



Université Mohamed Khider de Biskra
Faculté des Sciences et de la Technologie
Département de Génie Electrique

MÉMOIRE DE MASTER

Sciences et Technologies
Filière : Télécommunication
Spécialité: Réseaux et télécommunication

Réf. : /2020

Présenté et soutenu par :
Meharzi siham

Le : [Click here to enter a date.](#)

Fusion de la transformée d'ondelette et les Réseaux de neurone artificielle pour la classification de texture

Jury :

Mme. Therghini Werda	MCB	Université de Biskra	Président
Melle. Hendaoui Mounira	MCA	Université de Biskra	Examineur
Melle. Zehani Soraya	MAA	Université de Biskra	Rapporteur

Dédicace

Je dédie ce modeste travail à tous ceux qui me sont chers:

A l'être le plus cher pour moi dans cette vie, ma mère et, à l'être que je respecte le plus dans ce monde, mon cher père, pour leur sacrifice et encouragement pour finir ce travail. Je les souhaite une vie pleine de joie, de santé et de bonheur. A mes chers frères Ahmed Rami, Mehdi et Hicham et ma chère sœur Nawel, Dieu me les garde pour le reste de ma vie.

Remerciement

D'abord et avant tout, je remercie 'ALLAH' de m'avoir donné le courage de reprendre mes études après une rupture de vingt ans et la patience de continuer et de terminer cette année scolaire avec ce travail malgré toutes les circonstances.

Je tiens à exprimer mes remerciements à Mlle *Zehani Soraya* directeur de ce mémoire pour m'avoir proposé cette étude et pour la confiance et le soutien qu'elle m'a accordée et pour sa patience et ses encouragements durant la période de ce mémoire afin de la finaliser.

Je tiens également à adresser l'expression de ma reconnaissance, ma gratitude les plus sincères et mes vifs remerciements à Mme *Therghini Werda* de m'avoir honoré et accepté de présider le jury de ce mémoire.

J'exprime ma profonde gratitude à Mme *Hendaoui Monira* d'avoir trouvée de l'intérêt et d'avoir acceptée d'examiner les travaux de ce mémoire.

Je remercie également toutes les personnes qui nous ont aidés de près ou de loin pour mener à bien ce projet de fin d'étude.

Résumé

Ce travail présente une nouvelle approche de la classification des textures. L'objectif de notre travail est de proposer l'extraction de caractéristiques dans le domaine d'ondelettes utilisant la transformation en ondelettes discrète (DWT), avec et sans prétraitement pour la classification des textures à l'aide de réseaux de neurones artificiel (RNA ou ANN) et l'étude de l'effet du prétraitement et ondelettes dans la précision de la classification. Les entités extraites (les paramètres extraites) sont utilisées comme entrée du classificateur ANN. Les performances de la méthode proposée sont évaluées en utilisant deux classes de textures de base de données BRODATZ et OUTEX. La méthode appliquée sur les deux bases de données utilisées a donné des résultats satisfaisants avec des taux de classification de : 99.0% (de base de données BRODATZ) et 81.3% (de base de données OUTEX) avec prétraitement et 95.8% (de base de données BRODATZ) et 80.6% (de base de données OUTEX sans prétraitement. La méthode proposée est évaluée en utilisant la matrice de confusion et les courbes ROC et le taux de classification TC% ou ACC%.

Mots clés: réseau de neurones artificiels (RNA), transformée en ondelettes discrètes (DWT), prétraitement, extraction de caractéristiques, analyse de texture, Base de données BRODATZ, Base de données OUTEX, Courbe ROC, Matrice de Confusion, Taux de classification (TC% ou ACC%).

Abstract

This work presents a new approach for texture classification. The objective of our work is to propose the features extraction using Discrete Wavelet Transform (DWT), with and without preprocessing stage for the texture classification using neural networks for pattern recognition and studying the effect of the preprocessing and wavelets in

classification accuracy. The extracted features are used as the input of the ANN classifier. The performances of the proposed methods are evaluated by using two classes of BRODATZ database textures and OUTEX database textures and were compared. The method applied in the used database gave satisfactory results at classification rates: 99.0% (of BRODATZ database) and 81.3% (of OUTEX database) with preprocessing and 95.8% (of BRODATZ database) and 80.6% (of OUTEX database) without preprocessing.. Finally, classification assessment measures such as the confusion matrix, ROC curves and accuracy are applied to the proposed methods.

Keywords—artificial neural network (ANN), discrete wavelet transforms (DWT), preprocessing, features extraction, Texture analysis. BRODATZ database, OUTEX database, ROC curves (Receiver Operating Characteristic), Confusion Matrix, the classification accuracy (ACC %).

ملخص

يقدم هذا العمل نهجا جديدا لتصنيف النسيج ، الهدف من عملنا هو اقتراح استخراج الميزات في مجال الموجات باستخدام التحويل المويج المنفصل (DWT) مع وبدون المعالجة المسبقة لتصنيف النسيج باستخدام الشبكات العصبية الاصطناعية (RNA أو ANN) ودراسة تأثير المعالجة المسبقة والموجات في دقة التصنيف، يتم استخدام الميزات المستخرجة (المعلومات المستخرجة) كمدخلات لمصنف ANN يتم تقييم أداء الطريقة المقترحة باستخدام فئتين من قاعدة بيانات BRODATZ و OUTEX ، أعطت الطريقة المستخدمة نتائج مرضية مع معدل التصنيف % 99.0 (بالنسبة لقاعدة بيانات BRODATZ) و % 81.3 (بالنسبة لقاعدة بيانات OUTEX) مع المعالجة المسبقة و % 95.8 (بالنسبة لقاعدة بيانات BRODATZ) و % 80.6 (بالنسبة لقاعدة بيانات OUTEX) دون المعالجة المسبقة. يتم تقييم الطريقة المقترحة باستخدام مصفوفة الارتباك ومنحنيات ROC ومعدل تصنيف TC% أو ACC%.

الكلمات المفتاحين : الشبكة العصبية الاصطناعية RNA، تحويل الموجات المنفصلة، المعالجة المسبقة، استخراج الميزات، تحليل النسيج، قاعدة البيانات BRODATZE ، قاعدة البيانات OUTEX ، منحنيات ROC ، مصفوفة الارتباك، دقة التصنيف (ACC%).

Table des Matières

<i>Dédicace</i>	<i>I</i>
<i>Remerciement</i>	<i>II</i>
<i>Résumé</i>	<i>III</i>
<i>Abstract</i>	<i>III</i>
<i>Table des Matières</i>	<i>V</i>
<i>Liste des abréviations</i>	<i>IX</i>
<i>Liste des tableaux</i>	<i>X</i>
<i>Liste des figures</i>	<i>XI</i>
<i>Introduction Générale</i>	<i>1</i>
<i>Chapitre 01 : Généralité sur la texture</i>	
1 Introduction.....	5
2 Définition de la texture	5
3 Classification des textures.....	6
3.1 Textures structurelles.....	6
3.2 Textures aléatoires	6
3.3 Textures directionnelles.....	7
4 Les bases de données de textures.....	8
4.1 La base d'images de Brodatz.....	8
4.2 La base d'images de VISTEX	9
4.3 La base d'images de OUTEX.....	10
4.4 La base d'images de PRAGUE	11
5 Analyse de texture.....	11
6 Méthodes d'analyse de texture.....	12
6.1 .Méthodes structurelles	12
6.2 .Méthodes basées sur modèle	12

6.3	Méthodes statistiques.....	12
6.3.1	Méthodes statistiques du premier ordre	13
6.3.2	Méthodes statistiques du deuxième ordre	13
6.4	Méthodes spatio-fréquentielles.....	13
6.4.1	Transformation de Gabor	13
6.4.2	Transformée en ondelettes	14
7	Conclusion	14
 <i>Chapitre 02 : Généralités sur la transformation en ondelette</i>		
1	Introduction.....	16
2	Historique.....	16
3	Théorie de la transformée en ondelettes :	17
3.1	Qu'est-ce qu'une ondelette?	17
3.2	Pourquoi les ondelettes ?	17
3.3	Définition de la transformée en ondelettes	18
4	Familles d'ondelettes:.....	19
4.1	L'ondelette de Morlet :	20
4.2	L'ondelette de Haar :	20
4.3	L'ondelette de Daubechies :	22
5	Transformation en ondelette discrète(DWT) et Transformation en ondelette continue(CWT).....	23
5.1	Transformation en ondelette discrète(DWT):.....	23
5.1.1	Décomposition simple	24
5.1.2	Décomposition multi niveaux	25
5.1.3	Reconstruction par ondelette :	26
5.2	Transformation en ondelette continue(CWT).....	26
6	Analyse Multi résolution.....	27
6.1.	Notion de Détails et d'Approximations.....	27
7	Conclusion	29
 <i>Chapitre 03 : Les réseaux des neurones artificiels (RNA)</i>		

1	Introduction.....	31
2	Historique.....	31
3	Réseaux de neurones Artificiels :	32
3.1	Définitions	32
3.2	Neurone biologique	32
3.3	Neurone formel.....	34
3.3.1	Définition	34
3.3.2	L'état des neurones.....	34
4	Architecture des réseaux de neurones.....	35
5	La fonction d'activation des neurones	36
6	Les connexions entre neurones	38
6.1	Réseaux de neurones statiques (réseaux non bouclés)	38
6.1.1	Réseau multicouche à connexions Totales.....	39
6.1.2	Réseau à connexions locales	39
6.2	Réseaux de neurones dynamiques ou réseaux bouclés (ou récurrents)	40
6.2.1	Réseau à connexions récurrentes :	40
6.2.2	Réseau à connexions complètes :	40
7	Apprentissage des réseaux de neurones :.....	41
7.1	Définition.....	41
7.2	Apprentissage supervisé	41
7.3	Apprentissage non supervisé	42
8	La règle d'apprentissage de rétro-propagation	43
9	Choix des paramètres.....	44
10	Phase de reconnaissance (test) et de validation	44
11	Evaluation de la performance de classification	44
11.1	Matrice de confusion	45
11.2	Courbe de ROC (Receiver Operating Characteristic)	47
12	Propriétés des réseaux de neurones.....	48
13	Domaines d'application des réseaux de neurones	49

14	Conclusion.....	49
<i>Chapitre 04 : Résultats de Simulation</i>		
1	Introduction.....	51
2	Bases de données utilisées.....	51
2.1	Base de données textures BRODATZ.....	51
2.2	Base de données textures OUTEXT.....	52
3	Environnement de travail.....	54
4	Application.....	54
4.1	Etape de prétraitement de l'image.....	55
4.2	Etape d'extraction des paramètres.....	55
4.3	Etape de classification.....	56
5	Résultats et discussion.....	56
6	Conclusion.....	71
<i>Conclusion générale.....</i>		72
<i>Bibliographie.....</i>		74

Liste des abréviations

<i>Abréviations</i>	<i>Significations</i>
<i>DWT</i>	Discrete Wavelet Transform
<i>Acc</i>	Accuracy (le taux d'exactitude).
<i>FNR</i>	False Negative Rate (le taux de faux négatifs).
<i>FPR</i>	False Positive Rate (le taux de faux positifs).
<i>PMC</i>	Perceptron Multicouches.
<i>RGB</i>	Red (rouge), Green (vert), Blue (bleu).
<i>RNA</i>	Réseaux de Neurones Artificiels.
<i>ROC</i>	Receiver Operating Characteristic (caractéristique de fonctionnement du récepteur).
<i>SVM</i>	Machines à Vecteurs Supports.
<i>TC%</i>	Le Taux de Classification.
<i>Tbc</i>	Le taux de bonne classification.
<i>TNR</i>	True Negative Rate (le taux de vrais négatifs).
<i>TVP</i>	True Positive Rate (le taux de vrais positifs)

Liste des tableaux

Tableau3. 1 : Analogie entre le neurone biologique et le neurone formel.....	35
Tableau3. 2 : Matrice de confusion [31].....	45
Tableau4.1: les différents taux de classification sans prétraitement pour les deux bases de données (BRODATZ et OUTEX).	58
Tableau 4.2 : les différents taux de classification (TC%) avec et sans prétraitement de filtrage (filtre Médian) (Base de données BRODATZ et OUTEX).	69

Liste des figures

Figure 1.1: Textures structurales [1].	6
Figure 1.2: Textures aléatoires [1].	7
Figure 1.3: Textures directionnelles [1].	7
Figure 1.4 : Exemples de textures issues de l’album de BRODATZ.	9
Figure 1.5: Exemples de textures issues de l’album de VISTEX. [7]	10
Figure 1. 6 : Exemples de textures issues de l’album d’OUTEX [7]	10
Figure 1.7 : Exemples de textures issues de l’album de PRAGUE [7]	11
Figure 2.1 : Exemple de fonction d’ondelette (ondelette de Morlet) [16]	17
Figure 2.2 : Représentation temporelle vers ondelettes [30]	18
Figure 2.3 : Algorithme de décomposition de l’image a_j par la transformée en ondelettes où g et h désignent respectivement un filtre passe-bas et un filtre passe-haut. [21]	19
Figure 2.4 : Evolution de la forme d'une ondelette et de sa transformée de Fourier (à droite) . [30]	20
Figure 2.5 : Ondelette de Haar. [19]	21
Figure 2.6 : Ondelette de Haar. [18]	22
Figure 2.7 : Ondelettes de Daubechies. [18]	23
Figure 2. 8 : exemple de la transformée en ondelettes discrète 2D.[20].	24
Figure 2. 9 : Décomposition simple du signal s en approximations et détails.	25
Figure 2.10 : Décomposition du signal s en multi-niveaux	26
Figure 2.11 : Paire de filtres miroir [23].	28
Figure 2 .12 : Principe de la cellule de décomposition [23]	28
Figure 2.13 : Principe de la cellule de reconstitution [23].	29
Figure 3.1 : Discrimination entre les paramètres « triangle » et « rond » [8]. (a) linéaire - (b) : non linéaire - (c) : non continue.	31
Figure 3.2: Schéma représentatif d’un neurone biologique [10]	33
Figure 3.3 : Représentation schématique d’un neurone artificiel. [01]	34
Figure 3.4: Architecture d’un réseau à couches.	36
Figure 3.5: Différents types de fonctions de transfert pour le neurone artificiel. [11]	37

Figure 3.6: Graphe de la fonction sigmoïde. [25]	38
Figure 3.7: Définition des couches d'un réseau multicouche.....	39
Figure 3.8: Réseau à connexions locales.....	40
Figure 3.9: Réseau à connexions récurrentes.....	40
Figure 3.10 : Réseau à connexions complète.....	41
Figure 3.11 : Apprentissage supervisé.[27].....	42
Figure 3.12 : Apprentissage non supervisé.[27].....	43
Figure 3.13: Exemple de la courbe ROC de deux classes.[01].....	47
Figure 3.14 : Exemple de trois types de courbe ROC. [34]	48
Figure 4.1: Les deux classes utilisées de la Base de données textures.	52
Figure 4.2 : Exemple des opérations effectuées sur une texture prises de la classe 1, subdivisée en sous-images (Base de données BRODATZ).	52
Figure 4.3: Exemple d'images des deux classes de la Base de données textures OUTEX.	53
Figure 4.4: Exemple des opérations effectuées sur une texture prises de la classe 1, subdivisée en sous-images (Base de données OUTEX).....	54
Figure 4.5 : Algorithme proposé.	55
Figure 4.6: Architecture du réseau de neurones utilisé.....	57
Figure 4.7 : Exemple de l'étape de prétraitement, image de la classe1 base de données BRODATZ avant et après filtrage (filtre Médian).....	58
Figure 4.8: Matrice de confusion pour la classification des textures des résultats sans prétraitement. (Base de données BRODATZ).	60
Figure 4.9: Courbes ROC pour la classification des textures sans prétraitement. (Base de données BRODATZ).....	61
Figure 4.10 : Validation des performances de l'apprentissage, test et validation pour la classification des textures sans prétraitement. (Base de données BRODATZ).	61
Figure 4.11: Matrice de confusion pour la classification des textures des résultats avec prétraitement. (Base de données BRODATZ).	62
Figure 4.12 : Courbes ROC pour la classification des textures avec prétraitement. (Base de données BRODATZ).....	63
Figure 4.13 : Validation des performances de l'apprentissage, test et validation pour la classification des textures avec prétraitement. (Base de données BRODATZ).	64

Figure 4.14: Matrice de confusion pour la classification des textures des résultats sans prétraitement. (Base de données OUTEX).....	65
Figure 4. 15: Courbes ROC pour la classification des textures sans prétraitement (Base de données OUTEX).	66
Figure 4. 16 : Validation des performances de l'apprentissage, test et validation pour la classification des textures sans prétraitement (Base de données OUTEX).....	66
Figure 4.17 : Matrice de confusion pour la classification des textures des résultats avec prétraitement. (Base de données OUTEX).....	67
Figure 4.18: Courbes ROC pour la classification des textures avec prétraitement (Base de données OUTEX).	68
Figure 4.19: Validation des performances de l'apprentissage, test et validation pour la classification des textures avec prétraitement (Base de données OUTEX).	68

Introduction Générale

Nous vivons dans un monde numérique, où les informations sont stockées, traitées, indexée et recherchées par des systèmes informatiques, durant ces dernières années, l'informatique s'est affirmée comme une nouvelle technologie majeure. Les progrès des moyens informatiques et des techniques de traitement ont permis d'ouvrir une voie de développement très prometteuse. L'amélioration et la multiplication des moyens de diffusion des données informatiques ont pris également une grande part à la multiplication de ces techniques. Les outils de communication utilisent de plus en plus les images, ce qui a entraîné un accroissement des recherches dans les domaines du traitement et de l'analyse d'images. Ces techniques ont été développées avec succès dans des domaines divers et très variés (météorologie, biologie, industrie, robotique, agriculture, etc.)

