’1988)*, pp. 23-26, 1988.
- [Ammar88a] M. Ammar, Y. Yoshida and T. Fukumura, Off-line preprocessing and verification of signatures. *Int. J. Pattern Recognition and Artificial Intelligence* Vol. 2, pp. 589–902, 1988.
- [Ammar91] M. Ammar, Progress in verification of skillfully simulated handwritten signatures, *Pattern Recognition and Artificial Intelligence*, Vol. 5, pp. 337-351, 1991.
- [Anderson35] E. Anderson, The irises of the Gaspé peninsula, *Bull. Am. Iris Soc.* Vol. 59, pp. 2-5, 1935.
- [Appriou91] A. Appriou, Probabilités et incertitude en fusion de données multi-senseurs, *Revue Scientifique et Technique de la Défense*, pp. 27–40, 1^{er} trimestre 1991.
- [Appriou98] A. Appriou, Uncertain data aggregation in classification and tracking processes. In: B. Bouchon-Meunier, Editor, *Aggregation and Fusion of Imperfect Information*, Physica-Verlag, Heidelberg, pp. 231–260, 1998.
- [Appriou99] A. Appriou, Multisensor signal processing in the framework of the theory of evidence, In *Application of Mathematical Signal Processing Techniques to Mission Systems*, pp. 5-31. Research and Technology Organization (Lecture Series 216), November 1999. [Adan03] A. Adan, A. Vazquez, G. Bueno, F. Molina, “A Hand Biometric Prototype Based on their Natural Layout”, *Proceedings of the 3rd IASTED Int. Conference on Visualisation, Imaging, and Processing*, Benalmadena, Spain, pp. 704-709, September 8-10, 2003.
- [Baily78] T. Baily and A. K. Jain, A note on distance-weighted k-nearest neighbor rules. *IEEE Trans. on Systems, Man, and Cybernetics*, Vol. 8(4), pp. 311-313, 1978.
- [Bajaj97] R. Bajaj and S. Chaudhury, Signature verification using multiple neural classifiers. *Pattern Recognition*, Vol. 30(1), pp. 1–7, 1997.
- [Baldwin97] J.F. Baldwin, J. Lawry and T.P. Martin, A mass assignment based ID3 algorithm for decision tree induction. *Int. J. Intell. Systems.* Vol. 12 pp. 523–552, 1997.
- [Baldwin99] J.F. Baldwin, T.P. Martin and J.G. Shanahan, Controlling with words automatically identified fuzzy Cartesian granule feature models. *Internat. J. Approximate Reasoning*, Vol. 22, pp. 109–148, 1999.

- [Baltzakis01] H. Baltzakis, N. Papamarkos, A new signature verification technique based on a two-stage neural networks classifier. *Engineering Applications of Artificial Intelligence*, Vol. 14(1), 95-103, 2001.
- [Beaves95] P. Beaves, S.M.Quirk, J.P.Sattler, Object identification in greyscale imagery using fractal dimension, *Fractal Reviews in the Natwal and Applied Sciences*, Chapman & Hall, pp. 63-73. 1995.
- [Beiraghi00] S. Beiraghi, M. Ahmadi, M. Shridhar, M. Ahmed, Application of fuzzy integrals in fusion of classifiers for low error rate handwritten numerals recognition. In *Int. Conf. in Pattern Recognition*, 2000.
- [Belkasim92] S.O. Belkasim, M. Shridhar, M. Ahmadi, Pattern classification using an efficient KNNR, *Pattern Recognition*, Vol. 25, pp. 1269-1274, 1992.
- [Bellili02] A. Bellili, M. Gilloux and P. Gallinari, Reconnaissance de chiffres manuscrits par un système hybride MLP-SVM. In *13eme Congrès Francophone AFRIF-AFIA de Reconnaissance des formes et d'Intelligence Artificielle (RFIA'02)*, Vol. 3, pp. 761-769, Angers, France, 2002.
- [Belloir99] F. Belloir, *Système intelligent de reconnaissance de formes développé autour d'un capteur à courants de Foucault*, Thèse de Doctorat de l'Université de Reims Champagne Ardenne en Génie Automatique, Informatique et Traitement du Signal, 1999.
- [Benediktsson92] J.A. Benediktsson and P.H. Swain. Consensus theoretic classification methods. *IEEE Trans. Systems Man Cybernet.* Vol. 22, pp. 688–704, 1992.
- [Berkan97] R.C. Berkan, *Fuzzy System Design Principles* (1st ed.). IEEE Press Marketing, USA. 1997.
- [Bezdek91] dans la théorie des possibilités est [Bezdek81] J.C. Bezdek, *Pattern recognition with fuzzy objective function : Algorithms*, Plenum press, 1981.
- [Bezdek99] J.C. Bezdek, J. Keller, R. Krishnapuram, N.R. Pal, *Fuzzy models and algorithms for pattern recognition and image processing*, M.A. Norwell: Kluwer, 1999.
- [Bezdek01] J.C. Bezdek, L.I. Kuncheva, Nearest prototypes classifier designs: An experimental study, *Int. J. of Intelligent Systems*, Vol. 16, 1445-1473, 2001.
- [Billaudel99] P. Billaudel, A. Devillez and G. Villermain Lecolier, Performance evaluation of fuzzy classification methods designed for real time application. *Internat. J. Approximate Reasoning* Vol. 20, pp. 1–20, 1999.
- [BIOMET] S. Garcia-Salicetti, C. Beumier, G. Chollet, B. Dorizzi, J.L. les Jardins, J. Lunter, Y. Ni, D. Petrovska-Delacrétaz, BIOMET : A multimodal person authentication database including face, voice, fingerprint, hand and signature modalities, *Lecture Notes in Computer Science*, Publisher: Springer-Verlag GmbH, Vol. 2688 / 2003, pp. 845-853, 2003.
- [Bloch94] I. Bloch, H. Maitre. Fusion de données en traitement d'images : modèles d'information et décisions, *Traitement du Signal*, Vol 11(6), pp.435-446, 1994.
- [Bloch96] I Bloch, "Some Aspects of Demspter-Shafer Evidence Theory for Classification of Multi-Modality Medical Images Taking Partial Volume Effect into Account," *Pattern Recognition Letters*, vol.17, 905-919, 1996.
- [Borda1781] J.C. Borda, Mémoire sur les élections au scrutin, *Histoire de l'académie Royale des Sciences*, Paris, 1781.
- [Bouchon-Meunier95] Bouchon-Meunier Bernadette. *La logique floue et ses applications*. Addison-Wesley, France 1995.
- [Boulétreau95] V. Boulétreau, N. Vincent, H. Emptoz. A writing qualification invariant towards line thickness and resolution changes. *ACCV'95*, Singapore, pp. 325-330. December 5-8, 1995.

