

UNIVERSITÉ PIERRE ET MARIE CURIE - PARIS 6

HABILITATION À DIRIGER DES RECHERCHES

Spécialité **Informatique**

**Méthodes basées sur la perception pour  
caractériser les objets complexes:  
odeurs, textures...**

**Mohammed RAMDANI**

soutenue le 7 juin 2001

devant le jury composé de :

Mme Bernadette BOUCHON-MEUNIER	Rapporteur
M. Louis WEHENKEL	Rapporteur
M. Khaldoun ZREIK	Rapporteur
M. Herman AKDAG	Examineur
M. Patrick GALLINARI	Président
M. Dan RALESCU	Examineur
Mme Michèle SEBAG	Examineur



# Table des matières

<b>1</b>	<b>Thématiques des activités de recherche</b>	<b>7</b>
1.1	Introduction . . . . .	7
1.2	Présentation générale . . . . .	10
<b>2</b>	<b>Arbres de décisions flous et reconnaissance d'odeurs</b>	<b>13</b>
2.1	Introduction . . . . .	13
2.2	Le système d'apprentissage flou interactif (SAFI) . . . . .	14
2.2.1	Interaction numérique-symbolique . . . . .	14
2.2.2	Développement de l'arbre de décision flou . . . . .	18
2.2.3	Classification floue avec les degrés de satisfiabilité . . . . .	18
2.2.4	Le système SCOAD . . . . .	20
2.3	Le système Salammbô . . . . .	20
2.4	La reconnaissance d'odeur . . . . .	22
2.4.1	Description des données chimiques utilisées . . . . .	23
2.4.2	Classification en deux classes . . . . .	24
2.4.3	Classification en trois classes . . . . .	25
2.4.4	Utilisation des descripteurs GESDEM et physico-chimiques . . . . .	27
2.5	Conclusion . . . . .	32
	Bibliographie du chapitre . . . . .	34
<b>3</b>	<b>Caractérisation de la texture</b>	<b>35</b>
3.1	La texture . . . . .	35
3.2	Méthode des longueurs de plages uniformes (LDP) . . . . .	36
3.3	Les plages floues . . . . .	37
3.3.1	Les sous-ensembles flous de niveaux de gris . . . . .	37
3.3.2	Définition des plages floues . . . . .	38
3.4	Plages floues dominantes . . . . .	39
3.4.1	Les matrices de longueurs de plages floues dominantes . . . . .	40
3.5	Paramètres de longueurs de plages floues dominantes (LPDF) . . . . .	42
3.5.1	Utilisation des paramètres flous pour la caractérisation de la texture . . . . .	43

3.6 Conclusion . . . . .	47
Bibliographie du chapitre . . . . .	48
<b>4 Architecture hybride pour la surveillance d'un réseau local</b>	<b>49</b>
4.1 Introduction . . . . .	49
4.2 Surveillance automatique d'un réseau local . . . . .	50
4.2.1 Architecture générale du modèle . . . . .	51
4.2.2 Le module neuro-flou . . . . .	51
4.3 Module apprentissage . . . . .	54
4.4 Quelques éléments sur l'application de la surveillance d'un réseau local . . . . .	55
4.5 Recueil des données et apprentissage . . . . .	56
4.6 Discussion et conclusion . . . . .	56
Bibliographie du chapitre . . . . .	59
<b>5 Conclusion générale et perspectives</b>	<b>61</b>
<b>Bibliographie</b>	<b>64</b>
<b>Table des figures</b>	<b>71</b>
<b>Annexes</b>	<b>71</b>
<b>A Autres activités depuis ma thèse</b>	<b>75</b>
A.1 Participation à des projets . . . . .	75
A.2 Encadrement et Participation à des jurys . . . . .	75
A.2.1 Thèses . . . . .	75
A.2.2 DEA . . . . .	76
A.2.3 Projets de fin d'études en relation avec l'industrie. . . . .	76
A.3 Responsabilités scientifiques . . . . .	76
A.4 Responsabilités administratives . . . . .	77
<b>B Curriculum vit</b>	<b>79</b>
B.1 Etat civil . . . . .	79
B.2 Titres universitaires . . . . .	79
B.3 Carrière universitaire . . . . .	80
B.4 Publications . . . . .	80
B.4.1 Livre . . . . .	80
B.4.2 Revues internationales . . . . .	80
B.4.3 Recueil d'articles (ouvrages édités) . . . . .	80
B.4.4 Conférences internationales avec comité de lecture . . . . .	81

---

B.4.5	Conférences nationales avec comité de lecture . . . . .	82
B.4.6	Autres . . . . .	82
B.5	Séminaires . . . . .	82
<b>C</b>	<b>Principales publications</b>	<b>85</b>



# Chapitre 1

## Thématiques des activités de recherche

*Les odeurs comme les sons, les formes ou les couleurs, correspondent à des anisotropies physiques que notre cerveau utilise pour se faire une idée de notre environnement. Si la vision nous renseigne sur l'apparence des choses et des êtres par leur surface sur laquelle joue la lumière, l'odorat nous livre quelque chose de leur substance intime. La fleur n'a de parfum que si elle laisse diffuser un peu d'elle-même dans l'air qui l'entourne.*

### 1.1 Introduction

L'ensemble des activités de recherche que j'ai menées depuis ma thèse se situe dans le cadre de la caractérisation d'objets complexes. Nous utilisons pour cela quelques éléments de la perception humaine et quelques modèles physiques de représentation. J'ai surtout travaillé sur l'exploitation, d'un côté des données recueillies à l'aide des instruments de mesures relatifs à différentes variables caractérisant un phénomène, et d'un autre côté des connaissances expertes subjectives relatives à celui-ci. L'utilisation de ces deux types des connaissances dans des applications englobe plusieurs aspects ; j'ai travaillé sur quatre d'entre eux. Le premier aspect auquel je me suis intéressé est de relier ses connaissances symboliques en langage naturel aux valeurs numériques issues des instruments de mesure. Ces dernières sont en quelque sorte les connaissances explicatives des premières. Le deuxième aspect, lié généralement au premier, concerne l'existence d'un grand nombre de variables ayant des valeurs physiques mesurables pour expliquer un phénomène qui peut être perçu d'une façon subjective et pour lequel nous ne possédons pas de relations, aussi imprécises soient-elles, entre les variables et le phénomène. Dans ce type de problème, une partie de ces variables seule sert à ca-

ractériser le phénomène. La difficulté réside donc dans l'élimination des variables inutiles et la caractérisation du phénomène à l'aide des valeurs subjectives des variables explicatives. Le troisième aspect concerne l'utilisation des connaissances subjectives pour limiter les erreurs générées par les instruments des mesures physiques. En effet l'utilisation de ces valeurs brutes peut ne pas refléter le caractère subjectif du phénomène. Le dernier aspect est l'utilisation des relations subjectives entre variables.

Pour expliquer ces aspects, je me suis intéressé à trois domaines de complexité décroissante par rapport à la liaison entre leur appréhension par des instruments de mesure et leur perception par des humains : la caractérisation de l'odeur, la caractérisation de la texture et la caractérisation de la congestion du trafic dans les réseaux.

### **La caractérisation de l'odeur:**

L'odeur n'est pas une radiation comme la couleur, ni une fréquence comme le son, elle naît lorsqu'un peu de la substance, portée par les courants aériens, rencontre quelques-unes des millions de cellules qui forment notre appareil olfactif dans les profondeurs des fosses nasales.

Plusieurs théories d'olfaction ont été proposées (Wright, 1954), (Amoore et Thomas, 1970), (Beets, 1978), mais le mécanisme de perception reste jusqu'à nos jours méconnu et résiste encore aux progrès réalisés dans différentes disciplines annexes de la chimioréception. En absence d'une théorie, les chimistes tentent de contribuer à la compréhension des mécanismes impliqués dans l'olfaction par l'investigation des relations qui lient la structure chimique des odorants à la qualité de leurs odeurs. L'homme a une perception globale de l'odeur, mais aucune mesure physico-chimique expliquant l'odeur n'a une signification intuitive pour lui. Il est généralement incapable d'explicitier les raisons qui lui font dire qu'une odeur est "musquée" ou que quelque chose "sent la framboise". Certains spécialistes comme les "nez" dans l'industrie du parfum ou les œnologues sont en mesure d'analyser finement une odeur, mais leurs descriptions se limitent à l'identification d'odeurs élémentaires qu'ils reconnaissent dans une odeur donnée, par exemple "musc", "groseille". Ils ne sont par contre pas en mesure de décrire finement ces odeurs élémentaires. L'odeur peut de plus être décrite d'une façon graduelle en utilisant des modificateurs linguistiques tels que "très forte odeur du camphre". Tout ceci montre la complexité de l'explication de l'odeur et la difficulté à automatiser le processus naturel de perception de l'odeur.

### **La caractérisation de la texture**

La notion de texture est étroitement liée au mode de perception visuelle de l'homme. Pour définir la texture, il faudrait connaître la nature de l'information perçue par l'œil humain quand celui-ci observe une zone d'image. Diverses expériences ont été faites pour caractériser la perception visuelle humaine des textures.

Une des hypothèses avancées par (Julez et Bergen, 1987) suppose que le système visuel opère comme un détecteur d'éléments fondamentaux de structure locale nommés "textons". La détection de ces structures locales donne une possibilité de discriminer des textures ayant des distributions du deuxième ordre identiques.

La perception de la texture chez l'homme est moins complexe que l'odeur. En effet, l'homme peut décrire un objet qu'il voit avec des propriétés physiques qu'il identifie. La complexité de la caractérisation de texture réside dans le fait que les méthodes physiques qui quantifient la texture sont basées sur "le niveau de gris" et sont difficilement interfaçables avec les connaissances subjectives globales perçues par l'homme.

Une texture peut être évaluée subjectivement en termes de finesse, rugosité, régularité, linéarité. Tous ces qualitatifs sont sensés traduire les propriétés des primitives de niveau de gris et leur interactions. Malheureusement, peu de travaux ont tenté de donner une signification précise de ces termes.

### **L'administration des réseaux locaux**

Dans ce domaine, de nombreuses connaissances sont basées sur la perception humaine et peuvent être exprimées par l'administrateur réseaux, et d'autres connaissances sont issues des mesures physiques des performances du réseau. Aussi, dans ce domaine, est-on en présence d'une fonction basée sur la perception humaine. Elle est exprimée sous forme d'une collection de règles linguistiques de la forme "si...alors".

L'aspect mis en valeur dans ce domaine est l'interfaçage entre les connaissances subjectives et les connaissances issues des instruments de mesures, grâce à des concepts vagues et le mode de raisonnement adéquat.

Les trois facettes de mes travaux de recherches s'insèrent dans le cadre des orientations actuelles vers la théorie informatisée de la perception (Computational theory of perceptions CTP), mise en évidence récemment par L. A. Zadeh (Zadeh, 2001), comme un moyen de traitement d'informations issues de la perception humaine et de raisonnement sur de telles informations. En effet, l'homme a une grande aptitude à réaliser des tâches physiques ou mentales sans faire de mesure et sans faire de calcul, par exemple pour jouer au golf, garer une voiture, reconnaître une image, reconnaître une odeur, reconnaître une voix....

A travers ces exemples, on peut faire les constatations suivantes :

- Le cerveau humain n'a pas besoin de détail ni de précision pour réaliser une tâche.
- Sa perception est intrinséquement imprécise, il ne sait pas mesurer des distances, des vitesses avec exactitude.
- Les classes perçues ne possèdent généralement pas des limites nettes.
- Les organes sensoriels n'ont pas la capacité de percevoir des valeurs précises

pour décrire un objet et ils fournissent des informations granulaires plus ou moins fines. Un granule regroupe un ensemble de points ou d'objets qui sont similaires ou proches. Par exemple, la taille peut être décrite par les granules suivants : très grand, grand, moyen, petit et très petit.

La différence essentielle entre la perception et la mesure physique réside dans le fait que la première est floue et la seconde est nette, "crisp".

Dans mes travaux relatifs aux différents domaines (textures, odeurs ou réseaux), j'ai mis en avant les connaissances issues de la perception humaine pour améliorer les systèmes basés seulement sur les mesures physiques.

Le but général des travaux de recherche que j'ai menés jusqu'à présent est de trouver des méthodes rapprochant perception humaine et conception de systèmes d'aide à la décision.

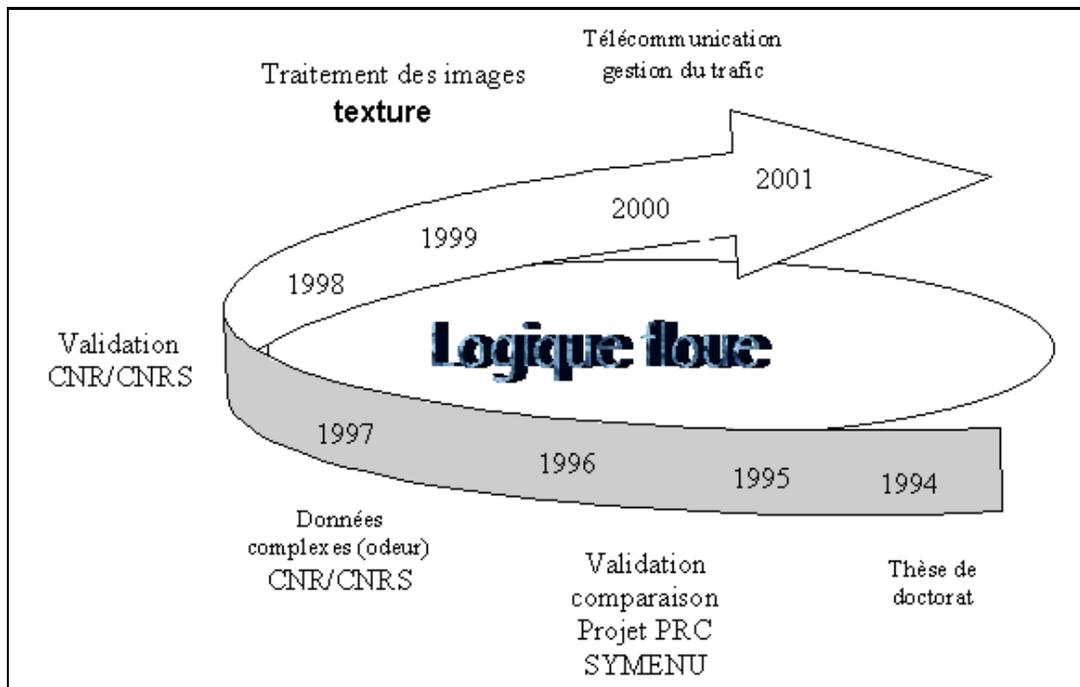


FIG. 1.1 – Cheminement de mes travaux de recherches

## 1.2 Présentation générale

Je présente dans ce mémoire une synthèse de mes travaux depuis l'obtention de la thèse de doctorat de l'université Pierre et Marie Curie en février 1994 (figure 1.1).

Pendant les années qui ont suivi ma thèse et en continuité directe avec mes travaux antérieurs, je me suis attaché à valider l'approche "apprentissage à l'aide des arbres de décision flous". Pour ce faire, j'ai collaboré avec C. Marsala dans le cadre de son stage de DEA et par la suite dans le cadre de sa thèse. Nous avons ainsi fait une adaptation de la méthode développée dans ma thèse pour la comparer avec les autres approches classiques. Elle a été réalisée dans le cadre du programme SYMENU du PRC-GDR IA en 1994 où, nous avons comparé notre méthode avec douze autres méthodes. Cette comparaison a été réalisée sur une base d'apprentissage commune (formes d'onde de Breiman), Ensuite, je me suis intéressé à des domaines plus complexes pour approfondir cette approche. J'ai travaillé sur la caractérisation de l'odeur à l'aide de la structure moléculaire, c'est un travail qui a été réalisé en collaboration entre le département d'informatique et le laboratoire de traitement d'information chimique de la Faculté des Sciences et Techniques de Mohammedia d'un côté et le LIP6 de l'autre. Ceci a été réalisé dans le cadre de plusieurs conventions CNR/CNRS. Une partie des résultats de ce travail a été soutenue dans le cadre de la thèse de M. Tollabi.

Pendant les trois dernières années, j'ai collaboré avec A. Bekhoucha dans le cadre de sa thèse de doctorat d'état en traitement d'images, sur la caractérisation des images texturées à l'aide de la théorie des sous-ensembles flous.

Depuis deux ans, j'ai collaboré avec des chercheurs de l'Institut National des Postes et Télécommunications sur l'utilisation des données expertes vagues pour la gestion du trafic dans les réseaux. Nous avons appliqué ceci à un réseau local en nous servant des méthodes hybrides utilisant réseaux de neurones et inférences floues.

Ce mémoire est divisé en trois parties. La première traite des arbres de décision flous et leurs variantes, avec des applications aux formes d'ondes et à la reconnaissance de l'odeur. La deuxième partie va être consacrée à la caractérisation de la texture en traitement d'images à l'aide du concept de plage floue. La dernière partie est consacrée à la gestion du trafic dans les réseaux locaux en utilisant des approches neuronales floues.



## Chapitre 2

# Arbres de décisions flous et reconnaissance d'odeurs

### 2.1 Introduction

Ce travail vient en continuité directe de mes travaux de thèse. La première partie de ce travail fait partie de la thèse de Christophe MARSALA (Marsala, 1998). La deuxième partie, concernant l'application des arbres de décisions à la caractérisation des odeurs, a été développée dans le cadre d'un projet Franco-Marocain entre l'équipe LOFTI du Laboratoire d'Informatique de Paris 6 et le laboratoire de traitement d'information chimique et moi-même à la Faculté des Sciences et Techniques de Mohammedia ; elle fait partie de la thèse de M. Tollabi (Tollabi, 2001).

L'objectif en est le traitement des attributs continus dans les systèmes d'apprentissage par des concepts mettant en valeur ce caractère continu. En effet, une valeur continue ne peut être représentée par un nombre fini d'entités avec des limites bien définies. Pour représenter la nuance des limites entre ces entités, je me suis appuyé sur la théorie des sous-ensembles flous.

La représentation numérique-symbolique que nous avons adoptée, est mise en oeuvre dans les différents systèmes d'apprentissage de type arbre de décision flou que je vais présenter dans la suite de ce chapitre. Elles permettent la prise en compte de données numérique-symboliques, non seulement pendant leur construction, mais aussi lors de la phase de classification de nouveaux exemples. Le Raisonnement à l'aide des valeurs numériques-symboliques est un mode de raisonnement très proche du raisonnement humain et l'utilisation de la théorie des sous-ensembles flous apporte une meilleure robustesse lors de la phase de classification de nouveaux exemples.

Ainsi la plate-forme du système d'apprentissage à partir de données nuan-

cées SAFI (Bouchon-Meunier et Ramdani, 1991) que j'ai développé pendant ma thèse, s'attache-t-elle à la fuzzication des attributs continus ayant une double description numérique-symbolique. Dans SAFI, une interface entre les données numérico-symboliques est utilisée. Pour pouvoir traiter ces données, nous utilisons une entropie floue généralisant l'entropie classique. Elle est basée sur les événements conditionnels flous. Le travail réalisé par C. Marsala en un premier temps pendant son stage de DEA, consistait à développer une approche traitant tous les attributs continus. Ceci a donné lieu à un premier système qui fuzzifie les données continues pendant la phase de classification (Marsala et Ramdani, 1995). Une deuxième approche (Marsala, 1998) implémentée dans le système Salammbô, a été développée par C. Marsala dans le cadre de sa thèse. Dans celle-ci, les attributs continus sont partitionnés automatiquement par des techniques basées sur la morphologie mathématique floue et formalisées par les techniques de réécriture de la théorie des langages.

Dans ce chapitre, je présente la particularité de SAFI, les caractéristiques de Salammbô (Figure 2.1) et la contribution des deux systèmes à la caractérisation de l'odeur.

## 2.2 Le système d'apprentissage flou interactif (SAFI)

C'est un système qui développe un arbre de décision flou à partir d'une base d'apprentissage (Ramdani, 1992a) en présence de données subjectives. Il est interactif en ce qui concerne la représentation des connaissances floues du domaine. L'architecture générale de SAFI est constituée de trois modules :

1. un module interactif,
2. un module de développement de l'arbre de décision,
3. un module de classification.

### 2.2.1 Interaction numérico-symbolique

On suppose donné un ensemble d'apprentissage où les attributs sont numérico-symboliques. Les valeurs des attributs dans la base d'apprentissage sont numériques, mais les experts, dans leur langage courant, emploient des valeurs symboliques vagues.

