



République Algérienne Démocratique et Populaire  
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



## **Université Amar Thelidji- Laghouat**

**FACULTE : TECHNOLOGIE**

**DEPARTEMENT : ELECTRONIQUE**

### **MEMOIRE DE MASTER**

**DOMAINE : Technologie**

**FILIERE : Electronique**

**OPTION : Electronique des systèmes embarqués**

#### **Présenté par :**

- HOUICHITI Hadjer
- OTHMANI Meriem

#### **Thème**

---

## **Classification des images texturées basée sur la fusion de l'information**

---

#### **Jury de soutenance :**

<b>Nom et Prénom</b>	<b>Grade</b>	<b>Qualité</b>
Mr. REGGAB Mourad	M.A.A	President
Mr. DELASSI Mostapha	M.A.A	examinateur
Mr. ZITOUNI Abdelkader	M.C.B	Encadreur

**Promotion : 2019/2020**

# *Remerciements*

En tout premier lieu, on remercie le bon Dieu, qui nous a donné la force et la patience d'accomplir ce Modeste travail

On voudra adresser toute nos gratitudee à l'encadreur de notre mémoire, **Mr ZITOUNI abd El-Kader**, pour sa patience, sa disponibilité et surtout ses judicieux conseils, qui ont contribué à alimenter notre réflexion.

On désira aussi à remercier les professeurs du département d'Électronique de l'université de Laghouat, pour leurs efforts constants pour nous enseigner, leurs précieuses informations et conseils, ainsi que leurs soutiens et encouragements.

Comme on exprime notre appréciation envers nos amis et collègues qui ont pris en charge notre soutien moral et intellectuel tout au long de notre préparation de ce mémoire.

Enfin, je remercie tous ceux qui, de près ou de loin, ont contribué à la réalisation de ce travail.

# *Dédicaces*

*Je dédie ce travail à*

*Mes très chers parents,*

*Mama et papa le plus grand soutien de ma vie, tous mes remerciement, appréciation, gratitude, amour et respect pour vos effort et votre soutien pour me permettre de terminer mes études. J'espère que ce travaillé sera une source de fierté et de bonheur pour vous.*

*Ma sœur Nadjet, mes frère Abdelaziz et abd-elmoumine,*

*Nadjet, qui a été la personne qui me donne le soutien moral et me supporte dans les moments de détresse. Mes frère la source de bonheur dans toute la famille.*

*Mon fiancé Tahar*

*La personne qui me donne l'encouragement, l'effort, le soutien moral, celui qui se soucie de moi et qui porte moi dans les moments difficiles, tous mes remerciement, gratitude et appréciation*

*Mon binôme Meriem*

*La fille qui a travaillé avec moi, m'a soutenu et m'a encouragé et m'a aidée tous mes remerciements à toi et ta famille.*

*Mes chers amis Katia Ryma Kayssa Zahra Marwa Iman,  
Narimane, Merime*

*Les personnes qui m'ont toujours conseillé, qui m'ont écouté et qui étaient avec moi dans les bons et les mauvais moments.*

*H. Hadjer*



# *Dédicaces*

*Avec joie, fierté et respect je dédie ce travail*

## *Mon père*

*L'homme de ma vie, mon exemple éternel, celui qui s'est toujours sacrifié pour me voir réussir, mon père 'Brahim' pour me voir réussir.*

## *Ma mère*

*Ma très cher Mama 'Oumelkheir', qui me donne toujours l'espoir de vivre, et qui n'a jamais cessé de prier pour moi.*

*Mes frères : Kouider, Khaled et Ali et leurs femmes : Aicha, Naima, Samia et à leurs enfants.*

*Mes sœurs : Aicha, Siham, Zhairo et son époux Mostapha.*

*Mes tantes : Fatna, Meriem, et à leurs familles.*

*Mes cousines Fathia, Souhir, Akila, Sara, Nada et Fatima.*

## *Mon binôme Hadjer*

*Qui sans elle ce travail n'aurait pas été fait, tous mes remerciements.*

*Tous mes amis et à tous ceux qui me sont chers.*

*O. Meryem*



---

## تلخيص

تجزئة الصور هي عبارة عن تقسيم الصورة إلى مناطق مترابطة ومتجانسة وذلك بمعيار التجانس الذي يصعب تحديده، خاصة في حالة المناطق النسيجية. ومع ذلك، فإن البحث عن الخصائص المميزة التي تميز النسيج واستخدام هذه الخصائص من أجل تجزئة الصور النسيجية لا يزال يمثل مشكلة حساسة، دون حل عام. في هذا السياق، نقترح في هذا العمل طريقة تجزئة الصور ذات النسيج. تعتمد هذه الطريقة على مرحلة استخراج المميزات من خلال محولة الموجات، والتي تميز بشكل موثوق المناطق النسيجية، بالإضافة إلى المرحلة ما قبل التصنيف باستخدام طريقة الشبكات العصبية، ثم التصنيف النهائي باستعمال دمج المعلومات للحصول على الحد الأدنى من الخطأ في التصنيف. ولقد تم اختبار الطريقة على بعض الأمثلة من قاعدة المعطيات Brodatz و صور صوتية.

**الكلمات المفتاحية:** تجزئة الصورة، النسيج، محولة الموجات، الشبكات العصبية، التصنيف، نظرية

الدليل

---

## Résumé

La segmentation d'images consiste à partitionner l'image en régions connexes et homogènes au sens d'un critère d'homogénéité difficile à définir surtout dans le cas de régions texturées. Cependant, la recherche de paramètres discriminants caractérisant la texture et l'utilisation de ces paramètres pour la segmentation des images texturées restent encore un problème délicat, sans solution universelle. C'est dans ce contexte nous proposons une méthode de segmentation d'images texturées. Cette méthode est basée sur une phase d'extraction des attributs par la transformée en ondelette, caractérisant d'une manière fiable les différentes régions texturées, ainsi qu'une phase de pré-classification par la méthode des réseaux de neurones, ensuite une classification finale par la théorie de l'évidence pour obtenir une erreur de classification minimale. La méthode a été testée sur des textures des bases Brodatz et images sonores.

**Mots clés :** Segmentation d'images, Texture, Transformée en ondelette, Réseau de neurones, Classification, la théorie de l'évidence.

---

### ***Abstract :***

Image segmentation consists to partition the image into related and homogeneous regions in the sense of a homogeneity criterion that is difficult to define, especially in the case of textured regions. However, the search for discriminating parameters characterizing the texture and the use of these parameters for the segmentation of textured images still remains a delicate problem, without a universal solution. It is in this context that we propose in this work a segmentation method of textured images. This method is based on a phase of extraction of the attributes by the wavelet transform reliably characterizing the different textured regions, as well as a pre-classification phase by the neural network method, then a final classification by evidence theory fusion in order to obtain a minimal classification error. The method was tested on texture images from Brodatz database and sonar images.

**Keywords:** Images Segmentation, Texture, Wavelet Transform, Neural Networks, Classification, evidence theory.

---

# Sommaire

Remerciement

Dédicaces

Résumé

Introduction générale 1

## *Chapitre I: Traitement d'image*

I.1 Introduction	5
Qu'est-ce qu'une image ?	5
Pourquoi et comment traiter les images ?	6
I.2. Notions fondamentales en traitement d'images	6
I.2.1. Pixel	6
I.2.2. Voisinage d'un pixel	7
I.2.3. Image numérique	8
I.2.4. Résolution d'une image	8
I.2.5. Bruit dans l'image	8
I.2.6. Histogramme	8
I.2.7. Contraste	9
I.3. Étapes de l'analyse d'images	9
I.4. Domaines d'applications du traitement d'images	10
I.5. Outils de traitement d'images	10
I.5.1. Modification d'histogramme	10
I.5.2. Binarisation	11
I.6. Réduction du bruit	12
I.6.1. Filtres linéaires	12
Filtre moyen	13
Filtre gaussien	14
I.6.2. Filtres non linéaires	15
Filtre médian	15
I.6.3. Filtres morphologiques	16
Dilatation	16
Erosion	16
Ouverture	16
Fermeture	16
I.6.4. Filtre adaptatifs	16
I.7. Conclusion	17

## ***Chapitre II : Textures et méthodes de segmentation***

II.1 Introduction	19
II.2. Analyse de la texture	19
II.2.1. Définition de la texture	19
II.2.2. Caractérisation de texture	19
II.2.3. Classification des textures	20
II.2.3.1 Textures structurelles	20
II.2.3.2 Textures aléatoires	20
II.2.3.3 Textures directionnelles	21
II.2.4. Niveau de définition à fixer	21
II.2.5. Méthodes d'Analyse de la texture	22
II.2.5.1. Approche structurelle	22
II.2.5.2. Approche statistique	23
II.2.5.2.1. Les méthodes statistiques du premier ordre	24
II.2.5.2.2. Les méthodes statistiques du deuxième ordre	25
II.2.5.2.3. Les méthodes statistiques d'ordre supérieur	27
II.2.5.3. Méthodes basées sur un modèle	28
II.2.5.4. Approche basée sur la morphologie mathématique	28
II.2.5.5. Approche fréquentielle	28
II .3. Transformée en ondelette	29
II.4. Conclusion	32

## ***Chapitre III : Notion de la fusion d l'information***

III.1 Introduction	34
III.2. Classification par réseaux de neurones	34
III.2.1. Modèle biologique	34
III.2.1.1. Définition du neurone	34
III.2.1.2. Structure du neurone biologique	34
III.2.1.3. Fonctionnement	35
III.2.2. Modèle artificiel	36
III.2.2.1. Définition du réseau de neurones artificiel	36
III.2.2.2. Fonctionnement du réseau de neurones	36
III.2.2.3. Neurone formel	37
III.2.2.4. Fonctions d'activation	38
III.2.3. Apprentissage	39
III.2.4. Architecture et classification des réseaux de neurones	40
III.2.4.1. Les réseaux non bouclés	40
III.2.4.1.1. Les Perceptrons	41
III.2.4.1.2. Les réseaux à fonction radiale	42
III.2.4.2. Les réseaux bouclés	42
III.2.4.2.1. Les cartes auto-organisatrices de Kohonen	43
III.2.4.2.2. Les réseaux de Hopfield	44
III.2.4.2.3. Les ARTs	44
III.2.5. Domaines d'applications des réseaux de neurones	45
III.3. Conclusion	46

## ***Chapitre IV : Fusion de L'information***

IV.1. Introduction	48
IV.2. Principes de la fusion	48
IV.2.1. Etapes du processus de fusion	49
IV.2.2. Manières de fusion de l'information	49
IV.2.3. Niveaux de fusion	50
IV.3. Imperfections de l'information	50
IV.4. Les méthodes de fusion	52
IV.4.1. Méthode de vote	52
IV.4.2. Théorie de l'évidence	53
IV.4.2.1. Bases mathématiques	54
IV.4.2.2 Modélisation des masses	55
IV.4.2.3. Combinaison	55
IV.4.2.4. Décision	56
IV.4.3. Théorie des possibilités	57
IV.4.3.1. Fondements de la théorie des possibilités	57
IV.4.3.2. Fusion par la théorie des possibilités	58
IV.5. Conclusion	60

## ***Chapitre V : Résultats et discussions***

V.1 Introduction	62
V.2 Explications des étapes suivies	62
V.2.1 Transformée on ondelette	62
V.2.1.1 Calcule des paramètres de texture	64
V.2.1.2 Choix d'ondelette	64
V.2.2 Classification par réseau de neurone	64
V.2.3 Fusion	65
V.2.3.1 Modélisation des masses	66
V.2.3.2 Combinaison	66
V.2.3.3 Décision	67
V.3 Présentation des résultats	69
V.4 Application sur des images sonar	71
V.3 Conclusion	73
Conclusion général	74

## Liste de figure

<b>Figure I.1:</b> Image en pixels.	7
<b>Figure I.2 :</b> Voisinage d'un pixel.	7
<b>Figure I.3 :</b> Histogramme d'image.	9
<b>Figure I.4 :</b> Principe de la modification d'histogramme.	11
<b>Figure I.5 :</b> Choix du seuil sur l'histogramme de l'image en niveaux de gris.	12
<b>Figure I.6 :</b> Filtrage linéaire.	13
<b>Figure I.7 :</b> Principe de fonctionnement du filtre médian.	15
<b>Figure II.1:</b> Exemple de textures structurées.	20
<b>Figure II.2 :</b> Exemple de texture aléatoire.	21
<b>Figure II.3 :</b> Une texture directionnelle.	21
<b>Figure II.4 :</b> Plus proches voisins du pixel 'x' selon 4 directions.	25
<b>Figure II.5 :</b> Exemples classiques d'ondelettes	29
<b>Figure II.6 :</b> Transformée en ondelettes discrètes pyramidales (DWT).	30
<b>Figure III.1 :</b> Structure du neurone biologique.	35
<b>Figure III.2 :</b> Réseau de neurones artificiel.	36
<b>Figure III.3 :</b> Dualité entre un neurone artificiel et biologique	37
<b>Figure III.4 :</b> Schéma du neurone formel (Mac Culloch et Pitts).	37
<b>Figure III.5 :</b> Représentation mathématique du neurone formel.	38
<b>Figure III.6 :</b> Organigramme des étapes d'apprentissage du réseau de neurone.	40
<b>Figure III.7 :</b> Réseau de neurones non bouclé.	41
<b>Figure III.8 :</b> Perceptron monocouche.	41
<b>Figure III.9 :</b> Perceptron multicouche (à trois couches).	42
<b>Figure III.10 :</b> Réseau de neurones bouclé.	43
<b>Figure III.11 :</b> Carte auto-organisatrice de Kohonen	43
<b>Figure III.11 :</b> Schéma récapitulatif des différentes classes des réseaux de neurones.	44
<b>Figure IV.1 :</b> les formes des fonctions d'appartenance.	59
<b>Figure V.1</b> Exemple décomposition d'une image	63

<b>Figure V.2</b> Décomposition en ondelettes sur deux niveaux	63
<b>Figure V.3</b> Segmentation d'images texturées par DWT.	65
<b>Figure V.4</b> Composition du vecteur de fusion.	67
<b>Figure V.5</b> Organigramme totale de la classification	68
<b>Figure V.6</b> exemples d'image sonar.	72
<b>Figure V.7</b> (À gauche) Image sonar : objet manufacturé (à droite) image sonar segmentée	72
<b>Figure V.8</b> (À gauche) Image sonar : Ombres d'un rocher et d'un objet manufacturé (à droite) image sonar segmentée.	73

### Liste de tableaux

<b>Tableau III.1</b> : Tableau récapitulatif de différents types de fonctions d'activation.	39
<b>Table IV.1</b> : La matrice $M$	<u>48</u>
<b>Tableau V.1</b> : Résultats expérimentaux.	71

# **Introduction générale**

## *Introduction générale*

La segmentation d'image est une opération importante dans un système de traitement d'image et de reconnaissance de formes, car elle est située à l'articulation entre le traitement et l'analyse des images [1]. C'est un traitement de bas niveau qui précède l'étape de mesure, de compréhension et de décision. Son objectif est de partitionner un ensemble de données plutôt une image en sous classes appelées régions connexes et homogènes au sens d'un critère d'homogénéité difficile à définir surtout dans le cas de régions texturées.

La texture est une caractéristique fondamentale des images et de la reconnaissance de formes. Elle joue donc un rôle important en analyse d'images non seulement dans les applications de segmentation mais aussi de classification et de caractérisation [2]. Bien qu'elle ait intéressé de nombreux chercheurs et que de nombreux travaux aient été publiés ces dernières années, la texture continue à susciter l'intérêt de plusieurs chercheurs.

Depuis les travaux de Haralick en 1979 sur la texture, plusieurs méthodes ont proposé, telles que : statistiques, structurelles, fréquentielles (bancs de filtres de Gabor, et transformée en ondelettes etc.) Cependant, la recherche de paramètres discriminants caractérisant la texture et l'utilisation de ces paramètres pour la segmentation des images texturées restent encore un problème délicat, sans solution universelle.

Dans ce travail nous proposons une méthode de segmentation d'images texturées. Cette méthode est basée sur une phase d'extraction des attributs par la transformée en ondelette, caractérisant d'une manière fiable les différentes régions texturées ainsi qu'une phase de première classification automatique des pixels de l'image à analyser, par la méthode des réseaux de neurones, ensuite une classification finale par la fusion des données ( théorie de fonctions de croyances) pour obtenir une erreur de classification minimale. La méthode a été testée sur des textures de l'album de Brodatz.

Pour atteindre notre objectif, nous avons déterminé plusieurs étapes, chacune d'elles est associée à un chapitre de ce mémoire dont :

Le premier chapitre introduit des généralités et quelques définitions fondamentales relatives au domaine du traitement d'images, et les algorithmes de prétraitement nécessaires pour améliorer la qualité de l'image.

Le second chapitre s'intéresse à l'analyse de la texture où on aborde les généralités sur la texture ainsi que les différentes méthodes d'analyse de texture, et plus précisément la transformée en ondelette.

Le troisième chapitre sera consacré à l'étude des réseaux de neurones, au passage du modèle biologique au modèle artificiel, aussi nous donnerons le protocole d'apprentissage et les différentes classes et architectures de ces réseaux tout en détaillant le réseau multicouche.

Le chapitre quatrième détaille la fusion de l'information, nous avons présenté les notions générales de la fusion et les différentes théories utilisées à cet effet, notamment la théorie de l'évidence.

Dans le cinquième chapitre nous présenterons les résultats obtenus et les interprétations correspondantes.

Nous concluons par une synthèse du travail effectué et quelques perspectives.

## Chapitre I

# Notions de traitement d'image

**I.1.Introduction :**

Avec la parole, l'image a toujours constituée l'un des moyens le plus privilégié qu'utilise l'homme pour communiquer avec autrui. En effet c'est un moyen de communication universel dont la richesse du contenu permet aux êtres humains de tout âge et de toute culture de se comprendre. Chacun peut analyser l'image à sa manière, pour en dégager une impression et d'en extraire des informations précises.

De ce fait, le terme générique traitement d'images est l'ensemble des méthodes et techniques opérant sur celles-ci, dans le but de rendre cette opération possible, plus simple, plus efficace et plus agréable, d'améliorer l'aspect visuel de l'image et d'en extraire des informations jugées pertinentes en regard de l'application concernée [3].

Avant de donner les notions fondamentales et les outils de traitement d'images, il serait utile de définir la notion d'image et les raisons de son traitement.

**• Qu'est-ce qu'une image ?**

L'image est une représentation d'une personne ou d'un objet par la peinture, la sculpture, le dessin, la photographie, le film, etc.

C'est aussi un ensemble structuré d'informations qui, après affichage sur écran, ont une signification pour l'œil humain.

Afin que l'image puisse être traitée par la machine, sa numérisation est nécessaire.

Nous distinguons trois groupes d'images : [4]

1. Les images physiques visibles, qui sont parfaitement matérielles et de nature volatile (soit des images optiques, constituées de photons dans le domaine visible, soit les images électro-optiques), ou de nature permanente (reproductions de toutes sortes : clichés photographique, peintures, sculptures, documents, imprimés, etc.

2. Les images physiques non visibles, les images optiques hors du domaine visible ou images de nature immatérielle (spectres de physique, cartes de population, de températures, etc.). Une vue infrarouge est une image non visible mais, après impression d'une pellicule sensible à ce rayonnement, elle devient une image physique visible.

3. Les images mathématiques, qui sont des concepts et sont donc invisibles par nature. Elles peuvent être continues (par exemple une fonction  $f(x, y)$ ) ou discrètes : ce sont alors des tableaux ou matrices de nombres.

**• Pourquoi et comment traiter les images ?**

On peut dire que l'on traite des images dès lors que l'on extrait une information de cette image. Il existe de très nombreuses façons de traiter des images. Une première manière de tenter une classification des types de traitement est de se référer au but poursuivi.

Pourquoi cherche-t-on à traiter une image ? [4]

1. On peut chercher à améliorer sa qualité subjective (la rendre plus agréable à l'œil) ou objective, donc mesurable : on veut améliorer son contraste, accroître la perception de certains détails ou contours, faire ressortir plus nettement certaines zones ou certaines formes, diminuer le bruit, etc. Il s'agit donc de techniques d'amélioration qui font appel à des procédés variés créant des lissages, rehaussements, etc.

2. On peut chercher à trouver une image « idéale » de l'objet qui a été dégradé par divers processus : on veut diminuer les fluctuations dues à des phénomènes de turbulence. Il s'agit là de techniques de restauration.

3. On peut chercher à détecter la présence de certaines formes, certains contours ou certaines textures de modèle connu, sans vouloir préserver les autres informations.

4. On peut chercher à réduire l'énorme quantité d'informations contenues dans une image, à la « comprimer » afin de gagner en vitesse de transmission, en encombrement des organes utilisés, en capacité de stockage, etc. tout en ne dégradant que le moins possible les images considérées. Ce domaine est celui du codage, de la compression des données et de l'approximation des images.

5. On peut chercher à faire une analyse de l'image. Cette dernière consiste en l'extraction des informations contenues dans les divers objets de la scène, sans toutefois fournir une interprétation. Il s'agit des techniques d'extraction d'attributs, c'est-à-dire de « formes » (contours, textures) et de segmentations.

Durant ce chapitre nous verrons quelques notions fondamentales, ainsi que quelques outils de traitement d'images.

**I.2. Notions fondamentales en traitement d'images :****I.2.1. Pixel :**

Abréviation de « Picture Élément », mot anglo-américain de pix pour pics, abréviation de « Picture » (image) et el pour « élément ». Élément d'image, le pixel est le plus petit point de l'image, c'est une entité calculable qui peut recevoir une structure et une quantification.