- [Boulétreau97] V. Boulétreau, *Vers un classement de l'écrit par des méthodes fractales*, Thèse, Institut National des Sciences Appliquées de Lyon, France, 1997.
- [Bow92] Sing-Tze Bow. *Pattern Recognition and Image Processing*, Marcel Dekker Inc. New York, USA, 1992.
- [Brault93a] J.J. Brault, R. Plamondon, A complexity measure of handwritten curves: modeling of dynamic signature forgery. *IEEE Transactions on Systems, Man and Cybernetics*, Vol. 23 (2), pp. 400-413, 1993.
- [Brault93b] J.J. Brault, R. Plamondon, Segmenting handwritten signatures at their perceptually important points. *Pattern Analysis and Machine Intelligence*. Vol. 15(9), pp. 953-957, 1993.
- [Broomhead88] D.S. Broomhead and D. Lowe, Multivariable functional interpolation and adaptive networks. *Complex Systems* Vol. 2, pp. 321-355, 1988.
- [Brouard99] T. Brouard, *Algorithmes hybrides d'apprentissages de Chaînes de Markov Cachées : Conception et applications à la reconnaissance des formes*. Thèse, Université François Rabelais, Tours, 1999.
- [Brunelli95] R. Brunelli, D. Falavigna, Person identification using multiple cues, *IEEE Trans. on PAMI*, Vol. 17(10), pp. 955-966, 1995.
- [Bruzzone99] L. Bruzzone, D.F. Prieto and S.B. Serpico, A neural statistical approach to multitemporal and multisensor and multisource remote sensing image classification. *IEEE Trans. Geosci. Remote Sensing* Vol. 37(3), pp. 1350-1359, 1999.
- [Calvo03] T. Calvo and R. Mesiar. Aggregation operators: ordering and bounds, *Fuzzy Sets and Systems*, Vol. 139(3), pp. 685-697, 2003.
- [Canny86] J. Canny, A computational approach to edge detection. *IEEE Transactions. PAMI-8*, 1986, 679-698.
- [Cao94] J. Cao, M. Ahmadi, M. Shridhar, Hand-written numerals with multiple features and multistage classifiers. *IEEE Int. J. on Circuits and Systems*, Vol. 6, pp. 323-326, 1994.
- [Cao95] J. Cao, M. Ahmadi, M. Shridhar, Fusion of classifiers with fuzzy integrals. *Int. Conf. in Document Analysis and Recognition (ICDAR'95)*, 1995.
- [Cardot93] H. Cardot, *Etude et spécification d'une architecture de réseaux neuronaux pour l'authentification de signatures manuscrites statiques*. Thèse, Université de Caen, 1993.
- [Cardot94] H. Cardot, M. Revenu, "A static signature verification system based on a cooperating neural networks architecture", *Pattern Recognition and Artificial Intelligence*. Vol. 8 (3), 679-692, 1994.
- [Carless97] C. Carless, R. Fullér, S. Fullér, OWA operators for doctoral student selection problem. in : R.R. Yager and J. Kacprzyk (eds.): *The Ordered Weighted Averaging Operators: Theory, Methodology and Applications*, Kluwer Academic Publishers, Boston, pp. 167-178, 1997.
- [Chen97] K. Chen, L. Wang, H. Chi, Methods of combining multiple classifiers with different features and their applications to text-independent speaker identification. *Pattern Recognition and Artificial intelligence*, Vol. 11(3), pp. 417-445, 1997.
- [Chen01] J. Chen, C. Zhang and G. Rong, Palmprint recognition using creases, *Proc. of International Conference on Image Processing*, pp. 234-237. 2001.
- [Chibelushi93] C. Chibelushi, J. Mason and F. Deravi, Integration of acoustic and visual speech for speaker recognition, *Eurospeech*, pp. 157-160, 1993.
- [Choquet53] G. Choquet, Theory of capacities, *Ann. Inst. Fourier*, Vol. 5, pp.131-295, 1953.

- [Chou94] K. Chou, L. Tu, I. Shyu, Performance analysis of a multiple classifiers system for recognition of totally unconstrained handwritten numerals. *4th Int. Workshop on Frontiers of Handwriting Recognition*, 480-487, Taiwan. 1994.
- [Clemen87] R.T. Clemen, & R.L. Winkler, Calibrating and Combining Precipitation Probability Forecasts. In R. Viertl, *Probability and Bayesian Statistics*. New York, NY: Plenum Press, 1987.
- [Condorcet1785] M. Condorcet, Essai sur l'application de l'analyse à la probabilité des décisions rendues à la pluralité des voix. Paris, 1785.
- [Connie05] T. Connie, A.T.B. Jin, M.G.K. Ong and D.N.C. Ling An automated palmprint recognition system, *Image and Vision Computing*, Vol. 23(5), pp. 501-515, 2005.
- [Connie05b] T. Connie, A. Teoh, M.Goh and D. Ngo. PalmHashing: a novel approach for cancelable biometrics *Information Processing Letters*, Vol. 93(1), pp. 1-5, 2005.
- [Cordella98] L. Cordella, P. Foggia, C. Sansone, F. Tortorella, M. Vento, Optimizing the error/reject trade-off for a multi-expert system using the bayesian combining rule. In *Advances in Pattern Recognition*, pp. 716-725, 1998.
- [Cover 67] T.M. Cover and P.E. Hart, Nearest neighbor pattern classification. *IEEE Trans. Inform. Theory*. Vol. 13(1), pp. 21-27, 1967.
- [Cremer99] F. Cremer, J.G.M. Schavemaker, E. den Breejen, K. Schutte, "Detection of anti-personal land-mines using sensor-fusion techniques," in : T. Windeatt, J. O'Brien (Eds.), *Proceedings of EuroFusion 99. International Conf. on Data Fusion*, Stratford Upon Avon, UK, pp. 159-166, 1999.
- [Cremer01] F. Cremer, K. Schutte, J. G. M. Schavemaker and E. den Breejen, "A comparison of decision-level sensor-fusion methods for anti-personal landmine detection," *Information Fusion*, vol. 2(3), pp.187-208, Sep 2001.
- [Dai99] X. Dai and S. Khorram, "Data fusion using artificial neural networks: a case study on multitemporal change analysis," *Computers, Environment and Urban Systems*, Vol. 23(1), pp.19-31, January 1999.
- [Dasarathy80] B. V. Dasarathy, Nosing around the neighborhood : A new system structure and classification rule for recognition in partially exposed environments, *IEEE Trans. PAMI*, Vol. PAMI-2, No. 1, pp. 67-71, 1980.
- [Dasarathy90] B.V. Dasarathy, *Nearest neighbor (NN) Norms: NN Pattern Classification Techniques*. Los Alamitos, California: IEEE Computer Society Press, 1990.
- [Dasarathy94] B.V. Dasarathy, Minimal consistent set (MCS) identification for optimal nearest neighbor decision systems design, *IEEE Trans. SMC*, Vol. 24, pp. 511-517, 1994.
- [Dasarathy97] V. B. Dasarathy, « Sensor fusion potentiel exploitation-innovative architecture and illustrative applications », *Proc. of IEEE*, Vol. 85, pp. 24-39, 1997.
- [Dasigi01] V. Dasigi, R.C. Mann and V.A. Protopopescu. Information fusion for text classification — an experimental comparison. *Pattern Recognition*, Vol. 34(12), pp. 2413-2425, 2001.
- [Dave91] R.N. Dave, Characterization and detection of noise in clustering, *Pattern Recognition Letters*, Vol. 12, pp. 657-664, 1991.
- [Demos] <http://www.gpds.ulpgc.es/download/index.htm>.
- [Dempster67] A. Dempster, Upper and lower probabilities induced by multi-valued mapping. *Annals of Mathematical Statistics* AMS-38, pp. 325-339, 1967.
- [Denoeux95] T. Denoeux, A k-Nearest Neighbor classification rule based on Dempster-Shafer theory. *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 25(5), pp. 804-813, 1995.