Comment se servir des valeurs symboliques dans un système d'apprentissage? L'idée est d'établir une interface, pour ces données numériques, avec les connaissances symboliques des experts. Pour cela, nous faisons appel à la théorie des sous-ensembles flous. Les valeurs symboliques sont représentées par des fonctions d'appartenance floues dans l'univers des valeurs numériques.

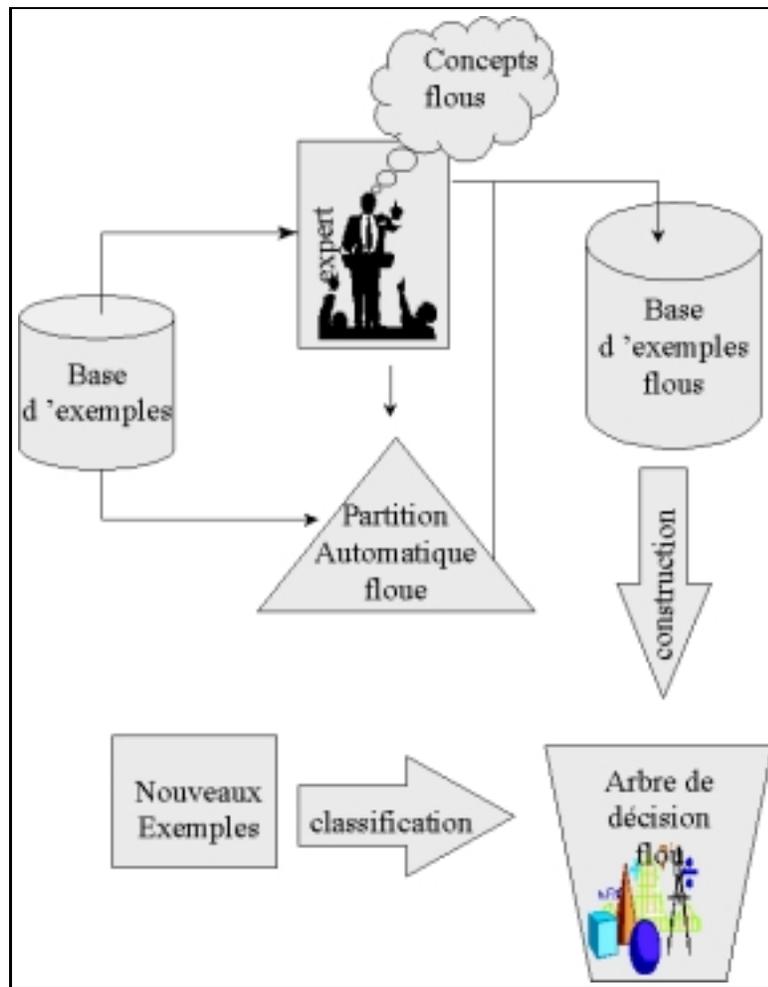


FIG. 2.1 – Architecture générale des arbres de décision flous

Pour illustrer cette idée, nous nous plaçons dans le cadre de la consommation de l'électricité par les ménages. A partir de la base d'exemples ci-dessous, nous cherchons la relation qui existe entre la consommation de l'électricité d'une part, la superficie d'un appartement, le mois, et la température moyenne du mois d'autre part :

<i>exemple</i>	<i>surface</i>	<i>mois</i>	<i>température</i>	<i>consommation</i>
$e_1$	50	1	5	30
$e_2$	60	2	7	30
$e_3$	70	3	10	20
$e_4$	80	1	1	40
$e_5$	100	1	1	50

Les connaissances subjectives utilisées dans la vie courante peuvent être des modalités symboliques qualifiant les valeurs numériques, telles que :

”grand appartement”, ”faible température” ”consommation élevée”ou ” hiver” pour désigner approximativement les mois de janvier et février.

Nous nous servons de ces connaissances symboliques pour partitionner l'espace des valeurs de chaque attribut continu. Chaque modalité symbolique est représentée par une fonction d'appartenance. Ces valeurs symboliques sont les valeurs usuellement utilisées par les experts du domaine.

### Degré de satisfiabilité

On suppose donc donné un ensemble d'attributs  $\{A_1, A_2, \dots, A_n\}$  et un attribut décision  $C$ , de modalités ou classes  $C_1, C_2, \dots, C_{n_c}$ . Les valeurs de tous les attributs sont supposées connues pour les éléments d'un ensemble d'apprentissage  $E = \{x_\ell, 1 \leq \ell \leq r\}$

Chaque donnée numérique ou symbolique relative à un attribut peut être traduite en donnée symbolique subjective avec un degré de satisfiabilité. Il est exprimé d'une manière formelle comme suit :

Soit  $V$  la modalité symbolique d'un attribut utilisée par l'expert et  $W$  une valeur issue de la base d'apprentissage, elles sont représentées par des sous-ensembles flous sur un univers  $X$ .

Le degré de satisfiabilité de  $W$  à  $V$  peut être exprimé par le degré d'inclusion de  $W$  dans  $V$  :

$$Deg(W \subset V) = \frac{\int_X f_{V \cap W}(x) dx}{\int_X f_W(x) dx}$$

Plus  $W$  est inclus dans  $V$ , plus le degré de satisfiabilité est grand. Si la donnée est une donnée précise  $W = \{x_0\}$ , le degré de satisfiabilité est la valeur d'appartenance de  $W$  à  $V$  :

$$Deg(W \subset V) = f_V(x_0)$$

Pour un attribut donné, si  $V$  est la modalité d'apprentissage et  $W$  est la modalité dans l'exemple, le degré de satisfiabilité représente le degré avec lequel  $V$  peut remplacer  $W$ .

### L'entropie floue comme critère d'ajustement

L'expert peut ne pas être sûr des paramètres des fonctions d'appartenance des valeurs symboliques, nous utilisons alors dans ce cas les données pour ajuster ces paramètres. Le critère d'ajustement est l'optimisation de la quantité d'information apportée par l'attribut par rapport à la décision. Cette quantité est exprimée par l'entropie floue.

L'entropie floue (Bouchon-Meunier et al., 1993a) mesure l'incertitude de la décision floue pour traiter les valeurs floues d'un attribut numérico-symbolique. Elle est définie à partir des probabilités d'événements flous de la façon suivante :

$$E_A^* = - \sum_i P^*(V_i) \sum_j P^*(C_j | V_i) \log P^*(C_j | V_i),$$

- $V_i$  étant les modalités floues de l'attribut  $A$
- $C_j$  étant les modalités floues de l'attribut décision  $C$
- $P^*(V_i) = \sum_l f_{V_i}(x_l)P(x_l)$  étant la probabilité de la modalité floue  $V_i$  de  $A$  (Zadeh, 1968)
  - $P(x_l)$  est calculée de façon approchée par la fréquence des  $x_l$  dans l'ensemble d'apprentissage  $E$
  - $f_{V_i}$  est la fonction d'appartenance de  $V_i$ .
- La probabilité conditionnelle floue de la modalité  $C_j$  de  $C$ , étant donné  $V_i$ , est définie par  $P^*(C_j | V_i) = \frac{P^*(C_j, V_i)}{P^*(V_i)}$ :
  - avec  $P^*(C_j, V_i)$  la probabilité floue conjointe, définie par:

$$P^*(C_j, V_i) = \sum_{1 \leq l \leq q} \sum_{1 \leq k \leq r} \min(f_{C_j}(y_l), f_{V_i}(x_k))P(y_l, x_k)$$

avec  $Y = \{y_1, y_2, \dots, y_q\}$  l'ensemble des valeurs numériques de l'attribut décision  $C$  dans  $E$ .

Ce critère va être aussi choisi pour ordonner les attributs entre eux durant la construction de l'arbre de décision flou. De plus, il généralise l'entropie classique et permet, comme elle, de classer aussi les attributs symboliques.

### 2.2.2 Développement de l'arbre de décision flou

L'arbre de décision est développé de la racine vers les feuilles, en prenant comme critère de discrimination l'entropie floue. Un attribut  $A$  est sélectionné parce qu'il minimise l'entropie  $E_A^*$ , étant donné les attributs déjà choisis. Il engendre le développement d'un ensemble de branches relatives à ses modalités. On associe les exemples ayant une valeur d'appartenance non nulle par rapport à une modalité à la branche associée à cette modalité. Un arbre de décision est ainsi développé, de façon descendante, jusqu'au nœud final qui correspond à la décision. Ce développement se poursuit jusqu'à ce qu'un critère d'arrêt soit atteint. Ce critère est par exemple :

1. la taille de la base d'apprentissage courante inférieure à un seuil fixé:

$$|base\ d'apprentissage| < Seuil_{Taille}$$

2. la valeur de l'entropie floue inférieure à un certain seuil fixé:

$$E_C^* < Seuil_{Entropie}$$

3. l'absence d'attribut pour décomposer la base d'apprentissage.

La conjonction entre les différentes modalités d'un chemin de l'arbre est réalisée en prenant une norme triangulaire (t-norme) par exemple le minimum ou le produit. En chaque feuille, (Marsala et Ramdani, 1995), les décisions sont pondérées par des probabilités conditionnelle floues calculées pendant le développement de l'arbre à partir des fréquences floues des modalités des attributs et de celles des modalités des décisions.

### 2.2.3 Classification floue avec les degrés de satisfiabilité

La classification de nouveaux exemples, dont on ne connaît que les valeurs des attributs  $A_i$  et non celle de l'attribut décision, prend en compte des valeurs des attributs dans ces exemples. Ces valeurs peuvent être différentes de celles qui ont servi pour l'apprentissage. Elles peuvent être obtenues par des modificateurs linguistiques, ou provenir d'experts différents, ou être numériques. Pour les filtrer dans l'arbre de décision, nous employons les degrés de satisfiabilité.

Un arbre de décision est considéré comme un système à base de règles, chaque branche correspondant à une règle "si  $\langle prémisses \rangle$  alors  $\langle conclusion \rangle$ ".

La classification d'un exemple correspond au déclenchement de règles, suivant le modèle d'inférence de modus ponens généralisé (Bouchon-Meunier, 1993).

A un chemin de l'arbre correspond une règle  $R_r$  de la forme :

$$si \langle A_{i_1} = V_{i_1} \rangle et \langle A_{i_2} = V_{i_2} \rangle et...et \langle A_{i_p} = V_{i_p} \rangle alors \langle C = C_k \rangle$$

où les  $A_{i_i}$  sont les attributs utilisés sur les arcs du chemin. Ils appartiennent à l'ensemble  $\{A_1, \dots, A_n\}$  des attributs. Les  $V_{i_i}$  sont les modalités des  $A_{i_i}$  associées aux arcs du chemin.

Soit  $e$  un exemple à classer, décrit par:

$$\langle A_1 = V_1 \rangle \text{ et } \langle A_2 = V_2 \rangle \text{ et } \dots \text{ et } \langle A_n = V_n \rangle$$

chaque condition  $\langle A_{i_i} = W_{i_i} \rangle$  de l'exemple est associée à la prémisse  $\langle A_{i_i} = V_{i_i} \rangle$  de la règle  $R_r$  avec le degré de satisfiabilité  $Deg(W_{i_i} \subset V_{i_i})$ . Nous agrégeons alors les degrés de satisfiabilité de toutes les prémisses d'une règle par la t-norme produit pour obtenir un degré global pour cette règle:

$$\prod_{i=1..p} Deg(W_{i_i} \subset V_{i_i})$$

Cette définition du degré global est consistante avec la définition du degré de satisfiabilité que nous avons choisi si nous prenons la t-norme produit pour l'intersection et le produit cartésien de sous-ensembles flous. Dans ce cas nous avons :

$$\prod_{i=1..p} Deg(W_{i_i} \subset V_{i_i}) = Deg((W_{i_1}, \dots, W_{i_p}) \subset (V_{i_1}, \dots, V_{i_p}))$$

Notons que dans le cas où les exemples à classer sont précis, cette égalité est aussi vraie en utilisant une t-norme quelconque. L'exemple est associé à la classe  $C_k$  suivant la règle  $R_r$ , avec un degré de satisfiabilité obtenu en pondérant le degré global pour la règle  $R_r$  par la probabilité conditionnelle floue de la classe  $C_k$  associée à la règle  $R_r$  :

$$FDeg_r(C_k) = \prod_{i=1..p} Deg(W_{i_i} \subset V_{i_i}) P^*(C_k | (V_{i_1}, \dots, V_{i_p}))$$

Ce degré indique dans quelle mesure  $C_k$  peut être considérée comme la classe de l'exemple, d'après la règle  $R_r$ .

Etant donné qu'une composante de l'exemple peut avoir des degrés de satisfiabilité non nuls par rapport à plusieurs modalités d'apprentissage d'un même attribut, un exemple peut déclencher plusieurs règles. Par conséquent nous obtenons, pour le même exemple, plusieurs classes par chacune des règles déclenchées. Nous agrégeons tous ces degrés à l'aide d'une conorme triangulaire (t-conorme)  $\perp$ , généralement la t-conorme max, afin d'obtenir pour chaque classe un seul degré de satisfiabilité. Si  $n_\rho$  est le nombre de règles dans l'arbre de décision, nous avons:

$$FDeg(C_k) = \perp_{r=1..n_\rho} FDeg_r(C_k)$$

Ceci représente le degré avec lequel l'exemple peut être associé à la classe  $C_k$  pour l'arbre de décision en question. Finalement, nous choisissons d'associer l'exemple  $e$  à la classe  $C_e$  qui correspond au plus haut degré obtenu :

$$FDeg(C_e) = \max_{k=1..n_c} FDeg(C_k),$$

où  $n_c$  est le nombre de classes possibles.

Notons que la classe peut être un descripteur continu partitionné en valeurs floues. Cette partition est généralement proposée par l'expert du domaine dans lequel on effectue l'apprentissage.

### 2.2.4 Le système SCOAD

Ce système basé sur les arbres de décisions, a été réalisé par C. Marsala pendant son projet de DEA. Ce système partitionne les attributs continus en utilisant l'entropie de Shannon. Pendant la phase de classification, SCOAD utilise le principe de modus-ponens généralisé (Marsala, 1994). Les deux valeurs critiques pour le partitionnement d'un attribut continu sont utilisées pour la fuzzification des modalités de cet attribut.

Le système SCOAD nous a permis de comparer notre approche d'apprentissage basée sur les arbres de décisions flous à d'autres méthodes d'apprentissage numérique-symboliques. Ceci a été réalisé dans le cadre du projet PRC-GDR "Méthodes Symboliques-Numériques de Discrimination" en 1995. Dans ce projet, nous avons comparé (Bouchon-Meunier et al., 1995) les performances (temps, explicabilité) de notre approche par rapport aux autres approches sur une base d'exemples classique, celle de la reconnaissance de formes d'ondes (Breiman et al., 1984).

**Remarque 1** *La base d'exemples sur les formes d'ondes est construite d'une façon artificielle, et ne permettait donc pas à notre méthode de montrer toute ses potentialités. Cependant les tests réalisés sur cette base étaient concluants (Gasquel et al., 1998).*

## 2.3 Le système Salammbô

Dans les bases de données, il existe en général deux sortes de données. Sur la première sorte de données, les experts du domaine ne possèdent pas de connaissances supplémentaires. Par contre, sur celles de la seconde sorte, ils possèdent des connaissances supplémentaires subjectives très importantes. Mais malheureusement dans la plupart de ces bases, les connaissances expertes ne sont pas

répertoriées. En effet, ces connaissances sont généralement jugées inutiles pour l'apprentissage. Ainsi pour les données relatives aux attributs continus, nous ne possédons pas de connaissances expertes subjectives pour les partitionner. L'univers de ces attributs est généralement partitionné d'une façon automatique dans toutes les méthodes basées sur les arbres de décision. Ces partitions sont généralement ordinaires et ne reflètent pas leur caractère continu. Parmi les systèmes basés sur les arbres de décision et qui utilisent ces approches ordinaires, on peut citer par exemple le système CART de (Breiman et al., 1984) et le système C4.5 (Quinlan, 1996). Une bibliographie plus complète est décrite dans la thèse de C. Marsala (Marsala, 1998).

Pour effectuer une partition d'une façon automatique et prendre en considération le caractère continu des attributs, C. Marsala a développé une méthode basée sur les morphologies mathématiques (Marsala et Bouchon-Meunier, 1996), qui tient compte de la répartition de classes sur l'ensemble des valeurs dans la base d'apprentissage.

Cette méthode de construction de partitions floues ne dépend que de la base d'apprentissage. Elle est calquée sur un processus intuitif de construction de telles partitions floues que pourrait mettre en œuvre une personne qui aurait cette tâche à accomplir. Elle est utilisée pour le partitionnement des descripteurs continus dans le système d'apprentissage Salammbô. Ce dernier se base sur le principe de développement et de classification de l'arbre de décision flou cité dans la section précédente.

**Remarque 2** *La méthode de C.Marsala pour le partitionnement des attributs continus suppose que l'attribut décision soit non flou. Nous travaillons sur une méthode automatique pour partitionner les attributs étant donné une partition floue sur l'attribut décision. Cette méthode repose sur l'algorithme du Subclustering (Chiu, 1997), qui effectue un partitionnement flou automatique de tous les attributs, y compris l'attribut décision. Elle est utilisée dans les systèmes de commande floue où le nombre d'attributs est relativement réduit.*

Dans la section suivante, nous présentons l'intérêt des arbres de décision flous pour expliquer l'association entre la structure des molécules et l'odeur. Pour ce faire, nous utilisons des descripteurs topologiques produits par un processus appelé GESDEM (Zakarya, 1988) (Génération Et Sélection des Descripteurs et Elaboration de Motifs) et des descripteurs physico-chimiques. Ce travail est réalisé dans le cadre d'une coopération Franco-Marocaine entre le laboratoire de traitement de l'information chimique de la F.S.T de Mohammedia et l'équipe LOFTI du laboratoire d'Informatique de Paris 6.

## 2.4 La reconnaissance d'odeur

Pour être perçus, les composés chimiques volatiles purs ou sous forme de mélanges sont transportés par l'air jusqu'au nez où ils sont réchauffés et humidifiés. La naissance du message olfactif résulte alors de l'absorption des molécules odorantes arrivées au mucus nasal sur des récepteurs glycoprotéiques de la membrane des cils olfactifs.

Plusieurs théories d'olfaction ont été proposées (Wright, 1954), (Amoore et Thomas, 1970), (Beets, 1978), mais le mécanisme de perception reste jusqu'à nos jours méconnu et résiste encore aux progrès réalisés dans différentes disciplines annexes de la chimioréception. De leur part, les chimistes tentent de contribuer à la compréhension des mécanismes impliqués dans l'olfaction par l'investigation des relations qui lient la structure chimique des odorants à la qualité de leurs odeurs. A ce but académique, peut s'ajouter un intérêt pratique et commercial des relations structure-odeur, pour l'élaboration formelle de nouvelles molécules pouvant être utilisées dans l'industrie de la parfumerie, des arômes de la cosmétique.

La recherche de telles relations n'est pas une tâche aisée. La première difficulté rencontrée est de traduire la structure chimique des composés en une série de paramètres contenant l'information nécessaire pour résoudre le problème. Outre les méthodes reposant sur des propriétés moléculaires (Wright, 1954), (Amoore et Thomas, 1970), (Beets, 1978), les méthodes topologiques (Chastrette et al., 1986), d'auto-corrélation (Zakarya, 1992) et de fragmentation (Brugger et Jurs, 1977) ont été appliquées avec un degré de succès satisfaisant.

Des paramètres de différentes natures (stériques, électroniques, géométriques, énergétiques, lipophiliques...), ainsi qu'une multitude d'outils de traitement de données (régression linéaire multiple, analyse en composantes principales, analyse discriminante, reconnaissance des formes...) ont été utilisés selon l'objectif de chaque étude.

Plus récemment, d'autres approches pour relever les relations structure-odeur ont été développées en utilisant les réseaux de neurones (Chastrette et al., 1994). Néanmoins, ceux-ci ne permettent ni d'établir explicitement des équations mathématiques entre l'odeur étudiée et les descripteurs utilisés, ni de dégager des règles permettant de connaître le rôle et l'influence de chaque descripteur.

De plus, si les descripteurs généralement utilisés dans ce domaine sont de nature précise-continue ou discrète, les décisions prises sont quant à elles nuancées. L'expert classe toujours cette présence ou cette absence d'odeur à l'idée de modificateurs symboliques en les représentant sur une échelle numérique, par exemple en utilisant des expressions symboliques telles que "*odeur faible ou forte de musc*". Les systèmes classiques de traitement des données ne permettent pas la prise en compte de cette double description.