La lettre A, par exemple, peut être affichée comme un groupe de pixels dans la figure I.1.



**Figure I.2:** Image en pixels.

La quantité d'information que véhicule chaque pixel donne des nuances entre images monochromes et images couleurs. Dans le cas d'une image monochrome, chaque pixel est codé sur un octet, et la taille mémoire nécessaire pour afficher une telle image est directement liée à la taille de l'image.

Dans une image couleur (R.V.B.), un pixel peut être représenté sur trois octets : un octet pour chacune des couleurs : rouge (R), vert (V) et bleu (B) [3].


### I.2.2. Voisinage d'un pixel :

Le voisinage d'un pixel est composé de tous les pixels qui l'entourent immédiatement. Si  $p$  est un pixel d'une image  $D$ , alors le voisinage de  $p$  est le plus petit sous-ensemble de  $D$  qui contient  $p$ .


Dans une image numérique, on distingue deux types de connexités relatives au voisinage utilisé :

La 4-connexité (Figure I.2.a) et la 8-connexité (Figure I.2.b).

Le voisinage d'un pixel  $(i, j)$  est dit 4-connexe s'il est formé des quatre pixels de coordonnées spatiales  $(i+1, j), (i, j+1), (i-1, j), (i, j-1)$ , et il est dit 8-connexe s'il est formé des pixels de coordonnées spatiales  $(i+1, j), (i, j+1), (i-1, j), (i, j-1), (i+1, j-1), (i+1, j+1), (i-1, j+1), (i-1, j-1)$  [5].



**b)** Voisinage 4-connexes



**a)** Voisinage 8-connexe

**Figure I.2 :** Voisinage d'un pixel.

**I.2.3. Image numérique :**

Contrairement aux images obtenues à l'aide d'un appareil photo, ou dessinées sur du papier, les images manipulées par un ordinateur sont numériques (représentées par une série de bits).

L'image numérique est l'image dont la surface est divisée en éléments de tailles fixes appelés cellules ou pixels, ayant chacun comme caractéristique un niveau de gris ou de couleurs prélevé à l'emplacement correspondant dans l'image réelle, ou calculé à partir d'une description interne de la scène à représenter [3].

**I.2.4. Résolution d'une image :**

La résolution d'une image est définie par un nombre de pixels par unité de longueur de la structure à numériser (classiquement en dpi (dots par inches) ou ppp (points par pouce)). Ce paramètre est défini lors de la numérisation et dépend principalement des caractéristiques du matériel utilisé lors de processus de numérisation. Plus le nombre de pixels est élevé par unité de longueur de la structure à numériser, plus la quantité d'information qui décrit cette structure est importante et plus la résolution est élevée. La résolution d'une image numérique définit le degré de détail qui va être représenté sur cette image [5].

**I.2.5. Bruit dans l'image :**

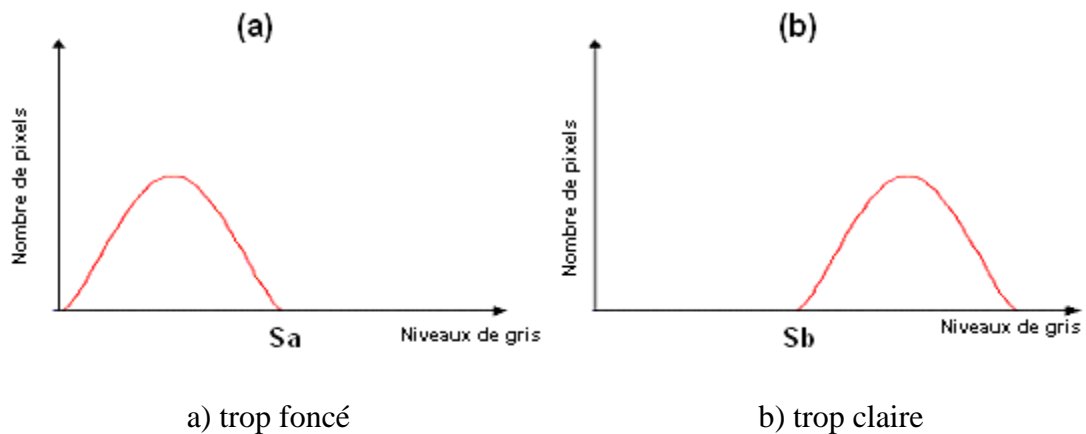
Le bruit dans une image est défini comme étant un phénomène de brusque variation d'un pixel isolé par rapport à ses voisins, il affecte la qualité de l'image et il provient soit du dispositif d'acquisition (scanner, caméra, amplification, quantification...) soit de la scène elle-même (poussières, rayures...) [5].

**I.2.6. Histogramme :**

L'histogramme des niveaux de gris ou des couleurs d'une image est une fonction qui donne la fréquence d'apparition de chaque niveau de gris (couleur) dans l'image. Pour diminuer l'erreur de quantification, pour comparer deux images obtenues sous des éclairages différents, ou encore pour mesurer certaines propriétés sur une image, on modifie souvent l'histogramme correspondant [3].

Il permet de donner un grand nombre d'informations sur la distribution des niveaux de gris (couleur) et de voir entre quelles bornes est répartie la majorité des niveaux de gris (couleur) dans les cas d'une image trop claire ou d'une image trop foncée. (Figure I.3) [5].

Il peut être utilisé pour améliorer la qualité d'une image (Rehaussement d'image) en introduisant quelques modifications, pour pouvoir extraire les informations utiles de celle-ci.



**Figure I.3 :** Histogramme d'image.

### I.2.7. Contraste :

C'est l'opposition marquée entre deux régions d'une image, plus précisément entre les régions sombres et les régions claires de cette image. Le contraste est défini en fonction des luminances de deux zones d'images [3].

Si  $L1$  et  $L2$  sont les degrés de luminosité respectivement de deux zones voisines  $A1$  et  $A2$  d'une image, le contraste  $C$  est défini par le rapport :

$$C = \frac{L1 - L2}{L1 + L2} \quad (I.1)$$

### I.3. Étapes de l'analyse d'images :

La plupart des applications de traitement d'image passent par les étapes suivantes : [6]

- Acquisition : Echantillonnage, Quantification.
- Analyse globale de l'image et transformations ponctuelles : Histogramme ; statistiques (moyenne, écart-type, etc.) ; transcodage (palette de couleur [LUT]) et classification.
- Opérations entre images : Indices, ratio, différence, opérations logiques, masques et seuillage.
- Amélioration, filtrage et segmentation : Opérations de convolution (lissage, rehaussement, détection de contours) ; squelettisation ; vectorisation.
- Interprétation et sémantique : Cartographie thématique (classification automatique et supervisée) ; cartographie vecteur ; représentation des graphes et de la topologie.

**I.4. Domaines d'applications du traitement d'images :**

Le traitement d'images possède l'aspect multidisciplinaire. On trouve ses applications dans des domaines très variés tels que les télécommunications (T.V., vidéo, publicité,...), la médecine (radiographie, ultrasons,...), la biologie, l'astronomie, la géologie, l'industrie (robotique, sécurité), la météorologie, l'architecture, l'imprimerie, l'armement (application militaire).

De nouvelles applications pratiques sont possibles aujourd'hui et touchent tous les domaines d'activités, tels que : métiers du spectacle, de la radio, créations artistiques, etc. [3]

**I.5. Outils de traitement d'images :**

La qualité d'une image peut être dégradée pour des raisons diverses. Les images brutes permettent rarement de parvenir à une extraction directe des objets à analyser :

- soit parce que l'éclairage de l'objet n'est pas uniforme,
- soit parce que le contraste n'est pas suffisant,
- soit encore parce que l'objet est perçu à travers un bruit assez important : les

images contiennent donc un signal et du bruit (dont on veut éliminer la plus grande partie possible).

Avant d'extraire les objets et d'analyser une image, il est donc souvent nécessaire d'améliorer sa qualité en lui appliquant quelques traitements (par exemple : modification d'histogramme, binarisation, amélioration du contraste, élimination de bruits, etc.).

Les traitements s'appliquent toujours aux images en niveau gris et parfois aussi sur des images couleurs. [7]

Nous allons présenter dans ce qui suit quelques types de ces traitements.

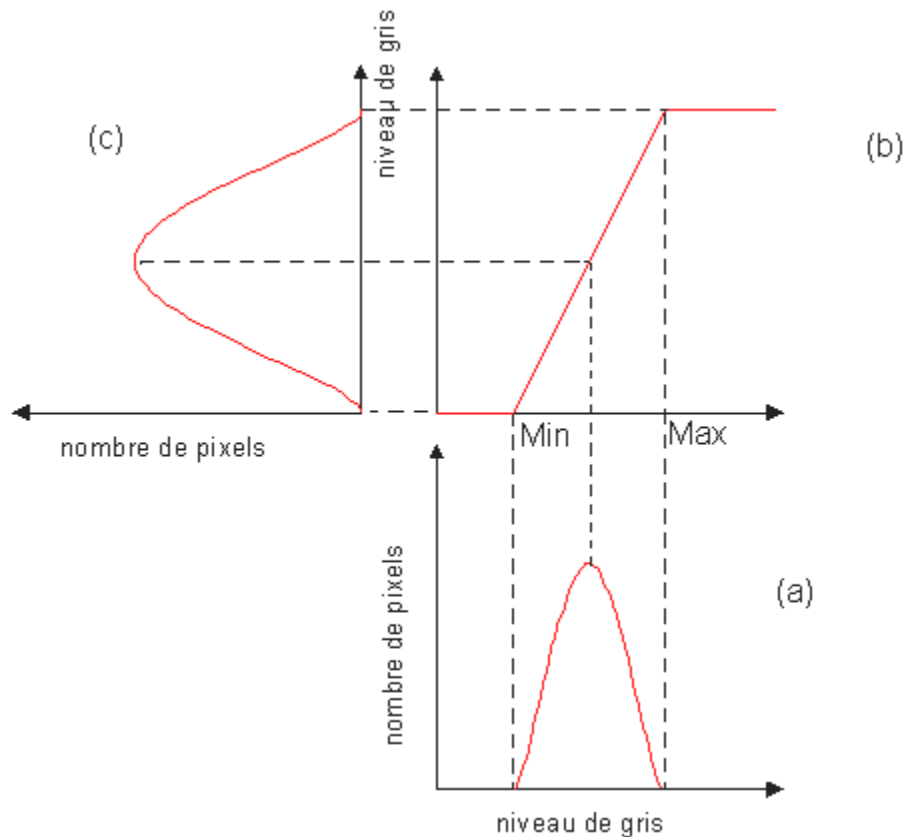
**I.5.1. Modification d'histogramme :**

L'histogramme d'une image est une fonction qui donne la fréquence d'apparition de chaque niveau de gris (ou couleur) dans l'image, (voir I.2.6). Or parfois certaines images apparaissent trop foncées (les niveaux de gris de l'image sont tassés vers le haut de l'échelle), ou trop claires (les niveaux de gris de l'image sont tassés vers le bas de l'échelle), ou bien peu contrastées (les niveaux de gris de l'image sont regroupés dans un intervalle étroit).

De ce fait, afin d'améliorer l'image on est ramené à modifier son histogramme, qui a pour but de redistribuer les niveaux de gris de l'image afin de leur faire occuper toute la bande de nuance possible. (Figure I.4).

Cette méthode est basée sur les transformations ponctuelles d'intensité. C'est-à-dire, qu'à tout pixel d'intensité  $s$  on associe une intensité  $s' = T(s)$ .

Du fait de leur caractère ponctuel, les méthodes de transformation d'histogramme n'affectent pas la forme des régions. Elles en modifient uniquement l'apparence visuelle. [8]  
[5]



a)- Histogramme de l'image originale.

b)- Fonction de transformation.

c)- Histogramme recadré.

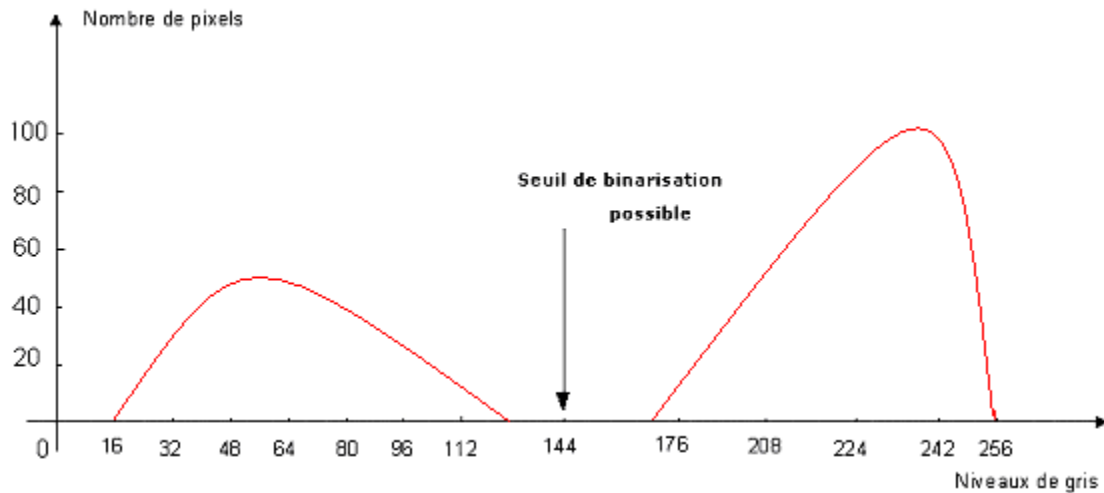
**Figure I.4 :** Principe de la modification d'histogramme.

### I.5.2. Binarisation (par seuillage) :

Binariser une image en niveaux de gris consiste à la transformer en une image biniveaux, c'est-à-dire attribuer à chaque pixel de l'image la valeur 0 « noir » ou 255 « blanc ». La dynamique de l'image est alors réduite à deux luminosités. La mise en œuvre la plus simple est de fixer un seuil ajustable, identique pour toute l'image. Pour une échelle à 256 niveaux de gris, cette valeur est comprise entre 0 et 255, généralement dans la plage médiane, chaque pixel est comparé à ce seuil en polarité directe, ceux de niveaux de gris inférieurs sont mis à « blanc » (1), ceux supérieurs mis à « noir » (0).

La difficulté réside dans le choix du seuil. Si le seuil est fait par le scanner un opérateur peut effectuer un réglage en fonction de l'aspect visuel du document et du résultat d'une première acquisition. Pour le seuillage automatique d'une image à niveaux de gris, une

méthode consiste à tracer un histogramme de ces niveaux de gris, et choisir le seuil au fond de la vallée qui sépare le pic correspondant au niveau de gris du fond et le premier pic suivant (Figure I.5). [9]



**Figure I.5** : Choix du seuil sur l'histogramme de l'image en niveaux de gris.

### I.6. Réduction du bruit :

Le transfert de l'image d'un objet jusqu'à l'ordinateur lors de l'acquisition des images se produit avec un certain bruit. Le bruit est dû en particulier aux imperfections de la source qui génère l'image, au capteur proprement dit (caméra, détecteur électronique, etc.), et enfin à toute l'électronique de transfert. [7]

L'amélioration de l'image est essentiellement obtenue par ce que l'on appelle une opération de filtrage.

Il existe un grand nombre de filtres, que l'on peut classer en 4 grandes catégories :

- Les filtres linéaires.
- Les filtres non linéaires.
- Les filtres morphologiques.
- Les filtres optimaux.


#### I.6.1. Filtres linéaires :

La transformation de chaque pixel est le fruit d'une combinaison linéaire des pixels voisins. Ces opérateurs sont caractérisés par leur réponse impulsionnelle  $h(x, y)$ . [9]

La relation entrée-sortie est décrite par l'équation de convolution :

$$C(x, y) = A * h(x, y) = \iint A(\alpha, \beta) h(x - \alpha, y - \beta) d\alpha d\beta \quad (1.2)$$

$H(x, y)$  : la réponse impulsionnelle d'un filtre .



**Figure I.6** : Filtrage linéaire.

Dans le cas d'une image numérique, l'équation (I.2) est remplacée par la relation de convolution discrète :

$$D[i, j] = \sum_m \sum_n h[m, n]A[i - m, j - n] = \sum_m \sum_n A[m, n]h[i - m, j - n] \quad (I.3)$$

$h[i - m, j - n]$  : comporte une opération de translation par le vecteur  $(i, j)$  est une symétrie centrale (inversion des coordonnées  $m$  et  $n$ ).

Il existe une grande variété de filtres plus ou moins utilisés et il serait fastidieux de vouloir tous les décrire, notre choix sera porté sur les filtres linéaires les plus courants, parmi eux on définit :

- Le filtre moyen.
- Le filtre gaussien.

- **Filtre moyen :**

Il consiste à considérer chaque point de l'image et d'en faire la moyenne avec les huit pixels qui lui sont voisins. Ceci va avoir pour effet d'adoucir l'image en réduisant les fluctuations des niveaux de gris.

Ce type de filtre utilisant la moyenne non pondérée des voisins peut être mis sous la forme d'un masque tel que celui-ci :

$$H_1 = \frac{1}{9} \begin{pmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{pmatrix}$$

On va alors déplacer ce masque sur toute l'image, le pixel affecté par la transformation étant le pixel central du masque. Le facteur  $1/9$  est égal à la somme des coefficients du masque et sert à normaliser le filtre de manière à ce que celui-ci n'influe pas sur l'intensité globale de l'image.

Si nous posons  $I_B$  comme étant l'image de départ (image bruitée),  $I_f$  l'image résultat (image filtrée), toutes deux de taille  $p \times p$ , et  $H_I$  le masque, nous avons alors pour chaque pixel de coordonnées  $x, y$  :

$$I_f(i, j) = \frac{1}{9} \sum_{j=-1}^1 \sum_{j=-1}^1 H_1(i+1, j+1) \cdot I_B(x+i, y+j) \quad (\text{I.4})$$

D'autres filtres ont été réalisés en utilisant des coefficients de pondérations différents. Par exemple :

$$H_2 = \frac{1}{10} \begin{pmatrix} 1 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 1 \end{pmatrix} \quad H_3 = \frac{1}{16} \begin{pmatrix} 1 & 1 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{pmatrix}$$

Le filtre  $H_2$  donne plus de poids au pixel central, ce qui le rend moins actif que le filtre  $H_1$ , le filtre  $H_3$  privilégie les directions  $x$  et  $y$ .

- **Filtre gaussien :**

Il représente un filtre linéaire parmi les plus courants, tant par sa facilité de mise en œuvre que par la bonne qualité de ses résultats. Ce filtre tire son nom de la valeur de ses coefficients qui sont ceux d'une courbe de Gauss à deux dimensions.

Un filtre gaussien consiste en la convolution d'une image  $I_B$  avec une gaussienne

$G(x, y, \sigma)$  :

$$I_f = G \otimes I_B \quad (\text{I.5})$$

Avec :

$$G(x, y, \sigma) = \frac{1}{\sqrt{2\pi\sigma}} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (\text{I.6})$$

$\sigma$  : l'écart type

Où  $G$  est un masque carré dont les coefficients sont les éléments discrétisés de la gaussienne. Le principal avantage du filtre gaussien est qu'il présente le meilleur compromis entre les localisations spatiales et fréquentielles.

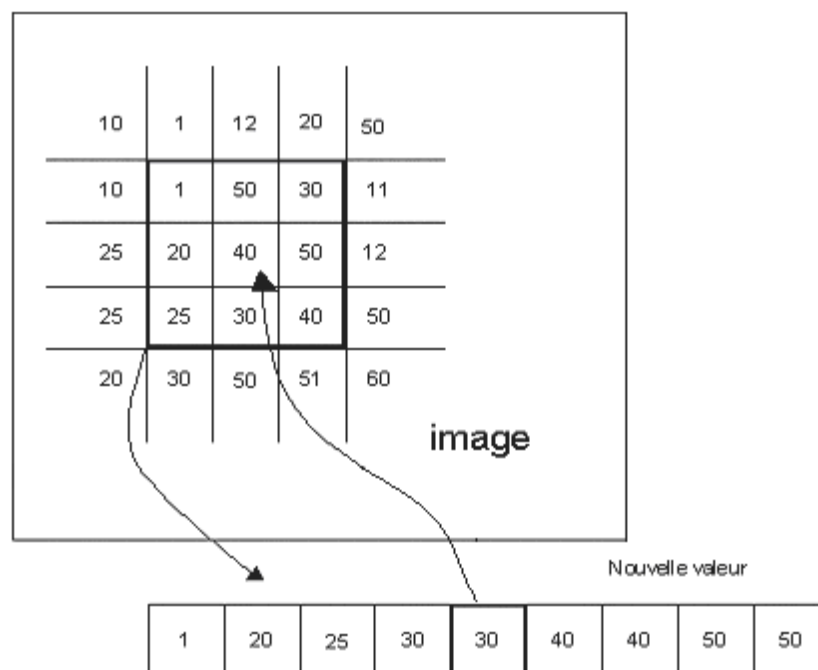
### 1.6.2. Filtres non linéaires :

Ce type de filtre s'oppose au précédent dans sa dénomination car il n'est pas le résultat d'une combinaison linéaire de pixels, les pixels voisins interviennent suivant une loi non linéaire. Le domaine du filtrage non linéaire est extrêmement vaste, l'exemple le plus classique de filtre non linéaire est le filtre médian de Tuckey.