- [Denoeux97] T. Denoeux, "Analysis of evidence-theory decision rules for pattern classification", *Pattern Recognition*, Vol. 30(7), pp. 1095-1107, 1997.
- [Denoeux00] Thierry Denoeux, A neural network classifier based on Dempster-Shafer theory. *IEEE Trans. On Systems, Man, and Cybernetics – Part A: Systems and Humans*, Vol 30(2), 131-150, 2000.
- [Devijver80] P.A. Devijver and J. Kittler, On the edited nearest neighbor rule, In: *Proc 5th Int. Conf on Pattern Recognition*, Los Alamitos, CA: IEEE Computer Society Press, pp. 72-80, 1980.
- [Devijver82] P.A. Devijver and J. Kittler, *Pattern recognition: A statistical approach*. Prentice-Hall, 1982.
- [Devillez04] A. Devillez, Four fuzzy supervised classification methods for discriminating classes of non-convex shape, *Fuzzy Sets and Systems*. Vol 141(2), pp. 219-240, January 2004.
- [Dimauro95] G. Dimauro, S. Impedovo, G. Pirlo, and S. Rizzo, Multiple experts; a new methodology for the evaluation of the combination processes. pp. 131-136, 1995.
- [Dimauro97] G. Dimauro, S. Impedovo, G. Pirlo, "Multiple Experts: a new methodology for the evaluation of the combination processes", *Progress in Handwriting Recognition*, ed. By A.C.Downton and S. Impedovo, World Scientific Publishing Co. Pte. Ltd., Singapore, pp. 329-335, 1997.
- [Dromigny-Badin98] A. Dromigny-Badin. *Fusion d'images par la théorie de l'évidence en vue d'applications médicales et industrielles*. Thèse, INSA de Lyon, 1998.
- [Dubois80] D. Dubois and H. Prade, *Fuzzy sets and systems: theory and applications*. New York: Academic Press, 1980.
- [Dubois82] D. Dubois and H. Prade, A class of fuzzy measures based on triangular norms, *International Journal of General Systems*, Vol. 8, pp. 43-61, 1982.
- [Dubois84] D. Dubois and H. Prade, Criteria aggregation and ranking of alternatives in the framework of fuzzy sets theory, in *Fuzzy Sets and Decision Analysis*, H.J. Zimmermann, B.R. Gaines and L.A. Zadeh, (Eds), North Holland, Amsterdam, pp. 209-240, 1984.
- [Dubois85] D. Dubois and H. Prade, A review of fuzzy sets aggregation connectives, *Information Sciences*, Vol. 36, pp. 85-121, 1985,
- [Dubois86a] D. Dubois and H. Prade, Weighted minimum and maximum operators in fuzzy sets theory, *Information Sciences*, Vol. 39, pp. 205-210, 1986.
- [Dubois86b] D. Dubois, H. Prade and C. Testemale, Fuzzy pattern matching with extended capabilities: proximity notions, importance assessment, random sets, recent developments in the theory and applications of fuzzy sets, in *Proceedings of NAFIPS'86*, New Orleans, pp.125-139, 1986.
- [Dubois88] D. Dubois and H. Prade. Representation and combination of uncertainty with belief functions and possibility measures. *Comput. Intell.*, 4 : 244-264, 1988.
- [Dubois88b] D. Dubois and H. Prade, *Théorie des possibilités, Applications à la représentation des connaissances en informatique*. deuxième édition, Masson, Paris, 1988.
- [Dubois90] D. Dubois and H. Prade, Rough fuzzy sets and fuzzy rough sets. *International Journal of General Systems*, Vol. 17, 191-209, 1990.
- [Dubois91] D. Dubois and H. Prade, "Combination of fuzzy information in the framework of possibility theory". *Data Fusion in Robotics and Machine Intelligence*, pp. 481-505, 1991.
- [Dubois92] D. Dubois and H. Prade, Combination of fuzzy information in the framework of possibility theory. In: M.A. Abidi and R.C. Gonzalez, Editors, *Data Fusion*

in Robotics and Machine Intelligence, Academic Press, New York 481–505, 1992.

- [Dubois94] D. Dubois and H. Prade, Possibility theory and data fusion in poorly informed environment. *Contr. Eng. Pract.* Vol.2, pp. 812–823, 1994.
- [Dubois98] D. Dubois and H. Prade, An introduction to fuzzy systems. *Clin. Chim. Acta* 270 pp. 3–29, 1998.
- [Dudani76] S. A. Dudani, “The distance-weighted k-nearest neighbor rule,” *IEEE Trans. SMC*, Vol. 6, pp.325-327, 1976.
- [Duin98] R. Duin, D.M.J. Tax, Classifier conditional posterior probabilities. *Advances in Pattern Recognition*, Vol. 1451, pp. 611-619, 1998.
- [Duta01] N. Duta, A.K.Jain, K.V. Mardia, matching of palmprint, *Pattern Recognition Letters*, Vol. 23 (4), 477-485, 2001.
- [Duta02] N. Duta, A.K. Jain, K.V. Mardia, Matching of palmprints, *Pattern Recognition Letters*, Vol. 23(4), pp. 477-485, 2002.
- [Dyckhoff84] H. Dyckhoff, W. Pedrycz, Generalized means as model of compensative connectives, *Fuzzy Sets and Systems*, Vol. 14, pp.143-154, 1984.
- [Ernst71] R. H. Ernst, “Hand ID system,” *USA patent No. 3576537*, 1971.
- [Elachi87] C. Elachi, Introduction to the physics and techniques of remote sensing, in: J.A. Kong (Series Ed.), *Wiley Series in Remote Sensing*, 1987.
- [El-Yacoubi00] A. El-Yacoubi, E.J.R. Justino, R. Sabourin, F. Bortolozzi, Off-line signature verification using HMMS and cross-validation, in : Proc. IEEE Workshop on Neural Networks for Signal Processing, USA, pp. 859-868, 2000.
- [Fang01] B. Fang, Y.Y. Wang, C.H. Leung, K.W. Tse, Y.Y. Tang, P.C.K.Kwok, Y.K. Wong. Off-line signature verification by the analysis of cursive strokes. *Int. J. Pattern Recognition & Artificielle Intelligence*. Vol 15(4), 659-673, 2001.
- [Fang03] B. Fang, Y.Y. Wang, C.H. Leung, K.W. Tse, Y.Y. Tang, P.C.K.Kwok, Y.K. Wong. Off-line signature verification by the tracking of feature and stroke positions. *Pattern Recognition*, Vol. 36, 91-101, 2003.
- [Farrell95] K.R. Farrell, Text-dependent speaker verification using data fusion, *IEEE International Conference on Acoustic, Speech and Signal Processing*, Detroit, Michigan, pp. 349–352, May 1995.
- [Farrell98] K.R. Farrell, R.P. Ramachandran, R.J. Mammone, An analysis of data fusion methods for speaker verification, *IEEE International Conference on Acoustic, Speech and Signal Processing*, Seattle, Washington, 1129–1132 May 1998.
- [Ferri98] F.J. Ferri, Combining adaptive vector quantization and prototype selection techniques to improve nearest neighbor classifiers. *Kybernetika* Vol. 34(4), pp. 405-410, 1998.
- [Feng04] Guiyu Feng, Kaifeng Dong, Dewen Hu and David Zhang. When Faces Are Combined with Palmprints: A Novel Biometric Fusion Strategy. *Lecture Notes in Computer Science*, Volume 3072 / 2004, Proceedings of First International Conference on Biometric Authentication:, *ICBA'2004*, Hong Kong, China, pp. 701 – 707, July 15-17, 2004.
- [Fisher36] R. A. Fisher, The use of multiple measurements in taxonomic problems, *Ann. Eugenics*, Vol. 7, pp. 179-188, 1936.
- [Fix51] E. Fix and J. L. Hodges, Discriminatory analysis, nonparametric discrimination: Consistency properties. Technical Report 4, USAF School of Aviation Medicine, Randolph Field, TX, 1951.