La méthode d'induction que nous avons donc adoptée repose sur la construction d'un arbre de décision flou, qui a l'avantage d'être simple à construire et à utiliser. De plus, c'est un outil explicite et aisément explicable. La structure arborescente d'un tel arbre est équivalente à une base de règles *si..alors*, ce qui rend justifiable une décision prise en suivant l'un de ces chemins. Cette structure de connaissances est en outre très proche des structures de connaissances manipulées naturellement par l'esprit humain. C'est pourquoi nous avons choisi cette méthode pour le traitement des odeurs.

Dans ce travail nous avons utilisé les arbres de décisions flous pour mettre en évidence les associations entre la structure chimique des composés odorants et la qualité de leurs odeurs.

### 2.4.1 Description des données chimiques utilisées

Nous nous sommes intéressés en un premier temps à l'odeur du camphre. C'est une odeur que les experts chimistes considèrent comme une odeur à structure relativement facile. Ils ont développé beaucoup de connaissances subjectives à travers la masse de travaux réalisés autour de celle-ci. Parmi les connaissances subjectives qui caractérisent les molécules camphrées, on utilise leur caractère presque sphérique (forme d'œuf), leur diamètre d'approximativement 7Å, et de taille relativement petite, avec un volume compris entre 90 et 180  $cm^3/mol$ .

La série de composés étudiée est constituée de 90 alcools aliphatiques dont 29 primaires, 52 secondaires et 8 tertiaires. Ils contiennent entre 1 et 12 atomes de carbones. L'odeur de ces alcools a été décrite en détail par Schnabel et al. (Schnabel et al., 1988) en utilisant 16 descripteurs qualitatifs sur une échelle allant de 1 à 5. Les notes les plus fréquentes (ou les descripteurs) sont "etherisch" (qui a été traduit comme camphre puisque le camphre est le composé de référence pour cette odeur) et "fruchtig" (fruité).

Dans le concept de la méthodologie *GESDEM* (Tollabi, 2001), les descripteurs utilisés sont construits à partir d'atomes liés entre eux et formant ainsi des graphes. Le nombre d'atomes dans les fragments est progressivement incrémenté. L'ordre  $n$  d'un descripteur donné est défini comme étant le nombre d'atomes (à l'exclusion des atomes d'hydrogène, qui sont indirectement pris en considération par la valence des autres atomes) qu'il contient. Ainsi, les descripteurs d'ordre 1 ( $1Di$ ) sont simplement les différents types d'atomes trouvés dans l'échantillon. Des descripteurs d'ordre 2 ( $2Di$ ) sont élaborés en ajoutant un atome existant dans les molécules étudiées aux descripteurs de l'ordre 1. De manière itérative, les descripteurs d'ordre  $n$  sont produits à partir des descripteurs d'ordre  $n-1$  en ajoutant, dans toutes les directions possibles, un atome existant dans les molécules. L'ensemble des descripteurs du même ordre  $n$  représente tous les arrangements

possibles de  $n$  types d'atomes existant dans l'échantillon étudié.

La figure 2.2 montre comment générer les descripteurs de chaque ordre à partir de ceux de l'ordre inférieur. Une série de descripteurs du même ordre  $n$  représente tous les arrangements possibles de  $n$  atomes existant dans l'échantillon.

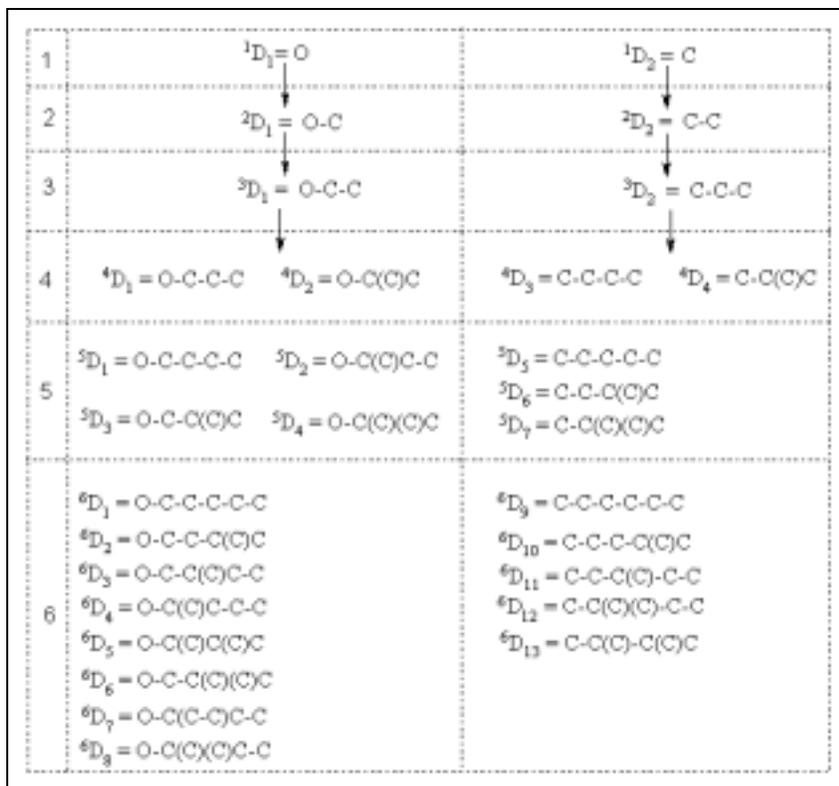


FIG. 2.2 – Méthode de génération des descripteurs

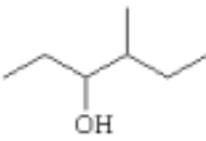
Chaque molécule est donc décrite par un vecteur dont les composantes représentent le nombre de fois où le descripteur est rencontré dans la molécule. La matrice de données est construite en disposant les molécules en ligne et les descripteurs en colonnes. La figure 2.3 montre un exemple de dénombrement des descripteurs pour la molécule 4-Méthyl-3-hexanol.

## 2.4.2 Classification en deux classes

Dans un premier cas, nous avons considéré comme camphré tout composé ayant un score compris entre 1 et 5 sur l'échelle de Schnabel.

- Les 58 molécules vérifiant cette condition sont attribuées à la classe 2.
- Les composés non camphrés sont ceux dont le score est nul, ils sont au nombre de 41 et attribués à la classe 1.

${}^1D_1 = 1$	${}^1D_2 = 7$			
${}^2D_1 = 1$	${}^2D_2 = 6$			
${}^3D_1 = 2$	${}^3D_2 = 6$			
${}^4D_1 = 3$	${}^4D_2 = 1$	${}^4D_3 = 5$	${}^4D_4 = 1$	
${}^5D_1 = 1$	${}^5D_2 = 3$	${}^5D_3 = 1$	${}^5D_4 = 0$	
${}^5D_5 = 3$	${}^5D_6 = 2$	${}^5D_7 = 0$		
${}^6D_1 = 0$	${}^6D_2 = 0$	${}^6D_3 = 1$	${}^6D_4 = 1$	
${}^6D_5 = 1$	${}^6D_6 = 0$	${}^6D_7 = 2$	${}^6D_8 = 0$	
${}^6D_9 = 1$	${}^6D_{10} = 1$	${}^6D_{11} = 1$	${}^6D_{12} = 0$	
${}^6D_{13} = 0$				



4-méthyl-3-hexanol

FIG. 2.3 – Exemple de dénombrement des descripteurs

La base de données est représentée par 28 descripteurs générés par la méthode GESDEM. Les attributs avec moins de cinq valeurs sont discrétisés alors que ceux qui représentent plus de cinq valeurs sont considérés comme des attributs continus.

Lors de la construction de l'arbre de décision flou, seulement 10 des 28 attributs présentés à la machine ont été sélectionnés. La classification était correcte pour 97 alcools sur les 99 de la série. Toutes les 41 molécules appartenant à la classe 1 ont été bien classées, alors que deux parmi les 58 constituant la classe 2 ont été mal classées. La figure 2.4 illustre l'arbre construit ainsi que les conditions sur chaque arc.

Les alcools 31 (2-butanol) et 73 (3-octanol) ont tous les deux un score de 2 sur l'échelle de Schnabel et appartiennent par conséquent à la classe 2 des composés camphrés alors qu'ils ont été attribués à la classe des composés non camphrés.

On peut dire que la classe 1 est homogène puisque tous les composés qui la forment n'ont aucune ressemblance d'odeur avec le camphre et par conséquent tous les composés de cette classe ont été bien classés. Par contre, la classe 2 contient tous les composés qui ont une faible ou forte ressemblance olfactive avec le camphre. Cette disparité dans la classe 2 peut être la cause de la mauvaise classification des molécules 31 et 73.

### 2.4.3 Classification en trois classes

Pour lever cette disparité et raffiner davantage les résultats, nous avons considéré trois classes dans la deuxième partie de ce travail :

- la première est équivalente à la classe 1 de la première partie et elle est formée par les composés non camphrés.

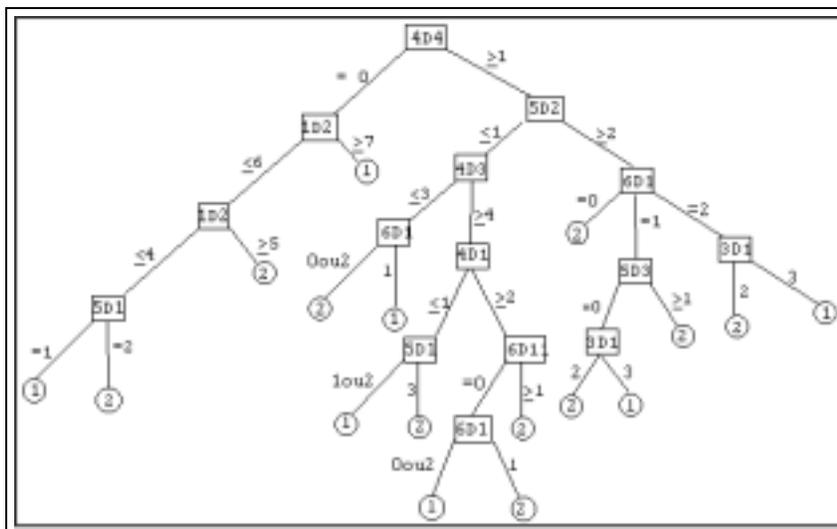


FIG. 2.4 – Arbre construit à partir de l'échantillon

- La deuxième classe est celle des alcools camphrés faibles et contenant tous les composés caractérisés par des scores de 1 ou 2 pour la note camphrée sur l'échelle de Schnabel.
- La troisième classe contient tous les composés restant et ayant les scores 3, 4 ou 5 et qui peuvent être considérés comme des camphrés forts.

Lors de la classification des composés, les 28 attributs ont été présentés à la machine mais seulement 14 d'entre eux ont été pris en considération, pour classer correctement 97 composés sur les 99 de la série. Seuls les alcools 42 (2-heptanol) et 50 (2-octanol), qui ont tous les deux un score nul, ont été incorrectement attribués à la classe 2 des composés faiblement camphrés au lieu de la classe 1 des non camphrés.

L'arbre 2 obtenu a les caractéristiques suivantes :

- Plus petite valeur d'information non nulle : 0,150
- Plus petit nœud : 2
- Nombre de branches : 30
- Profondeur : Maximum : 6, Moyenne : 4,87
- 97 bien classés pour 99 lus, soit 97,98 % ( erreur 2,02%)
- Classe 1 : 39 bons sur 41, soit 95,12 %
- Classe 2 : 13 bons sur 13, soit 100 %.
- Classe 3 : 45 bons sur 45, soit 100 %.

Du point de vue quantitatif (dénombrement), deux molécules sont mal classées, aussi bien dans le cas de deux classes que dans celui des trois classes. Cependant,

la signification de l'erreur commise lors de la classification dans chaque cas est différente. Dans le premier cas, l'erreur porte sur le fait qu'un composé est camphré ou non. Par contre, dans le deuxième cas, l'erreur n'est que l'attribution d'un composé à la classe des non camphrés ou à celle des camphrés faibles.

Finalement, des expériences ont été réalisées par la méthode de validation croisée en écartant 10 molécules dans chaque expérience. Les 99 exemples ont servi pour constituer 9 échantillons de 89 exemples chacun et un échantillon de 90 exemples.

Le taux moyen de l'erreur commise est de 18,2% avec des arbres composés de 9 à 12 arêtes et avec une longueur maximale moyenne de 4,3 nœuds.

Pour essayer de réduire l'erreur commise, et aussi pour comparer les descripteurs générés par *GESDEM* à d'autres systèmes de description, nous avons choisi de faire intervenir des descripteurs physico-chimiques.

#### 2.4.4 Utilisation des descripteurs GESDEM et physico-chimiques

Pour pouvoir estimer correctement les descripteurs physico-chimiques, les chimistes ont travaillé avec des structures moléculaires dans leur état le plus stable. Pour calculer la géométrie des conformations de plus basse énergie, ils ont utilisé une méthode de mécanique moléculaire.

Pour rendre compte de la forme de chaque molécule à partir de sa représentation structurale (Figure 5), ils ont placé les molécules de telle sorte que :

- la longueur maximale de la molécule est orientée selon l'axe  $x$ ,
- la largeur maximale est orientée selon l'axe  $y$ ,
- la hauteur maximale est orientée selon l'axe  $z$ .

Les conformations les plus stables dans de telles représentations ont permis de mesurer :

- la longueur moléculaire  $R$ , considérée comme étant la distance entre les deux atomes les plus éloignés sur l'axe  $x$ , plus leurs rayons de Van der Waal.
- la largeur  $r$  de la molécule, considérée comme étant la distance entre les deux atomes les plus éloignés sur l'axe  $y$ , plus leurs rayons de Van der Waal.
- la hauteur  $p$  (ou profondeur) de la molécule séparant, le long de l'axe  $z$ , les deux atomes les plus éloignés plus leurs rayons de Van der Waal.

D'autres paramètres ont été calculés pour tenir compte des caractéristiques physico-chimiques des molécules par le logiciel Molecular Modeling Pro : MMP :

- $LogP$  : le coefficient de partage entre l'eau et le n-octanol, estimant bien la lipophilicité relative d'une molécule. Il est souvent relié au transport et

à la diffusion des drogues à travers les membranes lipidiques des systèmes biologiques.

- la réfraction moléculaire calculée en se basant sur les contributions des atomes constituant chaque molécules
- la densité  $d$  pour chaque molécule.
- la solubilité aqueuse  $Saq$  de chaque molécule estimée en  $g/L$ .
- les rapports  $R/r$ ,  $R/p$  et  $r/p$  calculés pour tenir compte de la forme de chaque molécule.

Une matrice contenant tous les vecteurs engendrés par l'approche GESDEM ainsi que les paramètres géométriques et physico-chimiques calculés est construite. Cette matrice est associée au vecteur contenant la classe d'appartenance de chaque molécule en fonction du score donné par Schnabel et al. concernant l'odeur du camphre.

Dans la figure 2.5, nous donnons la conformation la plus stable de la molécule 67 : 4-Méthylhexan-3-Exanol ; le tableau suivant montre tous les descripteurs calculés pour cette molécule.

1D2	2D2	3D1	3D2	4D1	4D2	4D3	4D4	5D1	5D2
7	6	2	6	3	1	5	1	1	3
5D3	5D4	5D5	5D6	5D7	6D1	6D2	6D3	6D4	6D5
1	0	3	2	0	0	0	1	1	1
6D6	6D7	6D8	6D9	6D10	6D11	6D12	6D13	R	r
0	2	0	1	1	1	0	0	10,39	6,95
R/r	p	R/p	R/p	alogP e	aMR	d	Saq		Class
1,49	5,66	1,836	1,228	2,23	35,55	0,753	9,54		camph

Les valeurs des descripteurs de la molécule 4-Méthylhexan-3-Exanol

## Analyse des résultats

Comme dans la première partie de ce travail, nous avons considéré comme camphrés tous les alcools ayant un score entre 1 et 5 sur l'échelle de Schnabel. Ils sont au nombre de 58 et attribués à la classe 2. Ceux avec un score de 0 sont considérés non camphrés et attribués à la classe 1. Ils sont au nombre de 41.

La base de données est représentée par 38 descripteurs, dont 28 sont générés par l'approche GESDEM et 10 sont des paramètres géométriques et physico-chimiques des molécules.

Plusieurs tests ont été réalisés sur cette base de données. L'arbre de décision flou a été construit sur la totalité de base de données où chaque molécule est décrite par les 38 attributs. L'arbre obtenu est donné dans la figure 2.4.4.

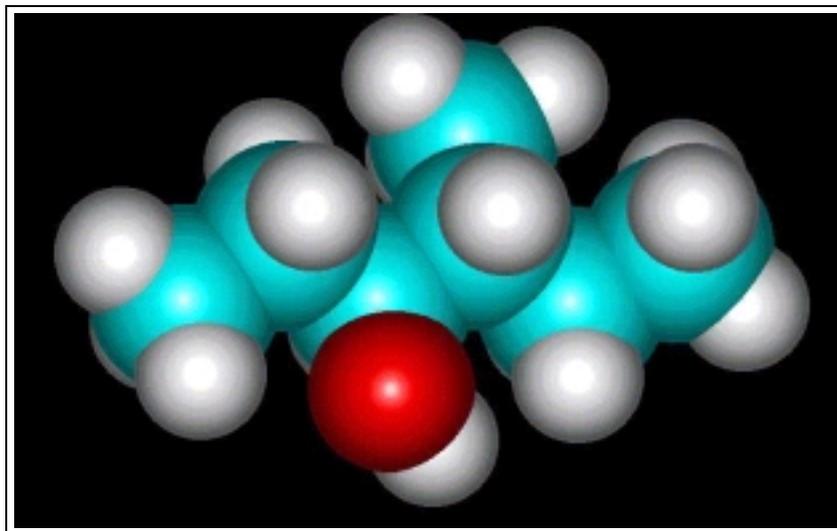


FIG. 2.5 – La molécule 4-Méthylhexan-3-Eranol

Sur cette figure, à l'intérieur de chaque nœud est donné le nombre de molécules qu'il sépare et sur chaque arête sortant d'un nœud est donné le test sur la valeur d'un attribut donné. Ce test peut être classique (comme par exemple  $< 1$ ), comme il peut être flou (comme par exemple "petit"). Dans ce dernier cas, l'appartenance à une partition construite par le système **Salammbô** est montrée sur l'arbre.

Sur cet arbre, nous relevons que l'attribut racine est le grand rayon  $R$ . Sur la branche droite, 24 molécules sur 25 appartiennent à la classe 1. Elles ont toutes une longueur  $R > 11,67$ . Sur la branche gauche de l'arbre, 44 molécules sur 45 ayant une longueur  $R < 11,67$ ,  $d < 0,81$  et  $R/r < 1,70$  appartiennent à la classe 2. De ces deux exemples, on peut tirer que, pour qu'une molécule ait l'odeur du camphre, il faut que sa longueur ne dépasse pas  $11,67\text{\AA}$  et que le rapport de sa longueur à sa largeur ne dépasse pas  $1,70$ . Ce qui donne une idée sur sa forme. La molécule peut être sphérique:  $R/r \rightarrow 1$ , ou ovale (sans que le rapport  $R/r$  ne dépasse  $1,7$ ). Nous remarquons aussi que les descripteurs physico-chimiques l'emportent sur les descripteurs générés par *GESDEM*, et que ces derniers n'interviennent qu'à partir du troisième test.

Les deux branches à l'intérieur de l'arbre sont composées d'éléments appartenant à la classe 1 et à la classe 2, et les règles font intervenir plusieurs attributs.

Pour vérifier la validité de ce genre d'arbres, nous avons réalisé des tests de validation croisée. La base de données a été découpée en 4 sous-groupes ( $S_1$ ,  $S_2$ ,  $S_3$ , et  $S_4$ ), chacun composé de 24 ou 25 molécules tout en gardant la même répartition en classes que dans la base entière.