- **Filtre médian**

Son principe est celui de la figure I.7 et il peut être décomposé selon les étapes suivantes : Pour chaque pixel de l'image

- On classe les pixels voisins du pixel courant (compris dans la fenêtre) par valeurs croissantes.
- On prend la valeur médiane des pixels classés et on l'affecte au pixel courant.



**Figure I.7** : Principe de fonctionnement du filtre médian.

### 1.6.3. Filtres morphologiques:

Ce type de filtrage est réalisé par une combinaison de traitement linéaire et non linéaire et il est appliqué à des images binaires, chaque pixel de l'image peut être codé comme un

élément logique donc à valeur vraie ou fausse, ainsi il est l'objet d'une transformation par une fonction logique plus ou moins complexe.

Parmi les opérateurs morphologiques (méthodes visant à améliorer les images binaires) nous citons : la dilatation, l'érosion, l'ouverture et la fermeture. [10]

- **Dilatation :**

Elle permet d'éliminer les pixels blancs isolés. On effectue le ET logique des huit voisins du pixel considéré.

La dilatation élimine les tâches (les trous) blanches dans les zones noires mais ajoute des pixels noirs au contour des objets présents dans l'image. Donc la taille des objets dans l'image augmente.

- **Erosion :**

Elle permet d'éliminer les pixels noirs isolés au milieu des parties blanches de l'image, on effectue le OU logique des huit voisins du pixel considéré.

En appliquant une érosion, ces tâches noires peuvent être éliminées mais la taille des objets présents dans l'image diminue car l'érosion enlève des pixels du contour, entraînant une déformation de certains objets

- **Ouverture :**

L'ouverture est constituée par une opération d'érosion suivie d'une dilatation. Elle permet de retrouver la taille normale des objets de l'image.

- **Fermeture :**

La fermeture est l'opération inverse de l'ouverture, qui consiste à faire subir à l'image une dilatation suivie d'une érosion. Elle permet aussi de retrouver la taille normale des objets de l'image.

#### **I.6.4. Filtres Adaptatifs**

Lorsque l'on veut filtrer une image, on peut rencontrer deux types de situations : soit la fenêtre d'analyse est située à l'intérieur d'une région, et on a affaire à un signal stationnaire éventuellement perturbé par du bruit à caractère impulsionnel ou continu ; soit elle inclut une transition entre deux régions (contour). L'intérêt des filtres adaptatifs est la possibilité

d'ajuster la structure ou les coefficients d'un opérateur à chacune de ces situations. Il s'agit donc de filtres comportant un étage de décision et un étage de filtrage de données. [8]

### **I.7. Conclusion :**

Dans ce chapitre, nous avons présenté des notions fondamentales ainsi que quelques techniques de traitement d'images, afin de préparer cette dernière à l'analyse. Nous avons présenté quelques traitements qui permettent une amélioration de l'image en vue d'éliminer toutes les imperfections qui existent sur cette dernière, dans le but de parvenir à une analyse plus fine.

## ***Chapitre II***

# **Analyse de la texture et Transformée en Ondelette**

## **II.1. Introduction :**

La texture, qui est presque omniprésente dans les images, joue donc un rôle important en analyse d'images non seulement dans les applications de segmentation mais aussi de classification et de caractérisation. Bien qu'elle ait intéressé de nombreux chercheurs et que de nombreux travaux aient été publiés ces dernières années, la texture continue à susciter l'intérêt des chercheurs surtout avec le succès réalisé par la transformée en ondelettes grâce à la possibilité d'effectuer une analyse spatio-fréquentielle des images.

Ce chapitre s'intéresse à l'analyse de la texture où on aborde les généralités sur la texture ainsi que les différentes méthodes d'analyse de texture, et plus précisément la transformée en ondelette.

## **II.2. Analyse de la texture :**

### **II.2.1. Définition de la texture :**

La texture est le terme utilisé pour caractériser la surface d'un objet ou un phénomène donné. Il est sans doute l'une des caractéristiques principales utilisées en traitement d'images et en reconnaissance des formes. Il est généralement admis que l'analyse de texture joue un rôle fondamental dans la classification des objets et dans la détermination des régions significatives d'une image à niveaux de gris donnée. La texture s'observe dans des différents types d'images allant des données multi spectrales de télédétection aux images microscopiques. Une solution au problème de l'analyse de texture sera un grand progrès pour le traitement d'images et la reconnaissance des formes et sera bénéfique pour plusieurs applications industrielles possibles.

### **II.2.2. Caractérisation de texture :**

Dans le traitement d'images, l'analyse de texture joue un rôle très important. Elle permet l'identification des objets. En effet, nous verrons qu'il est inévitable, pour distinguer les différentes régions d'une image, d'extraire une information texturale. Malgré cette importance, nous verrons tout d'abord qu'il est difficile de caractériser précisément la texture. Nous essayerons néanmoins d'en donner une définition générale.

Ensuite, dans un deuxième paragraphe, nous présenterons différentes méthodes d'analyse de textures. Nous mettrons en évidence les principales méthodes d'extraction de paramètres permettant d'identifier les textures. L'accent sera mis sur l'utilisation de la transformée en ondelette, car elle est une bonne caractérisation de la notion de texture. Comme

le but de notre première analyse est d'extraire et de tester des paramètres caractérisant les textures, nous présenterons les paramètres les plus utilisés.

### **II.2.3. Classification des textures :**

Il est possible de classer l'ensemble des textures en différentes catégories [11] :

#### **II.2.3.1 Textures structurées :**


Encore appelées macro-textures, elles sont constituées par la répétition spatiale plus ou moins régulière d'un motif de base (appelé primitive ou Textel). Les textures périodiques constituent un sous-ensemble des textures structurées. L'exemple du mur de brique illustre bien ce type de texture (figure II.1).



**Figure II.1:** Exemple de textures structurées.

#### **II.2.3.2 Textures aléatoires :**

Dans ces textures, aucun motif particulier n'est localisable ou détectable. Elles ont un aspect anarchique et désorganisé, tout en restant homogène et ne répondent à aucune règle d'agencement particulière. La primitive est ramenée au niveau du pixel, ce que vaut à ces textures le nom de micro-textures (ex : sable, laine tissée, herbe). (Figure II.2)



**Figure II.2** : Exemple de texture aléatoire

### II.2.3.3 Textures directionnelles :

Les textures directionnelles ne sont pas totalement aléatoires et ne présentent pas d'éléments structurants de base. Elles se caractérisent essentiellement par certaines orientations. La figure II.3 montre un exemple de texture directionnelle.



**Figure II.3** : Une texture directionnelle

### II.2.4. Niveau de définition à fixer :

Ces différentes catégories de textures montrent qu'il est difficile de donner une définition précise de la texture. Nous avons d'un côté une information structurale et constructive, et d'un autre côté une information désordonnée et plus difficile à décrire (même visuellement d'ailleurs). Nous pouvons cependant dire que la texture est une information obtenue à partir d'un ensemble de mesures locales dans une région (fenêtre de visualisation) d'une image [12].

La définition littéraire de la texture est la suivante : « répétition spatiale d'un même motif dans différentes directions de l'espace ». Cette définition est limitative car elle caractérise l'objet indépendamment d'un observateur humain. Elle manifeste aussi une information visuelle qui permet de décrire qualitativement à l'aide des adjectifs suivants : grossière, fine, lisse, tachetée, granuleuse, marbrée, régulière ou irrégulière... [13].

La notion de texture est utilisée pour traduire un aspect homogène de la surface d'un objet sur une image. La texture est appliquée dans plusieurs domaines telles que :

- La reconnaissance et classification de matériaux, contrôle de qualité.
- La reconnaissance d'objets, segmentation.
- La synthèse et la restauration d'images.

### **II.2.5. Méthodes d'Analyse de la texture :**

L'analyse de la texture regroupe un ensemble de techniques mathématiques permettant de quantifier les différents niveaux de gris présents dans une image en termes d'intensité et de distribution.

Cette analyse a d'abord été utilisée pour la segmentation d'images texturées. L'extraction des attributs caractéristiques a donné lieu à un certain nombre de méthodes d'analyse structurale et statistique. Elles sont utilisées actuellement pour l'indexation. La classification et la segmentation d'image [11] [14]. La diversité des images, ainsi que la complexité de donner une définition précise de la texture a permis l'émergence de plusieurs méthodes d'analyse de la texture. Ces méthodes ont pour but d'extraire un ensemble d'attributs ou paramètres pouvant décrire les caractéristiques de la texture.

Ces attributs doivent être représentatifs, pertinents et discriminants de façon qu'on puisse discerner une texture parmi d'autres. Leurs extractions peuvent être classées essentiellement en cinq approches [15] [16] :

- Approche structurale.
- Approche statistique.
- Approche basée sur un modèle.
- Approche basée sur la morphologie mathématique.
- Approche fréquentielle.

#### **II.2.5.1. Approche structurale :**

On considère que les textures sont constituées de motifs de base se répétant dans des directions de l'espace de façon quasi-régulière. Dans les images étudiées, on considère donc

l'existence de primitives. Une description structurale d'une texture implique la recherche des motifs élémentaires, leurs descriptions, puis, la détermination des règles conditionnant leur position. Elles sont donc applicables sur les textures aléatoires.

Plusieurs approches peuvent être regroupées en un ensemble de méthodes heuristiques, dites méthodes structurelles classique, pour lesquelles on cherche à détecter et caractériser des primitives, puis, à trouver des règles de placement, (méthodes « bottom up ») ou inversement (méthodes « top-down »). Elles s'appuient principalement sur le traitement du signal, la topologie et la géométrie. L'avantage des méthodes « bottom up » est que l'on peut utiliser les techniques classiques de segmentation, comme la croissance de région, les seuillages, la détection de contour, etc., pour isoler les primitives, considérées comme des ensembles de pixels ayant des propriétés d'homogénéité communes (en niveau de gris, par exemple). Ces propriétés (luminance, aire, taille, courbure, directionnalité, etc.) permettent la description d'un certain nombre de classes de primitives. Les règles de placement sont exprimées à l'aide de « vecteurs de régularité », de vecteurs de densités de primitives ou à partir des centres de gravité des classes. D'autres approches, dites approches syntaxiques font appel à la théorie des grammaires qui permet d'engendrer des formes en appliquant un ensemble de règles de placement données à un petit nombre de symboles. Ces symboles peuvent être considérés comme des sous-primitives de base et doivent pouvoir reconstituer toute texture structurale.

Mais, le formalisme de ces approches est souvent complexe. De plus, une texture peut être générée ou analysée par plusieurs grammaires. On limite donc leur utilisation à la génération de textures binaires ou à des applications très particulières.

Enfin, il existe une autre catégorie de méthodes structurelles dites approches ensemblistes. Ces approches sont principalement descriptives. Elles d'appuient sur des opérations de morphologie effectuées essentiellement sur des images binaires ; il est donc nécessaire d'appliquer des prétraitements (seuillage, détection de contour) sur les images originales. La description des primitives sera essentiellement géométrique avec des propriétés comme la taille, la forme [17].

#### **II.2.5.2. Approche statistique :**

Les méthodes statistiques consistent à étudier les relations entre les pixels et leurs voisins. Ces méthodes sont adaptées à l'étude des structures fines sans régularité apparente. Plusieurs méthodes appartenant à cette approche ont été proposées. Parmi elles, on peut citer les méthodes d'ordre un, d'ordre deux et celles d'ordre supérieur. L'ordre des méthodes est donné par le nombre de pixels mis en jeu dans le calcul des attributs.

### II.2.5.2.1. Les méthodes statistiques du premier ordre :

Elles considèrent les pixels pris individuellement. Les attributs sont calculés à partir de l'histogramme des intensités (ou histogramme du premier ordre). La moyenne, la variance, le Skewness (l'aplatissement), et le Kurtosis (dissymétrie) et le rapport signal-bruit sont les attributs le plus souvent utilisés pour caractériser une texture.

- **Moyenne :**

La moyenne donne le niveau de gris moyen dans la fenêtre :

$$MOY = \frac{1}{N} \sum p(i, j) \quad \text{II. 1}$$

- **Variance :**

La variance donne l'écart carre moyen des niveaux de gris par rapport à la moyenne :

$$VAR = \frac{1}{N} \sum (p(i, j) - MOY)^2 \quad \text{II. 2}$$

- **Aplatissement :**

$$SKEW = \frac{1}{N} \sum (p(i, j) - MOY)^3 \quad \text{II. 3}$$

- **Dissymétrie :**

La dissymétrie caractérise la forme du sommet de l'histogramme des niveaux de gris de l'image. Plus celle-ci est faible, plus le sommet est arrondi.

$$KURT = \frac{1}{N} \sum (p(i, j) - MOY)^4 \quad \text{II. 4}$$

- **Rapport signal-bruit :**

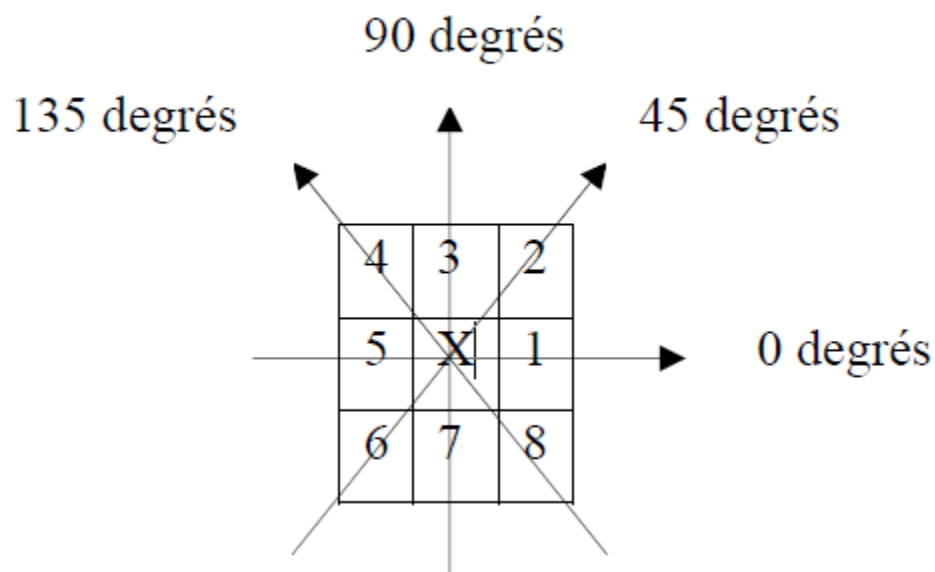
Le rapport signal-bruit rend compte de l'hétérogénéité d'une texture

$$SNR = \frac{MOY}{\sqrt{VAR}} \quad \text{II. 5}$$

Ces méthodes permettent une extraction rapide des attributs de texture. Cependant elles ne permettent pas d'étudier les relations entre deux pixels. Il est donc nécessaire d'utiliser des méthodes d'ordre supérieur pour une analyse plus précise [14].

#### II.2.5.2.2. Les méthodes statistiques du deuxième ordre (matrices de cooccurrences) :

Parmi ces méthodes, on trouve celle qui est basée sur les matrices de cooccurrences. La matrice de cooccurrence de niveaux de gris ou GLCM (Gray Level Co-occurrence Matrix) a été initialement introduite par Haralick en (1973) [18] [19]. Elle est considérée comme une méthode de référence dans le domaine de l'analyse de texture. Les matrices de cooccurrences d'Haralick, encore appelées matrices de dépendance spatiale des niveaux de gris, utilisent les statistiques d'ordre 2 et permettent de déterminer la fréquence d'apparition d'un motif formé de deux pixels séparés par une certaine distance  $d$  dans une direction particulière  $\Theta$  par rapport à l'horizontale [16], [19], [20].



**Figure II.4** : Plus proches voisins du pixel 'x' selon 4 directions

Les directions angulaires  $\Theta$  classiquement utilisées sont 0, 45, 90 et 135 degrés. Les relations de voisinage entre pixels, nécessaires au calcul des matrices, sont illustrées en figure II.4 ; par exemple, les plus proches voisins de 'x' selon la direction  $\Theta=135$  degrés sont les pixels 4 et 8. Les caractéristiques extraites à partir de ces matrices contiennent des informations notamment sur l'homogénéité, les dépendances linéaires entre les niveaux de

gris, le contraste et la complexité de cette image. La matrice de cooccurrence est riche d'information mais reste toujours difficilement exploitable dans son intégralité. Une solution consiste à réduire le nombre de niveaux de gris afin d'utiliser la matrice de cooccurrence comme une méthode d'extraction des attributs de texture. L'autre démarche qui est plus courante consiste à extraire de ces matrices des attributs afin de réduire la quantité d'informations à manipuler, tout en conservant la pertinence de ces descripteurs. Les attributs extraits de ces matrices les plus connus sont les quatorze attributs d'Haralick, nous avons cité par la suite que les premiers attributs.

- **L'énergie** est donnée par l'équation :

$$ENER = \sum_j \sum_j p(i,j)^2 \quad \text{II. 6}$$

- **Le contraste** est défini par :

$$CST = \sum_j \sum_j (i-j)^2 * p(i,j) \quad \text{II. 7}$$

Le contraste (ou inertie) mesure les variations locales des niveaux de gris. Ce paramètre a une valeur numérique importante si les  $p(i, j)$  sont concentrés hors diagonale. Il est fortement non corrélé à l'énergie.

- **La corrélation** est donnée par :

$$COR = \frac{\sum \sum (i - \mu_x)(j - \mu_y)p(i,j)}{\sigma_x \sigma_y} \quad \text{II. 8}$$

Avec :

$\mu_x$  : la moyenne des entrées normalisées pour le pixel de référence de valeur x.

$\mu_y$  : la moyenne des des entrées normalisées pour le pixel voisin de valeur y.

$\sigma_x$  : l'écart type des entrées normalisées pour le pixel de référence de valeur x.

$\sigma_y$  : l'écart type des entrées normalisées pour le pixel voisin de valeur y.

Ce paramètre a une grande valeur quand les valeurs sont uniformément distribuées dans la matrice de cooccurrence et une faible valeur dans le cas contraire.

- **L'homogénéité** indique une mesure de l'uniformité des niveaux de gris de l'image, cet indice est donné par :

$$HOM = \sum \sum \left( \frac{p_{ij}(i; j)}{1 + (i, j)^2} \right) \quad \text{II.9}$$

Les indices cités réduisent l'information contenue dans la matrice de cooccurrence et permettent une meilleure discrimination entre les différents types de textures. Le choix du vecteur de déplacement et de la taille de la fenêtre du voisinage sur laquelle s'effectue la mesure est les paramètres sur lesquels repose la réussite de la méthode. La difficulté à surmonter lors de l'application de cette technique réside justement dans le choix de ces paramètres car ils varient en fonction du type d'images et de textures. Pour ce qui est du vecteur de déplacement, si toutes les directions sont étudiées avec différents pas de déplacement, un grand nombre de matrices de cooccurrence doit être calculé. Ceci conduit à une grande complexité calculatoire. Plusieurs études ont été menées pour déterminer une distance ou une orientation optimale.

En 1986, Weszka [21] a conclu, qu'en pratique, une distance courte donne généralement de bons résultats, [22] La taille de la fenêtre d'analyse, elle doit satisfaire deux critères contradictoires à savoir, le plus petit possible pour réduire le risque de mélange de textures différentes et, en même temps, le plus grand possible pour pouvoir extraire des statistiques assez robustes et significatives.

### **II.2.5.2.3. Les méthodes statistiques d'ordre supérieur (les motifs locaux binaires) :**

La méthode LBP (Local Binary Pattern) est une méthode d'analyse de la texture qui a émergé ces dernières années. Elle considère un nombre de pixels voisins  $p$  et une distance  $d$  reliant le pixel central avec les pixels voisins, centré sur chaque pixel de l'image. Pour chaque pixel, on définit une matrice de taille  $(p \times p)$ . En codant ces matrices, on obtient un nombre appelé Local Binary Pattern ou (LBP) qui peut prendre  $2^p$  valeurs. Cette méthode est utilisée avec succès dans divers domaines comme la détection ou la reconnaissance faciale [23].

En termes d'efficacité discriminante, cette méthode offre de bonnes performances et contient des informations structurelles et statistiques. L'opérateur LBP peut être invariant aux rotations et changements d'échelles et offre une grande tolérance face aux changements de luminosité. De plus, c'est une méthode de faible complexité qui rend possible l'analyse d'images 2D en temps réel.

### **II.2.5.3. Méthodes basées sur un modèle :**

Les méthodes basées sur des modèles cherchent à caractériser statistiquement l'image au moyen de modèles probabilistes en considérant la texture comme une réalisation d'un processus aléatoire. Les principaux modèles sont [24] :

- Les modèles autorégressifs
- Les modèles de MARKOV
- Les modèles de Gibbs

### **II.2.5.4. Approche basée sur la morphologie mathématique :**

La morphologie mathématique est une discipline née en France en 1964 (G. Matheron, J. Serra), c'est une théorie non linéaire, fondée sur les ensembles, et treillis. Elle est utilisée en analyse d'images dans le but de l'étude des objets en fonction de leur forme, de leur taille, des relations avec leur voisinage, de leur texture, et de leurs niveaux de gris ou de leur couleur.

La morphologie mathématique a été appliquée avec succès en analyse d'images texturées car les opérations morphologiques traitent directement la caractéristique des objets dans l'image. Une opération morphologique fondamentale est l'ouverture qui supprime les objets de taille inférieure à celle de l'élément structurant et conserve tous les autres. Elle peut s'employer en décomposition d'images texturées. Ainsi afin de séparer les primitives de différentes tailles dans une texture [13].