La notion d'information texturale est apparue au début des années 1970. Elle consiste à intégrer l'analyse de texture dans le processus de classification automatisée. La texture est une des importantes caractéristiques des images, c'est une caractéristique visuelle hautement discriminante qui a été largement étudiée dans différents domaines du traitement et de la reconnaissance d'images. Elle est connue sous le nom des formes complexes, elle nous informe sur la distribution spatiale de la variation du niveau du gris des pixels. Il existe des différentes variétés ou formes des textures. La texture est une riche source d'informations visuelles est une composante clé dans l'analyse des images et la compréhension humaine.

L'analyse et la classification de la texture ont une riche histoire dans le traitement d'image et la vision par ordinateur. Il y a eu un grand intérêt pour le développement de méthodes de reconnaissance de formes basées sur la texture dans de nombreux domaines différents, tels que la télédétection, le diagnostic d'images médicales, l'imagerie biomédicale, l'image satellite, la reconnaissance biométrique ... En outre, du point de vue de la mise en œuvre, toute analyse de texture implique plusieurs étapes. Tout d'abord, les propriétés de texture sont décrites par le biais du vecteur de

caractéristiques. Ce dernier peut impliquer soit des caractéristiques statistiques du domaine d'intensité d'image, soit une approche structurelle. Deuxièmement, une tâche de classification détermine à quelle classe prédéfinie appartient la texture donnée.

Le problème de classification de texture est divisé en deux étapes: (1) extraction de caractéristiques et (2) classification. La sélection de caractéristiques inadéquates peut dégrader les performances de classification, et la sélection d'un trop grand nombre de caractéristiques, même appropriées, a des conséquences négatives et une dégradation potentielle de la précision. Pour cette raison, nous proposons dans ce travail une méthode plus performante afin d'extraire les paramètres les plus significatives qui permettent une bonne classification.

Dans ce travail, notre choix d'extraction de caractéristiques dans le domaine de la Transformation en ondelettes discrète (DWT) et de classificateur utilisant un réseau de neurones artificielles (RNA) avec et sans prétraitement. dans ce contexte, on propose la classification des textures d'extraire les caractéristiques des images de texture après l'application DWT, nous obtenons un vecteur d'attribut de quatre caractéristiques qui sont (la variance, la moyenne, l'énergie et l'entropie) qui deviennent les nombres de neurones d'entrée pour notre classificateur RNA

.Ce travail est composé des chapitres suivants :

Dans le chapitre 1, nous présentons une généralité sur la texture, puis la définition de la texture en générale, leurs différences classes et les bases de données textures disponibles et le plus couramment utilisées pour évaluer les méthodes d'analyse et classification de texture.

Dans le chapitre 2, nous étudions d'abord l'idée générale de la théorie de la transformation en ondelettes. On présentera ensuite quelques exemples d'ondelettes de base et les deux type de transformations d'ondelette (discrète, continue).

Dans le chapitre 3, nous présentons quelques notions de base sur les réseaux de neurones artificiels et leur Propriétés, nous donnons quelques informations permettant d'entrevoir les relations existantes entre ces réseaux et la classification et aussi nous

avons parlé sur L'apprentissage qui est la propriété la plus intéressante des réseaux neuronaux artificiels.

Dans le chapitre 3, nous présentons notre application ; les résultats et la discussion de notre méthode proposée appliquées sur la base de données BRODATZ (textures de niveaux de gris) et OUTEX (textures de niveaux de couleur).

Et enfin une conclusion générale avec des perspectives.

Chapitre 01 : Généralité sur la texture

1 Introduction

La texture est omniprésente dans les images. Les régions sont souvent homogènes au sens textural. La texture est donc utilisée dans de nombreuses applications de segmentation, de classification et d'identification.

L'analyse de texture regroupe un ensemble de techniques permettant de quantifier les différents niveaux de gris présents dans une image en termes d'intensité et de distribution dans le but de calculer un certain nombre de paramètres caractéristiques de la texture à étudier.

Dans ce premier chapitre, nous commençons donc par présenter la définition de la texture en générale, leurs différentes classes et les bases de données textures disponibles. Ensuite, l'état de l'art de la texture. Enfin, la dernière partie présente l'analyse de texture et les différentes méthodes d'analyse appliquées.

2 Définition de la texture

L'analyse de la texture reste un problème ouvert dans le domaine de la vision par ordinateur. Il n'existe pas de définition universelle ou définition mathématique exacte de la texture qui résulte plutôt d'une perception cohérente d'une entité observée dans une image [3], elle a plusieurs définitions selon les auteurs, qu'on peut citer quelques-unes :

Haralick a défini la texture comme « un phénomène à deux dimensions : la première concernant la description d'éléments de base ou primitives (le motif) à partir desquels est formée la texture ; la deuxième dimension est relative à la description de l'organisation spatiale de ces primitives ». [1]

Bernard Jähne a défini la texture comme : « Un motif arbitraire qui se prolonge sur une grande surface dans une image est certainement reconnue comme une texture. Ainsi, la propriété de base d'une texture est un petit motif élémentaire, qui se répète périodiquement ou quasi-périodique dans l'espace comme un motif sur un papier peint. Ainsi, il suffit de décrire le petit motif élémentaire et les règles de répétition. Ces derniers donnent l'échelle caractéristique de la texture ». [1]

Henri Maître a proposé une définition de la texture : « une texture est un champ de l'image qui apparaît comme un domaine cohérent et homogène, c'est-à-dire formant un tout pour un observateur. C'est cette propriété de cohérence de la texture placée dans son contexte d'être perçue comme un tout homogène par l'œil humain qui sera recherchée le plus souvent par le traiteur des images, dans le but d'isoler les textures, soit pour segmenter l'image, soit pour reconnaître des régions ». [1]

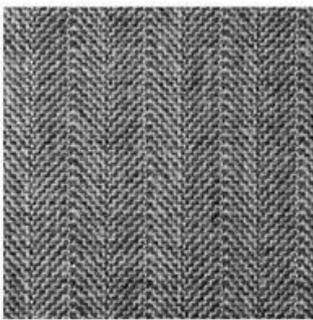
3 Classification des textures

La complexité de la notion de texture s'impose aussi dans la classification de l'ensemble des textures. En effet, ils existent une multitude de textures qu'on peut regrouper en 3 principales familles [1] qui sont : textures structurales, textures aléatoires, textures directionnelles.

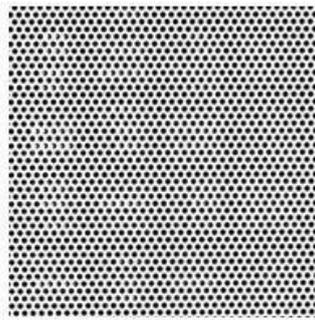
3.1 Textures structurales

Ce type de textures, se distinguent par la répétition spatiale d'un motif de base appelé texton. La récurrence spatiale de ces motifs obéit à des règles de directions et de placement. [4]

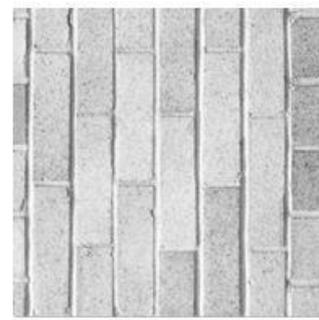
On peut l'appeler aussi les textures régulières, dans lesquelles la périodicité du motif est évidente : grilles, murs de brique, de certains tissus ou d'un grillage, etc...., voilà une figure qui illustre ce type de textures.



Tissu



Grille



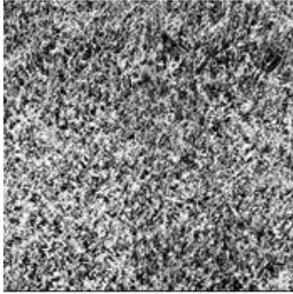
Mur

Figure 1.1: Textures structurales [1].

3.2 Textures aléatoires

Dans ce type de textures, aucun motif spécifique pouvant être traduit ou découvrable [4], ce type de texture présente un aspect plus chaotique. et plus

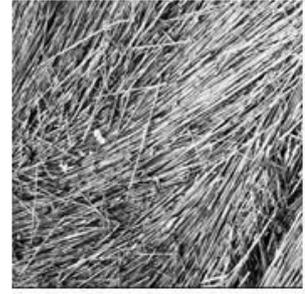
désorganisé, mais dont l'impression visuelle reste globalement homogène. Les différentes régions d'une image aérienne, les bois, les champs, etc., représentent des textures microscopiques. La figure qui suit donne quelques exemples de ce type de texture.



Paille



Sables



herbes

Figure 1.2:Textures aléatoires [1].

3.3 Textures directionnelles

Les textures directionnelles ne présentent pas d'éléments structurants de base et ne sont pas complètement aléatoires. Elles se caractérisent essentiellement par une certaine orientation. La figure suivante montre ce type de texture. [4]

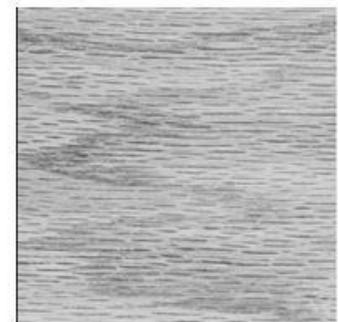
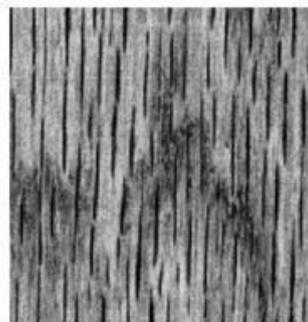
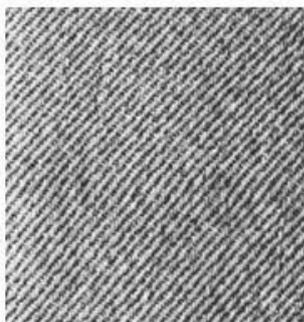


Figure 1.3:Textures directionnelles [1].

Ces différentes catégories de textures nous montrent vraiment qu'il est difficile d'en donner une définition précise à la texture. Les définitions semblent s'adapter aux différents types de textures. Quelques auteurs, préfèrent définir une texture selon deux manières qui correspondent à deux niveaux de perceptions [5].

- **Le micro textures** : les pixels qui obéissent localement au niveau d'un voisinage réduit du pixel lui-même. Elle est alors définie selon une approche probabiliste ou aléatoire dans la mesure où la distribution des couleurs des pixels apparaît irrégulière ou désordonnée dans l'image (pare exemple: sable, laine tissée, herbe).
- **Les macro textures** : la texture se compose de motifs élémentaires (texton) qui se répètent de manière régulière ou ordonnée dans l'image en suivant des règles précises de direction et de placement. La texture est définie selon une approche déterministe ou structurelle (comme la peau de lézard, mur de brique). [5]

4 Les bases de données de textures

Il existe différentes bases de données de texture appliqué dans les différents domaines d'applications et test des algorithmes. Les données d'image et les textures peuvent être artificielles ou naturelles. Les textures dites de Brodatz (1966) sont les données d'image les plus couramment utilisées dans la littérature d'analyse de texture. D'autres ensembles de données bien connus sont les textures VISTEX, OUTEX, USPTEX, Prague, ...etc. Nous présenterons les bases de données les plus connues et les plus utilisées dans le domaine de l'analyse et la classification des textures:

4.1 La base d'images de Brodatz

Brodatz a établi un catalogue de texture à des fins de synthèse d'images texturées (Brodatz, 1966). Ce catalogue est le plus connue et le plus utilisé comme une référence en matière de base de test pour les chercheurs travaillant sur la texture. Il s'agit de 112 images de textures distribuées sur 13 classes (sable, herbe, bulles, eau, bois, etc.). Ces images sont classiquement utilisées pour valider les différentes méthodes d'analyse de texture. La figure suivante donne six images de textures tirées de l'album de Brodatz représentés dans l'ordre : gazon (D9), écorce (D12), paille (D15), mur de brique (D19), étoffe de laine (D29) et sable de plage (D38). [6]

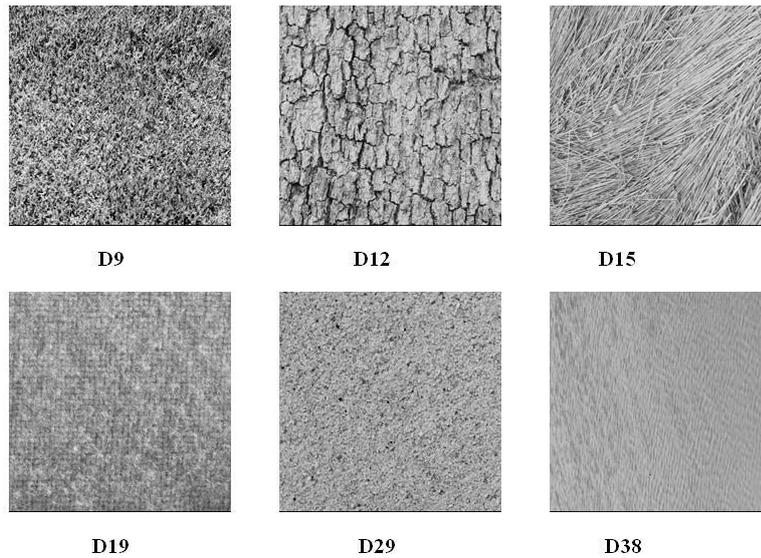


Figure 1.4 : Exemples de textures issues de l’album de BRODATZ.

4.2 La base d’images de VISTEX

VISION TEXTURE connue sous l’abréviation VISTEX [VisTex 1995] est une base d’images de texture souvent utilisée par la communauté de la vision par ordinateur. Elle a été proposée par l’Institut de Technologie de Massachusetts (MIT) en 1995.

VISTEX fournit plus de 100 échantillons de texture couleur de résolution (128×128) pixels et (512×512) pixels ainsi que des scènes naturelles complexes. Les textures de la base VISTEX appartiennent à plusieurs prototypes (herbes, eaux, toiles, briques, bâtiments et nuages) et ont été souvent exploitées pour construire des images synthétiques de textures composées, qui à leur tour ont été utilisées pour mesurer la performance des algorithmes de segmentation couleur/texture. La base de données de VISTEX est disponible en ligne à l’adresse : <http://vismod.media.mit.edu/pub/VisTex/VisTex.tar.gz> La figure suivante illustre quelques images extraites de cette base.[7]



Figure 1.5: Exemples de textures issues de l'album de VISTEX. [7]

4.3 La base d'images de OUTEX

La base de données de texture OUTEX [Ojala 2002] a également eu du succès auprès des chercheurs en vision par ordinateur. En effet, cette base offre une grande collection de textures couleur (toile, tapis, bois, sable, tuiles, etc...) qui peuvent être utilisées à la fois pour l'évaluation de la classification de texture et les algorithmes de segmentation. Cette base d'images de texture est disponible dans le site : <http://www.outex.oulu.fi/> La figure suivante illustre quelques images extraites de cette base. [7]



Figure 1. 6 : Exemples de textures issues de l'album d'OUTEX [7].

4.4 La base d'images de PRAGUE

HAINDL et MIKES ont proposé en 2008 [Haindl 2008], une base d'images connue sous le nom de Prague Texture Segmentation Data Generator and Benchmark. Elle fournit plus de 1000 mosaïques texturées. On y retrouve six catégories de mosaïques : mono-spectrale, multi-spectrale, fonction de texture bidirectionnelle (Bidirectional Texture Function (BTF)), invariance de rotation, invariance d'échelle et invariance de luminosité. Cette base d'images est librement accessible à l'adresse : <http://mosaic.utia.cas.cz/>. La figure suivante donne quelques images extraites de cette base. [7]



Figure 1.7 : Exemples de textures issues de l'album de PRAGUE [7].

5 Analyse de texture

Dans le traitement d'image, l'analyse de texture, consiste à extraire un certain nombre de propriétés distinctives et à les exprimer sous forme paramétrique. L'étape d'extraction des paramètres précède souvent une étape de décision de manière à pouvoir répondre à des questions telles que : matériau normal ou défectueux ? Tissu biologique sain ou pathologique? ... Les paramètres calculés permettent donc de décrire, de caractériser, de diviser et d'analyser les images. L'analyse peut être globale ou locale. Il est évident que le choix des paramètres dépend principalement de l'application considérée. [6]

6 Méthodes d'analyse de texture

Les méthodes d'analyse de textures sont utilisées pour déterminer les différentes textures présentes dans une image. Ces techniques d'analyse ont un pouvoir discriminatif meilleur que celui de l'ensemble œil-cerveau, qui est moins sensible à la modification complexe de texture.

Les méthodes d'analyse de textures peuvent être classées en quatre catégories.

6.1 .Méthodes structurelles

Ces méthodes tiennent compte de l'information structurelle et contextuelle d'une forme et sont particulièrement bien adaptées aux textures macroscopiques. Elles permettent de décrire la texture en définissant les primitives et les "règles" d'arrangement qui les relient. Les deux structures les plus importantes sont les structures de graphe et les structures syntaxiques. [6]

6.2 .Méthodes basées sur modèle

Le but de ces méthodes est d'obtenir un modèle générateur de la texture. Les paramètres de ce modèle permettent de caractériser ou de synthétiser une texture. On distingue en général trois types de modèles. Les modèles autorégressifs, les modèles fractals et les modèles Markoviens. [4]

6.3 Méthodes statistiques

Ce sont des méthodes très utilisées pour l'analyse de texture. Elles se basent sur les relations entre pixels et leurs voisins en termes de variation des niveaux de gris. Les méthodes statistiques sont utilisées généralement pour caractériser des structures fines sans régularité apparente. L'ordre de la statistique, renseigne sur le nombre de pixels pris en considération dans le calcul des paramètres.[2]

De nombreux descripteurs statistiques sont utilisés, on peut citer :

- Les statistiques d'ordre 1.
- Les statistiques d'ordre 2 (matrices de cooccurrences).
- Les histogrammes d'image.
- Etc...