La validation croisée est réalisée en construisant un arbre de décision flou sur une base d'apprentissage formée de trois sous-groupes (par exemple  $S_1 + S_2 + S_3$ )

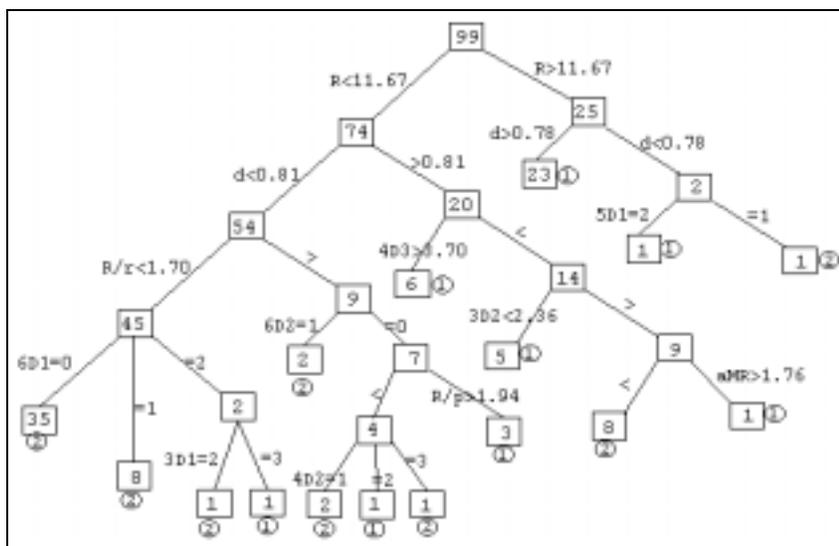


FIG. 2.6 – L'arbre obtenu avec les descripteurs *GESDEM* et physico-chimiques

et le taux de prédiction est mesuré sur le 4ème sous groupe *S4* pour l'exemple.

Le tableau ci-dessous résume les résultats obtenus lors de cette expérience de validation croisée.

	<i>Strict</i>	<i>Lukas</i>	<i>Racine</i>	<i>#chemin</i>	<i>Moyenne</i>
<i>S1</i>	88,5%	88,5%	4D4	10	3,5
<i>S2</i>	72,0%	76,0%	R/r	17	4
<i>S3</i>	95,8%	95,8%	4D4	15	3,6
<i>Moyenne</i>	87,0%	88,0%		14	3,7

#### Résultats de la validation croisée avec les 38 attributs

Dans ce tableau, les deux premières colonnes (*Strict* et *Lukas.*) montrent le taux de bonne classification quand les sous-groupes correspondants sont testés. Dans la colonne *Strict*, on trouve le taux de classification quand le test considéré dans l'arbre de décision flou est un test non flou. Dans la colonne *Lukas.*, est donné le taux de classification quand le test considéré dans l'arbre est flou et utilise la *t* – norme et la *t* – conorme de *Lukasiewicz* pour agréger les degrés intermédiaires.

La colonne *Racine* montre l'attribut sélectionné lors de la construction de l'arbre de décision flou comme attribut racine.



base de donnée en 4 sous-groupes a été gardée. Les résultats sont résumés dans le tableau suivant.

	<i>Strict</i>	<i>Lukas</i>	<i>Racine</i>	<i>#chemin</i>	<i>Moyenne</i>
$S_1$	73,1%	69,2%	$d$	6	2,67
$S_2$	84,0%	87,5%	$R/r$	6	2,67
$S_3$	87,5%	95,8%	$R/r$	7	3
$S_4$	58,3%	70,8%	9%	4	2,25
<i>Moyenne</i>	75,7%	77,9%		5,8	2,6

Contrairement à ce que nous avons remarqué lors de la phase de classification, les résultats obtenus lors de la validation croisée avec les descripteurs physico-chimiques seuls sont moins pertinents qu'en présence de ceux générés par *GESDEM*. Même si les descripteurs générés par *GESDEM* ne contribuent pas largement à la classification des molécules, leur importance lors de la prédiction de l'odeur de nouveaux composés ne peut être niée.

## 2.5 Conclusion

Dans ce chapitre, j'ai présenté deux systèmes d'apprentissage basés sur les arbres de décisions flous. Ce sont deux approches utilisant les connaissances subjectives, soit directement exprimées par l'expert et ajustées par le système, soit simulées à partir du comportement humain par une méthode automatique. Pour valider ces approches, je me suis intéressé à un domaine mal formalisé, la reconnaissance automatique des odeurs. En effet, les règles précises de l'olfaction humaine restent encore peu connues à l'heure actuelle, notamment à cause de la subjectivité inhérente à la perception de l'odeur.

Nous avons travaillé avec des chercheurs chimistes pour trouver des règles d'association entre l'odeur du camphre et la structure des molécules odorantes.

A travers cette coopération nous avons pu dégager un ensemble de résultats et perspectives.

### Conclusions :

- Obtention d'un ensemble de règles confirmant les connaissances subjectives des chimistes sur la relation structure-odeur,
- Comparaison de ces résultats avec les résultats des méthodes telles que (KNN, NN, Réseaux de neurones).
- Amélioration de leur connaissance relative à l'odeur par l'introduction de nouveaux descripteurs, notamment ceux produits par la méthode *GESDEM*,

- Observation de l’aspect graduel de l’odeur donnée par son intensité sur une échelle de 0 à 5, bien que le nombre réduit d’exemples ne nous ait pas permis d’apprendre de façon graduelle l’intensité de l’odeur.

**Perspectives :**

- Définition de nouveaux descripteurs capables de mettre en valeur les connaissances subjectives des chimistes,
- Augmentation de la taille de la base d’apprentissage pour pouvoir améliorer notre approche, ce qui nous permettra de travailler sur l’intensité de l’odeur,
- Application de notre approche à de nouvelles odeurs. Dans l’immédiat, nous travaillons sur l’odeur du bois de santal.
- Regroupement de toutes les données chimiques et neurobiologiques relatives à l’odeur, de façon à faire de l’extraction de connaissances.



## Chapitre 3

# Caractérisation de la texture

### 3.1 La texture

Dans le domaine du traitement d'image, la texture est considérée comme une caractéristique très importante. Cependant, il n'existe pas d'approche formelle ou de définition précise de la texture qui répond à tous les problèmes. Toutes les définitions qualitatives proposées de la texture, sont, soit adaptées aux méthodes d'analyse de textures employées, soit trop générales et donc sans valeur pratique.

La notion de texture est étroitement liée au mode de perception visuelle de l'homme. Pour définir la texture, il faudrait connaître la nature de l'information perçue par l'oeil humain quand celui-ci observe une zone d'image.

On peut dire que la texture caractérise un état de surface en s'intéressant à l'organisation sur l'image de motifs de base, les textons. Micro-objets constitués de quelques pixels, les textons peuvent être définis par leur forme, leur niveau de gris, leur taille ou leur orientation. Deux bois de natures différentes auront ainsi des textures différentes. Identifier une texture suppose donc de la modéliser au préalable à l'aide de paramètres caractéristiques.

Plusieurs méthodes, par exemple la signature fractale, permettent d'identifier, éventuellement de reproduire une texture, mais ces méthodes ne fonctionnent correctement qu'à la condition que la surface analysée n'ait pas subi de déformations. D'où le débat actuel sur la codification et l'analyse pixel par pixel de l'image qui, manifestement, ne correspondent pas à l'approche cognitive du cerveau.

La notion de fréquence spatiale est sous-jacente et se trouve dans plusieurs méthodes d'analyse de la texture.

L'image texturée peut être évaluée qualitativement en termes de finesse, rugosité, régularité, linéarité. Tous ces qualificatifs sont sensés traduire les propriétés des primitives de niveau de gris et leur interactions. Malheureusement, peu de travaux ont tenté de donner une signification précise de ces termes.

Les recherches actuelles s'orientent vers des approches de plus haut niveau en y introduisant un peu de sémantique.

De nombreuses méthodes de caractérisation de textures sur des images ont été proposées depuis les années 70 (Haralick et al., 1973), (Haralick, 1979), (Galloway, 1975) et (Weszka, 1978). Ces méthodes considèrent la texture comme une organisation spatiale des niveaux de gris les uns par rapport aux autres. Elles définissent des paramètres discriminants de la texture en s'appuyant sur des outils statistiques.

La digitalisation des scènes naturelles et la nature des capteurs utilisés introduisent une légère différence de niveau de gris pour des pixels appartenant au même objet. Ces nuances ne sont pas prises en compte dans les systèmes de traitement d'images en général, surtout par les méthodes de dépendances spatiales de niveau de gris. Elles peuvent engendrer une mauvaise interprétation de l'objet.

Dans cette partie, je m'intéresse au traitement de ces nuances en utilisant une représentation basée sur les sous-ensembles flous, et l'impact de celle-ci sur les méthodes reposant sur le principe des longueurs de plages uniformes.

## 3.2 Méthode des longueurs de plages uniformes (LDP)

L'idée de base de cette méthode est d'extraire l'information texturale d'une image à partir des plages de niveaux de gris. Elle est introduite par (Galloway, 1975). Il définit une plage comme une suite de pixels consécutifs de même niveau de gris dans une direction donnée ( $0^\circ, 45^\circ, 90^\circ, 135^\circ$ ). A partir des plages, une matrice  $(P([i, l]))_{1 \leq i \leq NG, 1 \leq l \leq LG}$  est définie. Chaque élément correspond au nombre de plages de niveaux de gris " $i$ " et de longueur " $l$ ",  $NG$  étant le nombre maximal de niveaux de gris et  $LG$  la longueur maximale des plages.

Sur cette matrice, cinq paramètres de statistiques sur les longueurs de plages ont été définis par Galloway.

Notons par  $Pl$  le nombre total de plages dans toute l'image, les paramètres sont :

- Accentuation des petites plages (Short Run Emphasis)

$$SRE = \frac{1}{Pl} \sum_{i=1}^{NGLG} \sum_{l=1}^{NGLG} \frac{P[i, l]}{l^2}$$

- Accentuation des grandes plages (Long Run Emphasis)

$$LRE = \frac{1}{Pl} \sum_{i=1}^{NGLG} \sum_{l=1}^{NGLG} l^2 P[i, l]$$

- Distribution des niveaux de gris (Grey level distribution)

$$GLD = \frac{1}{Pl} \sum_{i=1}^{NG} \left( \sum_{l=1}^{LG} P[i, l] \right)^2$$

*GLD* est minimum lorsque les plages sont également distribuées entre les niveaux de gris.

- Distributions des longueurs de plage (Run length Distribution)

$$RLD = \frac{1}{Pl} \sum_{l=1}^{LG} \left( \sum_{i=1}^{NG} P[i, l] \right)^2$$

*RLD* est minimum lorsque les plages sont également distribuées entre les longueurs.

- Pourcentage des plages (Run percentage)

$$RP = \sum_{i=1}^{NG} \sum_{l=1}^{LG} \frac{P[i, l]}{N}$$

RP est le rapport entre le nombre total de plages et le nombre  $N$  de pixels de l'image.

(Chu et al., 1990) et (Dasarathy et Holder, 1991) ont introduit respectivement deux et quatre autres paramètres de LDP. Tous ces paramètres permettent de quantifier les petites et les grandes plages.

## 3.3 Les plages floues

### 3.3.1 Les sous-ensembles flous de niveaux de gris

Sur une image composée d'objets où les pixels présentent de faibles variations d'intensité, les paramètres de LDP montrent la présence d'un nombre de pixels isolés ou de courtes plages. La représentation de cette image par le concept de plage uniforme ne prend pas en considération la proximité des pixels ayant des niveaux de gris voisins. Ceci ne met pas en relief la nuance de la perception visuelle sur les niveaux de gris proches. Cette représentation influe aussi sur les résultats d'une classification ou d'une segmentation.

Pour prendre en considération cette nuance des niveaux de gris, nous associons à un niveau de gris " $i$ " un sous-ensemble flou  $F_i$ . Celui-ci caractérise les nuances entre les niveaux de gris autour de la valeur " $i$ ". Le degré d'appartenance au sous-ensemble flou  $F_i$  est défini de façon graduelle (Figure 3.1). Nous considérons les nuances seulement sur  $\pm 3$  niveaux de gris à titre d'illustration. Remarquons que la vision humaine est incapable de distinguer des variations sur 10 niveaux de gris. Le sous-ensemble  $F_i$  est définie par :

$$f_{F_i}(j) = 1 - \frac{|k|}{4} \quad \text{si } j = i \pm k, \text{ avec } 0 \leq k \leq 3$$

$$f_{F_i}(j) = 0 \quad \text{sinon}$$

ou par notation  $F_i = \sum 1 - \frac{|k|}{4} |j$ ,

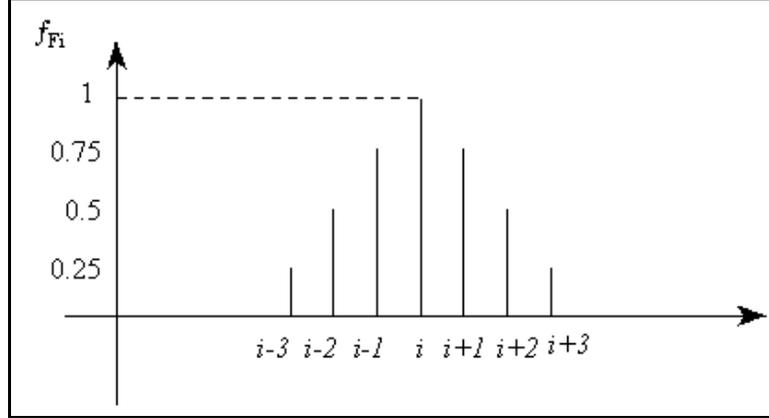


FIG. 3.1 – Fonction d'appartenance de  $F_i$

A un pixel  $(x_1, x_2) \in \mathbb{N} \times \mathbb{N}$ , on associe un niveau de gris "i" par une application définie par :

$$n : \mathbb{N} \times \mathbb{N} \longrightarrow \{0, \dots, 255\}$$

$$(x_1, x_2) \longrightarrow i$$

Ainsi on définit le sous-ensemble flou de niveau de gris d'un pixel  $(x_1, x_2)$  par :

$$F_{n((x_1, x_2))} = \sum 1 - \frac{|k|}{4} | n((y_1, y_2)) \quad \text{avec } n((y_1, y_2)) = n((x_1, x_2)) \pm k, k = 0, \dots, 3$$

### 3.3.2 Définition des plages floues

De façon récurrente, nous introduisons une relation de proximité,  $R_{12}$ , entre un pixel  $(x_1, x_2)$  de l'image et ses voisins. La fonction caractéristique,  $f_{R_{12}}$ , de la relation  $R_{12}$ , tient en compte du niveau de gris du pixel  $(x_1, x_2)$  et des valeurs des niveaux de gris de la suite des pixels consécutifs dans toutes les directions. La fonction  $f_{R_{12}}$ , est donnée par :

$$f_{R_{12}}((x_1, x_2), (y_1, y_2)) = 1 \quad \text{si } (x_1, x_2) = (y_1, y_2)$$

$$= f_{F_{n(x_1, x_2)}}(n(y_1, y_2)) \quad \text{si } (\exists (z_1, z_2) / (y_1, y_2) = (z_1, z_2) + (d_1, d_2) \text{ et } f_{R_{12}}((x_1, x_2), (z_1, z_2)) > 0$$

$$\text{avec } d_1, d_2 \in \{-1, 0, 1\})$$

$$= 0 \quad \text{sinon}$$

$d = (d_1, d_2)$  représente les différentes directions de déplacement dans l'image.

Une plage floue est définie comme une suite de pixels consécutifs de niveaux de gris proches dans toutes les directions possibles de parcours d'une image. Elle correspond au sous-ensemble flou constitué des éléments qui sont en relation avec  $(x_1, x_2)$  avec un degré non nul:

$$\hat{R}(x_1, x_2) = \sum f_{R_{12}}((x_1, x_2), (y_1, y_2)) \mid (y_1, y_2)$$

**Exemple de plages floues:**

Considérons l'image suivante, représentée par 6 pixels sur une ligne, nous nous déplaçons sur cette image en deux directions  $d_1 = (0, 1)$  et  $d_2 = (0, -1)$

(0, 0)	(0, 1)	(0, 2)	(0, 3)	(0, 4)	(0, 5)
1	2	2	3	6	7

A chaque pixel on associe une plage floue par

$$\hat{R}(0, 0) = \{1 \mid (0, 0), 0.75 \mid (0, 1), 0.75 \mid (0, 2), 0.5 \mid (0, 3)\}$$

$$\hat{R}(0, 5) = \{0.75 \mid (0, 4), 1 \mid (0, 5)\}$$

A une plage associée à un pixel  $(x_1, x_2)$ , nous définissons :

- le cardinal du noyau de la plage  $\hat{R}(x_1, x_2)$  représentant la longueur classique d'une plage si les pixels voisins sont tous de même niveau de gris. Il est représenté par  $\left| N(\hat{R}(x_1, x_2)) \right|$ .
- le cardinal du support de  $\hat{R}(x_1, x_2)$  représentant la longueur floue de la plage, représenté par  $\left| Supp(\hat{R}(x_1, x_2)) \right|$

### 3.4 Plages floues dominantes

En partant d'un pixel donné  $(x_1, x_2)$ , nous prenons une par une, les plages floues des pixels appartenant avec un degré non nul à la plage floue de  $(x_1, x_2)$ . Ces plages doivent contenir ou être contenues dans la plage initiale pour être prises en considération. La plage floue dominante résultante est la plage caractérisée par le niveau de gris du pixel le plus représenté (le plus grand noyau). En cas d'équité-représentativité de deux niveaux de gris, nous prenons la plage offrant le plus grand support.

Notons par  $\left\{ \hat{R}(x_1, x_2) \right\}$  l'ensemble ordinaire des pixels qui appartiennent avec un degré non nul à  $\hat{R}(x_1, x_2)$ :

$$\left\{ \hat{R}(x_1, x_2) \right\} = \{(y_1, y_2) / f_{R_{12}}((x_1, x_2), (y_1, y_2)) > 0\}$$

Pour déterminer la plage floue dominante à partir d'un pixel  $(x_1, x_2)$  donné ou à partir de sa plage, on utilise l'algorithme suivant:

**Algorithme de plages floues dominantes**

1.  $T = \hat{R}(x_1, x_2), D = \{(x_1, x_2)\}$

2. tant que  $\exists (y_1, y_2) \in \hat{R}(x_1, x_2)$  et  $(y_1, y_2) \notin D$  faire  
 début  
   si  $\{T\} \subset \{\hat{R}(y_1, y_2)\}$  ou  $\{T\} \supset \{\hat{R}(y_1, y_2)\}$   
   alors  
     si  $|N(\hat{R}(x_1, x_2))| > |N(T)|$  alors  $T = \hat{R}(x_1, x_2)$   
     si  $|N(\hat{R}(x_1, x_2))| = |N(T)|$  alors  
       si  $|Supp(\hat{R}(x_1, x_2))| > |Supp(T)|$  alors  $T = \hat{R}(x_1, x_2)$   
       sinon  $T = \hat{R}(y_1, y_2)$   
     sinon  $T = \hat{R}(y_1, y_2)$   
    $D = D \cup \{y\}$   
 fin   /\*fin du tant que\*/

### Exemple de plages floues dominantes

Considérons l'image suivante, représentée par 6 pixels sur une ligne, nous nous déplaçons dans cette image dans deux directions  $d_1 = (0, 1)$  et  $d_2 = (0, -1)$

(0, 0)	(0, 1)	(0, 2)	(0, 3)	(0, 4)	(0, 5)
1	2	2	3	6	7

A l'aide de l'algorithme ci-dessus, nous obtenons deux plages floues dominantes qui ne sont pas forcément disjointes :

$\hat{R}_1 = \hat{R}(0, 1)$  a pour niveau de gris dominant 2,

$\hat{R}_2 = \hat{R}(0, 4)$  a pour niveau de gris dominant 6.

Le pixel (0, 3) appartient à  $\hat{R}_1$  avec un degré d'appartenance de 0,75 et appartient à  $\hat{R}_2$  avec un degré de 0,25.

**Remarque 3** *Les plages floues dominantes constituent une partition floue de l'image.*

**Remarque 4** *A chaque plage floue dominante correspond un niveau de gris dominant. Dans la suite de ce chapitre nous indexerons les plages floues dominantes par leurs niveaux de gris dominants, on les note  $\hat{R}^i$ ,  $i$  étant le niveau de gris dominant.*

### 3.4.1 Les matrices de longueurs de plages floues dominantes

Ce sont des matrices qui contiennent des informations sur les longueurs des noyaux et les longueurs des supports des plages floues dominantes:

Nous définissons la matrice des longueurs des noyaux des plages floues dominantes par:

$$(P[i, l])_{1 \leq i \leq NG, 1 \leq l \leq LG}$$

avec  $NG$  la valeur maximale du niveau de gris,  $LG$  la longueur maximale des noyaux des plages floues dominantes et  $P[i, l]$  le nombre de plage floues dominantes associées au niveau de gris  $i$  et dont la longueur du noyau est égale à  $l$ .