- [Fodor92] J. Fodor and M. Roubens, Aggregation and scoring procedures in multicriteria decision making. *In Proc. of the FUZZ'IEEE Congress*, San Diego, CA. pp. 1261-1267. 1992.
- [Funada98] J. Funada, N. Ohta, M. Mizoguchi, T. Temma, K. Nakanishi, A. Murai, T. Sugiuchi, T. Wakabayashi and Y. Yamada, Feature extraction method for palmprint considering elimination of creases, *Proceedings of the 14th Int. Conference on Pattern Recognition*, Vol. 2, pp. 1849–1854, 1998,
- [Gader91] L. Gader B. Forester, M. Ganzberger, A. Gillies, B. Mictchell, M. Whalen and T. Yocum, Recognition of handwritten digits using template and model matching. *Pattern Recognition*, Vol. 24(5), pp. 421-431, 1991.
- [Gader96] P. Gader, M. Mohamed and J. Keller, Fusion of handwritten word classifiers. *Pattern Recognition Letters*, Vol. 17, pp. 577-584, 1996.
- [Gascuel98] O. Gascuel *et al.*, Twelve numerical, symbolic and hybrid supervised classification methods. *Internat. J. Pattern Recognition and Artificial Intelligence*. Vol.12(5), pp. 517–571, 1998.
- [Geva91] S. Geva, J. Sitte, Adaptive nearest neighbor pattern classifier, *IEEE Trans. Neural Networks*, Vol. 2(2), pp. 318-322, 1991.
- [Goh03] K.O. Goh, C. Tee, B.J. Teoh and C.L. Ngo, Automated hand geometry verification system based on salient points, *The 3rd International Symposium on Communications and Information Technologies (ISCIT 2003) Songkhla, Thailand, September*, pp. 720–724, 2003.
- [Gorman03] L. O’Gorman, What is Pattern Recognition ? *IAPR Newsletter*, Volume 25, Number 1, Winter 2003.
- [Gosselin97] B. Gosselin, Cooperation of multilayer perceptron classifiers. *8th Workshop on Circuits, Systems and Signal Processing*, pp. 187-190, Mierlo, Pays-Bas, 1997.
- [Grabish95] M. Grabish, H.T. Nguyen and E.A. Walker, *Fundamentals of uncertainty calcul with applications to fuzzy inference*, Kluwer Academic Publishers Dordrecht, 1995.
- [Gruyer99] D. Gruyer. *Etude du traitement de données imparfaites pour le suivi multi-objets : Application aux situations routières*. Thèse, université de Technologie de Compiègne, 1999.
- [Gupta91] M.M. Gupta, J. Qi, Theory of T-norms and fuzzy inference methods, *Fuzzy Sets and Systems*, Vol. 40(3), pp. 431-450, 1991.
- [Hall97] D. Hall, J. L. Linas, “An introduction to multisensor data fusion”, *Proc. IEEE*, Vol 85(1), pp.6-23, 1997.
- [Hamacher76] H. Hamacher, On logical connectives of fuzzy statements and their affiliated truth function, *Proc. 3rd Eur. Meeting Cybernetics and Systems*, Vienne, 1976.
- [Hamamoto97] Y. Hamamoto, S. Uchimura, S. Tomita, A bootstrap technique for nearest neighbor classifier design, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol. 19(1), pp. 73-79, 1997.
- [Han03] C. Han, H. Cheng, C. Lin, K. Fan, “Personal authentication using palmprint features,” *Pattern Recognition*, Vol. 36, pp.371-381, 2003.
- [Han04] Chin-Chuan Han. A hand-based personal authentication using a coarse-to-fine strategy. *Image and Vision Computing*, Vol. 22(11), 909-918, September 2004.
- [HandPunch4000] Time & Attendance Terminal, HandPunch 4000, Recognition Systems Inc. www.rsibiometrics.com.
- [Hanmandlu05] M. Hanmandlu, M.H.M.Yusof, V.K.Madasu, Off-line signature verification and forgery detection using fuzzy modeling. *Pattern Recognition*, Vol.38, 341-356, 2005.

- [Hart68] P.E. Hart, The condensed Nearest Neighbor rule. *IEEE Trans. Information Theory*, Vol. 14(3), pp. 515-516, May 1968.
- [Harvey00] N. Harvey, C. Harries, I. Fischer, Using advice and assessing its quality: *Organizational Behavior and Human Performance*, 81, 252–273, 2000.
- [HaSIS97] HaSIS,1997, A hand Shape Identification System. disponible sur www.csr.unibo.it/research/Biolab/hand.htm.
- [Hattori99] K. Hattori, M. Takahashi, A new nearest-neighbor rule in the pattern classification problem, *Pattern recognition*, Vol. 32, pp. 425-432, 1999.
- [Hellman70] M. E. Hellman, The nearest neighbor classification rule with a reject option, *IEEE Trans. on Systems, Man, and Cybernetics*, Vol. 3, pp. 179-185, 1970.
- [Herrera96] F. Herrera, E. Herrera-Viedma and J. L. Verdegay, Direct approach processes in group decision making using linguistic OWA operators, *Fuzzy Sets and Systems*, Vol. 79(2), pp. 175-190, 1996.
- [Heutte94] L. Heutte, Reconnaissance de caractère manuscrits : application à la lecture automatique des chèques et des enveloppes postales, Thèse, Université de Rouen, 1994.
- [Ho94] T.K. Ho, J.J. Hull and S.N. Srihari, Decision combination in multiple classifier systems. *IEEE Trans. PAMI*, Vol. 16, pp. 66–75, 1994.
- [Huang95] Y.S. Huang and C.Y. Suen, A method of combining multiple experts for the recognition of unconstrained handwritten numerals. *IEEE Trans. PAMI*, Vol. 17(1), pp. 90-94, 1995.
- [Huang02] K. Huang, H. Yan, Off-line signature verification using structural feature correspondence, *Pattern Recognition*, Vol. 35(11), pp. 2467-2477, 2002.
- [Ismail00] M.A. Ismail, S. Gad, Off-line arabic signature recognition and verification, *Pattern Recognition*, Vol. 33, pp. 1727-1740, 2000.
- [Jacoby72] I. H. Jacoby, A. J. Giordano, and W. H. Fioretti, “Personnel Identification Apparatus,” *USA pat. N° 3648240*, 1972.
- [Jain99] A.K. Jain, A.Ross, S. Pankanti, “A prototype hand geometry-based verification system,” *Proceeding of the 2nd Int. Conf. on Audio and Video based Biometric Person Authentication*, Washington DC, pp. 166-171, 1999.
- [Janikow96] C.Z. Janikow, A genetic algorithm for optimizing fuzzy decision trees. *Inform. Sci.* 89 pp. 275–296, 1996.
- [JDL91] U.S. Department of defense, *Data fusion lexicon*, Data Fusion Subpanel of the Joint Directors of Laboratories, Technical Panel for C3, 1991.
- [Jetto99] L. Jetto, S. Longhi and D. Vitali. Localization of a wheeled mobile robot by sensor data fusion based on a fuzzy logic adapted Kalman filter, *Control Engineering Practice*, Vol. 7(6), pp. 763-771, 1999.
- [Ji97] C. Ji, and S. Ma, Combinations of weak classifiers. *Special issue of neural networks and pattern recognition, IEEE Transactions on Neural Networks*, Vol. 8(1), pp. 32-42, 1997.
- [Jozwik83] Jozwik, A learning scheme for a fuzzy k-ppv rule. *Pattern Recognition Letters*, Vol. 1, pp. 287-289, 1983.
- [Justino01] E.J.R. Justino, F. Bortolozzi, R. Sabourin, S. Justino, Off-line signature verification using HMM for random, simple and skilled forgeries, *Internat. Conf. on Document Analysis and Recognition. ICDAR'2001*. Vol. 1. Seattle, USA. pp. 105–110, 2001.
- [Justino05] E.J.R. Justino, F. Bortolozzi, and R. Sabourin, A comparison of SVM and HMM classifiers in the off-line signature verification, *Pattern Recognition Letters*, Vol. 26(9), pp. 1377-1385, 2005.