6.3.1 Méthodes statistiques du premier ordre

Ces méthodes sont basées sur les histogrammes de premier ordre. Un tel histogramme indique la fréquence d'apparition d'un niveau de gris dans un voisinage considéré. Nombreux paramètres statistiques de degrés différents peuvent être extraits à partir de l'histogramme. [2]

6.3.2 Méthodes statistiques du deuxième ordre

La limitation des méthodes du premier ordre, réside dans le fait que les paramètres calculés ne prennent compte que de l'histogramme de l'image. Maintenant, Deux images différentes, donc de textures différentes, peuvent avoir le même histogramme. Il est donc indispensable d'intégrer des informations concernant la localisation du pixel, et ne pas se contenter du nombre de niveaux de gris dans l'image. Il s'agit de passer à une méthode d'analyse de texture, d'ordre statistique supérieur. Parmi ces méthodes, on trouve: les matrices de cooccurrence, la fonction d'auto-corrélation, le spectre de texture, les longueurs de plage...etc.[2]

6.4 Méthodes spatio-fréquentielles

Il existe d'autres attributs très intéressants les attributs spatio-fréquentiels. Parmi les attributs les plus utilisés, on retrouve entre autre les attributs extraits de :

- La transformation de Gabor,
- La transformée en ondelettes.

6.4.1 Transformation de Gabor

La transformation de Fourier d'une image permettra de mettre en évidence les régularités de la texture en examinant le domaine fréquentiel. Le problème de ce processus qui fonctionne globalement sur l'image, est qu'elle ne prend pas compte de la localisation spatiale.

Une solution est d'utiliser une transformation alternative appelée transformation de Fourier à fenêtre glissante, où le principe est d'appliquer la transformation de Fourier dans une fenêtre de contrôle de dimensions fixes qui se déplace dans l'image. Le choix de la taille de la fenêtre et du pas de déplacement dépend Plus exactement des caractéristiques spatiales des textures à analyser.

Il existe différentes fenêtres d'observation. Quand la fenêtre de Gausse est utilisé, on parle alors de la transformation de Gabor. [5]

Pour caractériser la texture couleur, les filtres sont appliqués à chacune des fenêtres balayant les images-composantes de l'image couleur texturée. Les coefficients de Gabor, dont l'expression est disponible dans la publication de Palm [03], sont ensuite calculés pour chaque fenêtre et chaque filtre. Pour un filtre donné, l'attribut caractérisant la totalité de l'image est alors obtenu en calculant l'énergie, l'entropie ou la variance des coefficients obtenus pour chaque fenêtre. [5]

6.4.2 Transformée en ondelettes

La transformation de Gabor se base sur une fenêtre d'observation de dimensions fixe, ce qui peut être un obstacle car certaines textures peuvent être distinguées selon différentes échelles. Pour pallier cette limite, la transformée en ondelettes se base sur une analyse multi-échelles de l'image, ce qui signifie que des fenêtres d'analyse de différentes tailles sont utilisées.[05]

L'analyse par ondelettes est un instrument mathématique capable de convertir un signal d'énergie finie dans l'espace spatial, en un autre signal d'énergie finie dans le domaine spatio-fréquentiel. Les composantes de ce nouveau signal sont appelées les coefficients d'ondelettes. Ces coefficients renseignent sur le contraste local des niveaux de gris autour d'un pixel spécifique de l'image. L'analyse par ondelettes est localisée en espace et en fréquence. [6]

Cette tâche sera détaillée dans le chapitre suivant.

7 Conclusion

Nous avons présenté dans ce chapitre une introduction sur les textures, où il est facile à reconnaître son concept, mais difficile à définir. Il n'existe pas de définition complètement satisfaisante.

Dans ce chapitre Nous avons cité quelques définitions selon les auteurs qui définissent la texture. Ensuite, les bases des données de textures existantes et l'analyse de textures et les différentes approches utilisées pour l'analyse. Dans le prochain chapitre nous allons détailler la Transformée en ondelettes.

Chapitre 02 : Généralités sur la transformation en ondelette

1 Introduction

Les recherches tant théoriques qu'appliquées se sont très largement développées ces dernières années au point que les ondelettes sont maintenant très à la mode et qu'on a parfois voulu en faire l'outil idéal adapté à tous les problèmes. Cet optimisme excessif a naturellement conduit à quelques déconvenues. A l'époque actuelle, la plupart des chercheurs scientifiques ont déjà entendu parler des ondelettes. Dans la majorité des congrès traitant de l'analyse du signal et de l'image, de la statistique, de la mathématique, etc., des conférences au sujet des ondelettes sont données. Pourquoi ? Dans ce chapitre nous étudions d'abord l'idée générale de la théorie de la transformation en ondelettes (Qu'est-ce qu'une ondelette?, Pourquoi les ondelettes ?). On présentera ensuite quelques exemples d'ondelettes de base et les deux transformations d'ondelette (discrète, continue).

2 Historique

La première transformation en ondelettes - le nom n'est pas encore utilisé - est proposée par **Haar** en 1910 ; il serait plus judicieux de parler alors de «pré-ondelette». La transformée en ondelettes est un outil qui découpe les données, les fonctions sous les opérateurs en composantes fréquentielles suivant une résolution adaptée à l'échelle. Les précurseurs conscients de cette technique ont été des mathématiciens (**Calderon** 1964), des physiciens (**Aslaken** et **Klauder** 1968, **Paul** en 1985), et surtout des ingénieurs (ou des chercheurs de sciences pour l'ingénieur) comme **Esteban** et **Galand** (1977), **Smith** et **Barnwell** (1986), **Vetterli** (1986). Nous pourrions parler dans leur cas de «pré-ondelette». Mais le premier à avoir utilisé la méthode et le premier à avoir proposé le nom d'ondelettes fut **Jean Morlet** (1983).

Le problème traité par **Morlet** était celui de l'analyse de données issues des ondes sismiques effectués pour des recherches géologiques ; ces données faites de nombreuses transitoires sont particulièrement adaptées à une technique d'analyse conservant la notion de localisation de l'événement tout en fournissant une information sur son contenu fréquentiel ce qui est tout l'intérêt de ce type de transformation. Les résultats obtenus par **Morlet** et formalisés par le physicien **Alex Grossmann** ont rapidement éveillé l'attention de nombreux chercheurs et bien tôt des bases mathématiques solides ont été mises en place faisant apparaître la notion de base orthogonale (**Y.Meyer** 1985),

d'analyse multi résolution (S.Mallat 1989) et d'ondelettes à support compact (I.Daubechies 1988). Les ondelettes modernes étaient nées. [14]

3 Théorie de la transformée en ondelettes :

3.1 Qu'est-ce qu'une ondelette?

Une ondelette notée $\psi(t)$ est une oscillation avec une amplitude qui commence à zéro, augmente, puis diminue à zéro. Il peut généralement être considéré comme une "courte oscillation" comme celle enregistrée par un sismographe ou un moniteur cardiaque. Généralement, les ondelettes sont intentionnellement appliquées pour avoir des propriétés spécifiques qui les rendent utiles pour le traitement du signal. En utilisant la torsion, les ondelettes peuvent être combinées avec des parties connues d'un signal endommagé pour extraire des informations des parties inconnues. [15] Un exemple est illustré sur la figure 2.1. [16]

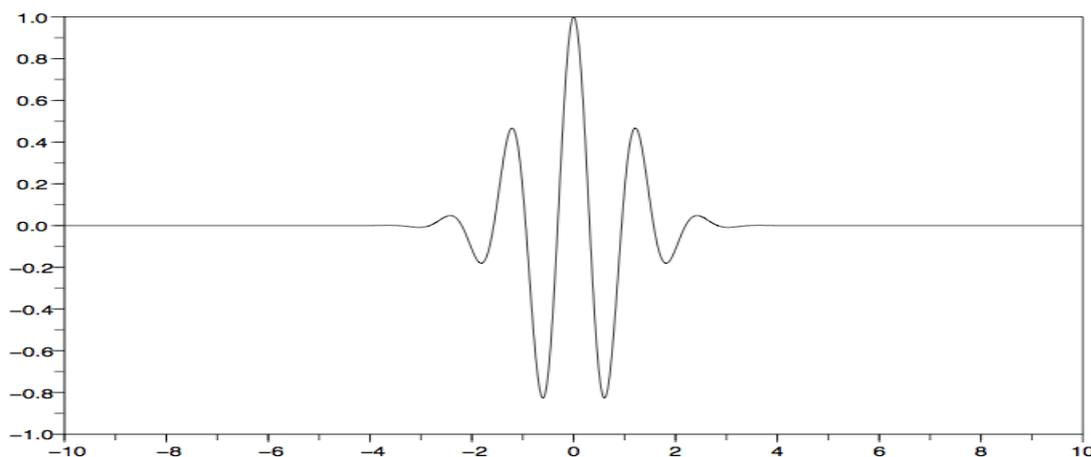


Figure 2.1 : Exemple de fonction d'ondelette (ondelette de Morlet) [16]

3.2 Pourquoi les ondelettes ?

La plupart des signaux du monde réel ne sont pas stationnaires, et c'est justement dans l'évolution de leurs caractéristiques (statistiques, fréquentielles, temporelles, spatiales) que réside l'essentiel de l'information qu'ils contiennent. Les signaux vocaux et les images sont à ce titre exemplaire. Or l'analyse de Fourier propose une approche globale du signal, les intégrations sont faites de moins l'infini à plus l'infini, et toute notion de localisation temporelle (ou spatiale pour des images) disparaît dans l'espace

de Fourier ; il faut donc trouver un compromis, une transformation qui renseigne sur le contenu fréquentiel tout en préservant la localisation afin d'obtenir une représentation temps/fréquence ou espace/échelle du signal. [14]

3.3 Définition de la transformée en ondelettes

La transformée en ondelettes et la transformée de Fourier (TF) sont similaires avec une fonction de mérite complètement différente. La différence principale est la suivante : la transformée de Fourier décompose le signal en cosinus et en sinus, c'est-à-dire en fonctions localisées dans l'espace de Fourier ; contrairement à la transformée en ondelettes qui utilise des fonctions localisées à la fois dans l'espace de Fourier et dans l'espace réel. [17] La transformation en ondelettes permet d'appliquer une analyse multi-résolution sur le signal étudié. L'analyse multi-résolution de la transformation en ondelettes équivaut à une décomposition atomique temps-échelle.[30]

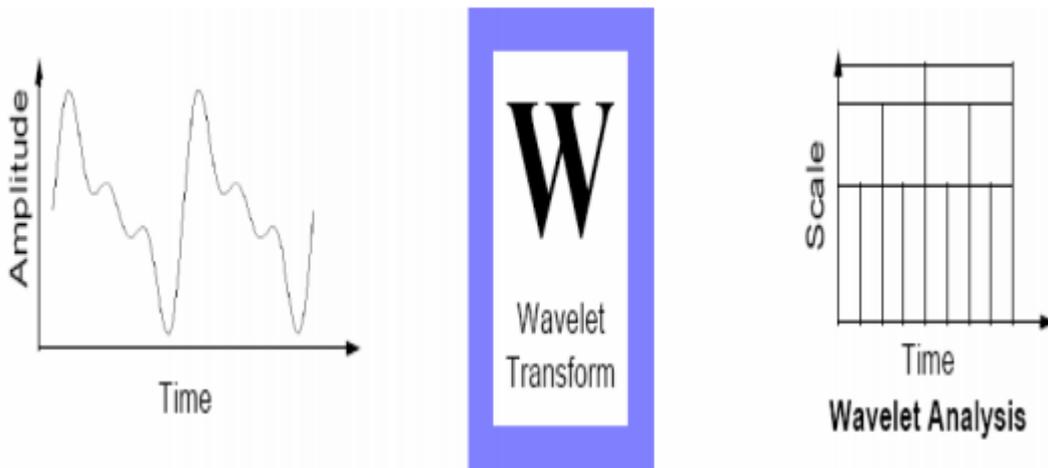


Figure 2.2 : Représentation temporelle vers ondelettes [30]

On définit la transformée en ondelettes par l'équation suivante [14] :

$$T^{ond} f(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \psi \left(\frac{t-b}{a} \right) dt \quad (2.1)$$

Dans cette expression, Le paramètre a est un facteur d'échelle, inversement proportionnel à la fréquence, b le paramètre de position, $\psi(t)$ est l'ondelette mère analysante et $f(a, b)$ est le résultat de la transformée donné par un ensemble des coefficients appelés coefficients d'ondelette de la fonction f dans l'espace-temps-échelle ou espace-échelle.

Calculer cette fonction $f(a, b)$, c'est faire l'analyse de f par l'ondelette ψ . La fonction f est alors décrite par ses coefficients d'ondelettes. Ils mesurent les fluctuations à l'échelle a , de la fonction f . [18]

Pour le cas particulier des signaux 2D, Mallat [9] a introduit un algorithme généralisant l'algorithme de décomposition à des images (Figure 2.3). Il suffit de séparer la double dimension en deux dimensions simples : on filtre d'abord les lignes par un filtre passe-haut h , puis par un filtre passe-bas g . Ensuite, on filtre les colonnes des résultats obtenus par h , puis par g . On obtient alors quatre images dont la quatrième (colonnes et lignes filtrées par h) représente l'image de résolution moindre depuis laquelle on relance l'algorithme jusqu'au niveau désiré. Notons ici qu'entre chaque niveau, il faut sur-échantillonner les filtres. [21]

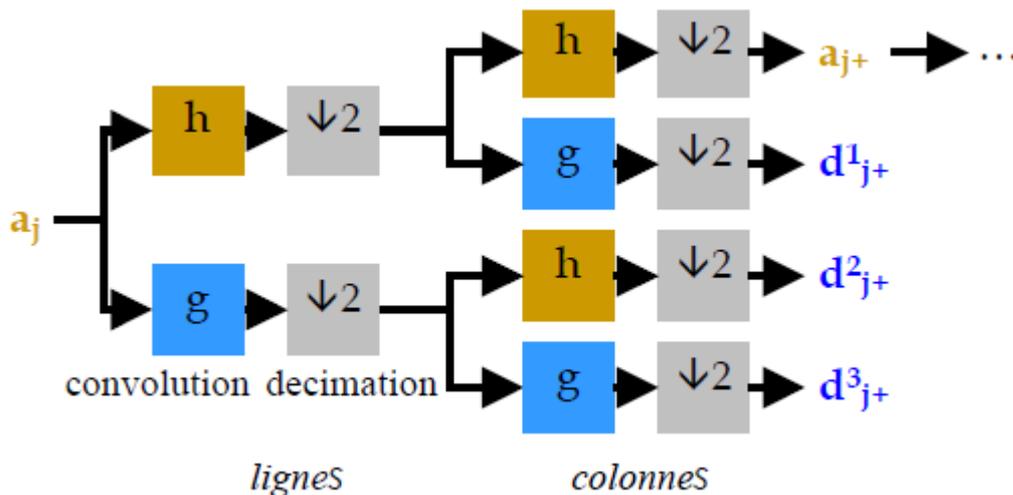


Figure 2.3 : Algorithme de décomposition de l'image a_j par la transformée en ondelettes où g et h désignent respectivement un filtre passe-bas et un filtre passe-haut.

[21]

4 Familles d'ondelettes:

Il existe plusieurs formes d'ondelettes, le choix de l'ondelette optimale dépend de l'application envisagée. Il convient de bien cerner le problème à étudier et d'identifier le type de transformée à utiliser (continue ou discrète).

Dans ce contexte, il y a nécessité de représenter quelques familles d'ondelettes les plus connues en traitement du signal : les ondelettes de **Morlet**, le **chapeau mexicain**, les ondelettes de **Haar** et les ondelettes de **Daubechies**, les ondelettes de Meyer. La famille d'ondelette est déduite à partir d'ondelette mère $\psi(t)$ par la formulation suivante :

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (2.2)$$

4.1 L'ondelette de Morlet :

L'ondelette de **Morlet** teste les ondelettes complexes les plus utilisées. Elle est obtenue en modification exponentielle complexe par une enveloppe gaussienne. Elle permet de réduire le produit des étalements temporels et fréquentiels de l'ondelette, et donc de maximiser la précision de la localisation de l'énergie au niveau temps fréquence.

Soit la formule mathématique de l'ondelette Morlet suivante :

$$\Psi(x) = e^{-\pi x^2} e^{10i\pi x} \quad (2.3)$$

Par la dilatation et la translation dans le temps, on trouve la fonction d'ondelette dilatée et traduite $\Psi_{a,b}(t)$ qui est schématisée dans la figure ci-dessous : [30]

$$\Psi_{a,b}(x) = \frac{1}{\sqrt{a}} e^{-\pi\left(\frac{x-b}{a}\right)^2} e^{10i\pi\left(\frac{x-b}{a}\right)} \quad (2.4)$$

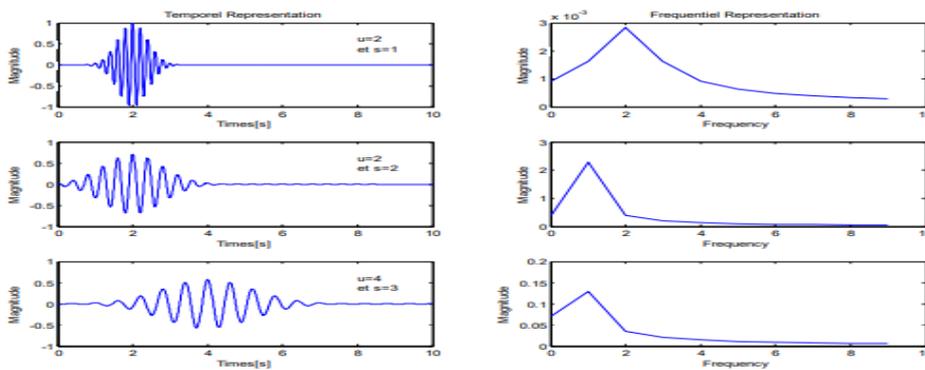


Figure 2.4 : Evolution de la forme d'une ondelette et de sa transformée de Fourier (à droite) . [30]

4.2 L'ondelette de Haar :

Elle est l'ondelette les plus anciennes, et définie par sa fonction d'échelle Φ et sa fonction d'ondelette Ψ ,

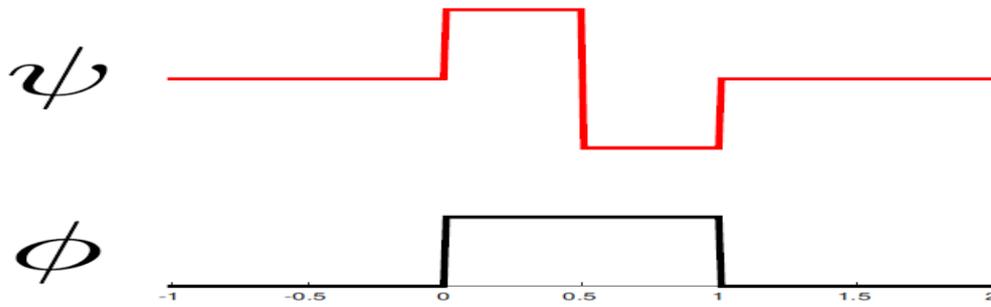


Figure 2. 5 : Ondelette de Haar. [19]

Elle est orthonormée à support compact, symétrique. Elle permet d'obtenir une reconstruction exacte du signal. Elle est utilisée à la fois pour les transformées continue et discrète. [18]

Cette ondelette est très facile et simple à implémenter. De plus elle est à support compact. Le calcul de la transformée de Fourier est donc exact.