Soit  $(\hat{R}_k^i)_{1 \leq k \leq m_i}$  la famille de plages floues dominantes de niveau de gris dominant  $i$ , les éléments de la matrice peuvent être exprimés par:

$$P[i, l] = \sum_{k=1}^{m_i} \delta_{ik}^l$$

avec

$$\begin{aligned} \delta_{ik}^l &= 1 \quad \text{si} \quad l = |N(\hat{R}_k^i)| \\ &= 0 \quad \text{sinon} \end{aligned}$$

A chaque élément  $P[i, l]$  nous associons un vecteur  $M_l^i$ , d'ordre  $P[i, l]$ . Il contient les longueurs des supports des plages floues dominantes de niveau de gris  $i$  et de longueur  $l$ .

Si  $(\hat{R}_k^i)_{1 \leq k \leq P[i, l]}$  est la famille des plages de niveau de gris dominant  $i$  et de longueur de plage  $l$  alors :

$$M_l^i(k) = |Supp(\hat{R}_k^i)|, 1 \leq k \leq P[i, l]$$

où  $Supp(\cdot)$  indique le support du sous-ensemble flou considéré.

### Exemple de matrices de longueurs de plages floues dominantes

Soit l'image suivante:

1	7	1	3	2
1	7	1	2	6
7	7	6	2	6
8	2	2	1	7
6	2	6	1	7

La matrice des longueurs des noyaux des plages floues dominantes est :

$$P[i, l] = \begin{array}{c} i \backslash l \\ \begin{array}{c} 1 \\ 2 \\ 6 \\ 7 \\ 8 \end{array} \end{array} \begin{array}{c} 1 \\ 2 \end{array} \begin{array}{c} 4 \\ 3 \\ 4 \\ 4 \\ 0 \end{array} \begin{array}{c} 0 \\ 1 \\ 0 \\ 1 \\ 0 \end{array}$$

Le vecteur  $(M_1^2(k))_{1 \leq k \leq 3}$  représente les longueurs des supports des plages floues dominantes ayant comme longueur de noyau 1 et de niveau de gris dominant 2 est :

$$M_1^2 = \begin{pmatrix} 2.5 \\ 1 \\ 1 \end{pmatrix}$$

### 3.5 Paramètres de longueurs de plages floues dominantes (LPDF)

Considérons par  $(\hat{R}_k^i)_{k=1..m_i}$  la famille des plages floues dominantes de niveau de gris  $i$ , et  $PL$  le nombre de plages floues dominantes dans l'image. Une généralisation des paramètres de longueurs de plages aux plages floues dominantes peut être obtenue à partir de la matrice des longueurs de plages floues dominantes de la façon suivante :

- Accentuation des petites plages floues (Fuzzy short run Emphasis)

$$FSRE = \frac{1}{PL} \sum_{i=1}^{NG} \sum_{l=1}^{LG} \sum_{k=1}^{m_i} \frac{\delta_{ik}^l}{|Supp(\hat{R}_k^i)|^2}$$

- Accentuation des grandes plages floues (Fuzzy long run Emphasis)

$$FLRE = \frac{1}{PL} \sum_{i=1}^{NG} \sum_{l=1}^{LG} \sum_{k=1}^{m_i} \delta_{ik}^l |Supp(\hat{R}_k^i)|^2$$

- Distribution des niveaux de gris flous (Fuzzy grey level distribution)

$$FGLD = \frac{1}{PL} \sum_{i=1}^{NG} \left( \sum_{l=1}^{LG} \sum_{k=1}^{m_i} \delta_{ik}^l \frac{|Supp(\hat{R}_k^i)|}{|N(\hat{R}_k^i)|} \right)^2$$

- Distribution des longueurs de plages floues (Fuzzy run length distribution)

$$FRLD = \frac{1}{PL} \sum_{l=1}^{LG} \left( \sum_{i=1}^{NG} \sum_{k=1}^{m_i} \delta_{ik}^l \frac{|Supp(\hat{R}_k^i)|}{|N(\hat{R}_k^i)|} \right)^2$$

– Pourcentage de plages floues

$$FRP = \frac{1}{N} \sum_{l=1}^{LG} \sum_{i=1}^{NG} \sum_{k=1}^{mi} \delta_{ik}^l$$

avec

$$\delta_{ik}^l = \begin{cases} 1 & \text{si } l = |N(\hat{R}_k^i)| \\ 0 & \text{sinon} \end{cases}$$

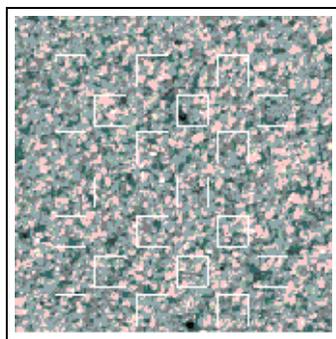
**Remarque 5** Notons que, pour ce travail de synthèse, je me suis limité, à présenter les cinq premiers paramètres définis par Galloway. Les autres paramètres de longueurs de plages définis par (Chu et al., 1990) et (Dasarathy et Holder, 1991) sont étendus par le même principe. Nous détaillons ceci dans (Bekhoucha et al., 2000b).

### 3.5.1 Utilisation des paramètres flous pour la caractérisation de la texture

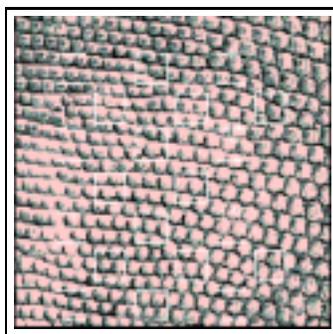
Je présente dans cette section les différents tests réalisés sur plusieurs images texturées ou non texturées. Elles sont quantifiées par les paramètres de longueurs de plages classiques et flous. Je ne présente dans cette synthèse que des tests avec les cinq paramètres pris ensemble.

#### Tests sur des images texturées

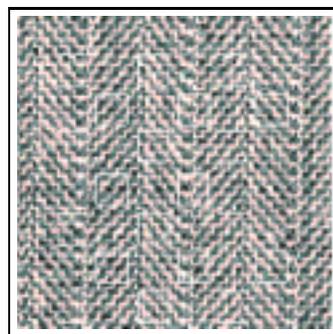
Nous avons fait des tests sur des images tirées du catalogue de Brodatz (Brodatz, 1966). Pour ce manuscrit, nous avons choisi de présenter les résultats relatifs aux trois images suivantes *Sable*, *Peau de lézard* et *canevas*. Visuellement, nous pouvons les différencier d'une manière relativement facile. Mais, verbalement, il nous est difficile de les caractériser, il faut plusieurs qualificatifs pour pouvoir le faire.



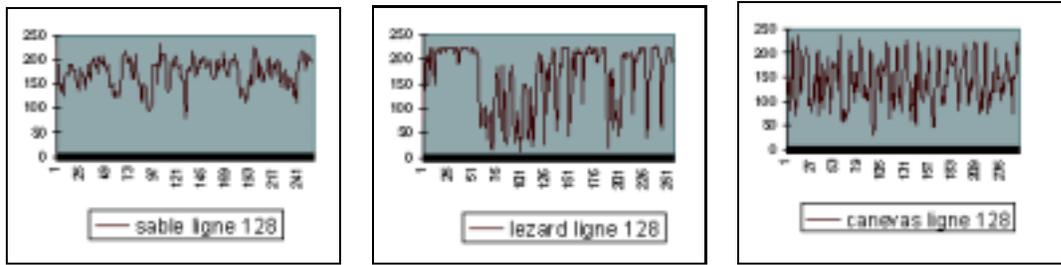
Sable



Lézard



Canevas



Si nous examinons ces images à un bas niveau, nous pouvons remarquer que les répartitions des niveaux de gris sont très différentes d'une image à une autre. En effet, si on compare la répartition des niveaux de gris sur la ligne 128 de ces figures (*canevas ligne 128*, *lézard ligne 128*, *sable ligne 128*) on constate que la différence est évidente mais néanmoins difficile à décrire.

Pour caractériser automatiquement ces images à l'aide des paramètres de longueurs de plages floues dominantes et non floues, nous avons prélevés 20 échantillons de taille  $25 \times 25$  sur les trois images. Nous avons calculé les paramètres de longueurs de plages classiques et non classiques. En utilisant ces paramètres comme descripteurs et leurs mesures comme valeurs, nous avons pu séparer ces images à l'aide d'un arbre de décision classique.

La caractérisation des trois textures à l'aide des paramètres de longueurs de plages sous forme de règles obtenus par l'arbre de décisions est donnée ci dessous :

- R1:  $RLD > 514.5 \ \& \ GLD > 8.26 \ \& \ RLD > 598 \rightarrow$  canevas
- R2:  $RLD > 514.5 \ \& \ GLD > 8.26 \ \& \ RLD \leq 598 \rightarrow$  sable
- R3:  $RLD > 514.5 \ \& \ GLD \leq 8.26 \ \& \ RLD > 576.5 \rightarrow$  canevas
- R4:  $RLD > 514.5 \ \& \ GLD \leq 8.26 \ \& \ RLD \leq 576.5 \ \& \ GLD > 7.025 \ \& \ LRE > 1.095 \ \& \ RLD > 559.5 \ \& \ GLD > 8.1 \rightarrow$  canevas
- R5:  $RLD > 514.5 \ \& \ GLD \leq 8.26 \ \& \ RLD \leq 576.5 \ \& \ GLD > 7.025 \ \& \ LRE > 1.095 \ \& \ RLD > 559.5 \ \& \ GLD \leq 8.1 \ \& \ RLD > 568.5 \ \& \ RLD \leq 570 \rightarrow$  canevas
- R6:  $RLD > 514.5 \ \& \ GLD \leq 8.26 \ \& \ RLD \leq 576.5 \ \& \ GLD > 7.025 \ \& \ LRE > 1.095 \ \& \ RLD > 559.5 \ \& \ GLD \leq 8.1 \ \& \ RLD > 568.5 \ \& \ RLD \leq 571 \rightarrow$  sable
- R7:  $RLD > 514.5 \ \& \ GLD \leq 8.26 \ \& \ RLD \leq 576.5 \ \& \ GLD > 7.025 \ \& \ LRE > 1.095 \ \& \ RLD > 559.5 \ \& \ GLD \leq 8.1 \ \& \ RLD \leq 568.5 \rightarrow$  sable
- R8:  $RLD > 514.5 \ \& \ GLD \leq 8.26 \ \& \ RLD \leq 576.5 \ \& \ GLD > 7.025 \ \& \ LRE > 1.095 \ \& \ RLD \leq 559.5 \rightarrow$  canevas
- R9:  $RLD > 514.5 \ \& \ GLD \leq 8.26 \ \& \ RLD \leq 576.5 \ \& \ GLD > 7.025 \ \& \ LRE \leq 1.095 \rightarrow$  canevas
- R10:  $RLD > 514.5 \ \& \ GLD \leq 8.26 \ \& \ RLD \leq 576.5 \ \& \ GLD \leq 7.025 \rightarrow$  sable
- R11:  $RLD \leq 514.5 \rightarrow$  lézard

L'interprétations de ces règles est très difficile, et ne reflète pas l'aisance avec laquelle la perception visuelle permet de différencier ces images.

La caractérisation de ces images en utilisant les paramètres de longueurs de plages dominantes floues est donnée par les règles ci-dessous :

R1:  $FRLD > 324.091$  &  $FSRE > 1.25862 \rightarrow$ sable

R2:  $FRLD > 324.091$  &  $FSRE \leq 1.25862 \rightarrow$ canevas

R3:  $FRLD \leq 324.091 \rightarrow$ lézard

L'interprétation de ces règles est moins difficile qu'avec les paramètres de longueurs de plages classiques :

- Comme avec les paramètres classiques, l'image *Peau de lézard* est identifiée avec le seul paramètre  $FRLD$ . En effet, ce paramètre met en valeur les plages qui sont grandes et uniformes, de façon compatible avec notre perception visuelle.
- Par contre le paramètre  $FRLD$  ne peut à lui seul caractériser *le canevas* et *le sable*. Le paramètre  $FSRE$ , qui accentue les petites plages départage *le sable* et *le canevas*. En effet le sable par sa structure présente des plages qui sont grandes par rapport à celles du canevas. Ceci est relativement conforme à notre perception visuelle des images ci-dessus.

### Test sur des images non texturées

Nous avons fait d'autres tests sur des images non texturées. Nous présentons dans ce manuscrit les résultats obtenus relativement à la photo d'une femme (figure 3.2), nous voulons séparer le visage, le bras, les cheveux de la femme et le fond de l'image.



FIG. 3.2 – *Image de jeune femme*

Les paramètres des longueurs de plages classiques fournissent les résultats suivants :

R1:  $GLD > 12.35$  &  $GLD > 19.55 \rightarrow$ visage

- R2:  $GLD > 12.35 \ \& \ GLD \leq 19.55 \rightarrow$ bras  
 R3:  $GLD \leq 12.35 \ \& \ GLD > 8.695 \ \& \ RP > 0.945 \ \& \ RP0.95 \rightarrow$ fond  
 R4:  $GLD \leq 12.35 \ \& \ GLD > 8.695 \ \& \ RP > 0.945 \ \& \ RP0.96 \rightarrow$ bras  
 R5:  $GLD \leq 12.35 \ \& \ GLD > 8.695 \ \& \ RP \leq 0.945 \rightarrow$ cheveux  
 R6:  $GLD \leq 12.35 \ \& \ GLD \leq 8.695 \ \& \ RP > 0.948 \rightarrow$ cheveux  
 R7:  $GLD \leq 12.35 \ \& \ GLD \leq 8.695 \ \& \ RP \leq 0.948 \rightarrow$ fond

Les résultats obtenus pour les paramètres des longueurs de plages floues sous formes de règles sont:

- R1:  $FGLD > 19.3259 \rightarrow$ visage  
 R2:  $FGLD \leq 19.3259 \ \& \ FLRE > 1.44569 \ \& \ FGLD > 8.98671 \rightarrow$ cheveux  
 R3:  $FGLD \leq 19.3259 \ \& \ FLRE > 1.44569 \ \& \ FGLD \leq 8.98671 \ \& \ FRLD > 338.909 \ \& \ FRP0.820313 \rightarrow$ cheveux  
 R4:  $FGLD \leq 19.3259 \ \& \ FLRE > 1.44569 \ \& \ FGLD \leq 8.98671 \ \& \ FRLD > 338.909 \ \& \ FRP0.847188 \rightarrow$ fond  
 R5:  $FGLD \leq 19.3259 \ \& \ FLRE > 1.44569 \ \& \ FGLD \leq 8.98671 \ \& \ FRLD \leq 338.909 \rightarrow$ fond  
 R6:  $FGLD \leq 19.3259 \ \& \ FLRE \leq 1.44569 \ \& \ FRP > 0.734375 \rightarrow$ bras  
 R7:  $FGLD \leq 19.3259 \ \& \ FLRE \leq 1.44569 \ \& \ FRP \leq 0.734375 \rightarrow$ fond

Les résultats obtenus sur des images non texturées sont proches et ne permettent pas de retrouver cette facilité avec laquelle les humains arrivent à différencier ces régions au niveau de la texture. Nous avons fait les tests sur trois et deux classes, nous avons constaté un léger avantage des paramètres flous pour la discrimination par rapport aux paramètre classiques.

Notons que les cinq paramètres que nous avons considérés dans cette synthèse ne prennent pas en considération le degré du niveau de gris. Les autres paramètres de *Chu* et de *Dasaraty* et leur extensions floues prennent en considération le degré du niveau de gris. Dans ce cas, la différenciation des textures se fait d'une manière réduite et équivalente entre le cas flou et non flou.

**Remarque 6** *L'équivalence des résultats sur la photo de la femme est due au fait que les objets que nous avons essayé de séparer sont homogènes au niveau des variations des niveaux de gris, les paramètres flous et non flous sont équivalents dans ce cas.*

Nous avons aussi fait varier la nuance des sous-ensemble flous pour étudier l'impact de cette nuance sur la caractérisation de la texture. Cette nuance passe généralement par un seuil critique qui permet au mieux de caractériser la texture. Ce seuil est généralement grand pour des régions texturées et petit pour des régions moins texturées.

## 3.6 Conclusion

Dans ce chapitre, j'ai présenté un ensemble de travaux que j'ai effectués en collaboration avec B. Bekkhoucha, pour caractériser la texture en imagerie. Nous nous sommes appuyés pour cela sur la théorie des sous-ensembles flous. Dans un premier temps, nous nous sommes intéressés aux longueurs de plages et à leur paramètres. Nous avons montré l'intérêt d'une représentation avec des sous-ensemble flous. Cela nous a permis de définir des plages floues et leur longueurs. Nous avons aussi développé un algorithme qui généralise des plages floues dominantes. Ces plages floues dominantes nous ont permis de définir de nouveaux paramètres capables de caractériser les textures.

Pour cette synthèse je me suis contenté de présenter les cinq premiers paramètres de Galloway et leur extension. Mais, dans nos travaux, nous avons aussi généralisé les paramètres de Chu (Chu et al., 1990) et de Dasarathy (Dasarathy et Holder, 1991). Nous avons aussi montré sur des images l'intérêt de cette approche en accord avec la perception humaine de la texture.

En perspective de ces travaux, nous étudions la possibilité d'utiliser cette représentation pour segmenter l'image en régions ou taches floues. En effet l'algorithme que nous avons présenté pour chercher les plages floues dominantes parcourt l'image dans les deux directions horizontales. Il devient complexe quand on la parcourt dans toutes les directions. Nous souhaitons réduire sa complexité pour définir des régions homogènes dans l'image. La nuance des niveaux de gris pour définir les sous-ensembles flous de niveaux de gris est fixée par l'utilisateur, nous envisageons d'effectuer un prétraitement de l'image pour définir une nuance par région.

## Bibliographie du chapitre 3

- Beck, J. (1982). *Organisation and representation in perception*, chapter Texture Segmentation, pages 285–317. Erlbaum, Hillsdale NJ.
- Bekkhoucha, A., Ramdani, M., et A.Fares (2000). Définition de paramètres de caractérisation de texture par les longueurs de plages floues. In *International Symposium On Image/Video Communications Over Fixed and Mobile Networks ISIVC'2000*, pages 55–65. Rabat.
- Brodatz, P. (1966). *A Photographic Album for Artists Designers*. Dover, New York.
- Chen, Y.Q., Nixon, M.S., et Thomas, D.W. (1995). Statistical geometrical features for texture classification. *Pattern Recognition*, (4)28:537–552.
- Chu, A., Sehgal, C.M., et Greenleaf, J.F. (1990). Use of grey value distribution of run lengths for texture analysis. *Pattern Recognition Letters*, 11:415–420.
- Cross, G. R. et Jain, A.K. (1983). Markov random field texture models. *IEEE Trans. on Patter Analysis and Machine Intelligence*, (5)1:25–39.
- Dasarathy, B.V. et Holder, E.B. (1991). Image caractérisation based on joint grey level-run length distributions. *Pattern Recognition Letters*, 12:497–502.
- Davis, L.S., Johns, S.A., et Aggarwal, J.K. (1979). Textures analysis using generalized co-occurrence matrices. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1(3):251–259.
- Galloway, M.M. (1975). Texture analysis using grey level run lengths. *Computer Graphics Image Processing*, 4:172–179.
- Haralick, R.M. (1979). Statistical and structural approaches to textures. *Processing of IEEE*, (5)67:786–804.
- Haralick, R.M., Chanmugan, C., et Dinstein, I. (1973). Texture features for image classification. *IEEE Trans. Syst. Man and Cybern*, SMC-3:610–621.
- Julez, B. et Bergen, J.R. (1987). Textons, the fundamental elements in preattentive vision and perception of textures. In Fischler, M.A. et Firschein, O., editors, *Reading in Computer vision*, pages 234–256, Los Altos CA. Morgan Kaufmann.
- Unser, M. (1984). *Description Statique de Textures: application à l'inspection automatique*. Thèse de doctorat, Ecole Polytechnique Fédéral de Lausanne, Suisse.
- Weszka, J.S. (1978). Survey of threshold selection technique. *Computer Graphics Image Processing*, 7:259–265.