- [Kacprzyk85] J. Kacprzyk, S.A. Orlovski, Optimization models using fuzzy sets and possibility theory, ed : D. Reidel, Dordrecht, 1985.
- [Kanal74] L. Kanal Patterns in pattern recognition, *IEEE Transactions on Information theory*, Vol. 20, 697-722. 1974.
- [Karayiannis96] N.B. Karayiannis, J.C. Bezdek, N.R. Pal, R.J. Hathaway, P-I Pal, Repairs of GLVQ: a new family of competitive learning schemes, *IEEE Trans. Neural Networks*, Vol. 7, pp. 1062-1071, 1996.
- [Keeney76] R.L. Keeney and H. Raiffa, Decisions with multiple objectives, John Wiley and Sons, New York, 1976.
- [Keller85] J.M. Keller, M.R. Gray and J.A. Givens, Jr., A fuzzy k -nearest neighbor algorithm. *IEEE Trans. SMC* 15(4), pp. 580-585, 1985.
- [Kelly91] J.D. Kelly, L. Davis Jr. Hybridizing the genetic algorithm and the k -nearest neighbors classification algorithm. *Proc. 4th International Conf. on Genetic Algorithms*, San Diego, CA, 377-382, 1991.
- [Kelman96] A. Kelman, *Modèles flous pour l'agrégation de données et l'aide à la décision*. Thèse, Université de Paris 6, 1996.
- [Kelman95] A. Kelman, R. Yager, Compatibilité et agrégation partielle : méthode de fusion modulaire. *Logique floue et ses applications, LFA'95*, Paris, pp. 73-79, 1995.
- [Kettler97] J. Kittler, A. Hojjatoleslami, T. Windeatt, Strategies for combining classifiers employing shared and distinct pattern representations. *Pattern Recognition Letters*, Vol. 18, pp. 1373-1377, 1997.
- [Kim95] H. kim, P.H. Swan, Evidential reasoning approach to multisource data classification in remote sensing, *IEEE Trans. SMC*, 25(8), 1257-1265, 1995.
- [Kim00] J. Kim, K. Kim, C. Nadal and C. Suen, A methodology of combining HMM and MLP classifiers for cursive word recognition. *International Conference on Document Analysis and Recognition (ICDAR)*, Vol. 2, pp. 319-322, 2000.
- [Kimura91] F. Kimura, M. Shridhar, Handwritten numeral recognition based on multiple algorithms. *Pattern Recognition*, Vol. 24(10), 1991.
- [Klein98] F. Klein, *Etude comparative de méthodes de classification floues*, Thèse de doctorat en Génie Automatique, Université de Reims Champagne Ardenne, 1998.
- [Klein98b] L.A. Klein , A Boolean algebra approach to multiple sensor voting fusion. *IEEE Transactions on Aerospace and Electronic Systems*, Vol. 29(2) pp. 317-327, 1998.
- [Klette94] R. Klette, P. Zamperoni, *Handbook of Image Processing Operators*, Ed. Wiley 1994.
- [Klir95] G.J. Klir, B. Yuan, *Fuzzy sets and fuzzy logic theory and applications*. NJ: Prentice Hall, 1995.
- [Kohonen95] T. Kohonen, *Self-organizing maps*, Germany, Springer, 1995.
- [Kong02] W. K. Kong and D. Zhang, palmprint texture analysis based on low-resolution images for personal authentication," *Proc. ICPR-2002*, Quebec City, Canada.
- [Kong03] W.K. Kong, D. Zhang and W. Li. Palmprint feature extraction using 2-D Gabor filters. *Pattern Recognition*, 36(10), pp. 2339-2347, 2003.
- [Kong04] A.W-K Kong and D. Zhang. Feature-Level Fusion for Effective Palmprint Authentication. *Lecture Notes in Computer Science*, Vol. 3072 / 2004, *Proceedings of First International Conference on Biometric Authentication:*, ICBA 2004, Hong Kong, China, 761-767, July 15-17, 2004.
- [Kowalski79] R. Kowalski, *Logic for Problem Solving*, North-Holland, Amsterdam, 1979.
- [Krinsnapuram93] R. Krinsnapuram, J. Keller, A possibilistic approach to clustering, *IEEE Trans. on Fuzzy Systems*, Vol. 1, pp. 98-109, 1993.

- [Kruse94] R. Kruse, J. Gebhardt, F. Klawonn, *Foundations of fuzzy systems*. New York: Wiley, 1994.
- [Kumar02] A. Kumar, H.C. Shen, "Recognition of palmprints using wavelet-based features", *SCI-2002*, Orlando, Florida, 2002.
- [Kumar03] A. Kumar, D.C.M. Wong, H.C. Shen, A.K. Jain. Personal Verification Using Palmprint and Hand Geometry Biometric. *Lecture Notes in Computer Science* Publisher: Springer-Verlag GmbH Vol. 2688 / 2003. Chapter: pp. 668-678, 2003.
- [Kumar04] A. Kumar, D. Zhang. Palmprint authentication using multiple classifiers. *Proceedings of SPIE*, Vol. 5404, pp. 20-29, August 2004.
- [Kuncheva95] L.I. Kuncheva, Editing for the k-nearest neighbors rule by a genetic algorithm. *Pattern Recognition Letters*. Vol.16, pp. 809-814, 1995.
- [Kuncheva95] L.I. Kuncheva, Fitness functions in editing k-NN reference set by genetic algorithms. *Pattern Recognition*. Vol. 30, pp. 1041-1049, 1997.
- [Kuncheva98] L.I. Kuncheva and J.C. Bezdek, An integrated framework for generalised nearest prototype classifier design. *Int. J. Uncertainty, Fuzziness and Knowledge-Based Systems*, Vol. 6 (5), 437-457, 1998.
- [Kuncheva01] L.I. Kuncheva, J.C. Bezdek and R.P.W. Duin, Decision templates for multiple classifier fusion: an experimental comparison. *Pattern Recognition*, Vol. 34(2), pp. 299-314, 2001.
- [Laugt99] D. Laugt, *Calcul de la dimension fractale locale*, Ecole Polytechnique Universitaire de Tours, Département Informatique, 1999-2000.
- [Leclerc94] F. Leclerc and R.Plamondon. Automatic signature verification: the state of the art-1989-1993. *International Journal of Pattern Recognition and Artificial Intelligence*, 8(3) 643-660, 1994.
- [Lee92] S. lee, J. C. Pan, Off-line tracing and representation of signatures, *IEEE Trans. Systems Man Cybernetics*, SMC-22, 755-771, 1992.
- [Li98] Y. Li, A. Jain, Classification of text documents, *The computer Journal*, Vol. 41(8), pp. 537-546, 1998.
- [Li02] W. Li, D. Zhang, and Z. Xu, "Palmprint identification by Fourier transform," *IJPRAI*, 16(4), pp. 417-432, 2002.
- [Li03] W. Li, D. Zhang and Z. Xu, Palmprint identification by Fourier Transform, *International Journal of Pattern Recognition and Artificial Intelligence* 16 (4), 417-432, 2003.
- [Liang03] L. R. Liang and C. G. Looney, Competitive fuzzy edge detection, *App. Soft Comp.*, 3(2), 2003, 123-137.
- [Liao97] T. Warren Liao, Damin Li, Two applications of the fuzzy k-ppv algorithm, *Fuzzy sets and systems* Vol. 92, 1997, pp. 289-303.
- [Lefevre01] E. Lefevre, Fusion adaptée d'informations conflictuelles dans le cadre de la théorie de l'évidence, application au diagnostic médical. Thèse, INSA de Rouen. 2001.
- [Looney02] C.G. Looney, Radial basis functional link nets &fuzzy reasoning, *Neurocomputing*, 48(1-4), 2002, pp. 489-509.
- [Lu03] G. Lu, D. Zhang and K. Wang, Palmprint recognition using eigenpalms features, *Pattern Recognition Letters*, Vol. 24(9-10), pp. 1463-1467, 2003.
- [Luo97] W. B. Luo and B. Caselton, "Using Dempster-Shafer theory to represent climate change," *Journal of Environment Management*, Vol. 49, pp. 73-93, 1997.