Le désavantage de cette ondelette est qu'elle est discontinue donc il n'est pas possible d'approximer les signaux continus d'une manière très adéquate.

Elle est définie par :

$$\left\{ \begin{array}{ll} \Psi(t) = 1 & \text{si } 0 < t < 0.5 \\ \Psi(t) = -1 & \text{si } 0.5 < t < 1 \\ \Psi(t) = 0 & \text{sinon} \end{array} \right. \quad (2.5)$$

La fonction échelle de **Haar** :

$$\left\{ \begin{array}{l} \Psi(t) = \Phi(2t) - \Phi(2t-1) \\ \Phi(t) = \Phi(2t) + \Phi(2t-1) \end{array} \right. \quad (2.6)$$

C'est-à-dire :

$$\left\{ \begin{array}{ll} \Phi(t)=1 & \text{si } 0 < t < 0.5 \\ \Phi(t)=-1 & \text{si } 0.5 < t < 1 \\ \Phi(t)=0 & \text{sinon} \end{array} \right. \quad (2.7)$$

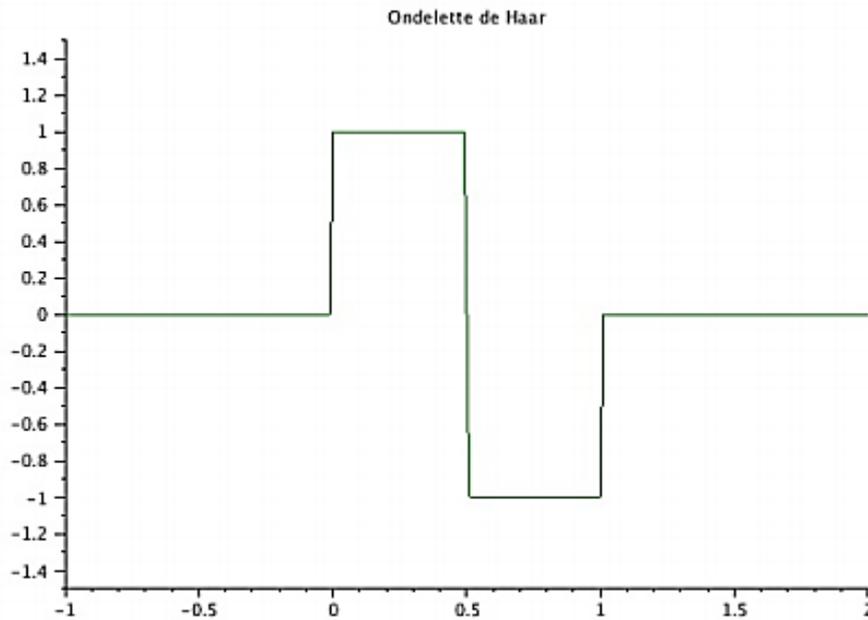


Figure 2.6 : Ondelette de Haar. [18]

4.3 L'ondelette de Daubechies :

Les ondelettes de Daubechies sont une famille la plus connue d'ondelettes orthogonales définissant une transformée en ondelettes discrète. Ses ondelettes sont généralement dénommées par le nombre de coefficients à k non nuls, on parle donc d'ondelettes Daubechies4, Daubechies6, etc.

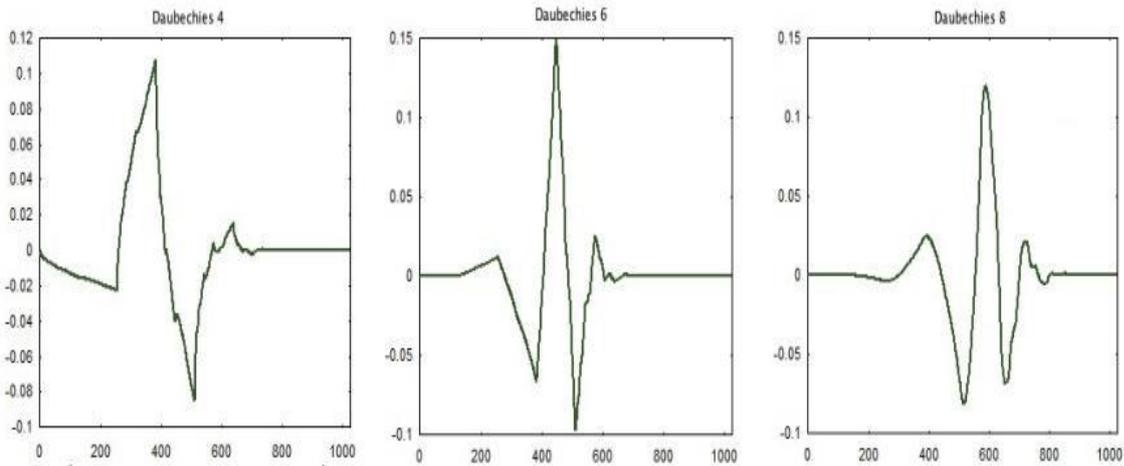


Figure 2.7 : Ondelettes de Daubechies. [18]

Quand l'ordre augmente, les supports grandissent ainsi que la régularité des ondelettes.

Dans son travail, la mathématicienne **Ingrid Daubechies** a cherché à concilier deux contraintes liées: l'orthogonalité de la base d'ondelettes et la compacité du support de l'ondelette-mère. Cela signifie que toute ondelette de la base est à support compact et donc que le calcul de la transformée en ondelettes est précis. De plus, elle a imposé à ses ondelettes une troisième condition: avoir n moments nuls. [18]

5 Transformation en ondelette discrète(DWT) et Transformation en ondelette continue(CWT)

Il existe de nombreuses manières de classer les types de transformées en ondelettes. Nous ne présentons ici que la division basée sur l'orthogonalité des ondelettes. Nous pouvons utiliser les *ondelettes orthogonales* pour le développement en ondelettes discret et les *ondelettes non-orthogonales* pour le développement en ondelettes continu.

5.1 Transformation en ondelette discrète(DWT):

La transformée en ondelettes discrètes est une représentation multi-résolutions/multi-fréquences, [8]. C'est un outil qui découpe les données, les fonctions ou les opérateurs en composantes fréquentielles suivant une résolution adaptée à l'échelle. L'image d'entrée est décomposée à chaque fois en quatre sous-images (image approximée A_i , détail horizontal DH , détail diagonal DD , détail vertical DV) avec différentes combinaisons de filtre passe-bas et passe-haut à savoir fonction d'échelle et

ondelette d'analyse.les échelles d'analyse son dyadique, ce qui introduit une décimation de $\frac{1}{2}$ à chaque résolution. [6]

La plupart des informations (l'énergie de l'image) se trouvent dans l'image approximée(les basses fréquences), tandis que les images détails contiennent les détails de l'image ou les contours(les hautes fréquences).

Un exemple de la transformée en ondelettes discrète 2D utilisée dans JPEG2000. L'image originale est filtrée passe-haut, ce qui donne les trois grandes images, chacune décrivant les changements locaux de luminosité (détails) dans l'image originale. Il est ensuite filtré passe-bas et réduit l'échelle, donnant une image d'approximation; cette image est filtrée passe-haut pour produire les trois images de détail plus petites et filtrée passe-bas pour produire l'image d'approximation finale dans le coin supérieur gauche. [20]

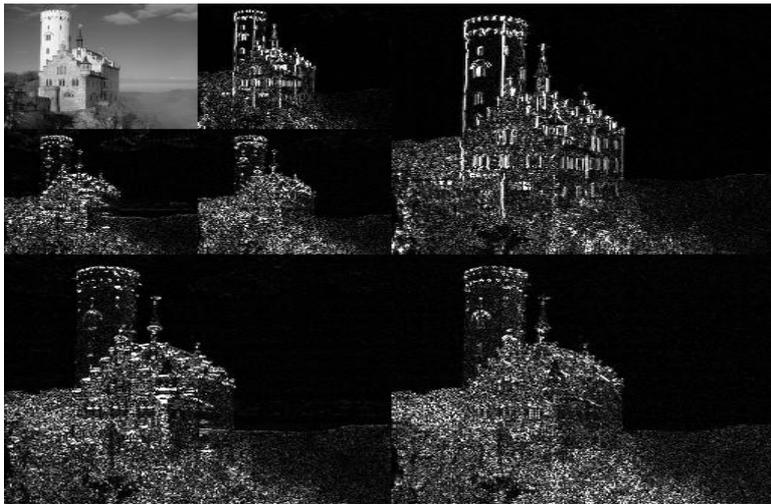


Figure 2.8 : exemple de la transformée en ondelettes discrète 2D.[20].

5.1.1 Décomposition simple

Le signal est divisé en deux signaux mais, actuellement pour faire cette opération dans un signal réelle, on trouve deux signaux de même taille que le signal S. Supposé, pour l'instant, que le signal original S contient 1000 échantillons donc le résultat des deux signaux à 1000 échantillons pour chaque signal, le total est 2000 échantillons Pour donner deux vecteurs respectivement CA (Coefficients ondelette d'approximation) et

CD (Coefficients ondelette de détails). Tous deux sont de taille approximativement égale à la moitié du vecteur d'origine. [30]

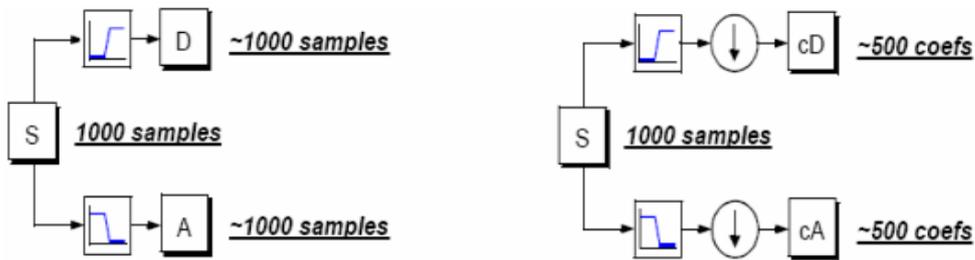


Figure 2.9 : Décomposition simple du signal s en approximations et détails.

5.1.2 Décomposition multi niveaux

L'algorithme de Mallat permet de décomposer le signal original S en plusieurs niveaux. Le processus de décomposition peut être réitéré, avec des approximations successives étant décomposées alternativement, de sorte qu'un signal soit décomposé en beaucoup de composants de hautes résolutions. Ceci s'appelle l'arbre de décomposition en ondelettes. Puisque le processus d'analyse est itératif, dans la théorie il peut être continué indéfiniment. En réalité, la décomposition peut procéder seulement jusqu'à ce que les différents détails se composent d'un échantillon ou d'un Pixel simple. Dans la pratique, on choisira un nombre approprié de niveaux basés sur la nature du signal à décomposer, ou sur un critère approprié tel que l'entropie. Le signal $S(n)$ est un signal de temps discret pour être décomposé en ses versions approximatives et détaillées en utilisant l'analyse multi-résolution. Les premiers coefficients de décomposition sont A_1 et D_1 , où A_1 est la version approximative du signal original $S(n)$ et D_1 est la représentation détaillée du signal original $S(n)$ qui est défini dans la figure (2.10) : [30]

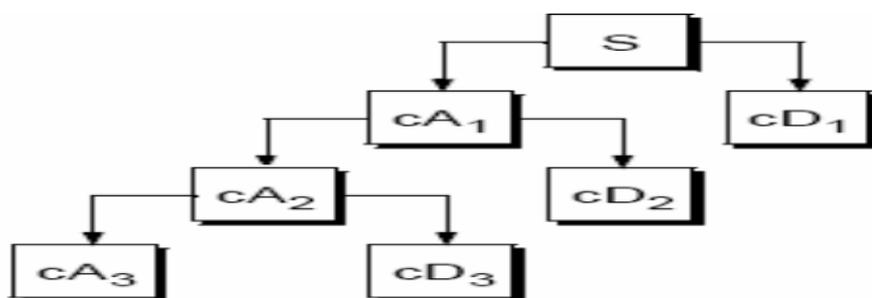


Figure 2.10 : Décomposition du signal s en multi-niveaux

5.1.3 Reconstruction par ondelette :

On a appris précédemment comment la TOD peut utiliser pour analyser, ou décomposer le signal. La deuxième partie de l'histoire est comment peut assembler ces composants pour revenir au signal original sans perdre l'information. Cette procédure est appelée la reconstruction. La manipulation mathématique qui fait cette opération est appelée (TODI).

5.2 Transformation en ondelette continue(CWT)

La transformée en ondelettes dépend de deux paramètres:

- Un paramètre de facteur d'échelle, noté " a ", car si $|a| > 1$ l'ondelette ψ est dilatée, et si $|a| < 1$ elle est comprimée.
- Le paramètre de translation, noté "b " qui joue le rôle de la position de la fenêtre dans la transformée de Fourier à fenêtre. Ce paramètre correspond donc à l'axe des temps.

La transformée en ondelettes continue est donc définie comme suit:

$$\left\{ \begin{array}{l} \mathbf{f(a, b)} = \int_{-\infty}^{+\infty} \mathbf{f(t)} \boldsymbol{\psi}_{\mathbf{a, b}}(\mathbf{t}) \mathbf{d(t)} \quad (2.8) \\ \boldsymbol{\psi}_{\mathbf{a, b}}(\mathbf{t}) = \frac{1}{\sqrt{\mathbf{a}}} \boldsymbol{\psi}\left(\frac{\mathbf{t-b}}{\mathbf{a}}\right) \quad (2.9) \end{array} \right.$$

Cette transformation consiste en des translations et des dilatations d'une seule fonction Fixée. Dans la transformée en ondelette continue, les paramètres de translation et de dilatation varient continûment.

Cette transformée est souvent représentée par une image 2D (en couleurs ou en niveaux de gris) correspondant en module et phase de la transformée $f(a, b)$. L'avantage de cette caractérisation par rapport à la transformée de Fourier est qu'elle ne donne pas seulement une information sur le type de singularité mais aussi sa localisation dans le temps. [22]

6 Analyse Multi résolution

Il existe deux façons de présenter les ondelettes : l'une par la transformation ondelette continue, l'autre par l'analyse multi résolution. En effet, afin d'assurer une représentation non-redondante du signal et la possibilité de le reconstruire parfaitement à partir de sa décomposition, Mallat et Meyer ont développé en 1989 un outil très efficace et très flexible qui a engendré depuis un nombre impressionnant d'applications: l'analyse multi résolution. Grâce à ce concept il a été possible d'appliquer pratiquement de la décomposition en ondelette. [23]

6.1. Notion de Détails et d'Approximations

Le principe de base de la TOD, est de séparer le signal en deux composantes, l'une représentant l'apparence générale du signal, l'autre représentant ses détails. L'allure générale d'une fonction est représentée par ses basses fréquences, les détails par ses hautes fréquences.

Pour séparer les deux, nous avons donc besoin d'une paire de filtres : un filtre passe-bas pour obtenir l'allure générale (aussi appelée approximation ou moyenne), et un filtre passe-haut pour estimer ses détails, c'est-à-dire les éléments qui varient rapidement. Pour ne pas perdre d'information, ces deux filtres doivent bien sûr être complémentaires : Les fréquences coupées par l'un doivent être conservées par l'autre. On dit que les deux filtres forment une paire de filtres miroirs en quadrature. [23]

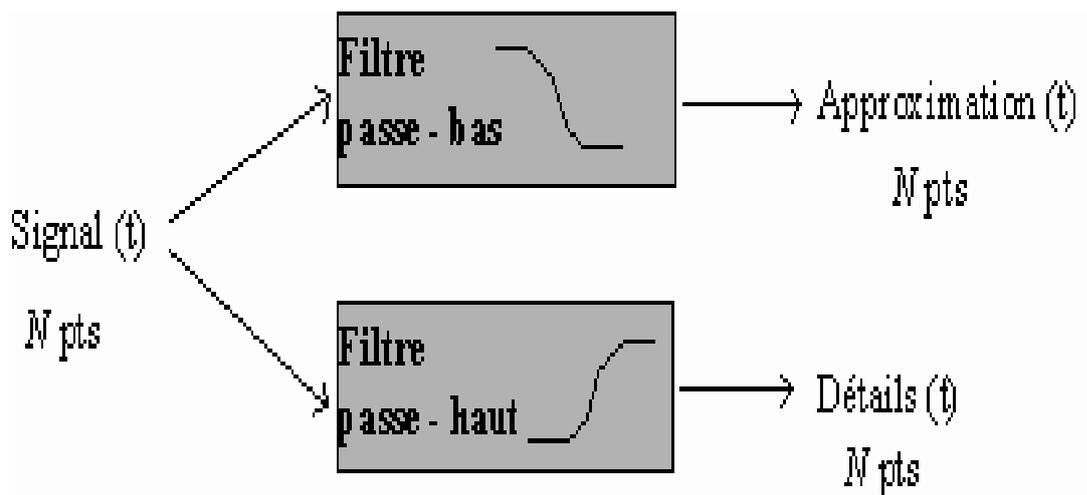


Figure 2.11 : Paire de filtres miroir [23].