# Chapitre 4

## Architecture hybride pour la surveillance d'un réseau local

### 4.1 Introduction

Ce travail entre dans le cadre d'une coopération avec l'Institut National des Postes et Télécommunications de Rabat. Cette coopération s'intéresse au problème de la congestion dans les réseaux en général, en utilisant des méthodes basées sur la perception humaine. Pour commencer, nous nous sommes intéressés à l'automatisation de la surveillance d'un réseau local en utilisant l'interfaçage entre la perception humaine des paramètres du réseau et les paramètres physiques.

Dans la gestion des réseaux (Stevenson, 1995), les principales fonctions pouvant être associées à l'approche des techniques de l'intelligence artificielle sont la gestion des performances, le diagnostic des fautes ou de la cause des imperfections, et le contrôle du réseau ainsi que sa configuration.

La première phase consiste à détecter les anomalies dans les performances du réseau. La deuxième phase consiste en un diagnostic des causes de ces anomalies. Enfin, après identification de la source du problème, il faut établir une suite d'actions à entreprendre pour régler les paramètres du réseau et donc son comportement.

La complexité et la variabilité des réseaux rendent l'analyse de leurs données une prémisses fondamentale pour une administration et une gestion optimale de leurs performances. L'avantage des réseaux modernes réside dans leur capacité à fournir l'état de leurs paramètres, ce qui devrait permettre une identification des erreurs et par la suite une correction dynamique du comportement du réseau.

Les données intervenant dans un processus sont généralement interprétées d'une manière imprécise dans la perception de l'administrateur des réseaux. La représentation de ces données par des sous-ensembles flous et l'utilisation de mode

d'inférence issu des techniques de la commande floue, associées aux techniques des réseaux de neurones, contribuent de façon très substantielle à la conception des systèmes d'aide à la décision pour réduire la congestion du trafic d'un réseau. En effet, la congestion est caractérisée par plusieurs paramètres qui sont plutôt vagues dans l'esprit de l'administrateur. Il utilise généralement des propositions floues telles que "le temps de réponse est long".

Le problème de la congestion dans les réseaux locaux a fait l'objet de plusieurs travaux de recherche en se basant sur les techniques de logique floue. Dans ses travaux (Leckie, 1995) a développé un système expert flou pour la gestion et le diagnostic des fautes dans un réseau. Dans l'article (Carvalho et al., 1999), les auteurs ont mis en œuvre les techniques floues pour la gestion distribuée d'un réseau local (Lewis, 1994).

Notre approche est basée sur des techniques classiques, de logique floue, d'inférence neuronale floue et, d'apprentissage neuronal flou. Nous les avons exploitées pour représenter la perception, des paramètres de performance de réseau et les fonctions de perception de ces paramètres sous formes de règles "si.. alors".

Dans la première section de ce travail, je présente l'approche de l'inférence neuronale permettant le traitement des règles floues. Dans la deuxième section, je présente quelques éléments de l'application sur le trafic dans le réseau local. La troisième partie consiste en un sondage des données du réseau sur quelques journées et à la modélisation de son comportement en fonction des intervalles de temps. Enfin, dans la dernière section, nous discutons les perspectives souhaitées.

## 4.2 Surveillance automatique d'un réseau local

Les réseaux sont de plus en plus complexes, il faut donc analyser leurs données pour gérer leurs performances. Il reste que les réseaux modernes sont capables d'informer, plus que jamais, sur les détails de leurs performances, donc une solution de correction doit être déclenchée automatiquement en attendant d'arriver à diagnostiquer des problèmes plus subtils et aider à identifier des erreurs plus tôt, avant qu'ils n'affectent davantage de sites.

La tâche journalière d'un administrateur réseau est de surveiller ces données durant une journée. Leur interprétation par l'administrateur est généralement imprécise, il ne va pas jusqu'aux détails de ces données pour faire son diagnostic. Ainsi, nous proposons un modèle basé sur la perception en utilisant la logique floue et les réseaux de neurones pour la surveillance d'un réseau local. Ceci permet d'aider l'administrateur dans ses tâches journalières de prévention, et de planification de l'extension ou de l'augmentation du débit en cas de problème persistant. Le but en est de rapprocher la perception humaine et les systèmes d'aides à la décision.

### 4.2.1 Architecture générale du modèle

Le modèle est composé de deux modules (figure 4.1) : un module neuro-flou qui fait l'interface entre les données du réseau et les connaissances expertes puis l'inférence, et un module d'apprentissage. Le but de ce dernier est de nous livrer une fonction proche de la perception humaine qui lie l'état du réseau et le temps. Ceci se base sur les données recueillies à partir des sorties du module neuro-flou pendant quelques jours.

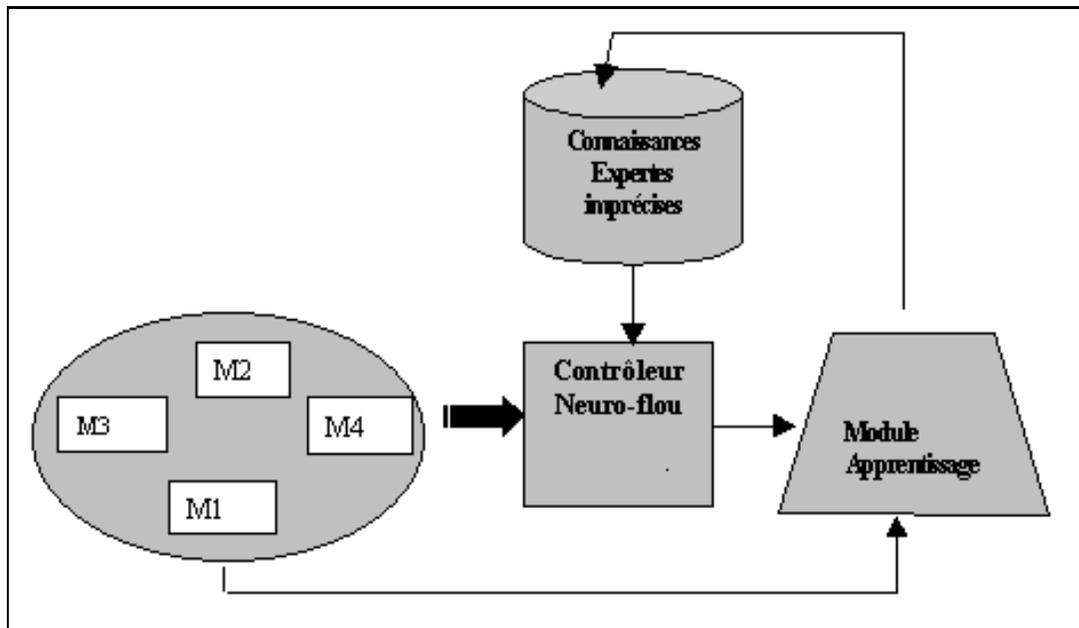


FIG. 4.1 – Architecture Générale de la plate-forme

### 4.2.2 Le module neuro-flou

Le module neuro-flou (Fig 4.2) est composé :

- d'un sous-module de fuzzification des entrées, il permet la conversion des données numériques en des données symboliques,
- d'un sous-module d'inférence floue, il met en œuvre les règles floues de l'expert,
- enfin d'un sous-module de défuzzification, qui permet la conversion des sorties symboliques en numériques.

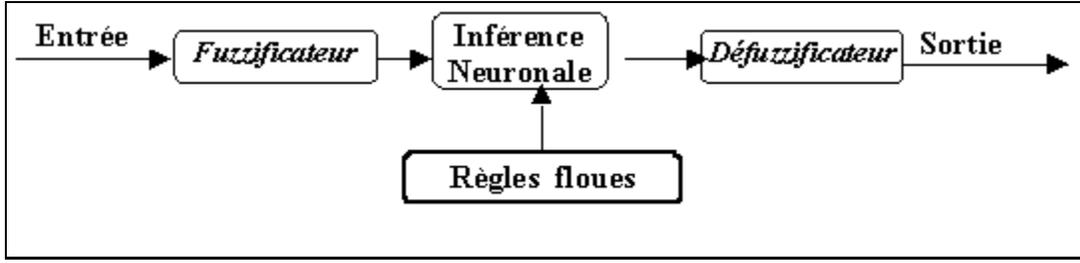


FIG. 4.2 – Schéma d'un régulateur neuro- flou

### Inférence neuronale

Pour illustrer notre approche d'inférence neuro-floue nous présentons le cas où on a deux variables d'entrées et une variable de sortie.

Considérons trois variables floues :

$$(u, U = \{U_i\}, (\mu_{U_i}))_{i=1..n}$$

$$(v, V = \{V_i\}, (\mu_{V_i}))_{i=1..m}$$

$$(w, W = \{W_i\}, (\mu_{W_i}))_{i=1..k}$$

où  $\mu_{U_i}$  est la fonction d'appartenance de l'ensemble flou  $U_i$  défini sur l'univers de discours  $U$  de la variable d'entrée  $u$ . Les fonction  $\mu_{V_i}$  et  $\mu_{W_i}$  sont définies de la même façon sur les univers  $V$  et  $W$ . Supposons que nous avons  $N_r$  règles floues représentant les connaissance expertes.

$$\begin{array}{llll}
 R_1 & \text{si } u \text{ est } U_1 & \text{et } v \text{ est } V_1 & \text{alors } w \text{ est } W_1 \\
 R_2 & \text{si } u \text{ est } U_2 & \text{et } v \text{ est } V_2 & \text{alors } w \text{ est } W_2 \\
 \dots & \dots\dots & \dots & \dots\dots \\
 R_{N_r} & \text{si } u \text{ est } U_{N_r} & \text{et } v \text{ est } V_{N_r} & \text{alors } w \text{ est } W_{N_r}
 \end{array}$$

Si les valeurs des variables d'entrées sont des nouvelles valeurs telles que  $u$  est  $U'$  et  $v$  est  $V'$ , l'inférence floue classique nous permet de déduire une conclusion de la forme  $w$  est  $W'$ , calculée en utilisant la règle compositionnelle suivante:

$$W' = (U', V') \wedge \left( \bigvee_{i=1}^{N_r} R(U_i, V_i, W_i) \right) = \bigvee_{i=1}^{N_r} (U', V') \wedge R(U_i, V_i, W_i)$$

où  $\wedge$  est une t-norme généralement le *min* et  $\vee$  est la t-conorme associée le *max*.

Le calcul peut se faire directement, en utilisant le principe utilisé par les méthodes de contrôle. Pour simplifier ce calcul d'inférence, nous discrétisons les univers des variables linguistiques, nous transformons la règle d'inférence en fonction de la discrétisation et, nous effectuons l'inférence à l'aide d'un réseaux de neurones.

**Discrétisation et inférence** Nous discrétisons les univers  $U$ ,  $V$  et  $W$  respectivement en  $\{u_i, i = 1, \dots, n\}$ ,  $\{v_j, j = 1, \dots, m\}$  et  $\{w_k, k = 1, \dots, p\}$ .

Tous les points  $u_i, v_j, w_k$ , sont reliés par une relation floue

$$r_l(u_i, v_j, w_k) = ((\mu_{U_l}(u_i) \wedge \mu_{V_l}(v_j)) \wedge \mu_{W_l}(w_k))$$

si nous appliquons la règle  $R_l$ .

Nous déduisons une relation globale  $r_l(u, v, w_k)$ , mettant en évidence la contribution du produit cartésien de  $U_l$  et  $V_l$  par rapport aux discrétisations pour obtenir  $w_k$ .

$$r_l(u, v, w_k) = [(\bigvee_{i=1}^m \mu_{U_l}(u_i)) \wedge (\bigvee_{j=1}^n \mu_{V_l}(v_j))] \wedge \mu_{W_l}(w_k)$$

Nous utilisons l'opérateur  $\vee$  pour l'agrégation de l'ensemble des règles de la base de connaissance, nous obtenons:

$$r(u, v, w_k) = \bigvee_{l=1}^{N_r} r_l(u, v, w_k)$$

Soit  $U'$  et  $V'$  deux nouvelles valeurs floues, pour chaque  $u_i$  et  $v_j$  de la discrétisation nous calculons le degré d'appartenance de  $w_k$  de la sortie  $W'$ :

$$\mu_{W'}^{ij}(w_k) = (\mu_{U'}(u_i) \wedge \mu_{V'}(v_j)) \wedge r(u, v, w_k)$$

le degré d'appartenance de la sortie finale  $w_k$  est obtenue en agrégeant par une t-conorme  $\vee$ :

$$\mu_{W'}(w_k) = \bigvee_{ij} \mu_{W'}^{ij}(w_k)$$

Ces calculs sont effectués par un réseau de neurones dont les éléments de la matrice des poids synaptiques sont les  $R_l(u, v, w_k)$ . Ceci est calculée pour toutes les  $w_k$  de la discrétisation.

**Remarque 7** *Si les entrées sont précises, nous utilisons les valeurs les plus proches dans les discrétisations.*

**Remarque 8** *Pour la défuzzification, nous utilisons la méthode du barycentre.*

### 4.3 Module apprentissage

Ce module relié au réseau local et au module neuro-flou permet de collecter les données du réseau en temps réel, en effet pendant des intervalles de temps réguliers le module neuro-flou fournit au module d'apprentissage des données sur l'état du réseau. Ce module est composé (figure 4.3) d'un sous-module de Groupement Soustractif (GS) (Chiu, 1997) permettant de faire des regroupements flous non supervisés sur les données. Le nombre et les centres de groupes sont déterminés d'une façon automatique en utilisant l'algorithme de Chiu (Chiu, 1994). Chaque groupe détermine une règle de la forme "si l'entrée est autour de  $x^*$  alors la sortie est autour de  $y^*$ ", ( $x^*$ ,  $y^*$ ) étant le centre du groupe,  $x^*$  identifie le vecteur associé à la prémisse de la règle et  $y^*$  identifie le vecteur associé à sa conclusion. Les entrées sont des sous-ensembles flous représentés par des fonctions d'appartenance de type gaussien autour de  $x^*$ . Les sorties sont considérées comme des fonctions linéaires des entrées. Les paramètres de celles-ci sont déterminés d'une façon optimale par la méthode des moindres carrés. Les règles déterminées ainsi vont être exploitées par un système d'inférence floue (SIF) de type Takagi-Sugeno (Takagi et Sugeno, 1985).

Pour ajuster les règles du SIF nous faisons appel à un sous-module d'inférence neuronale floue adaptatif (INFA). Ce dernier se base sur un algorithme d'apprentissage hybride (Jang, 1993). Il utilise une combinaison entre la méthode des moindres carrés et la méthode de rétro-propagation du gradient sur l'ensemble des données. Les règles déduites vont être utilisées comme base pour le système d'inférence floue amélioré (SIFA).

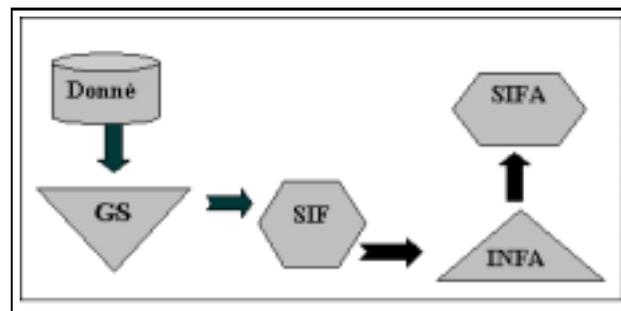


FIG. 4.3 – Module d'apprentissage

## 4.4 Quelques éléments sur l'application de la surveillance d'un réseau local

Pour des raisons de conformité avec la perception de l'administrateur réseaux, nous avons considéré un système à deux entrées et une sortie. Les variables d'entrée sont le *Temps de réponse* du réseau et le *nombre de collisions*. En effet ces deux paramètres sont suffisants pour que l'administrateur évalue l'état du réseau. La variable de sortie étant la *Charge du réseau*, elle est caractérisé par un taux de saturation.

### Les variables de perception

Elles sont représentées par des fonctions d'appartenances trapézoïdales par :

– Variables d'entrées

- $u = \text{Temps de réponse}$ ,  $U = [0, 80]$ , {Petit, moyen, Fort},  
 $\{\mu_{U_1} = [0 \ 20 \ 20 \ 40], \mu_{U_2} = [20 \ 40 \ 40 \ 60], \mu_{U_3} = [40 \ 60 \ 60 \ 80] \}$
- $v = \text{Nombre de collision}$ ,  $V = [0, 200]$ , {faible, moyen, élevé},  
 $\{\mu_{V_1} = [0 \ 50 \ 50 \ 100], \mu_{V_2} = [50 \ 100 \ 100 \ 150], \mu_{V_3} = [100 \ 150 \ 150 \ 200] \}$

– Variable de sortie

- $w = \text{Charge du réseau}$ ,  $W = [0, 100]$ , {normal, saturé, très saturé},  
 $\{\mu_{W_1} = [0 \ 25 \ 25 \ 50], \mu_{W_2} = [25 \ 50 \ 50 \ 75], \mu_{W_3} = [50 \ 75 \ 75 \ 100] \}$

L'univers des discours et les nuances linguistiques peuvent être mises à jour par l'utilisateur.

### Les fonction de perception

Les règles qui représentent les fonctions de perception de l'administrateur réseaux peuvent naturellement se mettre à jour. Cette fonction est constituée de neuf règles, un exemple de ces règles est le suivant :

**Si** " *Temps de réponse est grand* " **et** " *Nombre de collision est moyen* "  
**Alors** " *Charge du réseau est très saturée* "

Le contrôleur neuro-flou a deux entrées qui reçoivent les données relativement aux deux variables *Temps de réponse* et *Nombre de collisions* et nous livre en sortie le taux de saturation du réseau. Pour pouvoir faire cela et en temps réel, nous avons interfacé notre contrôleur neuro-flou avec le logiciel NetControl ([www.rzk.com](http://www.rzk.com)). Ce logiciel, permet de lister tous les paramètres de performance d'un réseau local en

temps réel. Le contrôleur neuro-flou est donc alimenté par des données directement issues du réseau local et nous donne la situation du trafic du réseau en temps réel. Ceci permet à l'administrateur de connaître l'état du réseau en temps réel et aussi de connaître l'état du réseau pendant son absence.

## 4.5 Recueil des données et apprentissage

Les entrées du module neuro-flou sont collectées à intervalle de temps régulier sur plusieurs jours. Les sorties sont les degrés de saturation du réseau. Elles sont stockées dans une base de données en fonction du facteur temps, voir figure 4.4 la ligne continue. Le module d'apprentissage permet de générer les règles d'inférence floue entre l'état de la saturation du réseau et l'heure. Cela revient à apprendre à partir du comportement du réseau sur plusieurs jours afin de prédire, anticiper et planifier en cas de problèmes.

Le processus d'apprentissage est constitué de deux étapes. La première permet de générer des règles floues avec le GS (Groupement Soustractif), la fonction de corrélation entre les entrées (l'heure et le degré de saturation) est décrite dans la figure 4.4 par des tirets. La seconde étape est l'utilisation de la méthode ANFI pour ajuster les règles d'inférence floues, décrites dans la figure 4.5. Le système a généré sept règles qui correspondent aux différentes plages horaires où il y a un changement du comportement du réseau.

Les sorties prédites en fonction du temps sont représenté dans la figure 4.4 par des points-tirets. Nous remarquons que la fonction prédite est une bonne approximation de la fonction réelle.