### **II.2.5.5. Approche fréquentielle :**

Les méthodes fréquentielles, souvent utilisées en traitement du signal, permettant d'analyser une texture en identifiant les différentes fréquences qui la composent. Parmi elles, on retrouve notamment [13] :

- La transformée de Fourier.
- Les masques de Laws.
- Les filtres de Gabor.
- La transformée en ondelettes.

### II .3. Transformée en ondelette :

Nous introduisons ici quelques concepts de base relatifs à la transformation en ondelettes. On peut trouver plus de détails sur la théorie des ondelettes dans plusieurs travaux, notamment ceux de Mallat (1989) et de Cohen (1992).

Les ondelettes sont des fonctions dont la forme générale est donnée par la formule suivante :


$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad \text{with } a \neq 0 \quad \text{II. 10}$$

$$C_{a,b} = \int_{-\infty}^{+\infty} x(t) \Psi_{a,b}(t) dt \quad \text{II. 11}$$

Où le paramètre (a) est le facteur d'échelle est (b) le paramètre de translation.

L'analyse par ondelettes est un outil mathématique capable de transformer un signal d'énergie finie dans le domaine spatial en un autre signal d'énergie finie dans le domaine spatio-fréquentiel. Les composantes  $C_{a,b}$  de ce nouveau signal sont appelées les coefficients d'ondelettes. Ces coefficients renseignent sur la variation locale des niveaux de gris autour d'un pixel donné de l'image. Ils sont d'autant plus grands que cette variation est importante. Contrairement à la transformation de Fourier, l'analyse par ondelettes est localisée dans l'espace et en fréquence, ce qui la rend très utile pour l'analyse des signaux non stationnaires comme c'est le cas pour les images texturées.

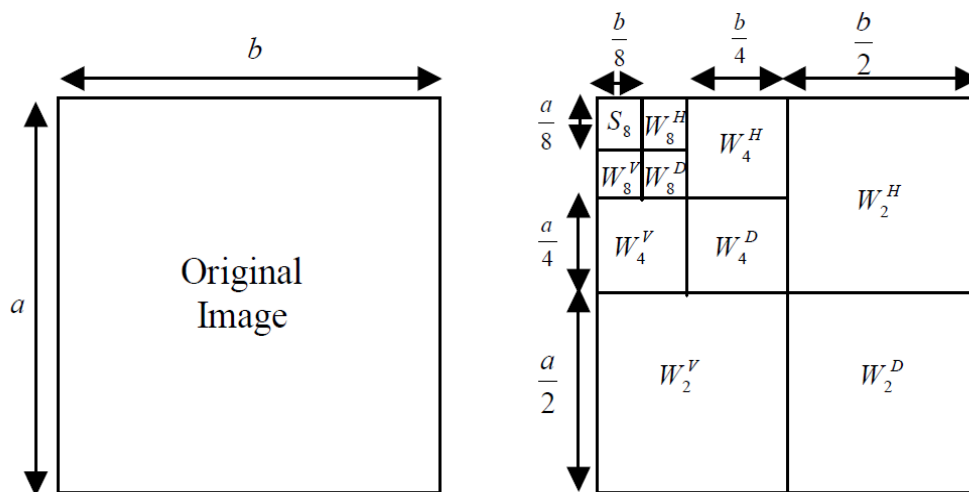
Figure II.5 représente quelques exemples d'ondelettes généralement utilisées dans le domaine du traitement d'images.



(a) Ondelette de Morlet (b) Ondelette chapeau mexicain (c) ondelette de Meyer

**Figure II.5** : Exemples classiques d'ondelettes

En 1989, Mallat a proposé un algorithme de décomposition multi-résolution basé sur la transformation en ondelettes. L'algorithme décompose une image en entrée en un ensemble d'images de détails et une image d'approximation. À chaque niveau de décomposition la taille des images transformées est réduite par un facteur deux.



**Figure II.6** : Transformée en ondelettes discrètes pyramidales (DWT).

La figure II.6 montre une décomposition pyramidale en ondelettes à trois niveaux d'une image de taille  $a \times b$  pixel. Dans le premier niveau de décomposition, une image passe-bas LL1 (contient des basses fréquences verticales et horizontales, elle représente les coefficients d'approximation) et trois images passe-haut d'orientation sélective : HL1 (contient les hautes fréquences verticales et horizontales, il représente les détails horizontaux), LH1 (contient les hautes fréquences verticales et horizontales, il représente les détails verticaux) et HH1 (contient les hautes fréquences verticales et horizontales, il représente les détails diagonaux) sont créés.

Dans le deuxième niveau de décomposition, l'image passe-bas est en outre décomposée en une image passe-bas et trois images passe-haut (LL2, HL2, LH2, HH2). Le processus est répété sur l'image passe-bas pour former un niveau plus élevé de décomposition en ondelettes. En d'autres termes, DWT décompose une image en une structure pyramidale des sous-images avec différentes résolutions correspondant aux différentes échelles. Nous notons qu'une décomposition en trois niveaux créera trois images passe-bas et neuf images (trois dans chaque direction horizontale, verticale et diagonale) passe-haut. Les images passe-bas sont des versions basse résolution de l'image originale à différentes échelles. Les sous-images horizontales, verticales et diagonales fournissent respectivement les informations sur les changements dans les directions correspondantes.

Les valeurs des coefficients transformés en images d'approximation et détail (images de sous-bande) représentent les caractéristiques nécessaires qui capturent des informations de discrimination utiles pour la segmentation de texture [25].

La transformée en ondelettes à une variante connue sous le nom de "transformée en paquets d'ondelettes" qui permet une analyse très fine des textures. A chaque niveau, les sous-bandes sont sélectionnées pour la prochaine décomposition. La différence entre la transformée en ondelettes et la transformée en paquets d'ondelettes est que cette dernière transformée décompose les composants haute fréquence, construisant ainsi une extension d'arbre multi-échelle de la transformée en ondelettes [25].

- **Calcul des indices de texture** : L'un des indices les plus utilisés pour caractériser la texture dans le plan spatio-fréquence est la mesure d'énergie. Parce que les images transformées ont des fréquences, des orientations et des échelles différentes, l'indice d'énergie est une mesure locale de la distribution du coefficient d'ondelettes en fonction de la fréquence, de l'orientation et de l'échelle. Il a été utilisé avec succès pour la classification et la segmentation des textures [25].

L'expression d'énergie exprimée sous forme normalisée est donnée par [25] :

$$E = \frac{1}{N} \sum_R C(i, j)^2 \quad \text{II. 12}$$

Le deuxième indice utilisé conjointement avec l'énergie est la mesure de la moyenne locale des coefficients d'ondelettes donnée par [25] :

$$M = \frac{1}{N} \sum_R |C(i, j)|, \quad \text{II. 13}$$

Où  $N$  désigne le nombre de pixels, nommé par les indices  $(i, j)$ , et enfermé dans le voisinage  $R$  sur lequel la texture est estimée.

L'évaluation de ces indices se fait sur une fenêtre coulissante  $W$ . L'énergie et la moyenne locale sur la fenêtre coulissante sont calculées à partir des images de sous-bandes résultantes. Ainsi, si une ondelette à un niveau est utilisée, le vecteur caractéristique de chaque fenêtre est composé de huit paramètres  $V = [E_{LL}, E_{LH}, E_{HL}, E_{HH}, M_{LL}, M_{LH}, M_{HL}, M_{HH}]$ .

Cette méthode a été largement utilisée en littérature pour la segmentation des images texturées [26]. Arivazhagan [27] a utilisé les caractéristiques de la matrice de cooccurrence dérivées de la transformée en ondelettes sur des blocs de l'image dans le même cadre.

#### **II.4. Conclusion :**

L'analyse d'images englobe une multitude de domaines, ici nous avons abordé celui de l'analyse de textures. L'analyse de textures est un problème difficile. Cette difficulté est due essentiellement au fait qu'il n'existe pas de définition précise et rigoureuse permettant de caractériser complètement la notion de texture. Le but de cette partie de ce travail est de passer en revue des méthodes permettant d'extraire, dans les images à niveaux de gris, une certaine information caractéristique de la texture.

La transformée en ondelettes présente de nombreux avantages dans le domaine du traitement du signal et de l'image. L'analyse par ondelettes ne se limite plus à l'image telle qu'elle nous apparaît, mais permet l'étude des objets présents dans l'image à différentes échelles, elle permet de réduire la redondance pour améliorer la compression d'une image, elle peut également extraire les informations importantes (texture, contours, etc.) contenues dans une image et aussi de réduire le bruit contenu dans l'image. C'est un outil puissant de transformation du signal qui permet de « préparer » le signal afin de faciliter le traitement envisagé.

***Chapitre III***

**Classification par  
réseaux de neurones**

**III.1. Introduction :**

Nous allons présenter dans ce chapitre une étude générale sur les réseaux de neurones, le passage du modèle biologique au modèle artificiel, le protocole d'apprentissage, ainsi les différentes classes et architectures de ces réseaux.

**III.2. Classification par réseaux de neurones :**

Le cerveau humain est capable de s'adapter, d'apprendre et de décider, et c'est sur ce fait que des chercheurs se sont intéressés à comprendre son principe de fonctionnement et de on formalisa le neurone en un modèle mathématique à partir du modèle biologique. [28]

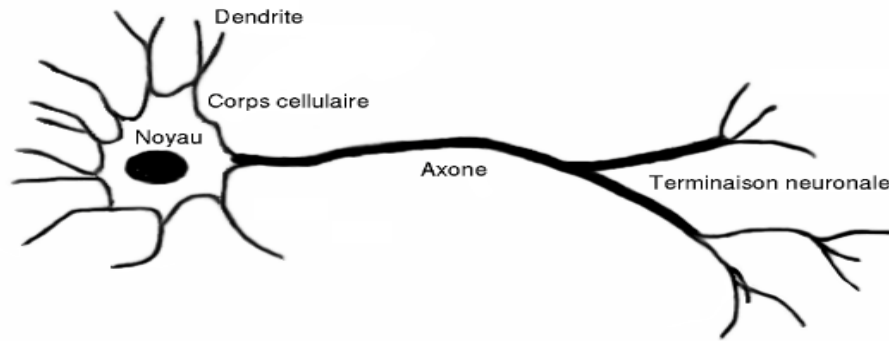
**III.2.1. Modèle biologique :****III.2.1.1. Définition du neurone :**

Le neurone biologique est une cellule vivante spécialisée dans le traitement des signaux électriques. Les neurones sont reliés entre eux par des liaisons appelées axones. Ces axones vont eux-mêmes jouer un rôle important dans le comportement logique de l'ensemble. Ces axones conduisent les signaux électriques de la sortie d'un neurone vers l'entrée (synapse) d'un autre neurone. Les neurones font une sommation des signaux reçus en entrée et en fonction du résultat obtenu, vont fournir un courant en sortie. [28]

**III.2.1.2. Structure du neurone biologique :**

Le système nerveux compte plus de 1000 milliards de neurones interconnectés. Bien que les neurones ne soient pas tous identiques, leur forme et certaines caractéristiques permettent de les répartir en quelques grandes classes. En effet, les neurones n'ont pas tous un comportement similaire en fonction de leur position dans le cerveau [28].

Voici le schéma d'un neurone biologique :



**Figure III.1 :** Structure du neurone biologique.

On peut le décomposer en trois régions principales :

**- Le corps cellulaire :**

Il contient le noyau du neurone ainsi que la machine biochimique nécessaire à la synthèse des enzymes. Ce corps cellulaire de forme sphérique ou pyramidale contient aussi les autres molécules essentielles à la vie de la cellule. Sa taille est de quelques microns de diamètre.

**- Les dendrites :**

Ce sont de fines extensions tubulaires qui se ramifient autour du neurone et forment une sorte de vaste arborescence. Les signaux envoyés au neurone sont captés par les dendrites. Leur taille est de quelques dizaines de microns de longueur.

**- L'axone :**

C'est le long de l'axone que les signaux partent du neurone. Contrairement aux dendrites qui se ramifient autour du neurone, l'axone est plus long et se ramifie à son extrémité ou il se connecte aux dendrites des autres neurones. Sa taille peut varier entre quelques millimètres à plusieurs mètres.

**- Synapse :**

Une synapse est une jonction entre deux neurones, et généralement entre l'axone d'un neurone et une dendrite d'un autre neurone (mais il existe aussi des synapses axo-axonales par exemple).

**III.2.1.3. Fonctionnement :**

La membrane externe d'un neurone exécute cinq fonctions :

- Propagation des impulsions électriques le long de l'axone et des dendrites.
- Libération des médiateurs à l'extrémité de l'axone.
- Réagir à ces médiateurs chimiques au niveau des dendrites.

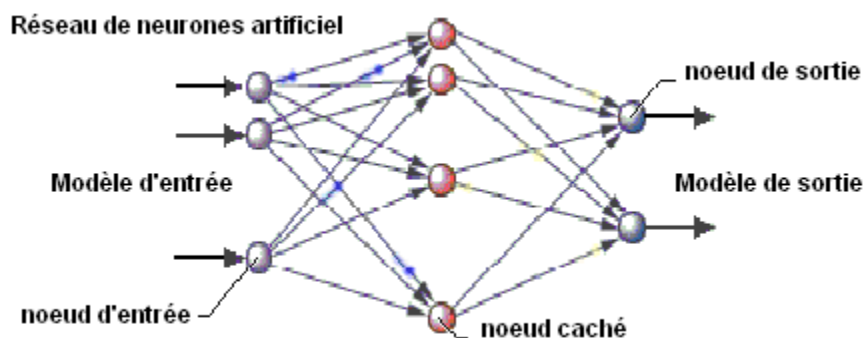
- Réagir au niveau du corps cellulaire aux impulsions électriques issues des dendrites pour générer ou non une nouvelle impulsion.
- Permettre au neurone de reconnaître ses voisins pour se situer au cours de la formation du cerveau et trouver à quelles autres cellules il doit se connecter.

### III.2.2. Modèle artificiel :

#### III.2.2.1. Définition du réseau de neurones artificiel :

Ce que l'on désigne habituellement par "réseau de neurones" (neural network), ou réseau neuromimétique est un réseau de neurones artificiels basé sur un modèle simplifié de neurone. Ce modèle permet certaines fonctions du cerveau, comme la mémorisation associative, l'apprentissage par l'exemple, le travail en parallèle, etc. Cependant le neurone formel ne possède pas toutes les capacités des neurones biologiques, comme le partage de synapses, l'activation membranaire ou la structuration prénatale des neurones, par conséquent les réseaux de neurones actuels sont loin d'avoir les possibilités du cerveau. [28]

#### III.2.2.2. Fonctionnement du réseau de neurones :



**Figure III.2 :** Réseau de neurones artificiel.

Le fonctionnement des systèmes de neurones se caractérise par trois principes :

- Le parallélisme des opérations de traitement.
- Le caractère collectif et la distribution de l'activité des éléments du réseau.
- Les capacités d'apprentissage à partir d'exemple.

Les simulations des systèmes de neurones ont manifesté des comportements analogues à ceux du modèle vivant : mémoire à long terme et à court terme. Il est même observé qu'il existe une limite du nombre d'article enregistrable en une seule fois ; si cette limite est dépassée, des objets de la mémoire sont effacés : c'est ce que l'on appelle l'effet " PALIMPSESTE ".

On pourrait penser que plus le nombre de neurones est important, plus le réseau est performant. Ceci n'est pas certain. Lorsque les concepteurs des réseaux essayent d'augmenter le nombre de neurones, ils sont limités par plusieurs contraintes, et en particulier par la durée d'apprentissage qui augmente avec le nombre de neurones. En effet, l'apprentissage s'effectue par l'exemple et il faut que le nombre de ceux-ci soit bien plus important que le nombre de connexions. Quand on sait qu'un système de 1000 neurones possède plus de 1000 000 connexions, on peut craindre le temps d'apprentissage. [29]

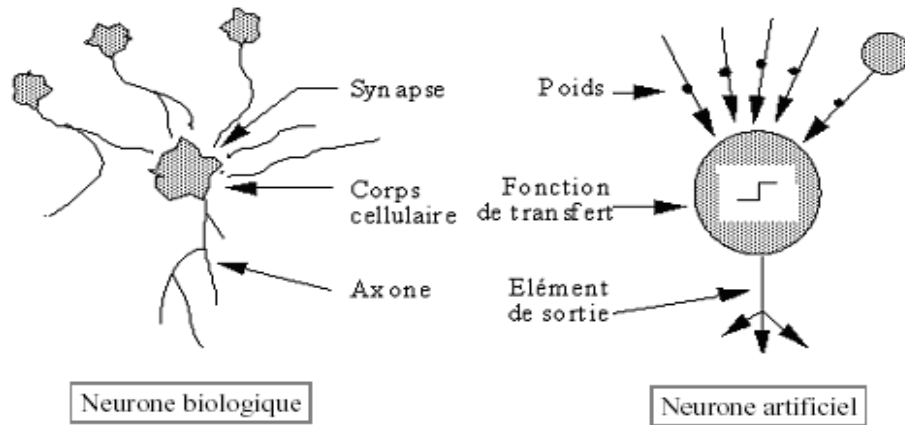


Figure III.3 : Dualité entre un neurone artificiel et biologique.

III.2.2.3. Neurone formel :

Le premier neurone formel est apparu en 1943. Mac Culloch et Pitts ont prouvé que pour des poids judicieusement choisis ce modèle offrait la puissance d'une machine de Turing universelle. Voici un schéma de leur modèle de neurone formel :




Figure III.4 : Schéma du neurone formel (Mac Culloch et Pitts).

Le neurone formel est donc une modélisation mathématique qui reprend les principes du fonctionnement du neurone biologique, en particulier la sommation des entrées. Sachant qu'au niveau biologique, les synapses n'ont pas toutes la même « valeur » (les connexions entre les neurones étant plus ou moins fortes), les auteurs ont donc créé un algorithme qui pondère la somme de ses entrées par des poids synaptiques (coefficients de pondération).

Les 1 et les -1 en entrée sont là pour figurer une synapse excitatrice ou inhibitrice.

### - Interprétation mathématique :

D'un point de vue mathématique, le neurone formel peut être représenté de la manière suivante :

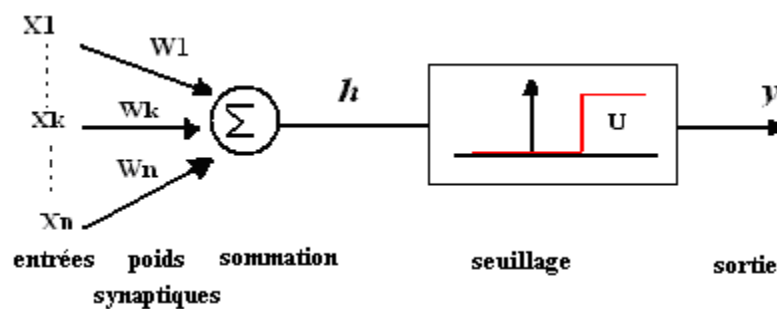


Figure III.5 : Représentation mathématique du neurone formel.

### III.2.2.4. Fonctions d'activation :

Chaque neurone calcule sa valeur de sortie à partir de la somme pondérée de ses entrées et de ses poids, il existe différentes fonctions d'activation permettant de calculer cette valeur. Dans sa première version, le neurone formel était donc implémenté avec une fonction à seuil, mais de nombreuses versions existent. Ainsi le neurone de McCulloch et Pitts a été généralisé de différentes manières, en choisissant d'autres fonctions d'activations, comme les fonctions linéaires ou les sigmoïdes par exemple.

Le tableau III.1 récapitule les différents types de fonctions d'activation les plus utilisées, avec leurs équations mathématiques et leurs dérivées [30].

Catégorie	Type	Equation	Allure	Dérivée
Seuil	Binaire (fonction de Heaviside)	$f(x) = 1$ si $x > 0$ $f(x) = 0$ si $x \leq 0$		-
	Signe	$f(x) = 1$ si $x > 0$ $f(x) = -1$ si $x \leq 0$		-
Linéaire	Identité	$f(x) = x$		$f'(x) = 1$
	Saturé positif	$f(x,k) = 0$ si $x < 0$ $f(x,k) = 1$ si $x \geq 1/k$ $f(x,k) = k.x$ sinon		$f'(x,k) = 0$ si $x < 0$ $f'(x,k) = 0$ si $x \geq 1/k$ $f'(x,k) = k$ sinon
	Saturé symétrique	$f(x,k) = -1$ si $x < -1/k$ $f(x,k) = 1$ si $x \geq 1/k$ $f(x,k) = k.x$ sinon		$f'(x,k) = 0$ si $x < -1/k$ $f'(x,k) = 0$ si $x \geq 1/k$ $f'(x,k) = k$ sinon
Sigmoide	Positive (type logistique)	$f(x,k) = \frac{1}{1+e^{-kx}}$		$f'(x,k) = \frac{k}{2+e^{-kx}+e^{kx}}$
	Symétrique (type tanh)	$f(x,k) = \frac{1}{1+e^{-kx}} - 1$		$f'(x,k) = \frac{2k}{2+e^{-kx}+e^{kx}}$

Tableau III.1 : Tableau récapitulatif de différents types de fonctions d'activation.

**III.2.3. Apprentissage :**

L'apprentissage est vraisemblablement la propriété la plus intéressante des réseaux neuronaux. C'est une phase du développement d'un réseau de neurones durant laquelle le comportement du réseau est modifié jusqu'à l'obtention du comportement désiré. L'apprentissage neuronal fait appel à des exemples de comportement [31].