Si on s'arrête là, on multiplie par 2 la quantité d'informations. En effet, si le signal à traiter contient N points, alors le signal d'approximation et le signal de détails feront également N points chacun, soit $2.N$ en tout.

Pour y remédier, le filtre passe-bas est choisi de telle sorte que sa fréquence de coupure soit $F_e / 4$, où F_e est la fréquence d'échantillonnage du signal, c'est le sous-échantillonnage. Le signal d'approximation et le signal de détails, on revient à deux signaux de longueur $N/2$, soit N points en tout, Pas de changement dans la quantité d'informations. Une étape élémentaire de la TOD, peut donc se schématiser de la façon suivante :

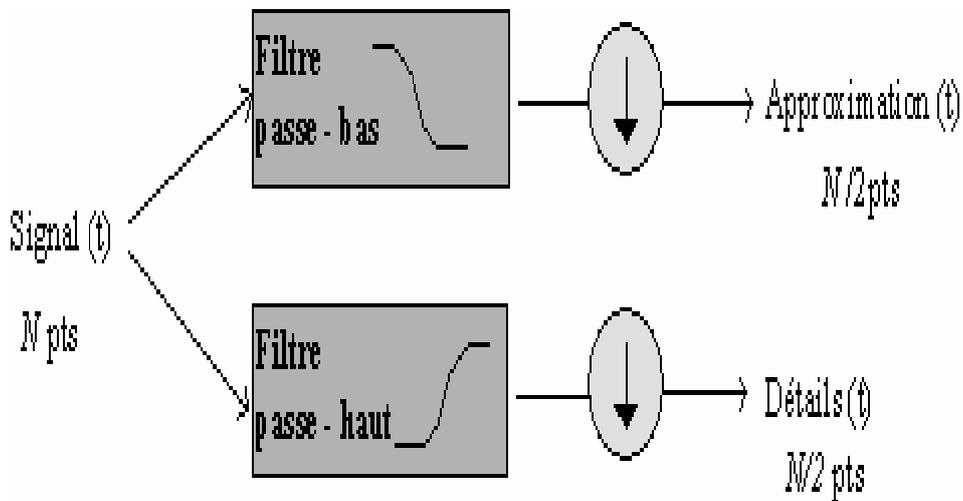


Figure 2.12 : Principe de la cellule de décomposition [23].

Où le symbole  représente l'opération de sous-échantillonnage : on ne prend qu'un point du signal sur deux.

Pour revenir au signal de longueur N , il suffit simplement de sur-échantillonner le signal d'un facteur 2 à chaque itération, avant l'opération de filtrage. Pour cela, il suffit de doubler à chaque pas la longueur de l'approximation et du détail. On passe donc de l'approximation A_j à l'approximation A_{j-1} par l'opération suivante :

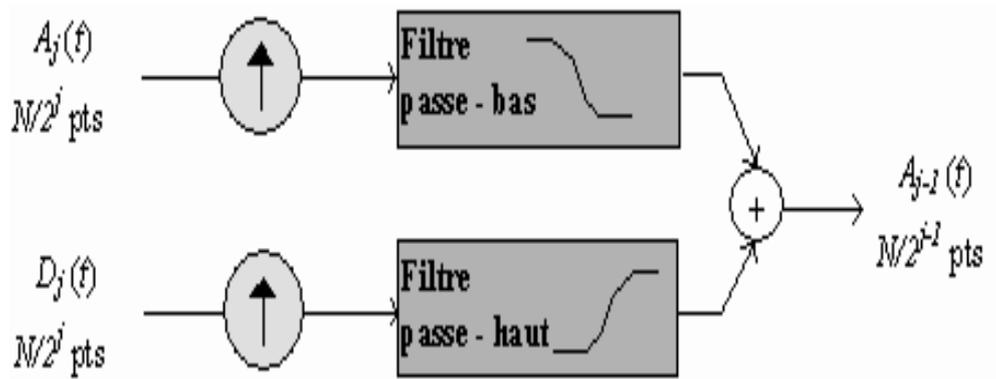


Figure 2.13 : Principe de la cellule de reconstitution [23].

Où le symbole  représente l'opération de sur-échantillonnage afin de doubler sa longueur N.

7 Conclusion

Les ondelettes apparaissent comme une découverte importante en mathématiques appliquées. Dans de nombreux domaines d'application où l'analyse de Fourier était traditionnellement employée, elles ont ouvert une voie alternative, souvent mieux adaptée à la nature des phénomènes étudiés. Elles ont également eu le mérite de favoriser le dialogue entre différentes communautés scientifiques intéressées par leurs potentialités.

Dans ce chapitre, nous avons vu une introduction à la théorie des Ondelettes qui sont les plus utilisées en traitement d'images et nous avons présenté ensuite quelques familles d'ondelettes. Nous avons parlé de l'analyse multi résolutions et aussi sur la notion de détails et d'approximations qui expliquent le principe de base de la TOD.

*Chapitre 03 : Les réseaux des neurones
artificiels (RNA)*

1 Introduction

Au cours des dix dernières années, l'utilisation des réseaux de neurones artificiels (RNA) s'est développée dans de nombreuses disciplines (sciences économiques, environnement, biologie et médecine...). Ils sont particulièrement appliqués pour résoudre des problèmes de classification, de prédiction, de catégorisation, d'amélioration, de reconnaissance des formes.

Les RNA sont également applicables dans toutes les situations où il existe une relation non linéaire entre une variable prédictive et une variable prédite. Par leur nature et leur fonctionnement, les RNA peuvent détecter les interactions multiples non linéaires parmi une série de variables d'entrée, ils peuvent donc gérer des relations complexes entre les variables indépendantes et les variables dépendantes. [8]

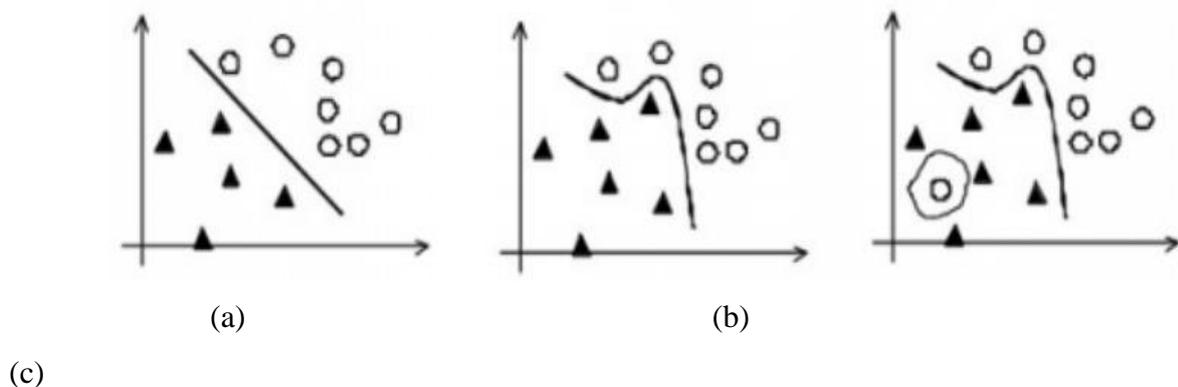


Figure 3. 1 : Discrimination entre les paramètres « triangle » et « rond » [8]. (a) linéaire - (b) : non linéaire - (c) : non continue.

Dans cette étude nous avons utilisé les réseaux de neurones artificiels pour faire la classification de texture. Cette méthode a montré son efficacité dans de nombreux domaines d'applications tels que le traitement d'image, la catégorisation de textes ou le domaine médicales et ce même sur des ensembles de données de très grandes dimensions.

2 Historique

L'étude sur les réseaux de neurones a débuté déjà à la fin du 19^{ème} siècle avec les travaux de Willam James en 1890, après l'élaboration d'une théorie sur les activités du cerveau, plus précisément au niveau du neurone et de la propagation de son excitation

sur ces voisins Les premiers travaux sur les réseaux de neurones artificiels sont débutés au début des années 1940 et ont été menés par Mc. Culloch et Pitts, ils décrivent les propriétés du système nerveux à partir de neurones idéalisés : ce sont des neurones logiques (0 ou 1). Dix années plus tard, en 1950, a été constitué le premier modèle réel d'un réseau de neurones. En 1960, le premier perceptron est créé par Rosenblatt. Plus, durant les années 1970 il y eut une remise en cause de l'intérêt des réseaux car les ordinateurs apprenaient lentement, coûtaient très cher et leurs performances n'étaient pas si impressionnantes. La disponibilité croissante des mini et microordinateurs, vers la fin des années 1970, a permis aux réseaux de neurones de prendre un nouveau départ. L'évolution des modèles du réseau et les algorithmes d'apprentissages ont donné aux réseaux de neurones, une grande richesse de comportement et une capacité à résoudre des problèmes complexes. [25]

3 Réseaux de neurones Artificiels :

3.1 Définitions

Les Réseaux de Neurones Artificiels (RNA) ou réseaux connexionnistes sont fondés sur une représentation schématique des neurones biologiques. Cette présentation tente de mimer et d'interconnexions les cellules du cerveau humain. La réponse du réseau de neurone à un signal d'entrée dépend de paramètres appelés poids synaptiques (mémoire). Une loi d'apprentissage ajuste progressivement ces paramètres pour réduire un paramètre d'erreur. L'objectif, d'un point de vue global, est d'exécuter des calculs complexes et de trouver, par apprentissage, une relation non linéaire entre des données numériques et des paramètres. L'élément fonctionnel du réseau de neurones artificiels est le neurone formel. [9]

3.2 Neurone biologique

Les modèles de réseaux de neurones artificiels sont issus du fonctionnement du cerveau. Il contient d'environ 10^{12} neurones (mille milliards), avec 1000 à 10000 synapses (connexions) par neurone. On voit ainsi sa complexité étonnante. Les connexions neuronales permettent le transfert d'informations sous forme d'impulsions électriques.

Le neurone biologique (Figure 3.2) est une cellule composée d'un corps cellulaire et d'un noyau. Le corps cellulaire se ramifie pour former les dendrites. C'est par les dendrites que l'information est acheminée de l'extérieur vers le stroma ou corps du neurone. L'information traitée par le neurone chemine ensuite le long de l'axone (unique) pour être transmise aux autres neurones. La transmission entre deux neurones n'est pas directe. En fait, il existe un espace intercellulaire de quelques dizaines d'angströms (10^{-9} m) entre l'axone du neurone afférent et les dendrites du neurone efférent, la jonction entre deux neurones est appelée la synapse.[11]

Un neurone ne se borne pas à faire passer l'information, il la filtre. L'objectif des réseaux de neurones artificiels est donc de modéliser le fonctionnement des neurones réels et de permettre un apprentissage. [12]

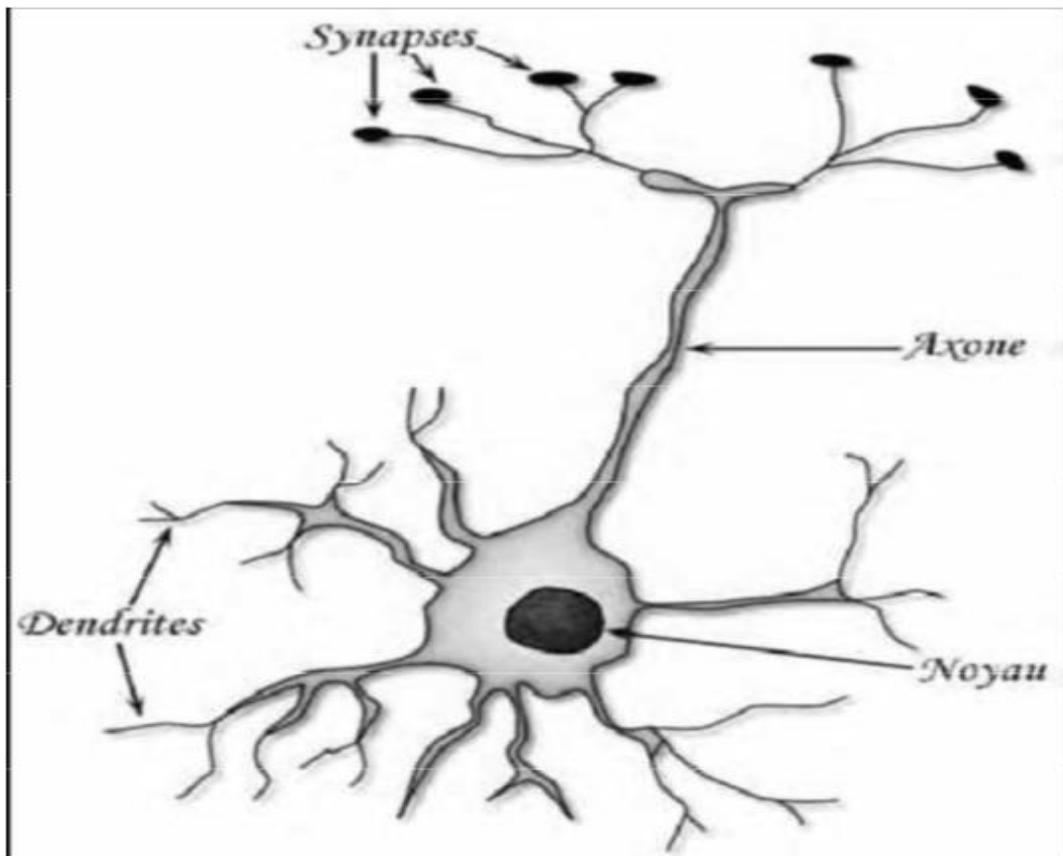


Figure 3.2: Schéma représentatif d'un neurone biologique [10].

3.3 Neurone formel

3.3.1 Définition

Le neurone formel ou artificiel est un processeur élémentaire imitant grossièrement la structure d'un neurone biologique. Il contient plusieurs entrées et une sortie. Chaque entrée P est pondérée par un poids $W_{1,R}$. La fonction de sommation est appliquée pour produire n . La fonction d'activation f est appliquée ensuite sur n . La (figure 3.3) montre le modèle classique d'un neurone artificiel. [12]

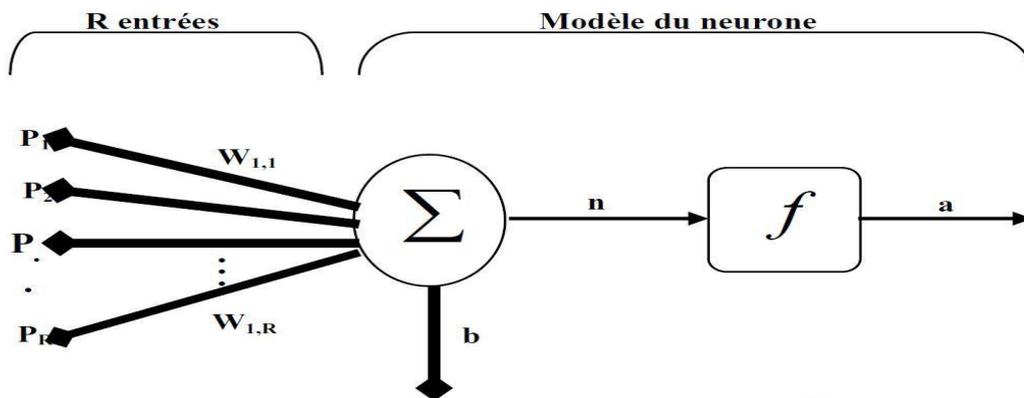


Figure 3.3 : Représentation schématique d'un neurone artificiel. [01]

Avec:

- P : entrées du neurone (pixels d'entraînements dans notre cas).
- $W_{1,R}$: poids synaptique.
- Σ : activation du neurone.
- f : Fonction d'activation.
- a : sortie du neurone (pixels classifié).
- n : fonction de sortie (résultat de la somme pondérée.).
- b : biais (seuil).

3.3.2 L'état des neurones

Les neurones artificiels sont un élément qui a un état interne. Il reçoit des signaux qui lui permettent éventuellement, de changer d'état. Par S nous ferons référence à un ensemble des états possibles d'un neurone. L'état d'un neurone peut alors être déterminé dans l'intervalle $S = [-1, 1]$, où -1 représente la valeur minimum du signal, et 1 le maximum. L'état d'un neurone est fonction des états des neurones auxquels il est

relié. Pour calculer l'état d'un neurone il faut donc penser aux connexions entre ces neurones et d'autres neurones. Ensuite, nous déterminons les connexions entre les neurones et leur poids. [9]

On pourra résumer cette modélisation par le Tableau (2.1), qui nous permettra de voir clairement la transition entre le neurone biologique et le neurone formel.

Tableau 3. 1 : Analogie entre le neurone biologique et le neurone formel.

Neurone biologique	Neurone artificiel
Synapses	Poids de connexion
Axones	Signal de sortie
Dendrite	Signal d'entrée
Soma	Fonction d'activation

4 Architecture des réseaux de neurones

Un RNA (Réseau de Neurones Artificiels) est un ensemble de neurones formels (d'unités de calcul simples) associés en couches (ou sous-groupes) et fonctionnant en parallèle.