## 4.6 Discussion et conclusion

Dans ce travail, nous avons mis en œuvre une approche se basant sur la perception humaine des paramètres de performance d'un réseau local et la perception des fonctions reliant ces différents paramètres. Vu le caractère imprécis de ces paramètres et le caractère non numérique des fonctions de perception, nous avons utilisé des modèles flou et neuronal. Ils sont les mieux adaptés pour modéliser ces types de connaissances. Ainsi, la combinaison de la commande floue et des réseaux de neurones nous a permis d'utiliser les fonctions de perceptions pour simuler le trafic d'un réseau local. Le suivi de l'état du réseau au cours du temps nous a conduits à générer un système d'inférence floue prédictive de type Takagi-Sugeno. Les sorties du système sont des fonctions linéaires des entrées. Ce système est loin des fonctions de perception de l'administrateur réseaux. Nous souhaitons dans la suite de ce travail générer un système d'inférence sous formes de fonctions de per-

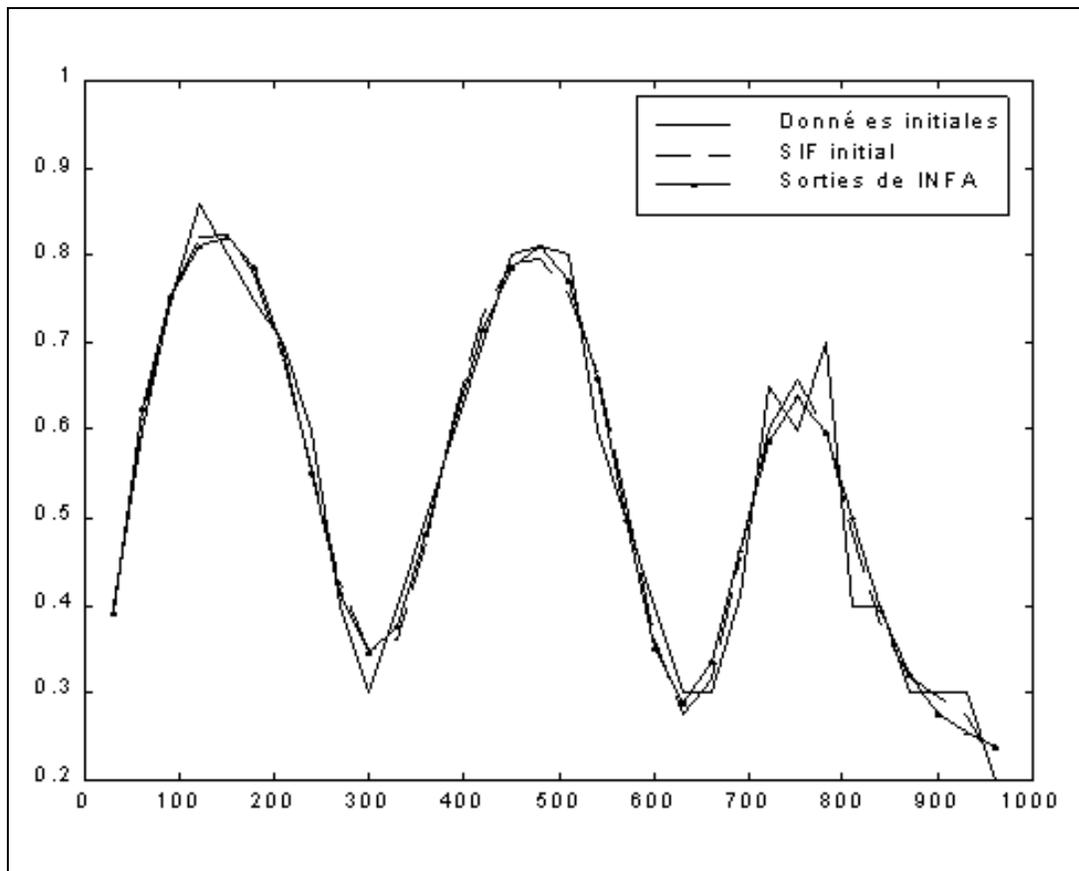


FIG. 4.4 – Représentation du processus d'apprentissage

ception de la forme *si...alors* où, les sorties comme les entrées auront des valeurs imprécises vagues. Elles peuvent être représentées par des fonctions d'appartenance gaussiennes ou trapézoïdales par exemple. Cette représentation serait plus proche de la perception fonctionnelle de l'administrateur réseaux.

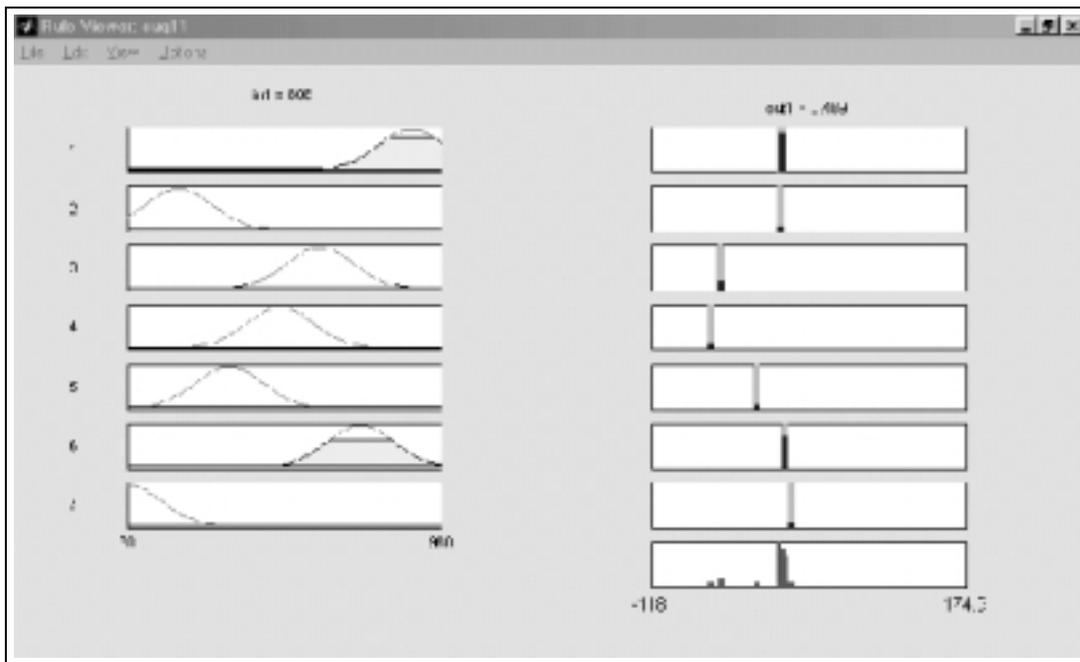


FIG. 4.5 – Les règles d'inférences floues finales

---

## Bibliographie du chapitre 4

- Carvalho, E., Belchior, A. Dias, et de Souza, J. Neuman (1999). A fuzzy logic application applied to local area network management. *Networking and Information Systems Journal*, 2(3).
- Chiu, S. (1994). Fuzzy model identification based on cluster estimation. *J. of Intelligent Fuzzy Systems*, 2(3):267–278.
- Chiu, S. (1997). Extracting fuzzy rules from data for function approximation and pattern classification. In *Fuzzy Information Engineering: A Guided Tour of Application*. D. Dubois, H. Prade and R. Yager (eds), John Wiley Sons.
- Jang, J.S.R. (1993). Anfis: Adaptive-network-based fuzzy inference systems. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3):665–685.
- Leckie, C. (1995). Experience and trends in ai for network monitoring and diagnosis. In *IJCAI'95 Workshop on AIDIN*. Bruxelles.
- Leray, Ph. (1998). *Apprentissage et diagnostic de systemes complexe : réseaux de neurones et réseaux bayésiens Application à la gestion en temps réel du trafic téléphonique français*. Thèse de doctorat, Université Pierre et Marie Curie, France, Paris.
- Lewis, L. (1994). Fuzzy logic representation of knowledge for detecting/ correcting network performance deficiencies. *Network Management and Control*, 2.
- Patton, R.J. et Chen, J. (1994). Fault diagnosis in nonlinear dynamic systems via neural networks. In *Proceedings of the International Conference on Control*.
- Petit-Renaud, S. (1999). *Application de la théorie des croyances et des systèmes flous à l'estimation fonctionnelle en présence d'informations incertaines ou imprécises*. Thèse de doctorat, Université de technologie de Compiègne, Compiègne.
- Ramdani, M., Bellafkih, M., Elhebil, F., et Kaitouni, B. Idrissi (2001). Architecture hybride neuro-flou : Gestion du trafic dans un réseau local. In *CSS'01*, pages 228–239, Maroc. INPT-Rabat.
- Stevenson, D. W. (1995). Network management - what is and what isn't? *white paper* : <http://smurfland.cit.buffalo.edu/NetMan/Papers.html>.
- Takagi, T. et Sugeno, M. (1985). Fuzzy identification of systems and its applications to modelling and control. *IEEE Trans. on Systems, Man, and Cybernetics*, 15:116–132.



## Chapitre 5

# Conclusion générale et perspectives

Dans mes activités de recherche, je me suis intéressé à l'exploitation, d'un côté de données recueillies par des instruments de mesures relativement à différentes variables caractérisant un phénomène et d'un autre côté de connaissances expertes subjectives au sujet de celui-ci. Je me suis intéressé à trois domaines : la caractérisation d'odeurs, la caractérisation de la texture et les outils de gestion des réseaux. Dans ces domaines, nous avons pu relever des propriétés communes mais de complexité différente :

- La perception humaine est difficilement formalisable dans les deux premiers domaines,
- Des mesures physiques nuancées sont disponibles sur ces domaines,
- Des valeurs subjectives permettent de caractériser ces domaines.

J'ai proposé dans mes différents travaux de recherche des méthodes permettant l'interfaçage entre les connaissances subjectives et les connaissances issues des instruments de mesures avec des représentations vagues. Ces connaissances vagues sont soit exprimées par l'expert, soit généralisées automatiquement, soit généralisées par des méthodes hybrides. J'ai proposé des nouvelles méthodes de mesure et de raisonnement qui sont adaptées au nouveau mode de représentation. Mon but est de trouver des méthodes rapprochant perception humaine et conception de systèmes d'aide à la décision. Ainsi d'une manière conceptuelle, j'ai utilisé une représentation vague pour décrire les descripteurs continus pour les systèmes d'apprentissage basés sur les arbres de décisions. Deux méthodes ont été développées : la première utilise les connaissances expertes et la deuxième utilise une méthode automatique simulant le comportement humain pour partitionner l'ensemble des valeurs des descripteurs continus. J'ai présenté par la suite une nouvelle mesure

d'information adaptée à la représentation vague. Cette mesure est utilisée pour ordonner les descripteurs pendant le développement de l'arbre de décision flou. La classification d'un nouvel objet, aussi vague qu'il soit, s'appuie sur le principe de modus ponens généralisé, conforme avec le type de représentation.

Par la suite, je me suis intéressé à la caractérisation des objets complexes mal formalisés. Je me suis attaché à deux domaines:

- La caractérisation de l'odeur en collaboration avec le laboratoire de traitement de l'information chimique de la F. S. T. de Mohammedia. Nous avons utilisé les arbres flous pour expliquer les associations entre odeur et structure moléculaire. Cette coopération a été fructueuse. En effet, à travers les différents tests réalisés sur plusieurs types de descripteurs, nous avons réussi à expliquer quelques associations que les chimistes connaissaient subjectivement sur la caractérisation de l'odeur du camphre. Notons que les chimistes utilisaient antérieurement des méthodes de type réseaux de neurones ou KNN. En perspective de ces travaux, nous travaillons sur d'autres types d'odeurs (bois de santal etc). Je m'intéresse actuellement au problème de l'intensité de l'odeur. Pour cela nous sommes en train d'enrichir la base de données pour arriver à un modèle capable de prédire les nuances sur les décisions relatives à la caractérisation de l'odeur. Enfin, nous nous sommes associés à une équipe de physiciens de l'Université de Mohammedia pour réaliser un capteur électronique de l'odeur (Nez artificiel).
- La caractérisation de la texture par des représentations vagues. Cette représentation est adaptée aux méthodes basées sur les longueurs de plages, qui permet de traiter convenablement les images texturées. En perspective de ces travaux, nous étudions la possibilité d'utiliser cette représentation pour segmenter l'image en régions floues ou taches floues, en généralisant l'algorithme de recherche des plages floues dominantes, dans toutes les directions possibles. Une des applications de notre approche est la recherche d'images sur internet.

Pour la troisième partie, nous avons mis en œuvre une approche simple permettant de simuler le comportement d'un administrateur pour la gestion des performances d'un réseau local. Dans cette simulation, nous avons utilisé les connaissances subjectives et les connaissances issues des instruments de mesure quantifiant les performances d'un réseau. Des méthodes hybrides basées sur la théorie des sous-ensembles flous et les réseaux de neurones ont permis de faire cohabiter les deux types de connaissances. Le suivi de l'état du réseau dans le temps nous a permis de générer un système d'inférence floue prédictive. Ce système d'inférence floue est de type Takagi-Sugeno. Les sorties du système sont des fonctions linéaires des entrées. Ces entrées représentent les intervalles de temps, représentés par des

gaussiennes. Nous souhaitons, à la suite de ce travail, générer une fonction sous formes de règles linguistiques, similaire à celle que peut produire la perception humaine.



# Bibliographie

- Amoore, C. et Thomas, C. (1970). Molecular basis of odors. Technical report, Springfield, Illinois (USA).
- Beck, J. (1982). *Organisation and representation in perception*, chapter Texture Segmentation, pages 285–317. Erlbaum, Hillsdale NJ.
- Beets, M. G. J. (1978). Structure activity relationships in human chemoreception. Technical report, Applied Science Publishers, London.
- Bekkhoucha, A., Fares, A., et Ramdani, M. (2000a). Image characterisation based on grey level fuzzy run lengths. In *IPMU Information Processing and Management of Uncertainty in Knowledge-based Systems IPMU'2000*, 1, pages 665–672. Madrid.
- Bekkhoucha, A. et Ramdani, M. (1999). Longueurs de plages floues pour la caractérisation des textures. In Cépaduès-Éditions, editor, *Rencontres Francophones sur la logique floue et ses applications*, pages 317–322. Valenciennes.
- Bekkhoucha, A., Ramdani, M., et A.Fares (2000b). Définition de paramètres de caractérisation de texture par les longueurs de plages floues. In *International Symposium On Image/Video Communications Over Fixed and Mobile Networks ISIVC'2000*, pages 55–65. Rabat.
- Bouchon-Meunier, B. (1993). *La Logique floue*. Que-sais-je?, n° 2702. Presses Universitaires de France.
- Bouchon-Meunier, B., Foulloy, L., et Ramdani, M. (1998). *Logique floue : Exercices corrigés et exemples d'applications*. CEPADUES-Éditions, Toulouse.
- Bouchon-Meunier, B., Marsala, C., et Ramdani, M. (1995). Arbres de décision et théorie des sous-ensembles flous. In *Actes des 5èmes journées du PRC-GDR d'Intelligence Artificielle*, pages 50–53. Tekna, Nancy.
- Bouchon-Meunier, B., Marsala, C., et Ramdani, M. (1996a). Inductive learning and fuzziness. *Scientia Iranica, International Journal of Science and Technology*, 2(4):289–298.
- Bouchon-Meunier, B., Marsala, C., et Ramdani, M. (1996b). Learning from uncertain and imprecise examples. In Cohen, M. E. et L.Hudson, D., editors, *Proc.*

- of the 11th Int. Proc. on Computers and their Applications*, pages 75–78. San Francisco.
- Bouchon-Meunier, B., Marsala, C., et Ramdani, M. (1997). Learning from imperfect data. In D. Dubois, H. Prade et Yager, R. R., editors, *Fuzzy Information Engineering: a Guided tour of Applications*, pages 139–148. John Wiley and sons.
- Bouchon-Meunier, B., Marsala, C., Ramdani, M., et Rifqi, M. (1996c). Generalization from uncertain and imprecise data. In *Proc. of the Conf. on Intelligent Systems: a Semiotic Perspective*, 1, pages 83–88. Gaithersburg, USA.
- Bouchon-Meunier, B. et Ramdani, M. (1991). Classification, entropies and fuzziness. In R. Lowen, M. Roubens, editor, *Actes du 4th World IFSA Congress (Computer, Management systems science)*, pages 13–15, Bruxelles.
- Bouchon-Meunier, B. et Ramdani, M. (1992). Apprentissage à partir d'exemples imparfaitement définis. In *PRC-IA, Méthodes Symbolique-Numérique*, pages 1–3, Marseille.
- Bouchon-Meunier, B., Ramdani, M., et Valverde, V. (1993a). Fuzzy logic, inductive learning and analogy. In *Workshop IJCAI 93 Fuzzy logic in Artificial Intelligence*, pages 21–27. Chambéry.
- Bouchon-Meunier, B., Ramdani, M., et Valverde, V. (1994). Fuzzy logic in artificial intelligence. In *Fuzzy logic, inductive learning and analogy*, pages 38–50. Lecture Notes in Computer Science, vol 847, Springer Verlag.
- Bouchon-Meunier, B., Ramdani, M., et Yager, R. R. (1993b). Similarity relations and learning. In *5th World IFSA Congress*, pages 741–746. Seoul.
- Breiman, L., Friedman, J.H., Richard, R.A., et Stone, C.J. (1984). Classification and regression trees. Chapman and Hall, New York.
- Brodatz, P. (1966). *A Photographic Album for Artists Designers*. Dover, New York.
- Brugger, W.E et Jurs, P.C. (1977). Extraction of important molecular features of musk compounds using pattern recognition techniques. *J. Agric. Food Chem.*, 25 (5):1158–1164.
- Brun, R., Renshall, H. R., et Watkins, H. (1986). *HPLOT User's Guide*. Cern Computer Centre, Geneva.
- Carvalho, E., Belchior, A. Dias, et de Souza, J. Neuman (1999). A fuzzy logic application applied to local area network management. *Networking and Information Systems Journal*, 2(3).
- Chandrasekhar, S. (1967). Geodesics in gödels universe. In Gold, T., editor, *The Nature of Time*, pages 68–74. Cornell University Press, Ithaca, New York.
- Chastrette, M., Zakarya, D., et Elmouaffek, A. (1986). Relation structure-odeur

- dans la famille des musc benzéniques nitrés. *Eur. J. Med.-Chim. Ther.*, 21(6):505–510.
- Chastrette, M., Zakarya, D., et Peyraud, J. (1994). Structure-musk odor relationships for tetrealins and in using neural networks. *Eur. J. Med.-Chim. Ther.*, 29:343–348.
- Chen, Y.Q., Nixon, M.S., et Thomas, D.W. (1995). Statistical geometrical features for texture classification. *Pattern Recognition*, (4)28:537–552.
- Chiu, S. (1994). Fuzzy model identification based on cluster estimation. *J. of Intelligent Fuzzy Systems*, 2(3):267–278.
- Chiu, S. (1997). Extracting fuzzy rules from data for function approximation and pattern classification. In *Fuzzy Information Engineering: A Guided Tour of Application*. D. Dubois, H. Prade and R. Yager (eds), John Wiley Sons.
- Chu, A., Sehgal, C.M., et Greenleaf, J.F. (1990). Use of grey value distribution of run lengths for texture analysis. *Pattern Recognition Letters*, 11:415–420.
- Cross, G. R. et Jain, A.K. (1983). Markov random field texture models. *IEEE Trans. on Patter Analysis and Machine Intelligence*, (5)1:25–39.
- Dasarathy, B.V. et Holder, E.B. (1991). Image caractérisation based on joint grey level-run length distributions. *Pattern Recognition Letters*, 12:497–502.
- Davis, L.S., Johns, S.A., et Aggarwal, J.K. (1979). Textures analysis using generalized co-occurrence matrices. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1(3):251–259.
- Fokker, A. D. (1972). Zonsactiviteit. Sterrekundig Instituut, Utrecht.
- Galloway, MM. (1975). Texture analysis using grey level run lengths. *Computer Graphics Image Processing*, 4:172–179.
- Gascuel, O., Bouchon-Meunier, B., Caraux, G., Gallinari, P., Guénoche, A., Guermeur, Y., Lechevallier, Y., Marsala, C., Miclet, L., Nicolas, J., Nock, R., Ramdani, M., Sebag, M., Tallur, B., Venturini, G., et Vitte, P. (1998). Twelve numerical, symbolic and hybrid supervised classification methods. *International Journal of Pattern Recognition and Artificial Intelligence*, 12(5):517–572.
- Haralick, R.M. (1979). Statistical and structural approaches to textures. *Processing of IEEE*, (5)67:786–804.
- Haralick, R.M., Chanmugan, C., et Dinstein, I. (1973). Texture features for image classification. *IEEE Trans. Syst. Man and Cybern*, SMC-3:610–621.
- Jang, J.S.R. (1993). Anfis: Adaptive-network-based fuzzy inference systems. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3):665–685.
- Janikow, C.Z. (1994). Fuzzy decision trees: Fidmv. In *JICI'94 Proceedings of the Joint Conference on Information Sciences*, Pinehurst, USA, pages 232–235.
- Julez, B. et Bergen, J.R. (1987). Textons, the fundamental elements in preattentive vision and perception of textures. In Fischler, M.A. et Firschein, O.,