Dans la majorité des algorithmes actuels, les variables modifiées pendant l'apprentissage sont les poids des connexions. L'apprentissage est la modification des poids du réseau dans l'optique d'accorder la réponse du réseau aux exemples et à l'expérience.

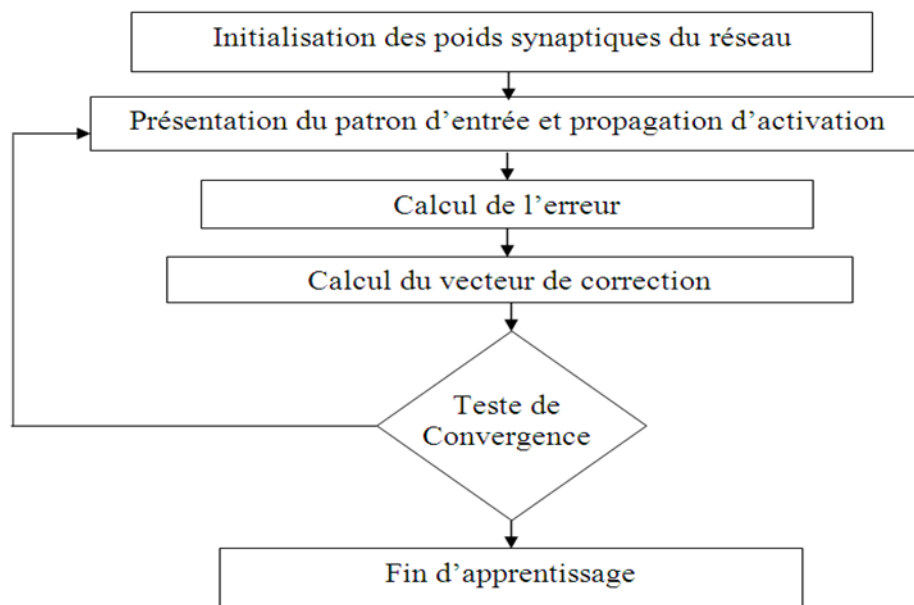
A l'issu de l'apprentissage, les poids sont fixés : c'est alors la phase d'utilisation.

**- Procédure d'apprentissage :**

L'apprentissage d'un réseau se fait généralement dans le contexte d'une tâche ou d'un comportement à apprendre. Les informations à traiter sont codées sous la forme d'un vecteur appelé patron d'entrée, qui est communiqué aux neurones d'entrée du réseau. La réponse du réseau s'interprète à partir de la valeur d'activation de ses neurones de sorties, dont le vecteur

s'appelle patron de sortie. Lors d'un apprentissage supervisé, on dispose aussi du comportement de référence que doit apprendre le réseau, exprimé sous la forme de patron de référence, ou patron de sorties désirées.

En général, l'apprentissage se fait sur une période relativement longue, durant laquelle les patrons d'entrée (et éventuellement de sorties désirées) peuvent être présentés au réseau un grand nombre de fois chacun. Les étapes de l'apprentissage du réseau de neurone sont décrites dans l'organigramme de la figure III.6.



**Figure III.6 :** Organigramme des étapes d'apprentissage du réseau de neurone.

#### **III.2.4. Architecture et classification des réseaux de neurones :**

On peut classer les RNA en deux grandes catégories : [28]

##### **III.2.4.1. Les réseaux non bouclés "FEED-FORWARD" :**

Appelés aussi "réseaux de type Perceptron", ce sont des réseaux dans lesquels l'information se propage de couche en couche sans retour en arrière possible.

Ce type de réseau réalise une fonction algébrique de ses entrées par composition des fonctions réalisées par chacun des neurones.

Ce type de réseau est dit acyclique car si l'on se déplace dans un réseau à partir d'un neurone quelconque suivant les connexions, on ne peut pas revenir au neurone de départ.




Figure III.6 : Réseau de neurones non bouclé.

### III.2.4.1.1. Les Perceptrons :

#### A- Le Perceptron monocouche :

C'est historiquement le premier RNA, c'est le Perceptron de Rosenblatt. C'est un réseau simple, puisqu'il ne se compose que d'une couche d'entrée et d'une couche de sortie. Il est calqué, à la base, sur le système visuel et de ce fait a été conçu dans un but premier de reconnaissance des formes. Cependant, il peut aussi être utilisé pour faire de la classification et pour résoudre des opérations logiques simples (telle "ET" ou "OU"). Sa principale limite est qu'il ne peut résoudre que des problèmes linéairement séparables.

Il suit généralement un apprentissage supervisé selon la règle de correction de l'erreur (ou selon la règle de Hebb).

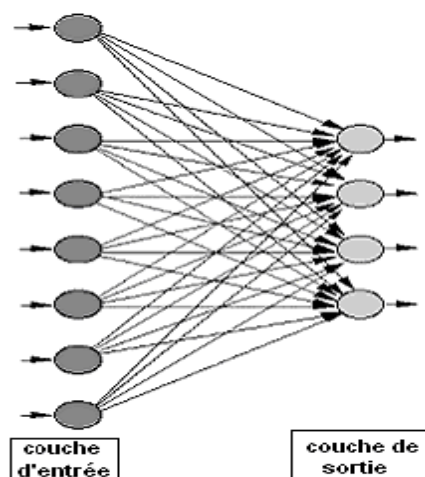
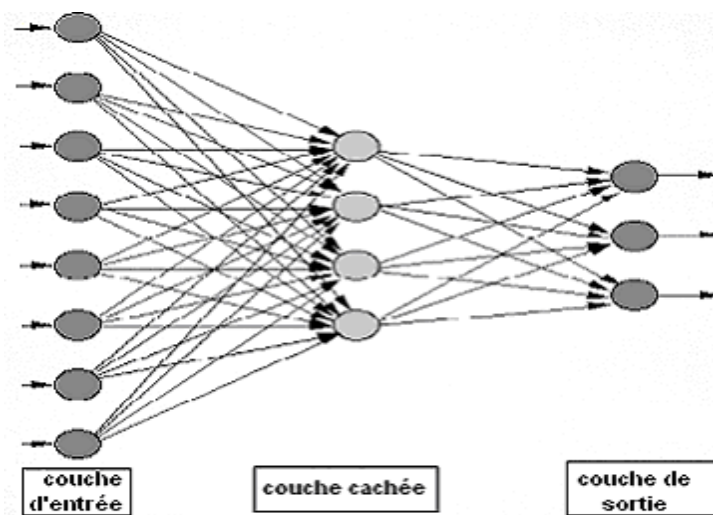


Figure III.7 : Perceptron monocouche.

**B- Le Perceptron multicouche (PMC) :**

C'est une extension du précédent, avec une ou plusieurs couches cachées entre l'entrée et la sortie. Chaque neurone dans une couche est connecté à tous les neurones de la couche précédente et de la couche suivante (excepté pour les couches d'entrée et de sortie) et il n'y a pas de connexions entre les cellules d'une même couche. Les fonctions d'activation utilisées dans ce type de réseaux sont principalement les fonctions à seuil ou sigmoïdes. Il peut résoudre des problèmes non linéairement séparables et des problèmes logiques plus compliqués, et notamment le fameux problème du XOR. Il suit aussi un apprentissage supervisé selon la règle de correction de l'erreur.



**Figure III.8 :** Perceptron multicouche (à trois couches).

**III.2.4.1.2. Les réseaux à fonction radiale :**


Ce sont les réseaux que l'on nomme aussi RBF ("Radial Basic Functions"). L'architecture est la même que pour les PMC cependant, les fonctions de base utilisées ici sont des fonctions Gaussiennes. Les RBF seront donc employés dans les mêmes types de problèmes que les PMC à savoir, en classification et en approximation de fonctions, particulièrement. L'apprentissage le plus utilisé pour les RBF est le mode hybride et les règles sont soit, la règle de correction de l'erreur soit, la règle d'apprentissage par compétition.

**III.2.4.2. Les réseaux bouclés "FEED-BACK" :**

Appelés aussi "réseaux récurrents", ce sont des réseaux dans lesquels il y a retour en arrière de l'information.

C'est l'architecture la plus générale pour un réseau de neurones et la plus répandue ; les réseaux bouclés possèdent un graphe cyclique tel que lorsqu'on se déplace dans le réseau suivant le sens des connexions, on peut toujours revenir vers notre point de départ.

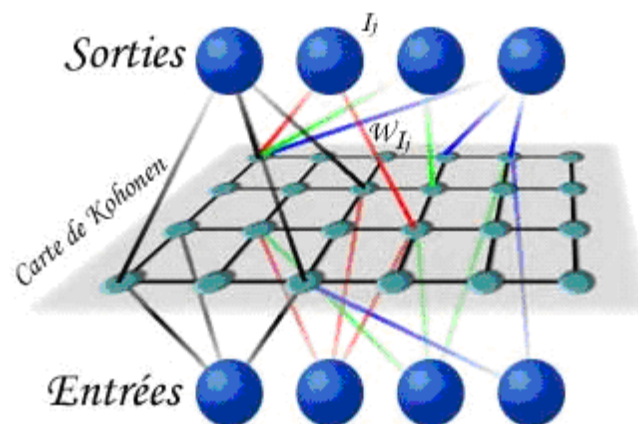
La sortie d'un neurone du réseau peut donc être fonction d'elle-même ; la notion de retard est donc introduite.



**Figure III.9** : Réseau de neurones bouclé.

#### III.2.4.2.1. Les cartes auto-organisatrices de Kohonen :

Ce sont des réseaux à apprentissage non-supervisé qui établissent une carte discrète, ordonnée topologiquement, en fonction de patterns d'entrée. Le réseau forme ainsi une sorte de treillis dont chaque nœud est un neurone associé à un vecteur de poids. La correspondance entre chaque vecteur de poids est calculée pour chaque entrée. Par la suite, le vecteur de poids ayant la meilleure corrélation, ainsi que certains de ses voisins, vont être modifiés afin d'augmenter encore cette corrélation.



**Figure III.10** : Carte auto-organisatrice de Kohonen.

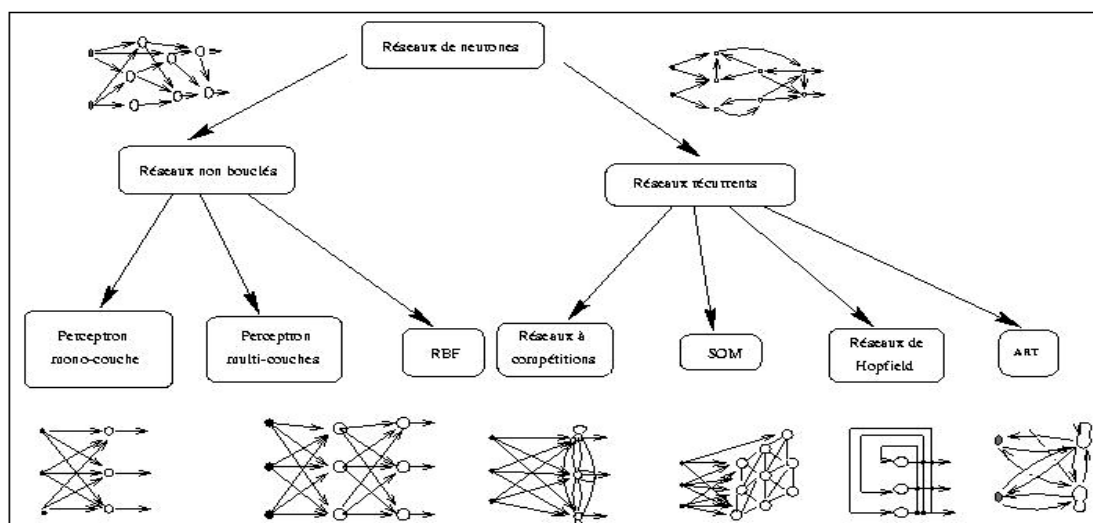
### III.2.4.2.2. Les réseaux de Hopfield :

Les réseaux de Hopfield sont des réseaux récurrents et entièrement connectés. Dans ce type de réseau, chaque neurone est connecté à chaque autre neurone et il n'y a aucune différenciation entre les neurones d'entrée et de sortie. Ils fonctionnent comme une mémoire associative non-linéaire et sont capables de trouver un objet stocké en fonction de représentations partielles ou bruitées. L'application principale des réseaux de Hopfield est l'entrepôt de connaissances mais aussi la résolution de problèmes d'optimisation. Le mode d'apprentissage utilisé ici est le mode non-supervisé.

### III.2.4.2.3. Les ARTs :

Les réseaux ARTs ("Adaptative Resonance Theorie") sont des réseaux à apprentissage par compétition. Le problème majeur qui se pose dans ce type de réseaux est le dilemme « stabilité / plasticité ». En effet, dans un apprentissage par compétition, rien ne garantit que les catégories formées vont rester stables. La seule possibilité, pour assurer la stabilité, serait que le coefficient d'apprentissage tend vers zéro, mais le réseau perdrait alors sa plasticité. Les ART ont été conçus spécifiquement pour contourner ce problème. Dans ce genre de réseau, les vecteurs de poids ne seront adaptés que si l'entrée fournie est suffisamment proche, d'un prototype déjà connu par le réseau. On parlera alors de résonance. A l'inverse, si l'entrée s'éloigne trop des prototypes existants, une nouvelle catégorie va alors se créer, avec pour prototype, l'entrée qui a engendrée sa création. Il est à noter qu'il existe deux principaux types de réseaux ART : les ART-1 pour des entrées binaires et les ART-2 pour des entrées continues. Le mode d'apprentissage des ARTs peut être supervisé ou non.

- **Récapitulation :** Les différents réseaux de neurones peuvent être classés comme dans le schéma ci-dessous :



**Figure III.11 :** Schéma récapitulatif des différentes classes des réseaux de neurones.

### III.2.5. Domaines d'applications des réseaux de neurones :

Voici quelques exemples d'applications : [28]

➤ *La reconnaissance de forme* : Dans ce type de problème, les données d'entrée représentent l'information recueillie par un ou plusieurs capteurs (caméra, sonar, micro). Le but est de reconnaître le ou les objets perçus par le capteur :

- *En reconnaissance de la parole* : Les entrées peuvent être une segmentation de la fréquence d'un signal sonore, et les sorties identifient la valeur de tel ou tel phénomène associé à l'entrée. Ou bien on peut transcrire le langage parlé en texte ASCII.
- *En reconnaissance de cibles* : Applications militaires qui utilisent des données issues d'images vidéo ou infrarouge pour déterminer la présence d'une cible ennemie.
- *En reconnaissance de Codes postaux* : Cette application fût l'un des premiers problèmes de reconnaissance d'images assez complexe, en raison de la variabilité des styles d'écritures, mais en plus cette application est moins onéreuse que de rectifier une erreur de tri.
- *En reconnaissance d'écriture* : Qu'elle soit manuscrite ou imprimée, le réseau va être confronté à un problème de classification, par rapport à la base d'apprentissage qui constitue la base de données.

➤ *La classification* : Ce type d'application ressemble beaucoup à la reconnaissance de formes, en ce que son but est d'associer à une entrée donnée l'étiquette d'une forme connue.

➤ *La transformation* : Plusieurs applications ont été proposées où le réseau doit apprendre une transformation mathématique entre l'entrée et la sortie. En traitement d'image, par exemple, il existe des modèles connexionnistes capables de calculer les contours d'objets, la correspondance temporelle d'objets en mouvement et la compression de données.

➤ *La prédiction et le contrôle de processus* : Le problème de la prédiction consiste à estimer l'état futur d'un processus à partir d'un historique de son comportement et des variables environnementales attenantes. En contrôle, il s'agit non seulement d'estimer passivement l'état futur, mais aussi d'intervenir de façon à atteindre un but donné. Dans ce cadre, un domaine où les réseaux ont un succès incontestable est dans le domaine de la finance. Dans un contexte plus industriel, les applications sont diverses ; citons la prédiction

de séries temporelles (par exemple, la consommation électrique ou le contrôle automatique de processus dynamiques).

➤ *En médecine* : Les entrées du réseau peuvent être un ensemble de valeurs résultant d'une liste de tests médicaux, les sorties étant les symptômes possibles de maladies infectieuses.

### **III.3. Conclusion :**

À travers ce chapitre, nous constatons que les réseaux de neurones sont une alternative qui peut être très efficace pour les problèmes que les algorithmes classiques ne peuvent résoudre. Leur capacité d'apprentissage automatique, permet de résoudre des problèmes sans nécessiter l'écriture de règles complexes, tout en étant tolérant aux erreurs.

*Chapitre IV*

**F**usion de l'information

### IV.1. Introduction

La fusion d'informations a été initialement proposé afin de gérer des quantités très importantes de données multi-sources dans le domaine militaire, surtout dans un contexte tels que la localisation des cibles ennemies, la fusion d'images radar, etc. Cependant, durant ces dernières années des méthodes de fusion ont été adaptées et développées pour des applications en traitement du signal. Bloch [32] ont présenté et définit les étapes nécessaires de fusion en traitement d'images, Martin [33] à proposer des approches de fusion d'informations de haut niveau particulièrement pour la fusion de classifieurs pour la classification d'images sonars, Chitroub [34] à proposer une méthode de combinaison de classifieurs pour l'amélioration de la classification des images multi sources/ multi dates de télédétection, Tabassian [35] ont proposé une approche de combinaison de classifieurs basées sur la théorie d'évidence afin de traiter l'imperfection des données, ...etc.

Bloch [36] a défini la fusion de donnée comme combinaison d'informations provenant de multiples sources pour aider à la prise de décision. L'image fusionnée résultante contient plus d'informations que les image sources individuelles, car on tient compte de la complémentarité des données.

### IV.2. Principes de la fusion

Soit  $N$  images  $I_j$  issues d'une même scène vue à travers des systèmes différents. Soit  $x$  l'élément pour lequel on souhaite affecter un élément  $C_k$  de l'espace de décision  $D = \{C_1, C_2, \dots, C_k\}$  ( $C_k$  détermine une classe dans notre cas).

La fusion s'effectue généralement par l'intermédiaire de mesures sur  $x$  extraites de  $I_j$  vis à vis de  $C_k$  notées  $M_j^k(x)$ . Toutes ces mesures sont rassemblées dans la matrice  $M$  de taille  $(N \times k)$ .

	$C_1$	$C_2$	...	$C_k$
$I_1$	$M_1^1$	$M_2^1$	...	$M_k^1$
$I_2$	$M_1^2$	$M_2^2$	...	$M_k^2$
...	...	...	...	...
$I_N$	$M_1^N$	$M_2^N$	...	$M_k^N$

**Table IV.1** La matrice  $M$ .

### IV.2.1. Etapes du processus de fusion

Les étapes du processus de fusion sont définies comme suit (Bloch (2003)) [36] :

1. **Modélisation** : consiste à passer des informations extraites des images à une représentation mathématique liée à une théorie particulière, ce qui revient à choisir le formalisme des éléments à fusionner en définissant la forme de  $M_j^k$ , qui peut être une distribution, une fonction de coût, une formule, etc.
2. **Estimation** : consiste à estimer les paramètres du modèle, cette étape est dépendante de la modélisation. Il s'agit par exemple de l'estimation des distributions.
3. **Combinaison** : L'étape de combinaison est la phase de regroupement des informations. C'est le cœur de la fusion. Il s'agit de choisir un opérateur adapté au formalisme de la modélisation. Les opérateurs de combinaison fournissent un résultat de même nature que les informations combinées. L'information ainsi fournie s'interprète de la même façon que les informations de départ.
4. **Décision** : La dernière étape de la fusion d'informations est la décision. Le choix du critère se fait en fonction du choix de la modélisation et de la combinaison. Classiquement, il s'agit de la minimisation ou de la maximisation d'une fonction issue de la combinaison. Cette étape doit donc fournir à l'expert la "meilleure" décision  $d_k$ .

### IV.2.2. Manières de fusion de l'information

Sachant qu'il existe différentes façons de combiner les informations provenant de plusieurs sources, quatre principes sont envisageables dépendant de la matrice  $M$  :

- 1- **Principe globale** : prend en compte la matrice globale  $M$ .
- 2- **Principe horizontal** : prend des décisions locales sur chaque image séparément, puis une décision globale sur  $x$  (colonne de  $M$ ). L'intérêt d'une telle approche réside dans le fait que l'information des sources n'est pas forcément disponible simultanément. Il est ainsi facile d'ajouter une source. Cette approche ne tient cependant pas compte des relations possibles (dépendances, corrélations) entre les sources.
- 3- **Principe vertical** : combine toutes les mesures relatives à une même classe  $C_i$ , puis une décision globale sur  $x$  (ligne de  $M$ ). Cependant, comme pour la fusion globale, toute l'information doit être présente simultanément.
- 4- **Principe intermédiaire** : choisit de manière adaptative les informations nécessaires pour un problème donnée en fonction des spécificités de l'image.

Le principe vertical est le plus utilisé, de ce fait nous nous baserons sur ce principe par la suite.

### **IV.2.3. Niveaux de fusion**

B.V. Dasarathy [37] a proposé trois niveaux de fusion qui sont les données, les caractéristiques, et les décisions. La fusion de données (ou fusion de bas niveau) correspond à la fusion d'informations directement en sortie du capteur ou de la source. La donnée est donc par exemple un coefficient d'un signal à une fréquence donnée, ou encore un pixel si le signal a été reconstruit sous forme d'image. La fusion de caractéristiques (ou fusion de moyen niveau) est la fusion d'informations extraites des données issues directement de la source. Les caractéristiques sont donc par exemple, les paramètres de texture d'une image. Enfin la fusion de décisions (ou fusion de haut niveau) est relative à la fusion d'informations correspondant à la formulation d'hypothèses issues d'un expert ou d'un système (par exemple un classifieur). Ces trois niveaux ont été souvent repris [38].