Dans un réseau de neurones multicouche les neurones sont organisés en couche successive, chacune de ces couches comportant plusieurs neurones. Chacun de ces neurones fait un traitement indépendant des autres et transmet le résultat de son analyse au sous-groupe suivant L'information donnée au réseau va donc se propager couche par couche, de la couche d'entrée à la couche de sortie, en passant soit par aucune, une ou plusieurs couches intermédiaires (dites couches cachées). Il n'y a pas de connexion entre neurones d'une même couche et les connexions ne se font qu'avec les neurones des couches avales, chaque neurone d'une couche est connecté à tous les neurones de la couche suivante et celle-ci seulement. Ceci nous permet d'introduire la notion de sens de parcours de l'information (de l'activation) au sein d'un réseau et donc définir les concepts de neurone d'entrée, neurone de sortie. Par extension, on appelle couche de sortie l'ensemble des neurones de sortie, couche d'entrée l'ensemble des neurones d'entrée. Les couches intermédiaires n'ayant aucun contact avec l'extérieur sont appelés couches cachées. [11]

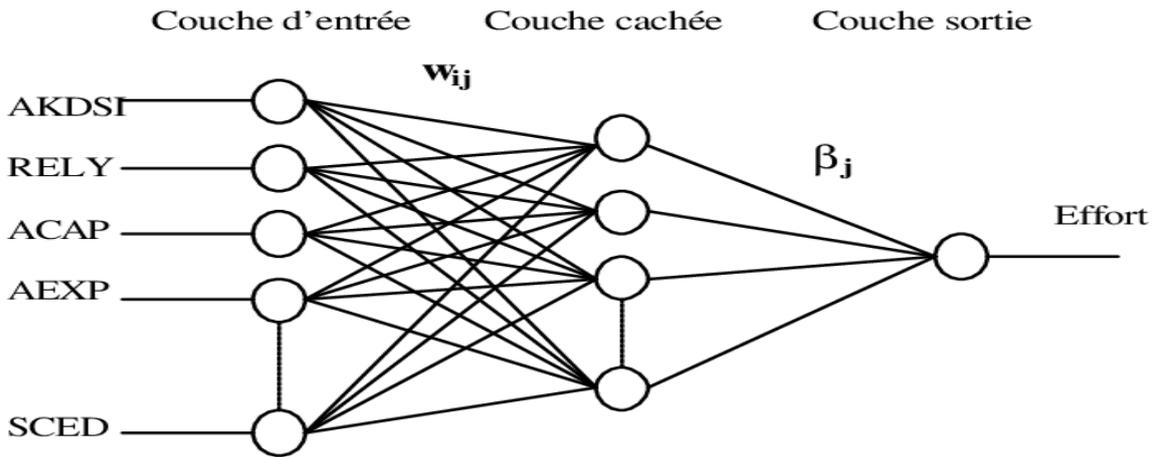


Figure 3. 4: Architecture d'un réseau à couches.

Dans la (figure 3.4), les cercles représentent les neurones disposés en couches. Le réseau représenté ici comporte trois couches, la couche d'entrée qui reçoit les informations sur un certain nombre des neurones, et la couche de sortie qui comportant un seul neurone et donnant le résultat du calcul interne. Entre ces deux couches se trouve une couche invisible de l'extérieur, dite couche cachée servant à effectuer des calculs intermédiaires.

Les neurones sont reliés entre eux par l'intermédiaire de poids synaptiques, notés $w_{i,j}$. L'algorithme d'apprentissage aura pour tâche d'évaluer ces poids en fonctions des données présentées lors de la phase d'apprentissage.

Il est à noter que certains réseaux plus complexes peuvent rajouter des connexions directes entre la couche d'entrée et la couche de sortie. [13]

5 La fonction d'activation des neurones

Dans le domaine des réseaux de neurones artificiels, la fonction d'activation est une fonction mathématique appliquée à un signal en sortie d'un neurone artificiel.

La fonction d'activation 'F' transforme la variable 'n' en une valeur de sortie 'a'. Elle joue un rôle important dans le processus d'apprentissage. [12]

Le biais b joue un rôle de seuil, quand le résultat de la somme pondérée dépasse ce seuil, l'argument de la fonction de transfert devient positif ou nul; dans le cas contraire, il est considéré négatif. Finalement si le résultat de la somme pondérée est: [26]

1. en dessous du seuil, le neurone est considéré comme non-actif.

2. aux alentours du seuil, le neurone est considéré en phase de transition.
3. au-dessus du seuil, le neurone est considéré comme actif.

Il existe plusieurs types de fonctions d'activation on utilise le plus souvent les fonctions d'activations suivantes : la fonction seuil, la fonction partiellement linéaire et la fonction sigmoïde.

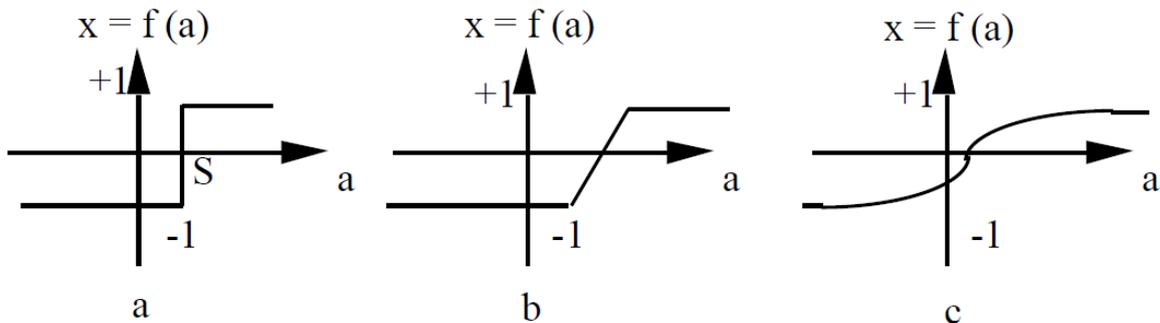


Figure 3.5: Différents types de fonctions de transfert pour le neurone artificiel. [11]

Avec

a : fonction à seuil (S : la valeur du seuil)

b : fonction partiellement linéaire

c : fonction sigmoïde

□ **La fonction seuil:** la fonction seuil applique un seuil sur son entrée. Plus précisément, une entrée négative ne dépasse pas le seuil, la fonction retourne la valeur 1 (vrai), et la fonction retourne la valeur 0 (faux), alors qu'une entrée positive ou nulle ne dépasse le seuil. [12]

□ **La fonction partiellement linéaire :**

Les neurones dont la fonction d'activation est la fonction linéaire sont appelés neurones linéaires. [9]

□ **La fonction sigmoïde :**

Le sigmoïde est la fonction la plus utilisée comme fonction d'activation dans les RNA. Particulièrement dans les réseaux utilisant l'algorithme de rétro-propagation car contrairement à la fonction sigmoïde, les autres fonctions ne donnent que des sorties binaires ce qui rend plus difficile à estimer les poids optimaux. [26]

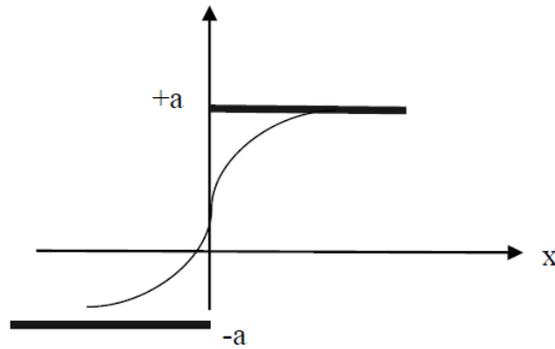


Figure 3.6: Graphe de la fonction sigmoïde. [25]

6 Les connexions entre neurones

Les neurones sont connectés entre eux de différentes manières. (a) Réseaux multicouche à connexions Totales, (b) réseau à connexions locales, (c) réseau à connexions complète et (d) réseau multicouche à connexions récurrentes (dynamique) (Figure. 3.4.) [10].

De la (figure 3.4) on peut distinguer deux familles de réseaux de neurones : non bouclés ou statiques (a) et (b) et bouclés (dynamiques) (c) et (d).

6.1 Réseaux de neurones statiques (réseaux non bouclés)

L'exemple le plus simple de réseau de neurones statique est donné par le perceptron multicouche chaque couche contenant un ou plusieurs neurones. Pour illustrer cela, voici le rôle de chacune des couches dans un perceptron à trois couches.

La première couche c'est la couche d'entrée. Elle recevra les données source que l'on veut utiliser pour l'analyse. Donc sa taille est déterminée directement par le nombre de variables d'entrées.

La deuxième couche est la couche cachée. Dans cette couche, les fonctions d'activation sont généralement non linéaires. Le choix de leur taille (nombre de neurones) n'est pas automatique et il faut ajuster.

La troisième couche est appelée couche de sortie. Elle donne le résultat obtenu après compilation par le réseau des données entrée dans la première couche. Sa taille est aussi déterminée directement par le nombre de variables dont on a besoin en sortie. [10]

6.1.1 Réseau multicouche à connexions Totales

Les neurones sont organisés par couche. Il n'y a pas de connexions entre les cellules d'une même couche et les connexions ne se font qu'avec les neurones des couches avales (fig. 4). Habituellement, Chaque neurone dans une couche est connecté à tous les neurones de la couche précédente et de la couche suivante et celle-ci seulement. Ceci nous permet d'introduire la notion de sens de parcours de l'information (de l'activation) au sein d'un réseau et donc définir les concepts de neurone d'entrée, neurone de sortie. Par extension, on appelle couche d'entrée l'ensemble des neurones d'entrée, couche de sortie l'ensemble des neurones de sortie. Les couches intermédiaires n'ayant aucun contact avec l'extérieur sont appelés couches cachées. [11]

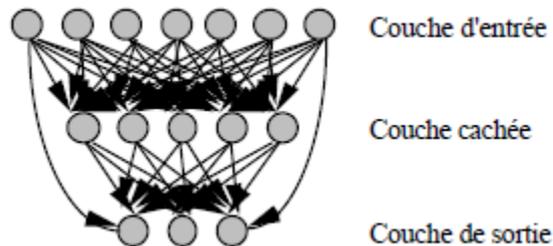


Figure 3.7: Définition des couches d'un réseau multicouche.

6.1.2 Réseau à connexions locales

Ce type des réseaux est une structure multicouche, mais elle est ressemblé à l'image de la rétine, conserve une certaine topologie. Chaque neurone entretient des relations avec un nombre réduit et localisé de neurones de la couche avale. Par conséquent, les connexions sont moins nombreuses que dans le cas d'un réseau multicouche classique. [11]

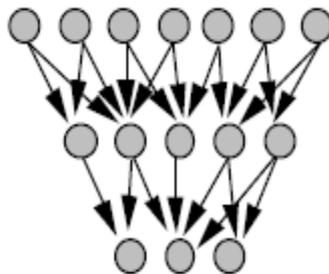


Figure 3.8: Réseau à connexions locales.

6.2 Réseaux de neurones dynamiques ou réseaux bouclés (ou récurrents)

Ce réseau contient des connexions sous forme des boucles, contrairement au réseau non bouclé ou les connexions sont orientées de l'entrée vers la sortie du réseau. Le réseau récurrent accepte tout type de connexion, c'est-à-dire d'un neurone à n'importe quel autre y compris lui-même. Dans ce réseau il est possible de trouver au moins un chemin qui retour à son point de départ en suivant le sens des connexions, ce chemin appelé un « cycle ». [25]

6.2.1 Réseau à connexions récurrentes :

Les connexions récurrentes ramènent l'information en arrière par rapport au sens de propagation définit dans un réseau multicouches.[11]

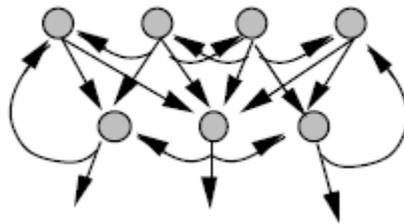


Figure 3.9: Réseau à connexions récurrentes.

6.2.2 Réseau à connexions complètes :

C'est la structure d'interconnexion la plus générale. Chaque neurone est connecté à tous les neurones du réseau (et à lui-même).[11]

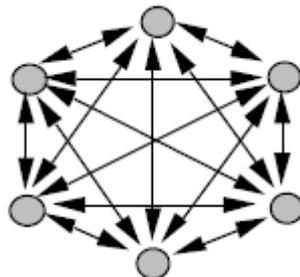


Figure 3.10 : Réseau à connexions complète.

7 Apprentissage des réseaux de neurones :

7.1 Définition

L'apprentissage est la propriété la plus intéressante des réseaux neuronaux artificiels, c'est une étape du développement d'un réseau de neurones durant laquelle le comportement du réseau est modifié jusqu'à l'obtention du comportement désiré.

Le comportement d'un réseau de neurone est régulé par sa connectivité, et plus spécifiquement, par les poids synaptiques des connexions entre les neurones. L'apprentissage d'un réseau de neurone est le processus de détermination de ces poids synaptiques. Ce processus est progressif ou itératif ou les poids du réseau sont modifiés plusieurs fois avant d'atteindre leurs valeurs finales. Au niveau des algorithmes d'apprentissage, il a été défini deux grandes classes selon que l'apprentissage est dit supervisé ou non supervisé. [25]

7.2 Apprentissage supervisé

Dans l'apprentissage supervisé ou l'apprentissage associatif la sortie désirée ou correcte du réseau à une entrée donnée est connue à priori. L'apprentissage du réseau consiste alors à mesurer la différence entre son comportement actuel et le comportement de référence (la sortie désirée) et corriger ses poids de façon à réduire cette erreur et obtenir le résultat désiré.[25]

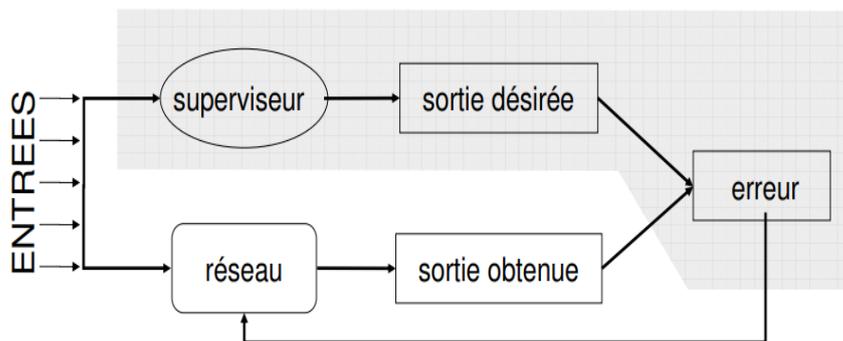


Figure 3. 11 : Apprentissage supervisé.[27]

7.3 Apprentissage non supervisé

Dans l'apprentissage non supervisé, les données fournies au système d'IA ne sont ni étiquetées, ni classées, et les algorithmes du système traitent les données sans aucun entraînement préalable. La sortie dépend des algorithmes codés. L'introduction dans un système d'une approche d'apprentissage non supervisé est un moyen d'expérimenter l'intelligence artificielle.

Les algorithmes d'apprentissage non supervisé peuvent exécuter des tâches de traitement plus complexes que les systèmes d'apprentissage supervisé, mais ils peuvent aussi être plus imprévisibles. Même si un système d'IA d'apprentissage non supervisé parvient tout seul, par exemple, à faire le tri entre des chats et des chiens, il peut aussi ajouter des catégories inattendues et non désirées pour y classer des races inhabituelles, créant la confusion au lieu de mettre de l'ordre.[28]

Les deux types d'apprentissage ont pour but d'ajuster les poids de connexions entre les neurones, en s'accordant de certaines règles.[01]

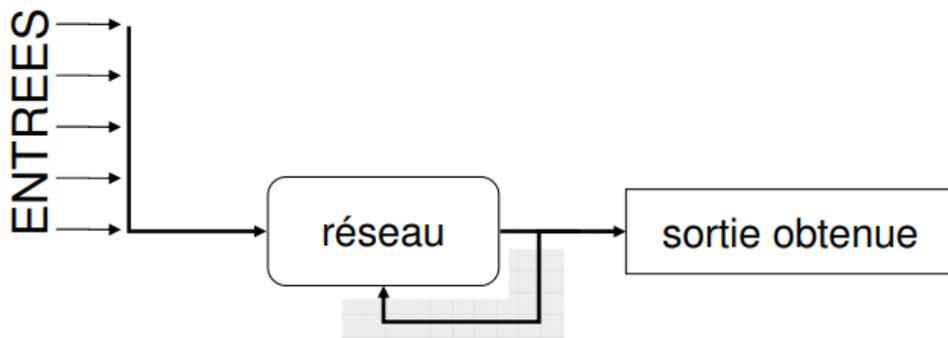


Figure 3. 12 : Apprentissage non supervisé.[27]

8 La règle d'apprentissage de rétro-propagation

Dans le cas d'un apprentissage supervisé, des données sont présentées à l'entrée du réseau de neurones et ce dernier produit des sorties. La valeur des sorties dépend des paramètres liés à la structure du réseau de neurones : les connexions entre neurones, fonctions de sommation et d'activation et les poids synaptiques. [29]

En statique, la rétro-propagation du gradient est une méthode pour calculer le gradient de l'erreur pour chaque neurone du réseau de neurones, de la dernière vers la première

couche. Cette technique utilise l'algorithme classique de correction des erreurs basée sur le calcul du gradient grâce à la retro propagation.

D'une façon générale, nous essayons d'obtenir du réseau une réponse préétablie comme correcte. On dispose pour cela d'une base de connaissance de type entrées /sorties désirées On compare en suite la sortie de chaque neurones de sortie à la sortie attendue. On introduit une fonction d'erreur pour chaque sortie $e_i = s_i - d_i$ que l'on va chercher à minimiser en modifiant les poids du réseau. [25]

L'algorithme de rétro propagation du gradient d'erreur cherche les poids qui minimisent l'erreur quadratique moyenne (MSE) entre la valeur imposée et la valeur estimée par le modèle : [01]

$$MSE = \frac{1}{2} \sum_i (d_i - a_i)^2 \quad (3.1)$$

Où i : dimension de neurone

9 Choix des paramètres

L'utilisateur doit déterminer :

1. les variables d'entrée et la variable de sortie.
2. L'architecture du réseau : le nombre de couches cachées, le nombre de neurones par couche cachée. Ces deux choix conditionnent directement le nombre de paramètres (de poids) à estimer et donc la complexité du modèle. Ils participent à la recherche d'un bon compromis biais/variance c'est-à-dire à l'équilibre entre qualité d'apprentissage et qualité de prévision.
3. Deux autres paramètres interviennent également sur ce compromis : le nombre maximum d'itérations.
4. Le taux d'apprentissage.
5. Le pourcentage de chaque phase (apprentissage, validation et test).[01]

10 Phase de reconnaissance (test) et de validation

Il faut établir la validité des résultats que le réseau de neurones produit, avant employé avec n'importe quel degré de confiance. C'est la phase d'utilisation du réseau ou phase de test. Il existe une autre phase dite de validation, souvent

conduite avec la phase de test. Habituellement les phases de test et de validation impliquent d'évaluer la performance du réseau sur des données qui n'ont pas été employées pour la phase d'apprentissage. Les solutions désirées et celles produites par le réseau peuvent être comparées d'une façon qualitative, ou d'une façon quantitative en utilisant un test statistique. [10]

11 Evaluation de la performance de classification

Évaluer les performances d'un système de classification est un enjeu de grande importance car ces performances peuvent être utilisées pour optimiser les valeurs des hyper paramètres du classifieur.[31]

Le taux de bonne classification est e l'indicateur le plus naturel et le plus évident permettant d'évaluer les performances d'un système de classification et il peut être défini simplement par :

$$T_{bc} = \frac{\text{Nombre d'éléments correctement identifiés}}{\text{Nombre d'éléments total}} \quad (3.2)$$

Il existe de plusieurs critères et méthodes pour évaluer la performance d'un classificateur mais les plus utilisées sont les matrices de confusions et les courbes ROC.