- [MacLeod87] J.E. MacLeod87, A. Luk, and D. M. Titterington, A re-examination of the distance-weighted k-nearest neighbor classification rule, *IEEE SMC* Vol. 17(4), pp. 689-696, 1987.
- [Mandelbrot83] B. Mandelbrot, *The Fractal Geometry of Nature*, Freeman, New York, 1983.
- [Martinez04] L.E. Martinez, C.M. Travieso, J.B. Alonso, M.A Ferrer, Parameterization of a forgery handwritten signature verification system using SVM, in *Proceeding of the IEEE 38th Annual 2004 International Carnahan Conference on Security Technology*, Albuquerque, New Mexico, pp. 193-196, October 2004.
- [Miller71] R. P. Miller, "Finger dimension comparison identification system," *USA patent No. 3576538*, 1971.
- [Mitchell01] H.B. Mitchell, P.A. Schaefer, A soft k-Nearest Neighbor voting scheme, *Int. J. of Intelligent Systems*, Vol. 16, pp. 459-468, 2001.
- [Morin81] R.L. Morin and D.E. Raeside, A reappraisal of the distance-weighted k-nearest neighbor classification for pattern recognition with missing data, *IEEE Trans. on Systems, Man, and Cybernetics*, Vol. 11, no. 3, pp. 241-243, 1981.
- [Munoz03] X. Muñoz, J. Freixenet, X. Cufí and J. Martí. Strategies for image segmentation combining region and boundary information. *Pattern Recognition Letters* 24 (1-3), 2003, 375-392.
- [Nadal90] C. Nadal, R. Legault, and C.Y. Suen, "Complementary Algorithms for the Recognition of Totally Unconstrained Handwritten Numerals," in *Proc. 10th Int. conf. Pattern Recognition.*, Vol. A, pp. 434-449, June 1990.
- [Oden03] C. Oden, A. Ercil, and B. Buke, "Combining implicit polynomials and geometric features for hand recognition," *Pattern Recognition letters*, Vol. 24(13), pp. 2145-2152, 2003.
- [Odorico97] R. Odorico, Learning vector quantization with training counters (LVQTC). *Neural Networks*, Vol. 10(6), pp. 1083-1088, 1997.
- [O'Hagan90] M. Ohagan, Using maximum entropy-ordered weighted averaging to construct a fuzzy neuron, *Proc. of the 24th Annual IEEE Asilomar Conf. On Signals, Systems and Computers*, Pacific Grove, CA, pp. 618-623, 1990.
- [Ong03] M.G.K. Ong, T. Connie, A.T.B. Jin, A single-sensor hand geometry and palmprint verification system, *Proc. of ACM SIGMM Workshop on Biometrics Methods and Applications*, pp. 100-106, Berkley, California, USA, 2003.
- [Ouhaddi98] H. Ouhaddi et P Horain, "Conception et ajustement d'un modèle 3D articulé de la main", 1998, *Institut National des Télécommunications dep. Signal et Image*, <http://www-eph.int-evry.fr/~horain/Publications/gt-rv98-ouhaddi.pdf> et *TDSPP-ouhaddi.pdf*.
- [Oussalah98] M. Oussalah. Fusion de données par la théorie des possibilités, application à la localisation d'un robot mobile. Thèse, Université d'Evry Val d'Essonne (EVE), 1998.
- [Oussalah01] M. Oussalah, H. Maaref and C. Barret, New fusion methodology approach and application to mobile robotics: investigation in the framework of possibility theory. *Information Fusion*, Vol. 2(1), pp.31-48. 2001.
- [Oussalah03] M. Oussalah. On the use of Hamacher's t-norms family for information aggregation, *Information Sciences*, Vol. 153, pp. 107-154 July 2003.
- [Otsu78] N. Otsu, "A threshold selection method from gray-scale histogram," *IEEE Trans. SMC*, Vol. 8, 62-66, 1978.
- [Oxenham96] M.G. Oxenham, D.J. Kewley, M. J. Nelson, "Measure" of information for multi-level data fusion , *SPIE*, Vol. 2755, pp.271-282, 1996.
- [Pal93] N. Pal, S. Pal, A review on segmentation techniques. *Pattern Recognition*, Vol. 26(9), pp. 1277-1294, 1993.

- [Palacharla97] P.V. Palacharla, "A pattern recognition approach to data fusion in Intelligent Vehicle Highway Systems., *Transportation Research Part A: Policy and Practice*, Vol. 31(1), pp. 64-65, Jan 1997.
- [Pavlidis98] I. Pavlidis, N.P. Papanikolopoulos, R. Mavuduru, Signature identification through the use of deformable structures, *Signal Processing*, Vol. 71(2), pp. 187-201, 1998.
- [Pavlidis90] T. Pavlidis and Y. Liow, Integrating region growing and edge detection. *IEEE Trans. on Pattern Analysis and Machine Intelligence* Vol. 12 (3), pp. 225–233, 1990.
- [Plamondon89] R. Plamondon and G. Lorette , Automatic signature verification and writer identification—the state of art. *Pattern Recognition*, 22(2), pp.107–131, 1989.
- [Plamondon00] R. Plamondon and S.N. Srihari, On-line and off-line handwriting recognition: a comprehensive survey. *IEEE Trans. PAMI*. Vol. 14(1) pp.3-19, 2000.
- [Pohl98] C. Pohl, and J.L. Van Genderen, Multisensor image fusion in remote sensing: Concepts, methods and applications. *International Journal of Remote Sensing* Vol.19(5), pp. 823–854, 1998.
- [Poon04] C. Poon, D.C.M. Wong and H.C. Shen. Personal Identification and Verification: Fusion of Palmprint Representations. Lecture Notes in Computer Science, Vol. 3072 / 2004, Proceedings of First International Conference on Biometric Authentication, ICBA 2004, Hong Kong, China, pp. 782 – 788, July 15-17, 2004.
- [Prevost03] L. Prevost, C. Michel-Sendis, A. Moises, L. Oudot, M. Milgram. Combining model-based and discriminative classifiers: application to handwritten character recognition. In *7th International Conference on Document Analysis and Recognition*, Vol. 1, pp. 31-35, 2003.
- [Qi94] Y. Qi, B.R. Hunt, Signature verification using global and grid features, *Pattern Recognition*, Vol. 27(12), pp. 1621-1629, 1994.
- [Quek02] C. Quek, R.W. Zhou. Antiforegory: a novel pseudo-outer product based fuzzy neural network driven signature verification system. *Pattern Recognition Letters*, Vol. 23, pp. 1795-1816, 2002.
- [Rabiner89] L.R.Rabiner, A tutorial on hidden Markov models and selected applications in speech recognition, *Proc. of IEEE*, Vol.77(2), pp. 257-286, 1989.
- [Rahman03] A. Rahman and M. Fairhurst, Multiple classifier design combination strategies for character recognition: a review. *Journal Document Analysis and Recognition JDAR*, pp. 166-194. 2003.
- [Ramesh99] V. E. Ramesh, M.N. Murty, Off-line signature verification using genetically optimized weighted features, *Pattern Recognition*, Vol. 32, pp. 217-233, 1999.
- [Rantilla99] A.K. Rantilla, and D.V. Budescu, Aggregation of expert opinions. In *Proceedings of the 32nd Annual Hawai'i International Conference on Systems Sciences*. 1999.
- [Reillo00] R. Sanchez-Reillo, "Hand geometry pattern recognition through Gaussian mixture modelling," *15th Int. Conf. on Pattern Recognition*, Vol. 2, pp. 937-940, September 2000.
- [Reillo00b] R. Sanchez-Reillo, C. Sanches-Avila, and A. Gonzales-Marcos, "Biometric identification through hand geometry measurements," *IEEE Trans. Pattern Anal. Mach. Intell.* Vol. 22 (10), pp.1168-1171, 2000.
- [Rouchouze94] C. Rouchouze, Fusion de données : exemples Défense et axes de recherche, *Traitement du signal*. Vol. 11(6), pp. 459-464. 1994.

- [Roy68] B. Roy Classement et choix en présence de points de vue multiples (la méthode ELECTRE), *Revue Française d'Informatique et de Recherche Opérationnelle*, Vol. 8, pp. 57-75, 1968.
- [Sabourin94] M. Sabourin et G. Genest. Coopération de classifieurs pour la vérification automatique des signatures. In *3eme Colloque National sur l'Ecrit et le Document*, pp. 89-98, Rouen, 1994.
- [Sabourin97] R. Sabourin, G. Genest and F. Preteux , Offline signature verification by local granulometric size distributions. *IEEE Trans. PAMI* 19(8), pp. 976-988, 1997.
- [Salotti92] M. Salotti and Garbay. A new paradigm for segmentation. *International Conference on Pattern Recognition*, Vol. C, 1992, 611–614.
- [Sasiadek02] J. Z. Sasiadek Sensor fusion, *Annual Reviews in Control*, Vol. 26(2), pp.203-228, 2002.
- [Serpico95] S.B. Serpico and F. Roli, Classification of multisensor remote sensing images by structured neural networks. *IEEE Trans. Geosci. Remote Sensing* 33 (3), pp. 562–578, 1995.
- [Sethian99] J. Sethian, *Level set methods: evolving interfaces in geometry, fluid mechanics, computer vision and materials*, Cambridge University Press, 1999.
- [Shafer76] G. Shafer. A Mathematical Theory of Evidence. Princeton University Press, Princeton, NJ, 1976.
- [Shalak94] D.B. Shalak, Prototype and feature selection by sampling and random mutation hill climbing algorithms, In: *Proc 11th Int; Conf. On Machine Learning, New Brunswick*, NJ. Los Alamitos, CA: Morgan Kaufmann, pp. 293-301, 1994.
- [Shi01] W. Shi, G. Rong, Z. Bain, and D.Zhang. Automatic palmprint verification. *Int. J. Image and Graphics*, Vol. 1(1), pp. 135-152, 2001.
- [Shu98] W. Shu, D. Zhang. Palmprint verification: an implementation of biometric technology. *14th Int. Conference on Pattern Recognition*. Australia, Vol. 1, pp. 219-221, 1998.
- [Shu98] W. Shu, D. Zhang. Automated personal identification by palmprint. *Optical Engineering*, Vol. 37 (8), 2659-2362, 1998.
- [Silver79] W. Silver, Symmetric Summation : a class of operations on fuzzy sets. *IEEE Trans. on SMC*, Vol. 9, pp. 659-667, 1979.
- [Simone02] G. Simone, A. Farina, F. C. Morabito, S. B. Serpico and L. Bruzzone. Image fusion techniques for remote sensing applications. *Information Fusion* Vol 3(1), pp. 3-15, March 2002,.
- [Smets90a] P. Smets. The combination of evidence in the transferable belief model. *IEEE Transactions on Pattern Analysis and Machine intelligence*, 12(5) pp. 447-458, 1990.
- [Smets90b] P. Smets, Constructing the pignistic probability function in a context of uncertainty, in M. Henrion, R. D. Schachter, L. N. Kanal, and J.F. Lemmer, editors, *Uncertainty in Artificial Intelligence*, Vol. 5, pp. 28-40, Amsterdam, North-Holland, 1990.
- [Smets00] P. Smets. Quantified possibility theory seen as an hyper cautious transferable belief model. LFA'2000, pp. 343-353, La Rochelle, 2000.
- [Solberg96] A.H.S. Solberg, T. Taxt and A.K. Jain, A Markov random field model for classification of multisource satellite imagery. *IEEE Transactions on Geoscience and Remote Sensing* 34 1, pp. 100–112, 1996
- [Sugeno74] M. Sugeno, Theory of fuzzy integrals and its application, Doctoral Thesis, Tokyo Institute of Technology, 1974.