### **IV.3. Imperfections de l'information :**

Une des caractéristiques importantes de l'information en fusion est son imperfection. Elle peut prendre diverses formes, qui sont brièvement décrites ci-dessous.

Les principales imperfections considérées sont l'incertitude et l'imprécision [39-40]. A ces deux imperfections peuvent être ajoutées l'incomplétude [41-42], la redondance et la complémentarité [36,43], le conflit [44,45,46,47,48], et enfin l'ambiguïté [36].

L'**incertitude** est relative à la vérité d'une information, et caractérise son degré de conformité à la réalité [49]. Elle fait référence à la nature de l'objet ou du fait concerné, à sa qualité, à son essence ou à son occurrence. Une information incertaine décrit donc une connaissance partielle de la réalité, alors que ce qui est certain entraîne nécessairement la connaissance de toute la réalité. Pour mesurer l'incertitude, la réalité doit donc être connue.

L'**imprécision** d'une information est caractérisée par le contenu de l'information. Elle est relative à l'information ou à la source. Elle mesure donc un défaut quantitatif de connaissance. La réalité doit donc être connue ou estimée.

L'**incomplétude** est le manque d'information apporté par la source. L'incomplétude de l'information peut être la cause de l'incertitude et de l'imprécision. Elle peut se mesurer par la différence de la quantité d'information réellement fournie par la source et de la quantité d'information que la source doit fournir (en cas de bon fonctionnement ou pour répondre à un problème posé). La quantité d'information est cependant difficile à quantifier. Une des

premières mesures de la quantité d'information a été introduite par C.E. Shannon [50], connue sous le nom d'entropie de Shannon.

Le **conflit** caractérise deux ou plusieurs informations conduisant à des interprétations contradictoires et donc incompatibles. Les situations conflictuelles sont fréquentes dans les problèmes de fusion, et posent toujours des problèmes difficiles à résoudre. Tout d'abord, la détection des conflits n'est pas forcément facile. Ils peuvent facilement être confondus avec d'autres types d'imperfection, ou même avec la complémentarité des sources. Ensuite, leur identification et leur typologie est une question qui se pose souvent, mais de manière différente suivant leur domaine. Enfin, leur résolution peut prendre différentes formes. Elle peut reposer sur l'élimination de sources non fiables, sur la prise en compte d'informations supplémentaires, etc. Dans certains cas, il peut être préférable de retarder la combinaison et d'attendre d'autres informations susceptibles de lever les conflits, ou même de ne pas fusionner du tout.

L'**ambiguïté** d'une information est le fait que celle-ci entraîne deux ou plus interprétations. L'ambiguïté peut provenir d'une autre imperfection de l'information (incertitude, imprécision, conflit, ...), mais pas nécessairement. Par exemple, la description d'une cible radar (par sa signature) ne permet pas toujours de distinguer cette cible d'une autre, lorsque les signatures sont trop proches, c'est le cas d'une signature imprécise. La fusion d'informations apportées par une autre source peut permettre de lever cette ambiguïté.

D'autres caractéristiques de l'information sont plus positives, et sont exploitées pour limiter les imperfections :

La **redondance** d'informations ou de sources est le fait d'avoir plusieurs fois la même information. La fusion s'appuie sur la redondance des sources pour confirmer une information. Par exemple l'observation d'un même objet par différentes sources peut permettre de situer l'objet avec précision et de le représenter dans un espace de dimension supérieure. Idéalement, la redondance est exploitée pour réduire les incertitudes et les imprécisions.

La **complémentarité** : Des sources ou des informations sont complémentaires si elles sont de nature différente et permettent de préciser la réponse du système. La complémentarité est exploitée directement dans le processus de fusion pour avoir une information globale plus complète et pour lever les ambiguïtés.

#### IV.4. Les méthodes de fusion

Les principales méthodes de fusion d'informations sont issues essentiellement de deux cadres de modélisation, les probabilités et les approches floues. On trouve d'une part la théorie des possibilités issue de la théorie des sous-ensembles flous, la théorie de croyance, d'autre part on trouve l'approche bayésienne issue des probabilités. Le principe du vote, est l'un des méthodes de fusion de haut niveau les plus simple à mettre en œuvre. L'ensemble de ces méthodes sera étudié ci-dessous.

##### IV.4.1. Méthode de vote

La méthode de vote est particulièrement adaptée à la fusion des décisions. Elle repose sur la combinaison des décisions fournies par les classifieurs sur les classes de la base de test [51,33,52].

###### - *Modélisation*

A chaque source  $I$  est associé une fonction indicatrice :

$$M_k^j(x) = \begin{cases} 1 & \text{if } I_j(x) = k \\ 0 & \text{elseif} \end{cases} \quad IV.1$$

Notons que  $I_j(x) = k$  le fait que la source  $I_j$  décide  $d_k$ , par exemple attribue la classe  $C_k$  à l'observation  $x$ .

###### - *Estimation*

$\alpha_{jk}$  fiabilité d'une source pour une classe donnée. Elle peut être estimée à partir des matrices de confusion de chaque classifieur.

$$\sum_{j=1}^N \alpha_j = 1 \quad IV.2$$

###### - *Combinaison*

La combinaison des sources s'écrit par :

$$M_k(x) = \sum_{j=1}^N \alpha_{jk} M_k^j(x) \quad IV.3$$

###### - *Décision*

La décision finale du vote correspond à la classe  $k$  la plus votée par les classifieurs individuels :

$$D = \operatorname{argmax}_{k=1\dots c} M_k(x) \quad \text{IV.4}$$

Cependant cette règle simple n'admet pas toujours de solutions dans l'ensemble des décisions. En effet, par exemple si le nombre de sources  $N$  est paire et que  $\frac{N}{2}$  sources décident  $C_1$  et  $\frac{N}{2}$  autres sources disent  $C_2$ , ou encore dans le cas où chaque source affecte à  $x$  une classe différente. Afin de pallier à ce problème, une version améliorée désignée par le vote majoritaire a été introduite, s'écrit par :

$$D = \begin{cases} k & \text{if } \max_k M_k(x) > \frac{N}{2} \\ D_{N+1} & \text{elseif} \end{cases} \quad \text{IV.5}$$

Où  $D_{N+1}$  représente l'incertitude totale liées aux classifieurs.

Les avantages de l'approche par vote sont doubles, elle est très simple et naturelle et elle ne nécessite pas de connaissances a priori. La règle de base peut cependant être modifiée de façon à intégrer les imperfections des données sous forme de fiabilité.

Cette méthode a permis de montrer théoriquement que la fusion de classifieurs peut donner sous certaines hypothèses de meilleures performances que chaque classifieur pris individuellement. Nous avons également remarqué qu'il est plus intéressant pour cette approche de considérer un nombre impair de classifieurs qu'un nombre pair. En pratique, il est donc plus intéressant de ne considérer qu'un nombre impair de sources pour accroître les performances.

De nombreuses études ont comparées le vote majoritaire dans le cas de la classification ou de la reconnaissance [53]. Même si cette règle reste simple, elle donne souvent des résultats comparables aux approches plus complexes.

#### IV.4.2. Théorie de l'évidence

La théorie de l'évidence encore connue sous le nom théorie de Dempster-Shafer ou théorie des fonctions de croyance, a été proposée par Dempster en 1967 [54] puis formulée mathématiquement par Shafer [55]. Cette théorie a été reprise en 1990 par Smets [56] sous le nom de modèle de croyance transférable. La théorie de l'évidence permet la modélisation des données qui présentent des imprécisions aussi bien que des incertitudes.

### IV.4.2.1. Bases mathématiques

#### - Cadre de discernement

Un cadre de discernement est l'ensemble de toutes les hypothèses possibles du problème étudié. Notons  $\Omega$  cet ensemble et supposons qu'il est composé de  $N$  hypothèses différentes.

$$\Omega = \{H_1, H_2, \dots, H_N\} \quad IV.6$$

Une seule hypothèse de cet ensemble est considérée vraie. L'ensemble des parties (ou power set en anglais) de l'ensemble de discernement est l'ensemble qui contient toutes les combinaisons possibles des hypothèses. L'ensemble des parties se définit comme suit :

$$2^\Omega = \{A/A \subseteq \Omega\} = \{\emptyset, \{H_1\}, \{H_2\}, \dots, \{H_1, H_2\}, \{H_1, H_3\}, \dots, \{H_1, \dots, H_N\}\} \quad IV.7$$

"A" peut-être une hypothèse simple ou une classe des hypothèses ou même un ensemble vide.

#### - Fonction de masses

Généralement une fonction de masse, également connue sous le nom de « masse de croyance » ou bpa (Basic Probability Assignment), est notée tout simplement  $m$ .

Cette masse est calculée pour tout élément de l'ensemble  $2^\Omega$  et se définit comme suit :

$$\forall A \in 2^\Omega, m(A) \in [0,1]$$

$$\sum_{A \in 2^\Omega} m(A) = 1 \quad IV.8$$

Un élément qui possède une masse non nulle est dit élément focal.

#### - Transformations des masses

A partir de la fonction de masse  $m$  on peut déduire d'autres fonctions comme la crédibilité et la plausibilité pour mieux représenter la connaissance.

##### a- Crédibilité :

La crédibilité (*belief*) désignée par *bel* mesure la croyance totale qui peut être attribuée à un élément donné. Elle se définit par :

$$\forall A \in 2^\Omega, \quad bel(A) = \sum_{B \subseteq A, B \neq \emptyset} m(B) \quad IV.9$$

**b- Plausibilité :**

La plausibilité (*plausibility*) désignée par  $pl$  mesure la croyance maximale qui peut être potentiellement attribuée à un élément donné. Elle se définit par :

$$\forall A \in 2^\Omega, \quad Pl(A) = \sum_{A \cap B \neq \emptyset} m(B) \quad IV.10$$

**- Exemple :**

Soit un ensemble formé de trois hypothèses concernant un problème donné  $\Omega = \{H_1, H_2, H_3\}$ .

L'ensemble des parties de  $\Omega$  est :

$$2^\Omega = \{\emptyset, \{H_1\}, \{H_2\}, \{H_3\}, \{H_1, H_2\}, \{H_1, H_3\}, \{H_2, H_3\}, \{H_1, H_2, H_3\}\}$$

La crédibilité et la plausibilité du sous-ensemble  $A = \{H_1, H_2\}$  se calculent comme suit :

$$bel(A) = m(H_1) + m(H_2) + m(\{H_1, H_2\})$$

$$\begin{aligned} Pl(A) &= m(H_1) + m(H_2) + m(\{H_1, H_2\}) + m(\{H_1, H_3\}) + m(\{H_2, H_3\}) + m(\{H_1, H_2, H_3\}) \\ &= 1 - m(H_3) \end{aligned}$$

L'intervalle  $[bel(A), Pl(A)]$  est appelé intervalle de confiance de  $A$ .

**IV.4.2.2 Modélisation des masses**

Une fois que l'on a défini l'ensemble de discernement et l'ensemble des parties, l'étape suivante est la modélisation des masses qui consiste à allouer des masses de croyance aux différents sous-ensembles de  $2^\Omega$ . La modélisation des masses est une étape difficile et il n'existe pas de méthodes de modélisation universelles pouvant s'appliquer à tous les problèmes et toutes les applications. Il existe des études où les auteurs définissent des modélisations de masses spécifiques aux applications traitées. Les informations qui sont utilisées pour modéliser les masses sont souvent des informations a priori et des observations sur les hypothèses.

**IV.4.2.3. Combinaison**

Nous supposons avoir  $N$  sources différentes notées :  $S_1, S_2, \dots, S_N$ . Les masses qui proviennent de chaque source attribuée à un élément  $A$  de l'ensemble du discernement sont notées respectivement :  $m_1(A), m_2(A), \dots, m_N(A)$ .

**- Loi orthogonale :**

La loi orthogonale ou la loi de combinaison de Dempster est la normalisation de la loi conjonctive.

Soit deux sources d'informations  $(S_1, S_2)$ , avec  $A$  un élément de l'ensemble des parties :

$$\forall A \in 2^\Omega, \quad m(A) = \frac{1}{1-k} \sum_{B_1 \cap B_2 = A} m_1(B_1)m_2(B_2) \quad IV.11$$

Avec  $m(\emptyset) = 0$  et:

$$k = \sum_{B_1 \cap B_2 = \emptyset} m_1(B_1)m_2(B_2) \quad IV.12$$

$k$  est un terme de normalisation de la loi connu aussi comme terme de conflit. Cette loi possède les propriétés de commutativité et associativité. Dans le cas de  $N$  sources différentes elle s'écrit :

$$\forall A \in 2^\Omega, \quad m(A) = \frac{1}{1-k} \sum_{B_1 \cap B_2 \cap \dots \cap B_N = A} \left( \prod_{j=1}^N m_j(B_j) \right) \quad IV.13$$

Avec:

$$\forall A \in 2^\Omega, \quad k = \sum_{B_1 \cap B_2 \cap \dots \cap B_N = \emptyset} \left( \prod_{j=1}^N m_j(B_j) \right) \quad IV.14$$

**IV.4.2.4. Décision**

La dernière étape de la fusion est la décision. C'est l'étape où l'on choisit une seule hypothèse parmi les hypothèses de l'ensemble de discernement  $\Omega$  après la fusion des connaissances apportées par les différentes sources. Dans le cas bayésien, le maximum a posteriori est la règle de décision alors que la théorie de l'évidence offre un ensemble de règles de décision différentes qui ne donnent pas forcément le même résultat :

**a- Maximum de crédibilité**

La crédibilité ( $Bel$ ) s'interprète comme la borne inférieure de la probabilité. La décision fondée sur le maximum de crédibilité est donc une décision pessimiste qu'on exprime comme suit :

$$Dec = \arg \max_{H \in \Omega} bel(H), \quad H \in \Omega \quad IV.15$$

$Bel$  est la fonction de crédibilité associée à la masse de l'hypothèse  $H \in \Omega$  correspondante.

**b- Maximum de plausibilité**

La plausibilité ( $Pl$ ) s'interprète comme la borne supérieure de la probabilité. La décision de maximum de plausibilité est alors une décision optimiste.

$$Dec = \arg \max Pl(H), \quad H \in \Omega \quad IV.16$$

$Pl$  désigne la fonction de plausibilité associée à la masse de l'hypothèse  $H$ .

**IV.4.3. Théorie des possibilités**

La théorie des possibilités est induite par la théorie des ensembles flous introduite par Zadeh [57]. Cette théorie été essentiellement développée par Dubois et Prade en France [58]. Elle se repose sur la fonction de distribution de possibilités qui permet de traiter et modéliser à la fois l'incertitude et l'imprécision. Cette théorie était l'objet de plusieurs travaux scientifiques [59-60].

**IV.4.3.1. Fondements de la théorie des possibilités****- Univers du discours :**

Soit  $\Omega$  l'univers du discours qui présente l'ensemble de toutes les hypothèses possibles modélisant le problème de fusion.

$$\Omega = \{\omega_1, \omega_2, \dots, \omega_n\} \quad IV.17$$

**- Distribution des possibilités :**

La distribution de possibilités notée  $\pi$  est la fonction fondamentale de la théorie des possibilités. Elle associe à chaque hypothèse de  $\Omega$  un degré de possibilité. La distribution de possibilités est une fonction de  $\omega$  dans  $[0,1]$  qui vérifie :

$$\sup_{\omega \in \Omega} \{\pi(\omega)\} = 1 \quad IV.18$$

En d'autres termes, il existe au moins un événement de  $\Omega$  tel que son degré de possibilité est égal à 1. Avec  $\pi(\omega)$  présente le degré de possibilité pour que l'observation  $x$  soit égale à  $\omega$  sachant que :

- Si  $\pi(\omega) = 0$ , cela indique qu'il est impossible que  $x$  soit égale à  $\omega$ .
- Si  $\pi(\omega) = 1$ , cela indique que rien n'empêche que  $x$  vaille  $\omega$ .

Une information précise est modélisée par la distribution de possibilités comme l'indique l'expression suivante :

$$\exists! \omega_0 \in \Omega \quad \text{tells que} \quad \begin{cases} \pi(\omega_0) = 1 \\ \pi(\omega) = 0 \quad \forall \omega \neq \omega_0 \end{cases} \quad IV.19$$

Cependant, on est dans le cas de l'ignorance totale lorsque :

$$\forall \omega \in \Omega, \pi(\omega) = 1 \quad IV.20$$

- **Mesure de possibilité :**

Une mesure de possibilité notée  $\Pi$  est une fonction de  $2^\Omega$  (l'ensemble des parties de  $\Omega$ ) dans  $[0,1]$  qui vérifie le système d'équations suivant :

$$\begin{cases} \Pi(\emptyset) = 0 \\ \Pi(\Omega) = 1 \\ \forall A \in 2^\Omega, \Pi(A) = \sup \{\pi(x), x \in A\} \end{cases} \quad IV.21$$

Plus la valeur de possibilité de l'évènement est proche de 1 plus sa réalisation est possible. Si la possibilité d'un évènement est nulle cela signifie que cet évènement est impossible. La mesure et la distribution de possibilité permettent de quantifier et de modéliser l'imprécision de l'information.

- **Mesure de nécessité :**

Une mesure de nécessité notée  $N$  est une fonction de  $2^\Omega$  dans  $[0,1]$  qui vérifie les équations suivantes :

$$\begin{cases} N(\emptyset) = 0 \\ N(\Omega) = 1 \\ \forall A \in 2^\Omega, N(A) = \inf \{1 - \pi(x), x \notin A\} \end{cases} \quad IV.22$$

La probabilité de réalisation d'un évènement  $A$  est délimitée par la mesure de nécessité  $N(A)$  et la mesure de possibilité  $\Pi(A)$ , (i.e.  $N(A) \leq Pr(A) \leq \Pi(A)$ ).

#### IV.4.3.2. Fusion par la théorie des possibilités

- **Modélisation**


La première tâche de cette étape de fusion consiste à déterminer les différentes hypothèses qui constituent l'univers du discours  $\Omega$ . Supposons que nous disposons de  $m$  sources, on note par  $S_j$  la source numéro  $j$  avec  $j \in \{1, \dots, m\}$ .

On note par  $\pi_x^j(\omega_i)$  le degré de possibilité pour que la décision numéro  $i$  soit valide pour l'observation  $x$  selon la source  $S_j$ .

- **Estimation**

La construction d'une distribution de possibilités doit se faire en fonction de la connaissance disponible qui peut se présenter sous différentes formes (données capteurs, avis d'experts, ...) et donc il n'y a pas de forme générale.

La distribution de possibilités peut prendre plusieurs formes. Nous citons les plus connues qui sont la forme triangulaire, la forme trapézoïdale et la forme gaussienne.



**Figure IV.1** les formes des fonctions d'appartenance.

Par ailleurs, plusieurs méthodes ont été adoptées pour déterminer la distribution de possibilités comme :

- 1- Les transformations histogrammes-possibilités [61, 62].
- 2- Méthode basée sur l'histogramme de niveaux de gris [63,64].
- 3- Les approches psychométriques [65].

#### - Combinaison

L'un des intérêts majeurs de la fusion par la théorie des possibilités est la grande variété d'opérateurs de fusion permettant la combinaison des distributions de possibilités. Il est courant de considérer les opérateurs conjonctifs ou disjonctifs :

**a- Opérateurs conjonctifs** : Ils combinent l'information à la façon d'un "ET logique" (conjonction). De cette façon le résultat sera proche de 1 si et seulement si toutes les valeurs à combiner sont proches de 1. Parmi ces opérateurs les normes triangulaires ou t-norme sont les plus employées.

Voici quelques t-normes pour deux sources  $S_1$  et  $S_2$ .

- T-norm de Zadeh:

$$\pi(\omega) = \min(\pi^{S_1}(\omega), \pi^{S_2}(\omega)) \quad IV.23$$

- T-norm Probabiliste:

$$\pi(\omega) = \pi^{S_1}(\omega) * \pi^{S_2}(\omega) \quad IV.24$$

- T-norm de Lukasiewicz:

$$\pi(\omega) = \max(0, \pi^{S_1}(\omega) + \pi^{S_2}(\omega) - 1) \quad IV.25$$

Les opérateurs conjonctifs sont généralement utilisés lorsque les sources sont concordantes et fiables.

**b- Opérateurs disjonctifs** : Ils combinent l'information à la façon du “*OU logique*” (disjonction). La valeur du résultat de la combinaison sera grande dès lors qu'une des valeurs combinées le sera. Les principaux opérateurs disjonctifs sont les conormes triangulaires ou t-conormes. Voici quelques t-conormes appliquées pour deux sources  $S_1$  et  $S_2$  :

- T-conorm de Zadeh:

$$\pi(\omega) = \max(\pi^{S_1}(\omega), \pi^{S_2}(\omega)) \quad IV.26$$

- T-conorm Probabiliste:

$$\pi(\omega) = \pi^{S_1}(\omega) + \pi^{S_2}(\omega) - \pi^{S_1}(\omega) * \pi^{S_2}(\omega) \quad IV.27$$

- T-conorm de Lukasiewicz:

$$\pi(\omega) = \min(\pi^{S_1}(\omega) + \pi^{S_2}(\omega) - 1, 1) \quad IV.28$$

Les opérateurs disjonctifs sont généralement utilisés lorsque les sources sont discordantes et non fiables.