11.1 Matrice de confusion

La matrice de confusion, dans la terminologie de l'apprentissage supervisé, est un outil servant à mesurer et évaluer la qualité d'un système de classification. Elle est obtenue en comparant les données classées (estimées) avec des données de référence (réelles).

Chaque colonne de la matrice représente le nombre d'occurrences d'une classe estimée, tandis que chaque ligne représente le nombre d'occurrences d'une classe réelle (ou de référence). Les données utilisées pour chacun de ces groupes doivent être différentes. L'évaluation d'un modèle de classification est basée sur le nombre de prédictions correctes et le nombre prédictions erronées.[32]

Tableau 3. 2 : Matrice de confusion [31]

	Décision Positifs	Décision Négatifs	
Étiquette Positifs	Vrai Positifs, TP	Faux positifs, FP	Pos ^a
Étiquette Négatifs	Faux Négatifs, FN	Vrai Négatifs, TN	Neg ^b
	PPos ^c	NNeg ^d	N

Avec :

a : Nombre d'éléments étiquetés positifs dans la base.

b: Nombre d'éléments étiquetés négatifs dans la base.

c : Nombre d'éléments classés positifs.

d : Nombre d'éléments classés négatifs.

– Le taux de vrais positifs ("True positive rate"),

$$TPR = \frac{TP}{POS} = \frac{TP}{TP + FN} \quad (3.3)$$

– Le taux de vrais négatifs ("True negative rate"),

$$TNR = \frac{TN}{NEG} = \frac{TN}{TN + FN} \quad (3.4)$$

– Le taux de faux positifs ("False positive rate"),

$$FPR = \frac{FP}{NEG} = \frac{FP}{FP + TN} \quad (3.5)$$

– Le taux de faux négatifs ("False negative rate"),

$$FNR = \frac{FN}{POS} = \frac{FN}{FN + TN} \quad (3.6)$$

– Le taux de bonne classification ou l’exactitude (accuracy) :

$$ACC = TBC = POS * TPR + NEG * (1 - FPR) \quad (3.7)$$

– La précision

$$PREC = \frac{TP}{PPOS} = \frac{TP}{TP + FP} \quad (3.8)$$

– Le rappel (recall)

$$REC = TPR = \frac{TP}{POS} = \frac{TP}{TP+FN} \quad (3.9)$$

Un des intérêts de la matrice de confusion est qu'elle montre rapidement si le système parvient à classifier correctement.

11.2 Courbe de ROC (Receiver Operating Characteristic)

Une courbe ROC (receiver operating characteristic) est un graphique représentant les performances d'un modèle de classification pour tous les seuils de classification. Cette courbe trace le taux de vrais positifs (fraction des positifs qui sont effectivement détectés) en fonction du taux de faux positifs (fraction des négatifs qui sont incorrectement détectés).[33]

En général, les courbes ROC sont basés sur le taux de vrai positifs (TPR) et le taux de faux positifs (FPR) comme le montre la Figure 3.13:

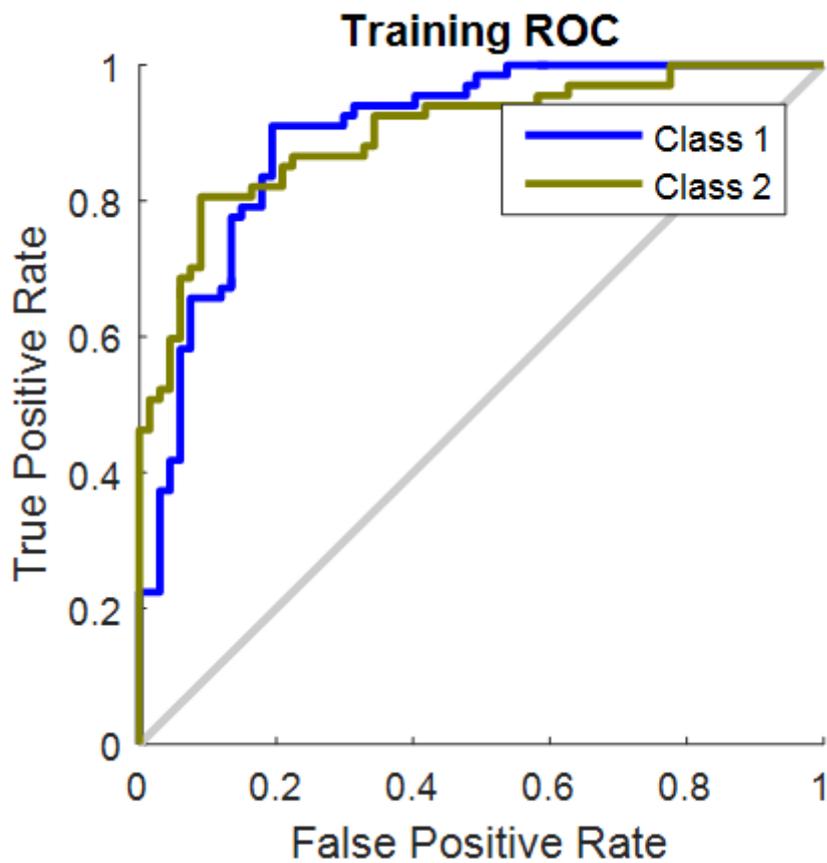


Figure 3.13: Exemple de la courbe ROC de deux classes.[01]

Plus une courbe a des valeurs élevées, plus l'aire sous la courbe est grande, moins le classificateur fait d'erreur. la Figure 3.14 montre un exemple de trois types de courbe ROC correspondants aux trois types de classificateurs :

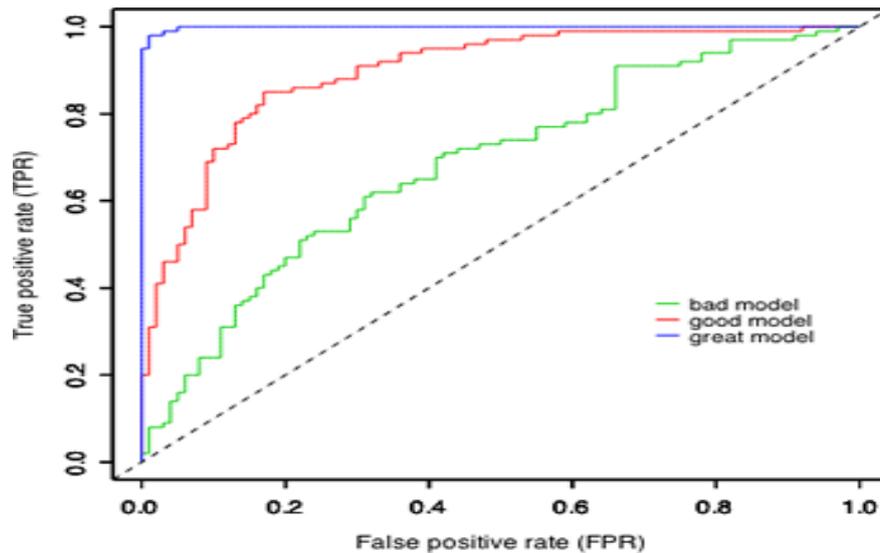


Figure 3.14 : Exemple de trois types de courbe ROC. [34]

Cette représentation met en avant un nouvel indicateur qui est l'aire sous la courbe. Plus elle se rapproche de 1, plus le classificateur est performant.

12 Propriétés des réseaux de neurones

Les réseaux de neurones possèdent quelques propriétés fascinantes, parmi les quelles on peut citer.

- Le parallélisme : il permet une rapidité de calcul supérieure, mais exige de penser et de poser différemment les problèmes à résoudre.
- La capacité d'adaptation: C'est la capacité d'apprentissage qui permet au réseau de tenir compte de nouvelles contraintes ou de nouvelles données. elle se caractérise dans certains réseaux par leur capacité d'auto organisation qui assure leur stabilité.
- La mémoire distribuée: Dans les réseaux de neurones, la mémoire d'un fait correspond à une carte d'activation des neurones. Cette carte est en quelques sorte un codage du fait mémorisé.
- La capacité de généralisation: La capacité de généralisation des réseaux de neurones a été mise en lumière par l'exemple de l'apprentissage des formes du passé pour les verbes de l'Anglais. Il est alors intéressant de disposer d'un système qui puisse apprendre à trouver des règles sous-jacentes ou à mimer les comportements qui permettent de résoudre le problème.

- Facilité de construction: La simulation informatique d'un réseau de neurone pour une petite application est simple et ne nécessite qu'un temps de développement assez court. [25]

13 Domaines d'application des réseaux de neurones

Les réseaux de neurones sont de puissants outils d'interprétation et d'analyse des données. ils s'appliquent sur une grande variété de domaines. [25]

Les réseaux de neurones ont été principalement appliqués en :

- La reconnaissance de la parole.
- La reconnaissance des caractères dactylographiés ou manuscrits.
- Imagerie biomédicale.
- Biométrie (reconnaissance des empreintes, visages, iris)
- Diagnostic des machines.
- Reconnaissance des défauts.
- Les prévisions météorologiques.

14 Conclusion

Les réseaux de neurones artificiels, inspirés du comportement du cerveau humain, permettent de créer de l'intelligence artificielle. Notamment appliqués en datamining principalement à travers l'apprentissage non supervisé, ils servent à prédire, à identifier et à classifier les données. L'apprentissage, moteur essentiel du système, leur permet d'assimiler un traitement d'information à travers une fonction et de le reproduire pour les données qui lui seront ensuite présentées.

Dans ce chapitre, nous avons présenté quelques notions de base sur les réseaux de neurones formels et leur Propriétés, et nous avons donné quelques informations permettant d'entrevoir les relations existantes entre ces réseaux et la classification et aussi nous avons parlé sur L'apprentissage qui est la propriété la plus intéressante des réseaux neuronaux artificiels.

Malgré les résultats très convainquant de ce réseau dans la classification, il reste toute de même limité.

Chapitre 04 : Résultats de Simulation

1 Introduction

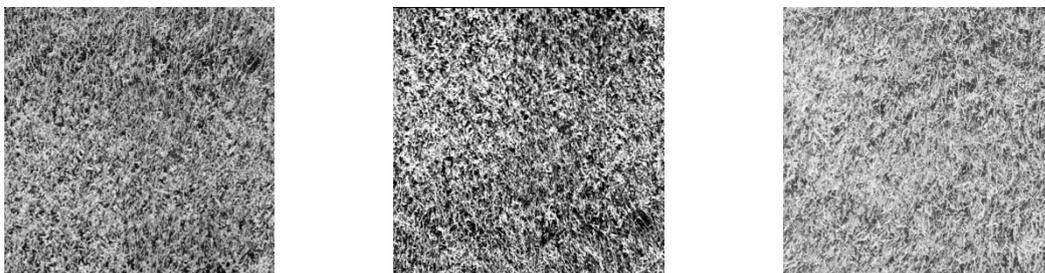
Dans ce chapitre, nous allons présenter la méthode de la transformation en ondelettes discrète (DWT) pour l'extraction de caractéristiques, avec et sans étape de prétraitement pour la classification des textures à l'aide de réseaux de neurones pour la reconnaissance de formes et l'étude de l'effet du prétraitement, tout en améliorant encore les performances de classification. Pour valider la méthode proposée, nous allons tester cette nouvelle contribution sur deux bases de données.

2 Bases de données utilisées

Pour valider la méthode proposée, nous allons tester cette nouvelle contribution sur deux bases de données.

2.1 Base de données textures BRODATZ

La base de données BRODATZ contient en réalité 112 textures, regroupées en 13 classes. Nous avons utilisé deux classes de la base de données Brodatz qui sont présentées dans la figure 4.1. Pour chaque classe, il y a trois textures images, deux avec la taille (512x512) pixels et la troisième avec la taille (1024x1024) pixels, donc pour augmenter la quantité de données nous avons partitionné chaque image de la base de données en 16 sous-images (voir Figure 4.2). Pour les deux images, ils deviennent de taille (128x128) pixels et pour la troisième de taille (256x256) pixels. Donc, pour chaque classe, nous avons 48 images. et en totale de 96 images pour les deux classes de la base de données utilisée. On prend 70% des images pour l'apprentissage, 15% pour le test et 15% pour la validation.



CLASSE1

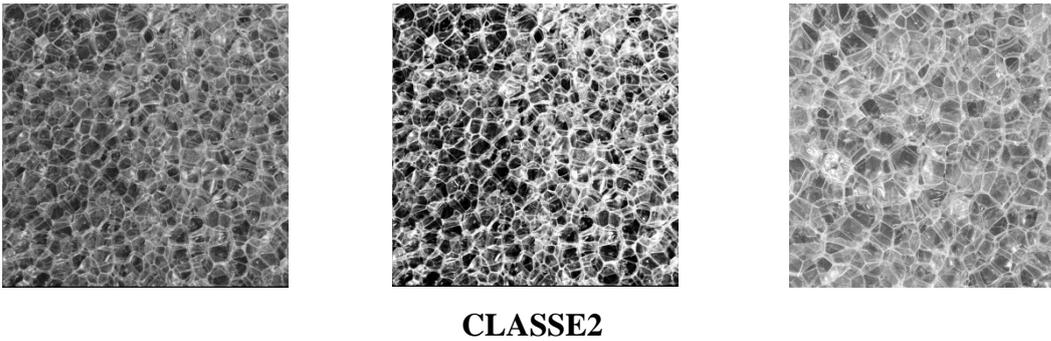


Figure 4.1: Les deux classes utilisées de la Base de données textures.

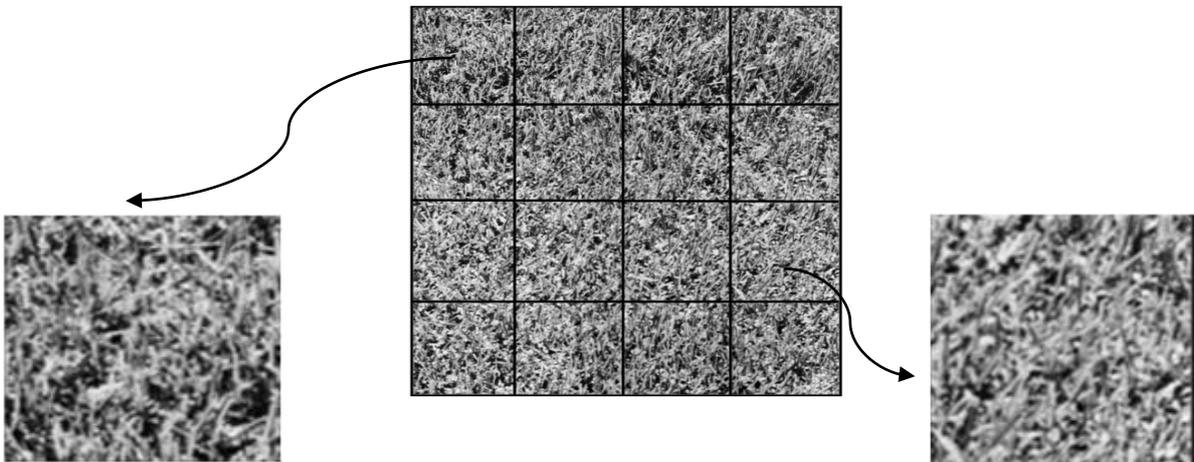


Figure 4.2 : Exemple des opérations effectuées sur une texture prise de la classe 1, subdivisée en sous-images (Base de données BRODATZ).

2.2 Base de données textures OUTEXT

La base de données OUTEXT contient 29 classes de différentes textures.

Nous avons choisi deux classes de la base de données OUTEXT publiquement disponible qui sont présentées dans la Figure 4.3.

- Classe 1 : Riz d'orge (barley rice).
- Classe 2 : Flocons (Flakes).



CLASSE1 (barley rice).



CLASSE2 (Flakes).

Figure 4.3: Exemple d'images des deux classes de la Base de données textures OUTEX.

Pour chaque classe, il y a dix textures images couleur avec la taille (746×538) pixels. Nous avons effectué les opérations suivantes :

- Changer la taille de chaque image vers la taille (512×512) pixels.
- partitionner chaque image en 16 sous-images de taille (128×128) pixels, donc, pour chaque classe, nous avons 160 images et en totale de 320 images pour les deux classes de la base de données utilisée.

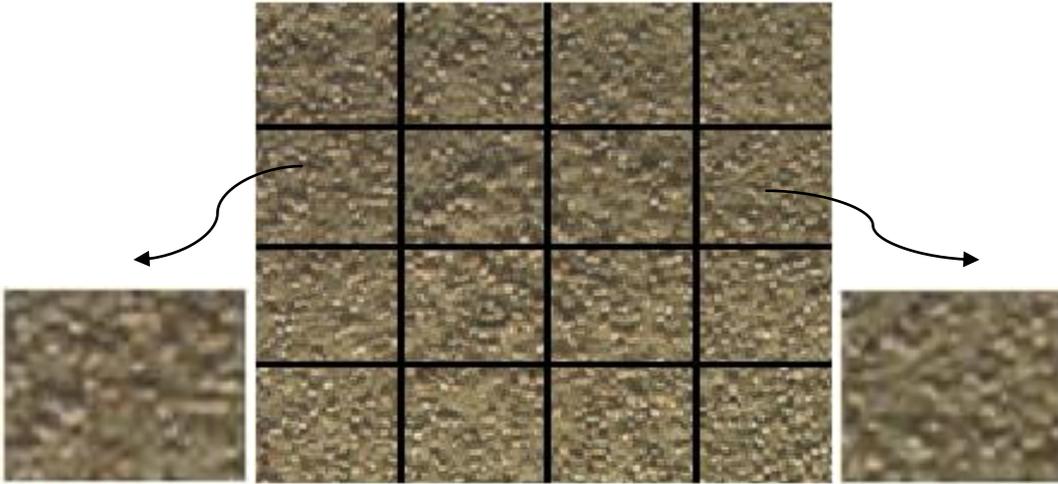


Figure 4.4: Exemple des opérations effectuées sur une texture prise de la classe 1, subdivisée en sous-images (Base de données OUTEX).