- [Sugeno77] M. Sugeno, Fuzzy measures and fuzzy integrals: a survey, in *Fuzzy Automata and Decision Process*, M.M. Gupta, G.N. Saridis & B.R. Gaines (eds.), Amsterdam: North-Holland Pub, pp. 89-102, 1977.
- [Survey03] Hand-based biometrics. Survey, *Biometric Technology Today*, Vol. 11(7), pp. 9-11, July 2003.
- [Tahani90] H. Tahani and J.M. Keller, Information fusion in computer vision using the fuzzy integral. *IEEE Trans. SMC*. Vol. 20, pp. 733–741, 1990.
- [Taxt97] T. Taxt and A.H.S. Solberg. « Information fusion in remote sensing. *Vistas in Astronomy*, Vol 41(3), pp. 337-342(6), 1997.
- [Toh03] K-A, Toh, W. Xiong, W-Y, Yau, X. Jiang, Combining fingerprint and Hand geometry verification decisions, *Lecture Notes in Computer Science*, Publisher: Springer-Verlag BmbH, Vol. 2688/2003, pp. 688-696, 2003.
- [Travieso04] C.M Travieso, J.B. Alonso, S. David, M.A. Ferrer, “Optimization of a biometric system identification by hand geometry” *Proc. of Complex Systems Intelligence & Modern Technological Applications (CSIMTA'04)*, Cherbourg, France, pp. 581-586, 19-22, September 2004.
- [Valet00] L.Valet, G. Mauris and Ph. Bolon. A statistical overview of recent literature in information fusion. In Proceeding 3rd International Conference Fusion 2000, Paris, July 2000, pp. MOC3-22-29, IEEE catalog 00EX438, ISBN-2-7257-00001-9, 2000.
- [Valet01] L. Valet, G. Mauris, Ph Bolon, A statistical overview of recent literature in information fusion, *IEEE Aerospace and Electronic Systems Magazine*. Vol. 16(3), pp. 7-14, 2001.
- [Van-Erp00] M. Van-Erp, and L. Schomaker. Variants of the Borda count method for combining ranked classifier hypotheses. In L. Schomaker and L. Vuurpijl, editors, 7th International Workshop on Frontiers in Handwriting Recognition, pp. 443-452, Amsterdam, 2000.
- [Vincent96] N. Vincent, C. Dujet, A new class of aggregation operators for data fusion in fuzzy sets, *IPMU'96*, Geenda, pp.465-470, 1996.
- [Vincent97] N. Vincent, C. Dujet, Un opérateur de fusion de données s'adaptant au contexte d'utilisation, *LFA'97*, Lyon, pp. 349-356, 3-4 décembre 1997.
- [Vincent00] N. Vincent, V. Boulétreau, R. Sabourin, H. Emptoz. How to use fractal dimensions to qualify writings and writers, *Fractals*, World Scientific, Vol 8, n°1, pp. 85-97, 2000.
- [Waltz90] E. Waltz and J. Llinas. Multisensor data fusion. Artech House, 1990.
- [Wald02] L. Wald, *Data fusion, Definition and architectures, Fusion of images of different spatial resolutions*. Presses de l'Ecole des Mines Paris, 2002.
- [Weber83] S. Weber, A general concept of fuzzy connectives, negations and implications based on T-norms and T-conorms, *Fuzzy Sets and Systems*, Vol. 11, pp. 115-134, 1983.
- [Wilson72] D.L. Wilson, Asymptotic properties of nearest neighbor rules using edited data. *IEEE Trans. on SMC*, Vol. 2, pp. 408-421, 1972.
- [Woods92] K. Woods, W. P. Kegelmeyer Jr., and K. Bowyer. Combination of multiple classifiers and their applications to handwritten recognition. *IEEE Trans. SMC*, 22(3) pp. 418-435, 1992.
- [Wong02] A.L.N. Wong, P. Shi, “Peg-Free Hand Geometry Recognition Using Hierarchical Geometry and Shape Matching, disponible sur internet <http://www.ee.ust.hk/~eeship/Papers/MVA02.pdf>

- [Wu02] X. Wu, K. Wang and D. Zhang, Fuzzy directional element energy feature (FDEEF) based palmprint identification, *International Conference on Pattern Recognition* Vol. 1, pp. 95–98, 2002.
- [Xiao02] X. Xiao, G. Leedham, “Signature verification using a modified Bayesian network”, *Pattern Recognition*, Vol. 35, pp. 983-995, 2002.
- [Xie93] Q. Xie, C.A. Laszlo, R.K. Ward, Vector quantization technique for nonparametric classifier design, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 15(12), pp. 1336-1330, 1993.
- [Xu92] L. Xu, A. Krzyzak and C.Y. Suen, Methods of combining multiple classifiers and their applications to handwriting recognition. *IEEE Transactions on Systems, Man and Cybernetics*, Vol. 22(3), pp. 418–435, 1992.
- [Yager 80] R.R. Yager, An approach to inference in approximate reasoning, *International J. Man-Machine Studies*, Vol. 13, pp. 323-338, 1980.
- [Yager 82] R.R. Yager, Levels sets for membership evaluation of fuzzy subsets, in : Fuzzy sets and possibility theory : recent developments”. ed : R.R. Yager, Pergamon Press, Oxford pp 90-97, 1982.
- [Yager 83] R.R. Yager, Hedging in the combination of Evidence. *Journal of Information and Optimization Sciences*, Vol. 4(1), pp. 73-81, 1983.
- [Yager 83b] R.R. Yager, An introduction to application of possibility theory, *Human Systems Managements*, Vol 3, pp. 246-249, 1983.
- [Yager87] R.R. Yager. On the Dempster-Shafer framework and new combination rules. *Information Sciences*, 1987, 41 : 93-138.
- [Yager87b] R.R. Yager, Ovchinnikov S, Tong RM, Nguyen HT, editors. Fuzzy sets and applications — selected papers by LA Zadeh. New York: Wiley, 1987.
- [Yager88] On ordered weighted averaging aggregation operators in multicriteria decision making, *IEEE Trans. SMC*, Vol. 18, pp. 183-190, 1988.
- [Yager92] R.R.Yager, Expert systems using fuzzy logic, in: *An introduction to fuzzy logic applications in intelligent systems*, R.R. yager and L. Zadeh (eds), Kluwer, 1992.
- [Yager93] R.R. Yager, A general approach to criteria aggregation using fuzzy measures, *Int. J. Man-Machine Studies*, Vol. 38, pp. 187-213, 1993.
- [Yager94a] R.R. Yager, Aggregation operators and fuzzy systems modeling, *Fuzzy Sets and Systems*, Vol. 67, pp. 129-146, 1994.
- [Yager94b] R.R. Yager, On weighted median aggregation, *Int. J. of Uncertainty, Fuzziness and knowledge-Based Systems*, Vol. 2, pp. 101-113, 1994.
- [Yager02] R.R. Yager, The induced fuzzy integral aggregation operator. *International Journal of Intelligent Systems*. Vol. 17, no. 11, pp. 1049-1065. Nov. 2002.
- [Yang02] M.H. Yang, D.J. Kriegman, N. Ahuja, “Detecting faces in images: A survey,” *IEEE PAMI*, Vol. 24, pp. 34-58, 2002.
- [You02] J. You, W. Li, and D. Zhang, “Hierarchical palmprint identification via multiple feature extraction,” *Pattern Recognition*, Vol. 35, pp. 847-859, 2002.
- [Yu00] K. Yu, X. Jiang, H. Bunke, Combining acoustic and visual classifiers for the recognition of spoken sentences, *Int. Conf. in Pattern Recognition (ICPR)*, Vol. 2, pp. 491-498, Barcelona, 2000.
- [Zadeh65] L.A. Zadeh. Fuzzy sets, *Information Control*, Vol. 8, pp. 338–353, 1965.
- [Zadeh71] L.A. Zadeh, Similarity relations and fuzzy orderings, *Informations Sciences*, 1971.
- [Zadeh78] L.A. Zadeh. Fuzzy sets as a basis for possibility theory. *Fuzzy Sets and Systems*, Vol. 1, pp. 3-28, 1978.