Il existe d'autres catégories d'opérateurs de combinaisons telles que : les opérateurs de moyenne, les intégrales floues... etc [66, 67].

#### - *Décision*

Une fois les informations issues des sources combinées, la décision se fait par la maximisation de la possibilité ou bien par de la nécessité. Ainsi, on choisit la décision  $d_k$  si :

$$\pi^k(x) = \max(\pi^i(x), i = 1 \dots n) \quad IV.29$$

### IV.5. Conclusion

Dans ce chapitre, nous avons présenté les notions générales de la fusion et les différentes théories utilisées à cet effet, notamment la théorie de l'incertitude. Dans le chapitre suivant, nous présentons toutes les contributions apportées dans ce mémoire, et nous évaluons les performances des systèmes proposés.

*Chapitre V*

**Résultats et discussion**

## V.1 Introduction

Le présent chapitre est constitué de trois parties, la première consiste à expliquer les différentes étapes à suivre pour faire la classification d'une image, ensuite on présente dans la deuxième partie les résultats obtenus et les diverses discussions et solutions proposées pour certains problèmes rencontrés, enfin la conclusion de ce chapitre est développée dans la troisième partie.

## V.2 Explications des étapes suivies :

### V.2.1 Transformée en ondelette

On a appliqué la transformée en ondelette (DWT) dans la première étape de notre travail et nous avons l'adopté comme une méthode d'extraction des informations et des caractéristiques dans les images texturées. C'est un outil mathématique utilisé dans la décomposition des signaux bidimensionnelle (image numérique) à différents niveaux de résolution. Les coefficients (détails) de la transformée en ondelettes discrète sont calculés par l'utilisation d'une série de filtre passe bas noter (L) produit des sous-bandes de basse fréquence, filtre passe haut noter (H) qui produit des sous-bandes de hautes fréquences, et un sous échantillonnage des lignes et colonnes. Le processus de décomposition par les ondelettes est appliqué sur une image de niveau  $j$  pour donner une image de basse fréquence (approximation) et trois images des hautes et basses fréquences (les détails dans les directions verticales, horizontales et diagonales). En passant d'un niveau  $j$  à  $j + 1$  la taille de l'image approximation et des images de détails (coefficients) est réduite de 4. La recombinaison permet de retrouver l'image originale à partir de l'image approximation et des images de détails [68].

Différents tests ont été effectués sur une série de tailles de fenêtres allant de  $5 \times 5$  à  $25 \times 25$ . Le taux de classification le plus élevé était atteint pour une fenêtre de  $11 \times 11$  de dimension.



### V.2.1.1 Calcul des paramètres de texture

A partir de chaque sous-bande (image) des paramètres sont calculés comme caractéristiques de texture, l'une de ces paramètres les plus utilisés est la mesure d'énergie, Il a été utilisé avec succès pour la classification et la segmentation des textures, l'expression de l'énergie exprimée sous la forme suivante :

$$E = \sum_{i=1} \sum_{j=1} (N(i, j))^2 \quad (4.1)$$

Le deuxième paramètre utilisé est la moyenne, elle s'exprime sous la forme suivante :

$$M = \frac{1}{N} \sum_{i=1} \sum_{j=1} |I(i, j)| \quad (4.2)$$

Où N est le nombre de pixels nommés par les indices (i, j)

### V.2.1.2 Choix d'ondelette

Dans notre travail nous avons utilisée l'ondelette bior1.1 de la famille Biorthogonales, cette ondelette a l'avantage de la symétrie, cette symétrie du traitement semble très souhaitable, et elle représente certaine souplesse par rapport aux autres ondelettes [69].

## V.2.2 Classification par réseau de neurone

Dans la deuxième étape de notre travail, on a utilisé un algorithme de classification, on a choisi le classifieur « le réseau de neurone ».

Les réseaux de neurones sont inspirés de la neurobiologie afin de résoudre les problèmes de classification, ils se manifestent par la capacité d'apprentissage qui permet de tenir compte de nouvelles contraintes ou de nouvelles données du monde extérieur. Ils sont considérés comme un ensemble d'entités élémentaires qui travaillent simultanément. Le parallélisme permet une rapidité de calcul supérieure mais exige de poser différemment les problèmes à résoudre.

La capacité de généralisation d'un réseau de neurones est sa capacité à donner une réponse satisfaisante à une entrée qui ne fait partie de son ensemble d'apprentissage.

Parmi les différents types de réseau de neurones on a choisi le perceptron multicouche (MLP), qui est un réseau à apprentissage supervisée, avec quatorze neurones dans la couche d'entrée (un neurone pour chaque paramètre) et un neurone dans la couche de sortie qui offrir le score obtenu de chaque fenêtre. Pour les fonctions d'activation du réseau on a choisi la fonction sigmoïde.

Pour la phase d'apprentissage des réseaux de neurones, dans notre travail, nous avons utilisé des images de 320 x 320, dont 6400 données, pour chaque image, sont choisies au hasard pour faire l'apprentissage, ce qui représente environ 6,25% du nombre total de données.

Le vecteur caractéristique de chaque fenêtre est considéré comme entrée du réseau neurone, et le score fournie par les réseaux est affecter au pixel central.

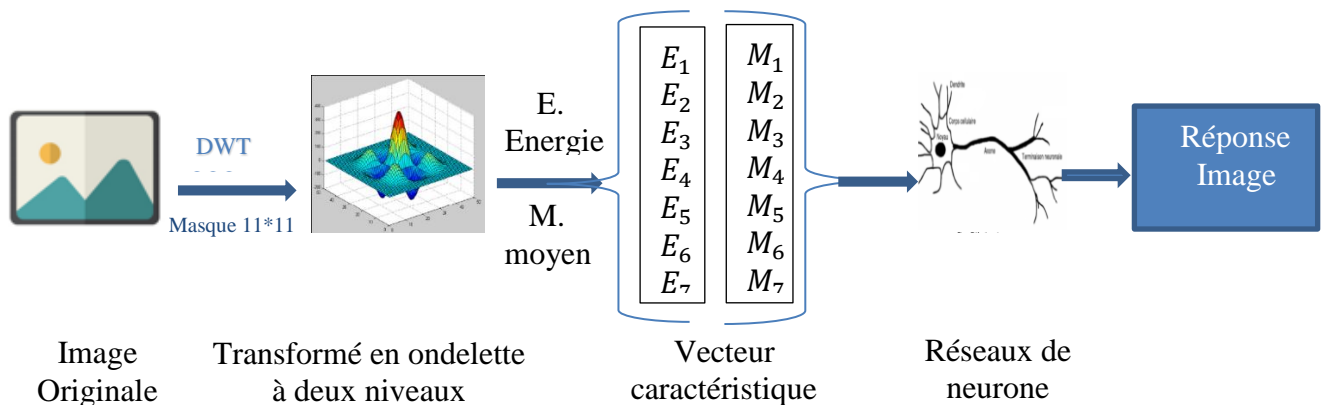


Figure V.3 Segmentation d'images texturées par DWT.

### V.2.3 Fusion

Dans la troisième étape de notre travaille on a utilisé la technique de la fusion de donnée, nous avons utilisé une fenêtre glissante pour faire un balayage d'image, la classe de cette fenêtre est affecté à son pixel central, ce dernier est contribué à la classification du pixel central de la fenêtre voisine, on obtient un résultat de segmentation par la combinaison de ces résultats des scores de différente fenêtre qui incluent ce pixel central.

Parmi les plusieurs méthodes de fusion on a choisi la théorie de fonction de croyance (déjà détaillé en chapitre IV).

### V.2.3.1 Modélisation des masses

Dans nos images nous avons 2 différentes textures ce qui implique qu'on a deux classes, donc l'ensemble de discernement est fourni de deux hypothèses (classes) :

$$\Omega = \{ c_1, c_2 \} \quad (V.3)$$

$C_1$  est l'hypothèse qu'un pixel appartient à la classe une, alors que  $C_2$  est l'hypothèse qu'un pixel appartient à la classe deux. L'ensemble des parties est alors :

$$2^\Omega = \{ c_1, c_2, \{ c_{1,2} \} \} \quad (V.4)$$

$\{ c_{1,2} \}$  est la classe de l'incertitude sur l'appartenance d'un pixel. Selon la valeur de niveau de gris du pixel nous ne pouvons décider si ce pixel appartient à la classe une ou bien à la classe deux.

### V.2.3.2 Combinaison

Nous avons utilisé une fenêtre de taille 3\*3 de façon que chaque pixel central est entouré par 8 pixels voisins. Ces neuf pixels sont considérés comme une source d'information qui apporte des reconnaissances sur les trois éléments d'ensemble de parties, notée  $S_9, S_{10}, S_{11}, S_{16}, S_{17}, S_{18}, S_{24}, S_{25}, S_{26}$ . Les masses qui proviennent de chaque source attribuée à l'élément  $C_1$  de l'ensemble du discernement sont notées respectivement  $m_9(c_1), m_{10}(c_1), m_{11}(c_1), m_{16}(c_1), m_{17}(c_1), m_{18}(c_1), m_{25}(c_1), m_{24}(c_1), m_{26}(c_1)$ , et les masses attribuées à l'élément  $C_2$  de l'ensemble du discernement sont notées respectivement  $m_9(c_2), m_{10}(c_2), m_{11}(c_2), m_{16}(c_2), m_{17}(c_2), m_{18}(c_2), m_{25}(c_2), m_{24}(c_2), m_{26}(c_2)$ , les masses attribuées à l'élément  $C_{1,2}$  de l'ensemble du discernement sont notées respectivement  $m_9(c_{1,2}), m_{10}(c_{1,2}), m_{11}(c_{1,2}), m_{16}(c_{1,2}), m_{17}(c_{1,2}), m_{18}(c_{1,2}), m_{25}(c_{1,2}), m_{24}(c_{1,2}), m_{26}(c_{1,2})$ , (voir figure V.3).

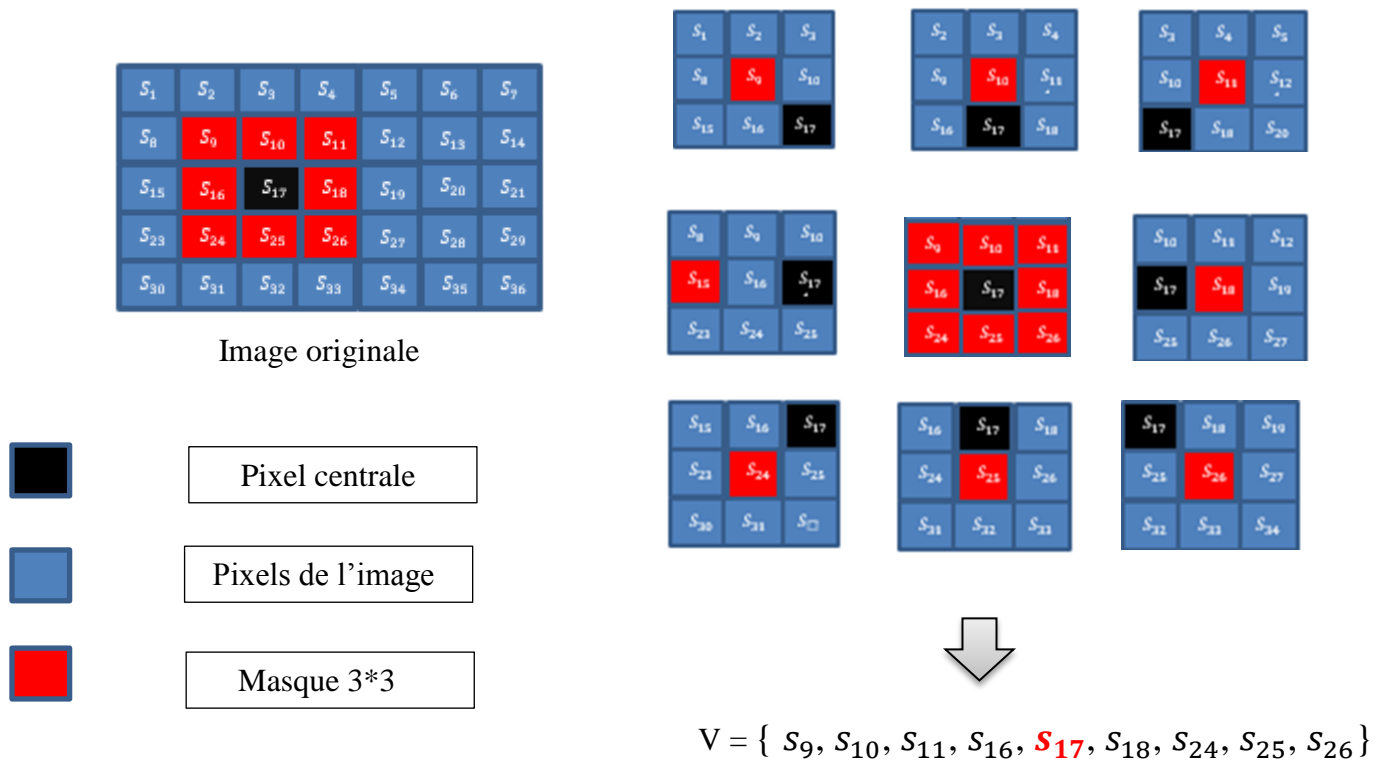


Figure V.4 Composition du vecteur de fusion.

On a applique la loi orthogonale de Dempster (équation 3.13), afin de fusionner les informations données par les neuf sources (pixels) pour créer une nouvelle masse globale sur l'ensemble de discernement, les masses globales pour les pixels sont alors définies comme :

$$m(c_1), m(c_2), m\{c_{1,2}\}$$

### V.2.3.3 Décision

Après la définition des masses globales, on a calculé la crédibilité (équation 3.17) et la plausibilité (3.18). La décision est faite en utilisant la règle de maximum de plausibilité.

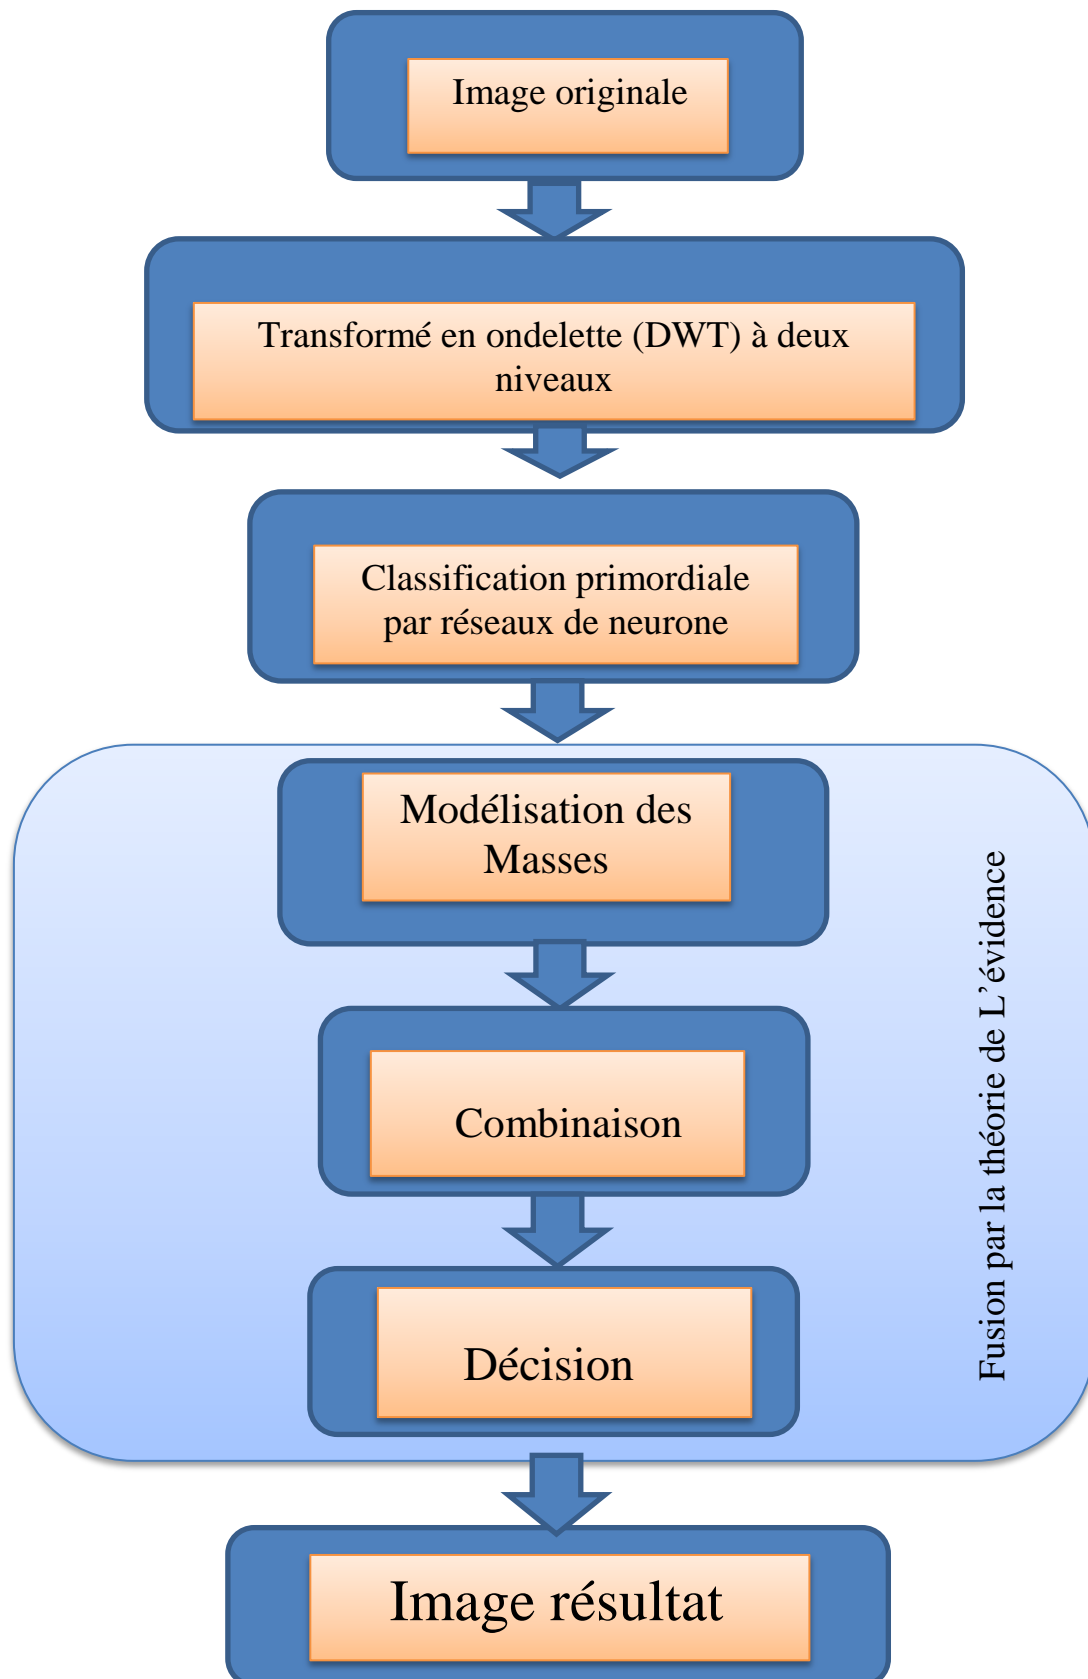
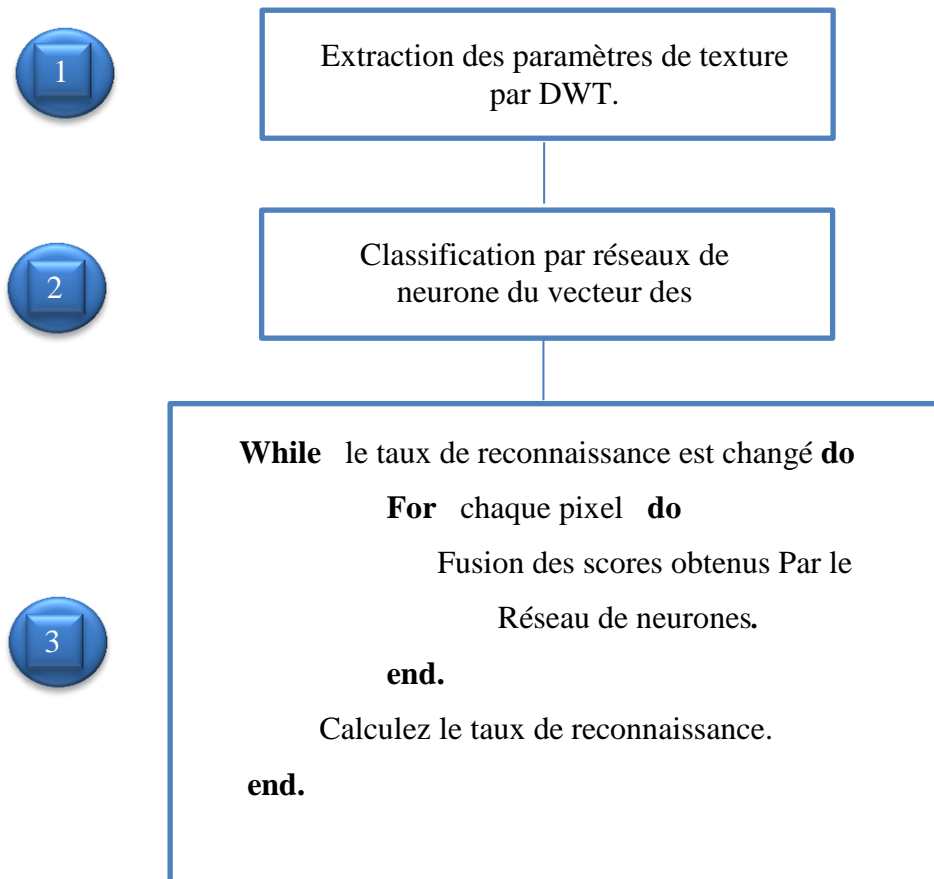


Figure V.5 Organigramme totale de la classification

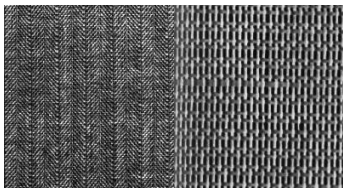

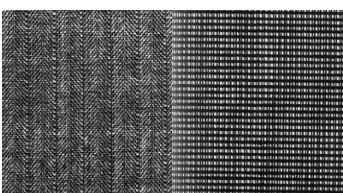

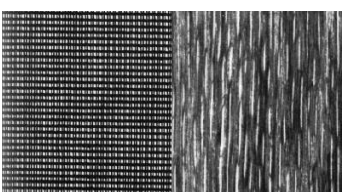

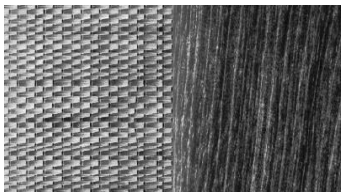

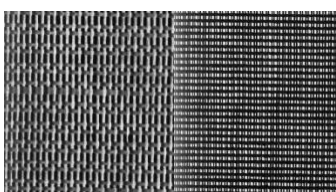

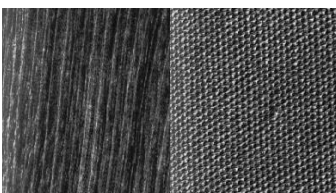
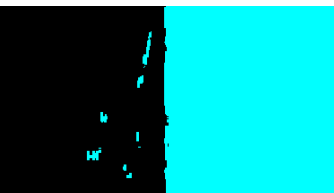
L'algorithme de classification est le suivant :




### V.3 Présentation des résultats

Pour évaluer les performances d'algorithmes proposés, on a utilisé un ensemble des images avec des différents textures à partir des bases de données Brodatz comme indique le tableau1 (image originale) chaque image contient deux différent textures.