- editors, *Reading in Computer vision*, pages 234–256, Los Altos CA. Morgan Kaufmann.
- Leckie, C. (1995). Experience and trends in ai for network monitoring and diagnosis. In *IJCAI'95 Workshop on AIDIN*. Bruxelles.
- Leray, Ph. (1998). *Apprentissage et diagnostic de systemes complexe : réseaux de neurones et réseaux bayésiens Application à la gestion en temps réel du trafic téléphonique français*. Thèse de doctorat, Université Pierre et Marie Curie, France, Paris.
- Lewis, L. (1994). Fuzzy logic representation of knowledge for detecting/ correcting network performance deficiencies. *Network Management and Control*, 2.
- Marsala, C. (1994). Arbres de décision et sous-ensembles flous,94/21. Technical report, LAFORIA-IBP, Université Pierre et Marie Curie, Paris, France.
- Marsala, C. (1998). *Apprentissage inductif en présence de données imprécises : construction et utilisation d'arbres de décisions flous*. Thèse de doctorat, Université Pierre et Marie Curie, Paris, Paris.
- Marsala, C. et Bouchon-Meunier, B. (1996). Fuzzy partitioning using mathematical morphology in a learning scheme. In *Proceeding of the 5th Conference on Fuzzy Systems, FUZZ'IEEE*, 2, pages 1512–1517. New Orleans, USA.
- Marsala, C. et Ramdani, M. (1995). Connaissances expertes floues et systèmes d'apprentissage descendant. In *Rencontres Francophones sur la logique floue et ses applications*, pages 163–168. Cépaduès-Editions, Paris.
- Marsala, C., Ramdani, M., Tollabi, M., et Zakaria, D. (1998). Recognition of odors: a fuzzy decision tree approach. In *Proc. of the 7th Int. Conference IPMU'98*, pages 532–539. E.D.K. Paris.
- Marsala, C., Ramdani, M., Tollabi, M., et Zakaria, D. (2000). Decision trees to extract features of odorous molecules. In Bouchon-Meunier, B., Yager, R. R., et Zadeh, L. A., editors, *Uncertainty in Intelligent and Information Systems, Advances in Fuzzy Systems -Applications and Theory series*, pages 235–249. World Scientific.
- Patton, R.J. et Chen, J. (1994). Fault diagnosis in nonlinear dynamic systems via neural networks. In *Proceedings of the International Conference on Control*.
- Petit-Renaud, S. (1999). *Application de la théorie des croyances et des systèmes flous à l'estimation fonctionnelle en présence d'informations incertaines ou imprécises*. Thèse de doctorat, Université de technologie de Compiègne, Compiègne.
- Quinlan, J.R. (1996). Improved use of continuous attributes in C4.5. *Journal of Artificial Intelligence Research*, 4:77–90.
- Ramdani, M. (1992a). Description numérique-symbolique en apprentissage. In

- Actes des 2èmes Journées nationales sur les applications des sous-ensembles flous*, pages 259–265. Nîmes.
- Ramdani, M. (1992b). Une approche floue pour traiter les valeurs numérique en apprentissage. In *Actes des 1ères JFAEC (Journées Francophones d'apprentissage et d'explication des connaissances)*, pages 179–187. Dourdan.
- Ramdani, M. (1993). Apprentissage à partir de données imparfaites. In *Congrès AFCET*, pages 209–218. Versailles.
- Ramdani, M. (1994). *Système d'induction formelle à base de connaissances imprécises*. Thèse de doctorat, Université Pierre et Marie Curie, France, Paris.
- Ramdani, M., Bellafkih, M., Elhebil, F., et Kaitouni, B. Idrissi (2001). Architecture hybride neuro-flou : Gestion du trafic dans un réseau local. In *CSS'01*, pages 228–239, Maroc. INPT-Rabat.
- Schnabel, K. O., Belitz, H.D., et Ranson, C. (1988). Untersuchungen zur struktur-aktivitäts-beziehung bei geruchsstoffen. *Z. Lebensm Unters Forsch*, 187:215–233.
- Stevenson, D. W. (1995). Network management - what is and what isn't? *white paper* : <http://smurfland.cit.buffalo.edu/NetMan/Papers.html>.
- Takagi, T. et Sugeno, M. (1985). Fuzzy identification of systems and its applications to modelling and control. *IEEE Trans. on Systems, Man, and Cybernetics*, 15:116–132.
- Tollabi, M. (2001). *Modélisation et synthèse de composés odorants*. Thèse de doctorat, Université Mohamed V de Rabat, Maroc.
- Unser, M. (1984). *Description Statique de Textures: application à l'inspection automatique*. Thèse de doctorat, Ecole Polytechnique Fédéral de Lausanne, Suisse.
- Wehenkel, L. (1997). Discretization of continuous attributes for supervised learning. variance evaluation and variance reduction. In Mares, M., Mesiar, R., Novak, V, Ramik, J., et Stupnanova, A., editors, *Proceedings of the Seventh International Fuzzy Systems Association World Congress*, volume 1, pages 413–418, Prague, Czech Republic.
- Weszka, J.S. (1978). Survey of threshold selection technique. *Computer Graphics Image Processing*, 7:259–265.
- Wright, R. H. (1954). Odour and molecular vibration, quantum and thermodynamic consideration. *J. Appl. Chem.*, 4:611–615.
- Zadeh, L.A. (1968). Probability measures of fuzzy event. *J. Math. Anal. App.*, 23:421–427.
- Zadeh, L.A. (2001). A new direction in ai: Towards a computational theory of perceptions. *AI MAGAZINE*, 1:73–84.

Zakarya, D. (1988). *Relations structure-odeur de musc. Mise au point d'une nouvelle méthode: GESDEM*. Thèse de doctorat, Université de Lyon I, Lyon.

Zakarya, D. (1992). Use of autocorrelation components and Wiener index in the evaluation of the odor threshold of aliphatic alcohols. *New J. Chem.*, 16:1039–1042.

---

## Table des figures

1.1	Cheminement de mes travaux de recherches . . . . .	10
2.1	Architecture générale des arbres de décision flous . . . . .	15
2.2	Méthode de génération des descripteurs . . . . .	24
2.3	Exemple de dénombrement des descripteurs . . . . .	25
2.4	Arbre construit à partir de l'échantillon . . . . .	26
2.5	La molécule 4-Méthylhexan-3-Exanol . . . . .	29
2.6	L'arbre obtenu avec les descripteurs GESDEM et physico-chimiques	30
2.7	L'arbre construit sur les paramètres physico-chimiques seuls . . . .	31
3.1	Fonction d'appartenance de $F_i$ . . . . .	38
3.2	Image de jeune femme . . . . .	45
4.1	Architecture Générale de la plate-forme . . . . .	51
4.2	Schéma d'un régulateur neuro- flou . . . . .	52
4.3	Module d'apprentissage . . . . .	54
4.4	Représentation du processus d'apprentissage . . . . .	57
4.5	Les règles d'inférences floues finales . . . . .	58



# Annexes



# Annexe A

## Autres activités depuis ma thèse

### A.1 Participation à des projets

**1992** : PRC-GDR-IA Méthodes Symboliques-Numériques

**1994** : Projet CARREFOUR INTELLIGENT à l'Institut National de Recherche sur le Transport et leur Sécurité (INRETS),

"Validation d'un système de détection d'incident de circulation dans un carrefour"

**1995** Projet SYMENU du PRC-GDR IA (Méthodes symbolique-numériques de discrimination)

**2001** PROTARS "Extraction de connaissances à partir des fichiers des accidents de la circulation dans le périmètre urbain" projet de recherche Marocain.

**1996-2001** : Projet de coopération Franco-Marocain CNR/CNRS "Extraction de connaissances à partir des bases de données (odeurs)"

### A.2 Encadrement et Participation à des jurys

#### A.2.1 Thèses

- **1998** : Christophe Marsala, Université Pierre et Marie Curie Paris VI, "Apprentissage inductif en présence de données imprécises: construction et utilisation d'arbres de décisions flous", *co-encadreur et membre du jury*
- **1998** : H. Hassar, Université Al Akhawayn à Ifrane, "Validation of fuzzy and crisp c-partitions, *rapporteur et membre du jury.*
- **2000** : H Benbrahim, Université Al Akhawayn à Ifrane, "A comparative study of pruned decision trees and fuzzy decision trees", *rapporteur et membre du jury*

- **2001** : Actuellement je dirige un doctorant (M. Kissi) en cotutelle entre la Faculté des Sciences et Techniques de Mohammedia et l'Université Pierre et Marie Curie sur le thème " Extraction des connaissances à partir des bases de données chimiques (odeurs, toxicité)"

### A.2.2 DEA

- **1993** : C . MARSALA Réalisation d'un système d'apprentissage basé sur la logique floue, DEA IARFA (Université Paris VI)

### A.2.3 Projets de fin d'études en relation avec l'industrie.

J'ai encadré plusieurs projets de fin d'études en relations avec l'industrie, voici quelques exemples :

- **1998** : S. Moussaid et J. Rguig, Programmation et facturation des spots publicitaire à la télévision Marocaine (service autonome de publicité)
- **1998** : A. Abaid, Statistiques sur les différentes opérations effectuées auprès des agences de la Banque Crédit du Maroc.
- **2000** : N. Handiri, Application des Algorithmes génétiques à la qualifications des minéraux argileux, Groupe OCP-Cerphos.

## A.3 Responsabilités scientifiques

- Responsable d'une action de recherche CNR-CNRS entre le département d'informatique de la F.S.T. de Mohammédia et le LIP6 de l'Université Pierre et Marie Curie entre 1996 et 2001.
- Responsable d'une coopération entre la F.S.T. de Mohammédia et l'Université Pierre et Marie Curie depuis 2001.
- Membre de la commission scientifique de la Faculté des Sciences et Techniques de Mohammedia, Maroc.
- Organisateur et président de la session spéciale " Automatic recognition of odors " à la 6<sup>ème</sup> conférence internationale IPMU Grenade (Espagne) juillet 1996.
- Président d'une session à la conférence internationale IPMU, Paris-Sorbonne, juillet 1998.
- Membre du comité de programme des Rencontres Francophones sur La logique Floue et ses Applications (LFA), tous les ans depuis 1998.
- Président d'une session plénière à LFA'99, Valenciennes, octobre 1999.

- Membre associé au thème APA du LIP6.
- Président de la 1<sup>ère</sup> journée nationale sur la gestion d'imprécisions et d'incertitudes dans les systèmes à bases de connaissances, JIISBC, Mohammedia, Février 2001 (Maroc).
- Relecteur de plusieurs articles pour des revues scientifiques (Scientia IRANICA, International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems IJUFKS, International Journal of Intelligent Systems).
- Co-auteur du livre "Logique floue : Exercices corrigés et exemples d'applications", B. Bouchon-Meunier, L. Foulloy et M. Ramdani, Cépadues-éditions, 1998

## A.4 Responsabilités administratives

- Membre du comité d'organisation de la 5<sup>ème</sup> conférence internationale IPMU, Paris, juillet 1994.
- Directeur du département informatique à la Faculté des Sciences et Techniques de Mohammedia de 1996 à 1998.
- Responsable de la formation continue au sein du département informatique à la Faculté des Sciences et Techniques de Mohammedia.
- Organisateur de la 1<sup>ère</sup> journée nationale sur la gestion d'imprécisions et d'incertitudes dans les systèmes à bases de connaissances JIISBC, Mohammedia, Février 2001 (Maroc).



# Annexe B

## Curriculum vitæ

### B.1 Etat civil

- Mohammed RAMDANI  
Date et lieu de naissance 13/11/62, Fès, MAROC  
Adresse professionnelle: F.S.T de Mohammedia  
B.P. 146 Mohammedia MAROC  
Tél. : 212 3 31 53 52  
Fax : 212 3 31 53 53  
Email : ramdani@deneb.uh2m.ac.ma  
Email : Mohammed.Ramdani@lip6.fr

### B.2 Titres universitaires

- 1994: Thèse de Doctorat de l'Université Pierre et MarieCurie :
  - Spécialité informatique  
Thèse soutenue le 28 février 1994, devant le jury : B. Bouchon-Meunier,  
D. Dubois, L. Gacogne, J.-G. Ganascia, J. Lorigny, et D. Zighed,
- 1988 : D.E.A en Informatique et Recherche Opérationnelle, Université Pierre et Marie Curie.
- 1987 : Maîtrise de Mathématiques Appliquées, Université Mohammed V, Rabat (Maroc).

## B.3 Carrière universitaire

- 1990 : Chargé d'enseignement à l'Université François Rabelais, antenne de l'Université de Blois
- 1991-1992: ATER à l'Université Pierre et Marie Curie
- 1993 -1994 :
  - Chargé d'enseignement à l'Ecole Française d'Electronique et d'Informatique de Paris (EFREI)
  - Chargé d'enseignement à l'Université de Marne la Vallée.
- 1995 -1998 : Maître Assistant à la Faculté des Sciences et Techniques de Mohammedia (Maroc).
- 1996 -1998 : Directeur du département d'Informatique à la Faculté des Sciences et Techniques de Mohammédia (Maroc).
- 1998 - 2001 : Professeur Assistant à la Faculté des Sciences et Techniques de Mohammédia (Maroc).

## B.4 Publications

### B.4.1 Livre

1. B. Bouchon-Meunier, L. Foulloy, **M. Ramdani**, *Logique floue : exercices corrigés et exemples d'applications*, Cépaduès éditions, 1998.

### B.4.2 Revues internationales

1. B. Bouchon-Meunier, C. Marsala, **M. Ramdani**, "Inductive Learning and Fuzziness", *Scientia Iranica, International Journal of Science and Technology*, volume 2, Number 4, 1996, pp. 289-298.
2. O. Gascuel, B. Bouchon-Meunier, G. Caraux, P. Gallinari, A. Guenoche, Y. Guermeur, Y. Lechevalier, C. Marsala, L. Miclet, J. Nicolas, R. Nocka, **M. Ramdani**, M. Sebag, B. Tallur, G. Venturini, P. Vitte, "Twelve numerical, symbolic and hybrid supervised classification methods", *Int. J. of Pattern Recognition and Artificial Intelligence*, volume 12, Number 5, 1998, pp. 517-572 .

### B.4.3 Recueil d'articles (ouvrages édités)

1. Bouchon-Meunier, C. Marsala, **M. Ramdani**, "Learning from imperfect data", *Fuzzy Information Engineering: a guided tour of applications*, D. Du-

- bois, H. Prade and R. R. Yager eds, John Wiley and Sons, chap. 8, 1997, pp 139-148.
2. B. Bouchon-Meunier, **M. Ramdani**, V. Valverde, "Fuzzy logic, inductive learning and analogy", Version longue dans *Fuzzy logic in artificial intelligence*, Lecture note in Artificial Intelligence, A. Ralescu editor, volume 847, Springer Verlag, 1994, pp 38-50.
  3. C. Marsala, **M. Ramdani**, M. Tollabi, D. Zakarya, "Decision trees to extract features of odorous molecules", dans *Uncertainty and Intelligent Information Systems, Advanced in Fuzzy Systems-Applications and Theory Series*, B.Bouchon-Meunier, R.R. Yager, L. A. Zadeh editors, World Scientific, 2000, pp 235-249.

#### B.4.4 Conférences internationales avec comité de lecture

1. **M. Ramdani**, B. Bouchon-Meunier, "Classification , Entropies and fuzziness", *4th World IFSA congress (Computer, Management & systems science)*, Bruxelles, juillet 1991, pp 13-15.
2. **M. Ramdani**, "Une approche floue pour traiter les valeurs numérique en apprentissage", *1<sup>ères</sup> JFAEC (Journées Francophones d'apprentissage et d'explicitation des connaissances)*, Dourdan, avril 1992, pp 179-187.
3. B. Bouchon-Meunier, **M. Ramdani** et R. R. Yager, "Similarity relations and learning", *5th World IFSA Congress*, Seoul, juillet 1993, pp 741-746.
4. B. Bouchon-Meunier, **M. Ramdani** et V. Valverde, "Fuzzy logic, inductive learning and analogy", *Workshop on Fuzzy logic in Artificial Intelligence, IJCAI 93*, Chambéry, septembre 1993, pp 21-27.
5. B. Bekkhoucha, **M. Ramdani**, "Longueurs de plages floues pour la caractérisation de la texture", *Rencontres Francophones sur La Logique Floue et ses Applications (LFA '99)*, Cépaduès éditions, Valenciennes, 1999, pp 317-322.
6. **M. Ramdani**, M. Bellafkih, F. Elhebil, B. Idrissi Kaitouni, "Architecture Hybride Neuro-flou : Gestion du trafic dans un réseau local", *International Conference Communications, Signals and Systems CSS'01*, Rabat, Maroc, mars 2001, pp 228-239.
7. B. Bouchon-Meunier, C. Marsala, **M. Ramdani**, M. Rifqi, "Generalization from Uncertain and Imprecise Data", *Proc. of the Conf. on Intelligent Systems: a Semiotic Perspective*, pp. 83-88, vol. I, Gaithersburg, USA - octobre 1996.
8. C. Marsala, **M. Ramdani**, M. Tollabi, D. Zakaria, "Recognition of Odors: a Fuzzy Decision Tree approach", *Proc. of the 7th Int. Conference IPMU'98*, Paris, juillet 1998, pages 532-539.

9. B. Bouchon-Meunier, C. Marsala, **M. Ramdani**, "Learning from uncertain and imprecise examples", *Proc. of the 11th Int. Proc. on Computers and their Applications*, M. E. Cohen and D. L. Hudson eds, San Francisco, mars 1996, pp. 75-78.
10. A. Bekkhoucha, A. Fares, **M. Ramdani**, "Image carcterisation based on grey level fuzzy run lengths", *Proc. of the 8th Int. Conference IPMU'2000*, Madrid, Espagne, juillet 2000, pp 665-672.
11. A. Bekkhoucha, **M. Ramdani**, A. Fares, "Définition de paramètre de caractérisation de la texture par les longueurs de plages floues", *International Symposium On Image/Vidéo Communications over fixed and mobile networks ISVIC'2000*, Rabat, Maroc, mars 2000, pp 55-65.

#### B.4.5 Conférences nationales avec comité de lecture

1. **M. Ramdani**, "Description numérique-symbolique en apprentissage", *2<sup>èmes</sup> Journées nationales sur les applications des sous-ensembles flous*, Nîmes, novembre 1992, pp 259-265.
2. **M. Ramdani**, "Apprentissage à partir de données imparfaites", *Congrès AFCET, Versailles*, juin 1993, pp 209-218.
3. B. Bouchon-Meunier, C. Marsala, **M. Ramdani**, "Arbres de décision et théorie des sous-ensembles flous", *Actes des 5<sup>èmes</sup> journées du PRC-GDR d'Intelligence Artificielle*, éditions Teknea, Nancy, janvier 1995, pp. 50-53.

#### B.4.6 Autres

1. **M. Ramdani**, "Système d'induction formelle à base de connaissances imprécises", *Thèse de l'Université Pierre et Marie Curie*, février 1994.

### B.5 Séminaires

1. **Synthèses des principales approches de la logique temporelle**, séminaire intelligence artificielle et Processus de la décision, Université Pierre et Marie Curie-Paris VI, février 1989.
2. **Apprentissage à partir d'exemples imparfaitement définis**, Journées Méthodes symboliques-Numériques, PRC-IA, Marseille, décembre 1992.
3. **Logique floue et apprentissage, groupe d'études sur la logique floue**, DRET, Ministère de la Défense, avril 1993.

4. **Les arbres de décisions flous**, Groupe numérique-symbolique du programme de recherche coordonné en Intelligence artificielle du CNRS, 7 octobre 1994.
5. **Arbres de décision et sous-ensembles flous**, C. Marsala et M. Ramdani, Séminaire du Groupe de Recherche en Automatique (pôle automatisé intégrée), Paris, mars 1994.
6. **La logique floue et les arbres de décision flous**, séminaire à l'Institut National des Postes et Télécommunications, Rabat, Maroc, mars 1997.
7. **Caractérisation de la texture à l'aide des longueurs de plages floues**, séminaire apprentissage, LIP6, Université Pierre et Marie Curie, Paris, juillet 2000.
8. **Le flou et les systèmes experts**, La logique floue, techniques, enjeux et applications, Association pour la formation aux techniques industrielles, Paris - La Défense, 26 mai 1996.
9. **Les systèmes experts flous**, formation continue CNRS sur la logique floue et ses applications, Gif-sur-Yvette, octobre 1995 et octobre 1996.
10. **Les outils informatique pour l'entreprise**, formation continue pour la société Maveltex, Mohammedia, Maroc, mars 1998.
11. **Programmation avancée**, formation insertion en collaboration avec l'Office de la Formation Professionnelle et de la Promotion et du Travail (OFPPT), Mohammedia, Maroc, septembre-novembre 2000.



## Annexe C

### Principales publications