- [Zadeh79] L.A. Zadeh. A theory of approximate reasoning, in: J.E. Hayes, D. Mitchie, L.I. Mikulich, Eds. *Machine Intelligence*, Vol. 9, pp. 149-194, Wiley, New York, 1979.
- [Zadeh83] L.A. Zadeh. A computational approach to fuzzy quantifiers in natural languages, *Computing and Mathematics with Applications*, Vol. 9, pp. 149-184, 1983.
- [Zimmer03] A. Zimmer, and L. Ling, A Hybrid On/Off-Line Handwritten Signature Verification System, *7th ICDAR 2003*, Edinburgh, Scotland, 3-6 August 2003.
- [Zimmermann80] H.J. Zimmermann and P. Zysno, Latent connectives in human decision making, *Fuzzy sets and Systems*, Vol. 4, pp. 37-51, 1980.
- [Zhang03] D. Zhang, J. You. Online palmprint identification, *IEEE Transactions on Pattern Analysis and Machine Intelligence*. Vol. 25 (9), 1041-1050, 2003.
- [Zhang99] D. Zhang, W. Shu. Two novel characteristics in palmprint verification: datum point invariance and line feature matching. *Pattern Recognition*, Vol. 32 (4), 691-702, 1999.
- [Zois99] E. Zois and V. Anastassopoulos, Fusion of correlated decisions for writer verification. *Pattern Recognition*, Vol. 32, pp. 1821-1823, 1999.
- [Zouari04] H.K. Zouari, Contribution à l'évaluation des méthodes de combinaison parallèle de classifieurs par simulation. Thèse, Université de Rouen, 2004
- [Zouhal98] L.M. Zouhal and T. Denoeux, "An evidence-theoretic k-NN rule with parameter optimization," *IEEE Trans. on Sys., Man and Cyber.*, Part C, Vol. 28(2), pp. 263-273, 1998.

Résumé

La fusion de données est une discipline remplie de points forts et de difficultés de toutes sortes. Elle prend une place de plus en plus importante dans de nombreux domaines. Les méthodes développées sont variées mais jusqu'à présent aucune n'est suffisante pour tous les types d'information ou de sources. Parmi les méthodes, on compte les opérateurs d'agrégation ou de vote, l'utilisation des réseaux de neurones artificiels, les chaînes de Markov cachées, la logique floue, les théories de l'incertain (théorie de l'évidence, théorie des possibilités, théorie des probabilités), etc. Une étude comparative des approches de fusion, en prenant en compte différents aspects du problème traité est présentée au travers d'applications à l'identification et à l'authentification des personnes par la géométrie de la main ou par une signature manuscrite hors ligne. Dans notre méthodologie, plusieurs classifieurs basés sur différents ensembles de caractéristiques sont d'abord réalisés. D'une part nous présentons des caractéristiques traditionnelles et des caractéristiques plus spécifiques à un système de biométrie (globales, statistiques, et géométriques). D'autre part nous avons segmenté l'ensemble de caractéristiques selon chaque type de caractéristiques pour accentuer l'information qu'elles peuvent apporter à la résolution des problèmes et puis nous avons réalisé la fusion. Le travail comporte donc en premier lieu une étude critique des méthodes existantes et en deuxième lieu un apport lié à l'utilisation de la notion du flou dans ce domaine. Nous proposons un formalisme flou pour définir les degrés d'appartenance d'une forme inconnue aux différentes classes, il repose sur l'information de distance, sur les variations de distance dans les k-plus proches voisins (k-ppv) de la forme entrante, sur le nombre d'occurrences des classes et sur les rangs des classes des k-ppv. Nous introduisons trois paramètres pour définir différents poids et nous montrons que l'optimisation de l'un d'entre eux donne un caractère très général au formalisme flou proposé quand il est employé comme une règle des k-ppv. Ce formalisme proposé est également employé pour définir les masses d'évidence dans la théorie de l'évidence et pour modéliser les distributions de possibilités dans la théorie des possibilités. Enfin, il est utilisé dans une méthodologie de fusion des classifieurs. Son emploi multiple, sa simplicité de mise en œuvre et sa robustesse nous conduisent à conclure qu'il constitue une approche efficace. En traitant deux applications, nous montrons que la fusion de classifieurs au niveau représentation (mesure de distance), est plus riche en information et plus pertinente que les deux autres types d'information décision et rang. Une des approches développées, la théorie de l'évidence, est employée également pour la détection de contours vue comme une fusion au niveau du pixel. Dans ce cas, on s'intéresse à l'interprétation pixel par pixel des cartes de contours, ce qui demande un système de fournir des informations de contours par des points de vue multi aspects. Les applications traitées montrent le caractère générique du travail.

Abstract

Data fusion is a discipline with many of strong points and difficulties of all kinds. It takes an increasingly important place in many fields. Various methods are developed but until now none of them is satisfactory for all the types of information or sources. The methods studied at large are aggregation operators, majority voting rules, artificial neuronal networks, hidden Markov models, fuzzy logic, the theories of uncertainty (evidence theory, possibility theory, probability theory) etc. A comparative study of various data fusion approaches in case of two applications personal identification and authentication through hand geometry and handwritten signatures, taking into account various aspects of problems is presented. In our methodology several classifiers based on various feature sets are initially created. On the one hand we are presenting traditional features and some features more specific to a biometric system (global, statistical, and geometrical). On the other hand the whole features set is divided into various subsets according to the information brought by each type of features to problem solving and then their fusion is carried out with the help of various methods. Work thus comprises first a critical study of the existing methods and secondly our contribution constituting a fuzzy approach in this field. We are proposing a fuzzy formalism to define various membership levels of an unknown pattern "x" to various classes based on the distance information from x to its k-Nearest Neighbors, on the distance variations within the k-Nearest Neighbors (k-NN), on the number of neighbors belonging to each class and the rankings of the classes of k-Nearest Neighbors. We are introducing three parameters to assign various weights to these variables and it has been shown that the optimization of these parameters gives a very general character to our proposed fuzzy formalism when it is employed as a k-NN rule. The proposed membership function is also employed to define the evidence masses in the evidence theory and the possibility distributions in possibility theory. Lastly, it is used in a fusion methodology to combine classifiers with creation of meta-classifier. Its multiple uses, its simplicity to employ and its robustness lead to conclude that it constitutes an effective approach. By performing two biometric applications, the fusion of classifiers on intermediate level (distance measurement level), being richer in information and more relevant than the other two fusion levels (decision and ranking levels), is found more robust. One of the developed approaches, evidence theory, is also employed for an edge detection problem where a pixel level fusion is carried out. In this case, pixel by pixel information is first acquired from the edge maps which are obtained with the help of various classical edge detectors from the point of view of multiple aspects. The treated applications show the generic character of work.