- La première colonne contient les images originales.
- La deuxième colonne représente les résultats de la classification par la théorie de l'évidence

Image original	Image classifiee
	
	
	
	
	
	



**Tableau V.1** : Résultats expérimentaux.

Comme on le voit dans la deuxième colonne de la tableau 1, les différentes textures sont bien discriminées, et nous avons obtenus des meilleurs résultats.

On remarque aussi que les résultats de la classification par la DWT est plus précis dans les zones à l'intérieur des classes, il y a quelque erreur par ce que les textures sont plus ressemble, donc la plupart des erreurs de segmentation se situent aux régions proches des frontières des différentes classes, parce que dans ces zones la fenêtre glissante contient deux différentes textures.

Et pour améliorer encore notre résultat nous allons essayer, comme futur travail, d'utiliser autres techniques d'extraction des paramètres de texture, comme le filtre de Gabor, et d'autre méthode de fusion afin de diminuer encore l'erreur de la classification.

#### **V.4 Application sur des images sonar**

Les images sonar ont souvent utiliser pour la détection, puis la classification d'objets posés sur le fond marin en zones côtières, ou enfouis dans le sédiment, et principalement, les mines sous-marines [70].

Dans les images sonar, nous nous sommes intéressés à l'exploitation des ombres produits par les différents objets reposant sur le fond marin. Cela permet l'identification et la Classification de ces objets en analysant la forme de leurs ombres correspondants.

La plupart des méthodes de détection et de classification à partir d'images sonar cherchent alors à isoler et à caractériser deux régions (classes) différentes sur les images : le fond et l'ombre de l'objet, La présence de ces éléments et leurs caractéristiques permettra de détecter, de localiser et, éventuellement, de classifier les objets présents dans le fond marin [71].

La figure V.5 représente quelques images sonores.



**Figure V.6** exemples d'image sonar.

Nous distinguons deux types d'ombres : les ombres produits par des objets manufacturés et celles produites par les rochers. Les ombres produites par des rocher sont caractérisées par leurs formes extrêmement variables, totalement aléatoires et qui n'ont en général, aucune caractéristique géométrique simple [70]. Les contours de ces ombres sont très chahutés et irréguliers. Par contre, les ombres produites par un objet manufacturé (pneu, épaves, ...), nous constatons que celle-ci est plutôt régulière et qu'elle peut être décrite avec des attributs géométriques simples (parallélogramme, polygone dont certains côtés peuvent être approchés par des arcs de cercle ou d'ellipse). Les contours de ces ombres sont eux aussi plutôt réguliers et lisses.

Notre méthode consiste à utiliser notre algorithme de fusion, vue précédemment, pour séparer le fond marin de l'ombre d'objet dans les images sonores. La même procédure suivie dans la segmentation des images texturé de la base de Brodatz est appliquée dans ce contexte. Pour la transformée en ondelette, le réseau de neurones et la théorie de l'évidence, les mêmes paramètres sont maintenus. Nous présentons deux images sonar réelles segmentées par l'approche proposé. La figure V.6 et figure V.7 présente obtient les résultats obtenus :



**Figure V.7** (À gauche) Image sonar : objet manufacturé (à droite) image sonar segmentée



**Figure V.8** (À gauche) Image sonar : Ombres d'un rocher et d'un objet manufacturé (à droite) image sonar segmentée.

Comme on le voit dans La figure V.6 et la figure V.7, le fond et l'ombre des objets sont bien discriminées dans les deux images sonores, alors on peut conclure que notre algorithme de fusion donne de bons résultats en segmentation d'image sonores.

### V.3 Conclusion

Dans ce chapitre nous avons utilisé une nouvelle méthode pour la classification des images texturé, basé sur la fusion de l'information.

On a commencé par l'extraction des caractéristiques de texture à l'aide de la transformée en ondelettes, après cela chaque vecteur estimé des caractéristiques de chaque pixel a été envoyé au réseau du neurone pour une classification primaire, et enfin on a fait la fusion des données.

Nous avons vu que la segmentation par l'analyse de texture avec l'approche proposée donne des bons résultats mais cette méthode nécessite une amélioration par l'addition des autres techniques d'extraction des caractéristiques, afin de diminuer encore l'erreur de la classification

## ***Conclusion Générale***

L'objectif de notre travail est faire une classification des images texturées par l'utilisation de la technique de fusion de l'information, afin d'obtenir des résultats corrects pour aider à la prise de décision.

Dans ce mémoire on a proposé une méthode de segmentation d'images texturées. Cette méthode est basée sur une phase d'extraction des paramètres de texture donc on calcul deux paramètres les plus utilisées pour la classification et la segmentation de texture (l'énergie et la moyenne), par la transformée en ondelette, dans notre travail on utilise ondelette biorthogonale (bior 1.1) car elle représente une certaine souplesse par rapport aux autres ondelettes, caractérisant d'une manière fiable les différentes régions texturées, ainsi qu'une phase de classification primaire des pixels de l'image à analyser par la méthode des réseaux de neurones (on travaillé avec le réseau de neurone multi couche), par l'utilisation d'un algorithme de classification ensuite une classification finale par la théorie de l'évidence qui permet la modélisation des données qui présentent des imprécisions aussi bien que des incertitudes pour cela on a utilisé une fenêtre glissante de taille  $3 \times 3$  pour faire un balayage de l'image tout ça pour minimiser au maximum l'erreur obtenus. La méthode a été testée sur des textures de l'album de Brodatz et images sonores. La segmentation par l'analyse de texture avec l'approche proposée donne des bons résultats, mais cette méthode nécessite encore des améliorations, notamment dans les régions proches des frontières des différentes classes.

Alors comme perspective nous suggérons de poursuivre l'étude dans ce sens pour améliorer encore plus les résultats obtenues, en utilisant d'autres techniques d'extraction des caractéristiques, comme le filtre de Gabor ... etc, et d'autres techniques de fusion comme la théorie des possibilités, la fusion bayésienne...etc.

## Références

[1] thèse BELMERABET Sarah, BARDJAK Nawal « Segmentation d'image ». 2016/2017

[2] Segmentation d'images texturées par transformée en ondelettes et classification C-moyenne floue. Sahbani Mahersia Hela , Hamrouni Kamel

Ecole Nationale d'Ingénieurs de Tunis (ENIT)

BP-37 le Belvédère 1004 Tunis, Tunisie

[3] M.Sandeli, " traitement d'images par des approches bio-inspirées application à la segmentation d'images ", Mémoire Magister en informatique, université Constantine 2. 2014

[4] André MARION, " Introduction aux techniques de traitement d'images ", Edition : EYROLLES, Paris, 1987.

[5] R. HAROUN- S. A. BOUHRICHE, " Séparation des chromosomes se touchant ou se chevauchant à partir de Meta phases ", mémoire d'ingénieur d'état en Electronique, ENP-Promotion 2001-2002.

[6] Jean FRUITET, " Outils et méthodes pour le traitement des images par ordinateur ",

URL: [http://etudiant.univ-mev.fr/~fruitet/Trait\\_image/an\\_image.html](http://etudiant.univ-mev.fr/~fruitet/Trait_image/an_image.html)

[7] C. BOUDRY, " Amélioration des images par filtrage ", URFIST de Paris, 2100-2002

URL: <http://www.ecr.jussien.fr/urfist/image-numérique.htm>

[8] J-P. COCQUEREZ, " Analyse d'image : Filtrage et segmentation ", Edition : MASSON, 1995.

[9] S. DOUMANDJI- Y. BOULFANI, " Système de vision par ordinateur ", Séminaire, ENP 2002-2003

[10] H.BENHIDOUR, " Système de classification des chromosomes par réseau de neurones ", mémoire d'ingénieur d'état en informatique, option : Systèmes Informatiques, INI, Promotion 2000-2001.

[11] O. D'hondt, " Analyse spatiale de texture non stationnaire dans les images SAR ", Thèse doctorat, Université de Rennes I, 2006.

[12] S. Mavromatis, "Analyse de texture et visualisation scientifique", Thèse Doctorat, Université de la Méditerranée, 2001.

- [13] GADA Saliha, " Décomposition Modale Empirique : Application à l'analyse de la texture " Mémoire de magister, Université Mouloud Mammeri de Tizi-Ouzou, 2013.
- [14] K. Albeau, " Analyse à grande échelle des textures des séquences protéiques via l'approche Hydrophobic Cluster Analysis (HCA) ", Thèse de Doctorat, Ecole Pratique Des Hautes Etudes Université, Versailles Saint-Quentin- En-Yvelines, 2005.
- [15] O.Hibon,"Analyse d'image : caractérisation de textures d'images de gels lactés". Rapport de stage INRA, Université de Nantes, 2010.
- [16] Z. Haliche, "Segmentation d'images texturées en niveau de gris à base de la matrice Aura", Mémoire de Magister, Université Mouloud Mammeri, Tizi Ouzou 2010.
- [17] Isabelle Claude, " Caractérisation et segmentation de textures sur la base de modèles autorégressifs à support spatial adapté ", Thèse de doctorat en Sûreté des systèmes, Ecole doctorale Sciences pour l'Ingénieur, Troyes France, 1997.
- [18] R..M..Haralick, K.Shanmugamand,I.Dinstein, "Textural features for image classification. IEEE Transaction on System", Man and cybernetics. Vol. SMC -3, No.6, pp.610-621. November 1973.
- [19] L. Risser. "Analyse multi-échelles des textures". Rapport DEA Informatique pour l'Image et Langage, Spécialité : Analyse d'Image, Université Paul Sabatier, Toulouse ,2003.
- [20] A. Hafiane. "Caractérisation de textures et segmentation pour la recherche par contenu", Thèse de Doctorat, Université de Paris Sud XI, 2005.
- [21] J.S. Weszka, C.R. Dyer, and A. Rosenfeld. "A comparative study of texture measures for terrain classification". IEEE Trans. On Sys., Man and Cyber., 6(4):269–285, April 1976.
- [22] Karthanassi, V., Iossifidis, C. and Rokos, D. " A texture based classification method for Classifying build areas according to their density". International Journal of Remote Sensing, Vol. 21, No. 9, pages 1807-1823, 2000.
- [23] L. Paulhac. "Outils et méthodes d'analyse d'images 3D texturées : Application à la segmentation des images échographiques". Thèse de Doctorat, Université François Rabelais deTours ,2009.

[24] O., Regniers, " Méthodes d'analyse de texture pour la cartographie d'occupations du sol par télédétection très haute résolution : Application à la forêt, la vigne et les parcs ostréicoles", Thèse de doctorat, Signal and Image processing, Université de Bordeaux Décembre 2014.

[25] ZITOUNI Abdelkader: 'Image Processing Methodology and Textures Analysis for their Segmentation'. PhD. Dissertation, Université Amar Telidji, Faculty of Technology, Laghouat, Algeria, 2020.

[26] Wang, B. et Zhang, L. (2003): 'Supervised texture segmentation using wavelet transform'. In Proceedings of the 2003 International Conference on Neural Networks and Signal Processing, pages 1078-1082.

[27] Arivazhagan, S. et Ganesan, L. (2003) : 'Texture segmentation using wavelet transform'. *Pattern Recognition Letters*, 24 :3197-3203.

[28] Y. BOULFANI, « Réseaux de neurones et leurs applications », Mini projet, ENP- 2003-2004.

[29] Scheunders, P., Livens, S., Van de Wouwer, G., et al. : " Wavelet-based Texture Analysis », *Int. J. Computer Science and Information Management*, December 1997.

[30] BOULEMNADJEL Amel : 'Partitionnement neuronal et validité des classes Application à la segmentation d'images', Mémoire de Magister, Université Mentouri – Constantine Le 07/07/2009.

[31] [http://gsite.univprovence.fr/gsite/Local/umr\\_6149/umr/page\\_perso/Touzet/Les réseaux de neurones artificiels.pdf](http://gsite.univprovence.fr/gsite/Local/umr_6149/umr/page_perso/Touzet/Les_reseaux_de_neurones_artificiels.pdf)

[32] Bloch, I. et Maitre, H. (1994) : 'Data fusion in image processing : information models and decisions'. *Traitement du Signal*, 11(6)

[33] Martin, A. (2012) : 'Fusion de classifieurs pour la classification d'images sonar'. *Revue Nationale des Technologies de l'Information*, E (5), pp.259-268.

[34] Chitroub, S. (2004) : 'Combinaison de classifieurs : Une approche pour l'amélioration de la classification d'images multi sources/multi dates de télédétection'. *Télédétection*, 4(3) :289-301.

- [35] Tabassian, M., Ghaderi, R. et Ebrahimpour, R. (2012): 'Combination of multiple diverse classifiers using belief functions for handling data with imperfect labels'. *Expert Systems with Applications*, 39:1698-1707.
- [36] Bloch, I. (2003): 'Information Fusion in Signal and Image Processing'. John Wiley and Sons.
- [37] B.V. Dasarathy: 'Sensor Fusion Potential Exploitation - Innovative Architectures and Illustrative Applications'. *Proceeding of the IEEE*, 85(1):2438, Janvier 1997.
- [38] P. Verlinde: 'A Contribution to Multi-Modal Identity Verification using Decision Fusion'. Thèse de doctorat, École Nationale Supérieure des Télécommunications, Paris, France, 1999.
- [39] D. Dubois et H. Prade : 'La fusion d'informations imprécises'. *Traitement du Signal*, 11(6) :447-458, 1994.
- [40] Ph. Smets: 'Imperfect information: Imprecision - Uncertainty'. In A. Motro et Ph. Smets, éditeurs: *Uncertainty Management in Information Systems*, pages 225-254. Kluwer Academic Publishers, 1997.
- [41] Ph. Smets: 'The variety of ignorance and the need for well-founded theories'. *Information Sciences*, 57-58:135-144, 1991.
- [42] A. Appriou : 'Décision et Reconnaissance des formes en signal', chapitre Discrimination multi signal par la théorie de l'évidence, pages 219-258. Hermes Science Publication, 2002.
- [43] F. Janez : 'Fusion de sources d'information définies sur des référentiels non exhaustifs différents'. Thèse de doctorat, Université d'Angers, Novembre 1996.
- [44] P.K. Varshney: 'Special Issue on Data Fusion'. *Proceeding of the IEEE*, 85(1):3-5, Janvier 1997.
- [45] Isabelle Bloch. Estimation of class membership functions for gray-level based image fusion. *Image Processing, 1997. Proceedings.*, 3 :268–271, 1997.
- [46] F. Delmotte et P. Borne: 'Modeling of Reliability with Possibility Theory'. *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, 28(1):78-88, Janvier 1998.

- [47] A. Josang: 'The Consensus Operator for Combining Beliefs'. *Artificial Intelligence Journal*, 141(1-2):157-170, 2002.
- [48] E. Lefevre, O. Colot et P. Vannoorenberghe: 'Belief function combination and conflict management'. *Information Fusion*, 3:149-162, 2002.
- [49] D. Dubois and H. Prade. 'Possibility Theory'. Plenum Press, New-York, 1988.
- [50] C.E. Shannon: 'A mathematical theory of communication'. *Bell System Technical Journal*, 27:379-423, October 1948.
- [51] Saidi, M. (2010) : 'Reconnaissance de Formes et d'Objets en Environnement Incertain : Application à la Reconnaissance de Cibles Radar'. Thèse de doctorat, Université Mohammed V-Agdal.
- [52] Martin, A. (2005) : 'La fusion d'informations'. Polycopié de cours ENSIETA.
- [53] L. Xu, A. Krzyzak et C.Y. Suen: 'Methods of Combining Multiple Classifiers and Their Application to Handwriting Recognition'. *IEEE Transactions on Systems, Man Cybernetics*, 22(3):418-435, Mai 1992.
- [54] A. P. Dempster: 'Upper and lower probabilities induced by a multivalued mapping'. *The annals of mathematical statistics*, pp. 325-339, 1967.
- [55] G. Shafer: 'A mathematical theory of evidence', vol. 1: Princeton university press Princeton, 1976.
- [56] P. Smets: 'The combination of evidence in the transferable belief model', *IEEE Transactions on pattern analysis and machine intelligence*, vol. 12, pp. 447-458, 1990.
- [57] Lotfi Askar Zadeh: 'Fuzzy algorithms'. *Information and control*, 12 :94–102, 1968.
- [58] Didier Dubois and Henri Prade : 'Théorie des possibilités : Applications à la Représentation des Connaissances en Informatique'. Masson, Paris. IMAGE EVALUATION TEST TARGET, 1985.
- [59] Mohammad Homam Alsun, Laurent Lecornu, Basel Solaiman, Clara Le Guillou, and Jean Michel Cauvin : 'Medical diagnosis by possibilistic classification reasoning'. In *Information Fusion (FUSION)*, 2010 13th Conference on, pages 1–7. IEEE, 2010.

- [60] S. Deveughele and B. Dubuisson : 'Adaptabilité et combinaison possibiliste : application à la vision multi-caméras'. *TS. Traitement du signal*, 11(6) :559–568, 1994.
- [61] Didier Dubois, Laurent Foulloy, Gilles Mauris, and Henri Prade : 'Probability-possibility transformations, triangular fuzzy sets, and probabilistic inequalities'. *Reliable computing*,10(4) :273–297, 2004.
- [62] Didier Dubois and Henri Prade: 'Additions of interactive fuzzy numbers'. *Automatic Control, IEEE Transactions on*, 26(4) :926–936, 1981.
- [63] Isabelle Bloch: 'Estimation of class membership functions for gray-level based image fusion'. *Image Processing*, 1997. Proceedings., 3 :268–271, 1997.
- [64] Weibei Dou : 'Segmentation d'images multispectrales basée sur la fusion d'informations : application aux images IRM'. PhD thesis, Université de Caen, 2006.
- [65] Enric Plaza, Claudi Alsina, R López de Mántaras, J Aguilar, and Jaume Agusti: 'Consensus and knowledge acquisition'. In *Uncertainty in Knowledge-Based Systems*, pages 294–306. Springer, 1987.
- [66] Isabelle Bloch and Henri Maître : 'Les méthodes de raisonnement dans les images'. Ecole Nationale Supérieure des Télécommunications-CNRS UMR, 5141, 2004.
- [67] Arnaud. M : 'La fusion d'informations'. Polycopié de cours ENSIETA-Réf,1484 :117, 2005.
- [68] Chaimae ANIBOU. Segmentation d'Images Texturées par Classification et Fusion d'Informations : Application aux Images Satellitaires et médicales. Informatique et télécommunications 2016
- [69] Abdelmounaime Safia. Comparaison entre la matrice de cooccurrence et la transformation en odelettes pour la classification texturale des images Hrv (Xs) de spot. Article. Janury 2004
- [70] Traitement d'images et fusion de données pour la détection d'objets enfouis en acoustique sous-marine. Frederic Maussang. HAL Id : tel-00011447. <https://tel.archives-ouvertes.fr/tel-00011447>. Submitted on 23 jan 2006
- [71] Segmentation d'images sonar par matrice de co-occurrence Mbark Iggane, Driss Mammass, Ali Khenchaf, Jean-Christophe Cexus HAL Id: hal-00839586 <https://hal-ensta-bretagne.archives-ouvertes.fr/hal-00839586> Submitted on 28 Jun 2013