3 Environnement de travail

L'environnement de programmation est Matlab R2013a et caractéristiques de PC (microprocesseur : Intel (R) Core (TM) i3-6006U CPU @ 2.00GH 1.99GH, RAM : 4.00Go, Système d'exploitation 64 bits). La mise en œuvre réalisée dans la plateforme Matlab nous permet de bénéficier de ses sous- programmes de traitements d'images très performants. Dans une telle configuration, le temps de fonctionnement nécessaire pour effectuer tous ces calculs a été de l'ordre de grandeur de millisecondes par image.

4 Application

Après la préparation de nos bases de données notre travail est représenté en 3 étapes de base :

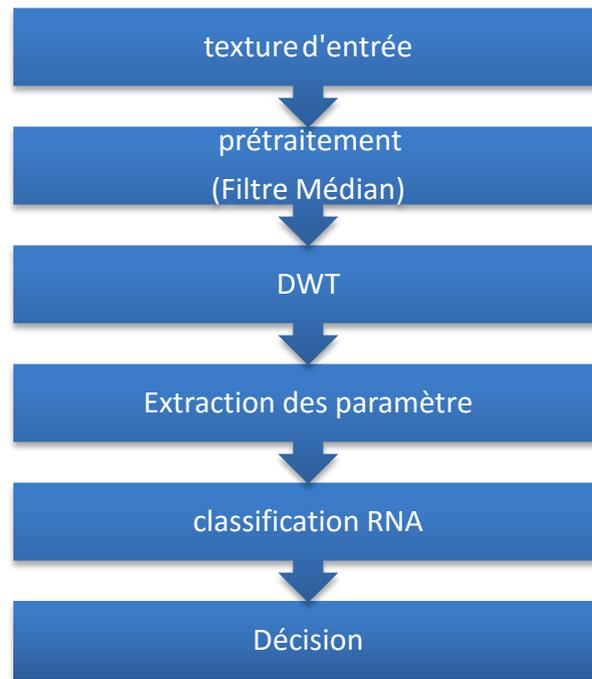


Figure 4.5 : Algorithme proposé.

4.1 Etape de prétraitement de l'image

Chaque image naturelle contient un certain type de bruit et le but de cette étape est d'améliorer la qualité des images en éliminant le bruit. Nous avons choisi le filtre Médian car il est le plus robuste pour éliminer les bruits impulsionnels et le plus utilisé dans ce type de traitement.

4.2 Etape d'extraction des paramètres

Le but de l'analyse est d'utiliser la méthode la plus performante afin d'extraire les paramètres les plus significatives qui permettent de classer notre base de données. Nous allons utiliser l'analyse spatio-fréquentielle basée sur la transformation d'ondelette. Nous allons appliquer la DWT avec l'ondelette (db1) en première résolution pour extraire les paramètres de chaque entrée image de texture de la base de données. Ces paramètres sont : « la variance, la moyenne, l'énergie et l'entropie ». L'extraction de caractéristiques est le processus d'obtention des informations d'une image. La majorité de l'information se trouve dans les bases fréquences (l'image approximation), et le reste de l'information dans les détails images (les contours de l'image). Dans le domaine de DWT, l'énergie est concentrée dans l'image approximée.

Pour chaque image de texture, nous obtenons les attributs (caractéristiques) un vecteur de 4 éléments.

$$\text{Vect_Feat}=[\text{Moy, Var, Energy, Entropy}]$$

4.3 Etape de classification

Nous avons utilisé le réseau de neurones de reconnaissance de formes (MLP) pour classer deux classes choisies dans la base de données publique Brodatz et dans la base de donnée OUTEX..Après extraire les caractéristiques des images de texture dans le domaine des ondelettes, après l'application du DWT (en utilisant les ondelettes de Daubechies (db1)), nous obtenons un vecteur d'attribut de 4 éléments (caractéristiques) qui deviennent les nombres de neurones d'entrée pour notre classificateur RNA, et nous avons deux classes, donc le nombre de sortie est de deux neurones.

5 Résultats et discussion

Nous avons utilisés la fonction: **patternnet** (hiddenSizes, trainFcn, performFcn) de matlab avec les paramètres par défauts :

- **trainFcn** : Les fonctions d'activation (par défaut = 'trainscg').
- **performFcn** : Fonction de performance (par défaut = 'MSE' ('Mean squared Error')).
- Taux d'apprentissage =0.01.
- Erreur = 6.
- Epochs : Nombre d'itérations = 1000.
- Gradient = .1.00e -06.
- 70% Pourcentage d'apprentissage.
- 15% Pourcentage de test.
- 15% Pourcentage de validation.
- **hiddenSizes** : Taille des couche cachées (par défaut : une seule couche cachée avec 10 neurones) (Figure 4.6) montre l'architecture du réseau de neurones par défaut.

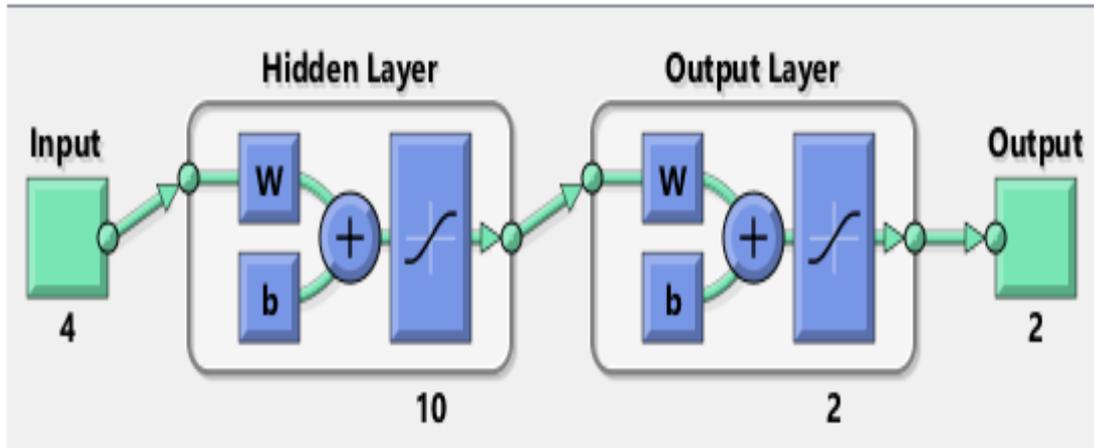
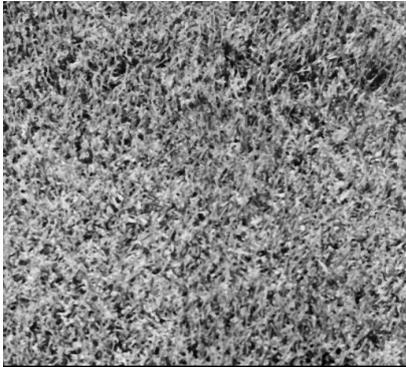


Figure 4.6: Architecture du réseau de neurones utilisé

Dans notre travail nous avons gardés toutes les paramètres de la fonction `patternnet()` par défaut sauf pour le paramètre `HiddenSizes` (Taille des couche cachées) nous commençons de faire l'apprentissage avec le paramètre par défaut (10 neurones dans une seule couche cachée) , si elle nous donne un très bon résultat c'est-à-dire le cas idéal nous sauvegardons les paramètres de notre réseau, sinon nous varions le nombre des couches cachées et le nombre des neurones de chaque couche jusqu'à qu'on arrive à l'erreur minimum voulu ou idéal et nous sauvegardons notre réseau et nous évaluons les performances de la classification par l'analyse des matrices de confusion et les courbes ROC pour chaque étapes (apprentissage, validation et test).

Après le processus de préparation des bases des données en partitionnant les images de chaque classe des bases de données en sous-images et cela pour le but pour augmenter le nombre d'images sources originales disponibles dans chaque classes nous passons à l'étape de prétraitement où dans la première étape nous n'avons pas effectué d'un filtre Médian pour éliminer les bruits mais Dans la deuxième étape, nous l'avons fait . La figure qui suit montre l'effet du filtre médian sur l'image originale :

Image de la classe 1



Après filtrage

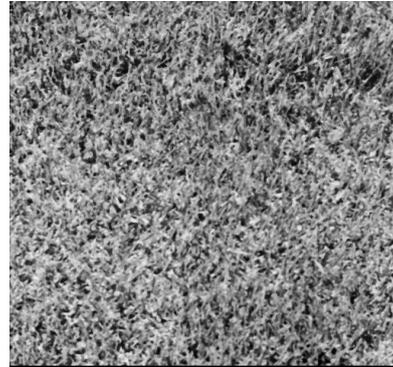


Figure 4. 7 : Exemple de l'étape de prétraitement, image de la classe1 base de données BRODATZ avant et après filtrage (filtre Médian).

Le tableau suivant regroupe les différents résultats de taux de classification (TC%) obtenus pour des différentes valeurs de nombre des neurones utilisées dans une seule couche cachée de notre réseau de neurone RNA, sans appliquer un prétraitement de filtrage (filtre Médian):

Tableau 4.1: les différents taux de classification sans prétraitement pour les deux bases de données (BRODATZ et OUTEX).

Base de données	Nombre de neurones	6	8	10	12	16
BRODATZ	TC%	95.8%	95.8%	95.8%	95.8%	95.8%
	Nombre d'itérations	47	49	56	72	51
OUTEX	TC%	77.2%	77.8%	80.6%	79.1%	79.4%
	Nombre d'itérations	44	60	66	55	52

Le Tableau 4.1 résume les différents taux de la classification, le taux de classification idéal 95.8% est obtenu quel que soit le nombre des neurones dans la couche cachée de notre réseau, mais nous avons sauvegardés les paramètres du modèle de réseau RNA par défaut (10 neurones dans une seule couche cachée) Figure 4.6. Par contre dans le cas de la base de données OUTEX les résultats montrent que le meilleur taux de classification 80.6% est obtenu avec le modèle de réseau RNA par défaut de dix neurones dans la couche cachée.

Nous avons sauvegardés les paramètres de réseau RNA du meilleur taux de classification pour la base de données BRODATZ (95.8%) obtenu avec le modèle de réseau RNA par défaut (10 neurones dans une seule couche cachée) Figure 4.6 et les performances sont évaluées par Les matrices de confusion et les courbes ROC.

La figure 4.8 illustre la confusion de la matrice, la figure 4.9 illustre les courbes ROC et la figure 4.10 illustre les performances d'apprentissage, de test et de validation sans prétraitement de filtre intermédiaire.

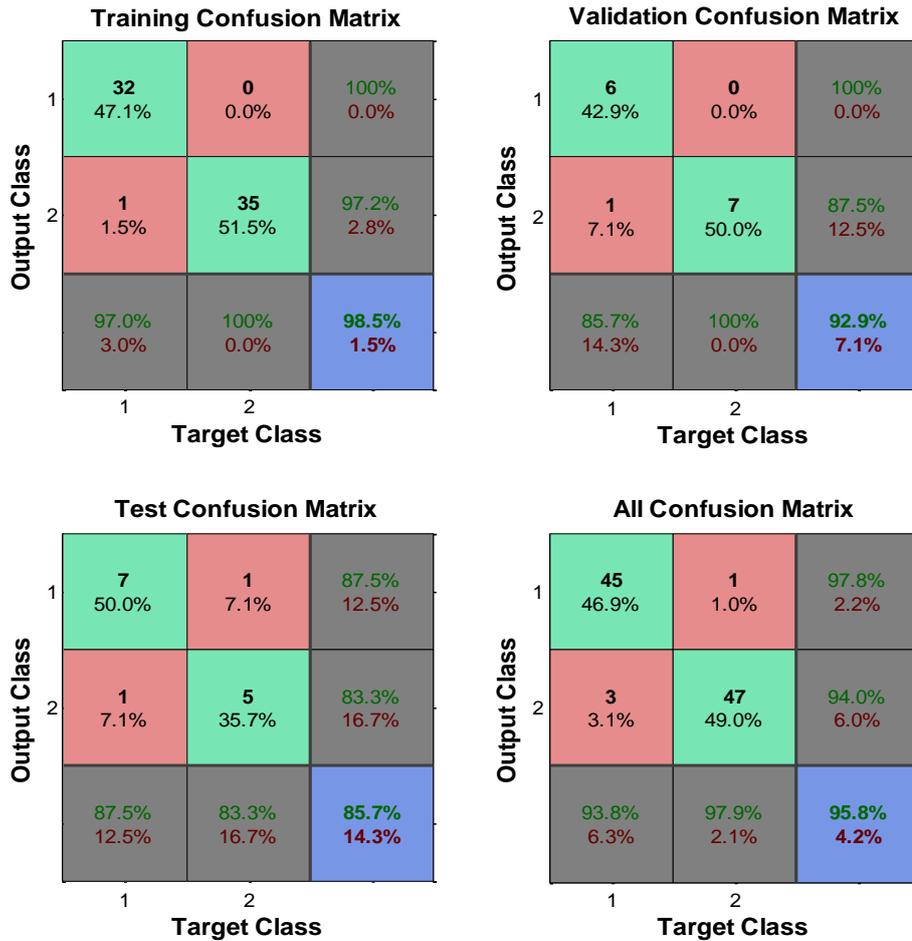


Figure 4.8: Matrice de confusion pour la classification des textures des résultats sans prétraitement. (Base de données BRODATZ).

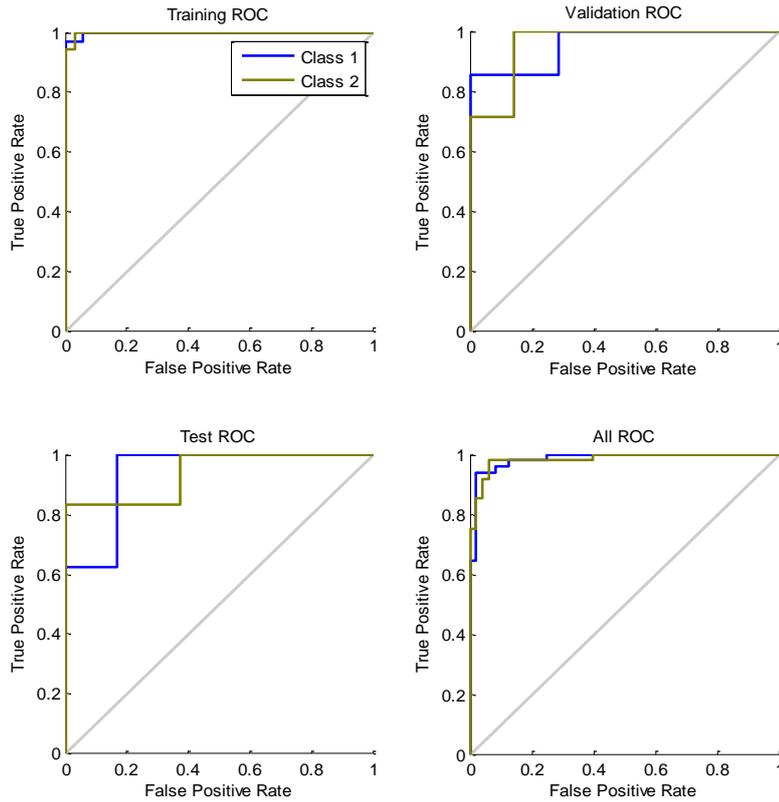


Figure 4.9: Courbes ROC pour la classification des textures sans prétraitement. (Base de données BRODATZ).

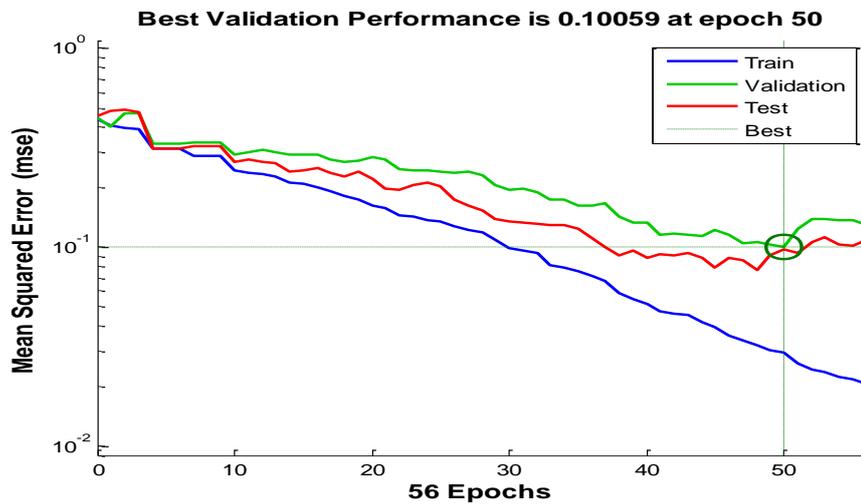


Figure 4.10 : Validation des performances de l'apprentissage, test et validation pour la classification des textures sans prétraitement. (Base de données BRODATZ).

La figure 4.11 illustre la confusion de la matrice, la figure 4.12 illustre les courbes ROC et la figure 4.13 illustre les performances d'apprentissage, de test et de validation avec prétraitement de filtre intermédiaire.



Figure 4. 11: Matrice de confusion pour la classification des textures des résultats avec prétraitement. (Base de données BRODATZ).

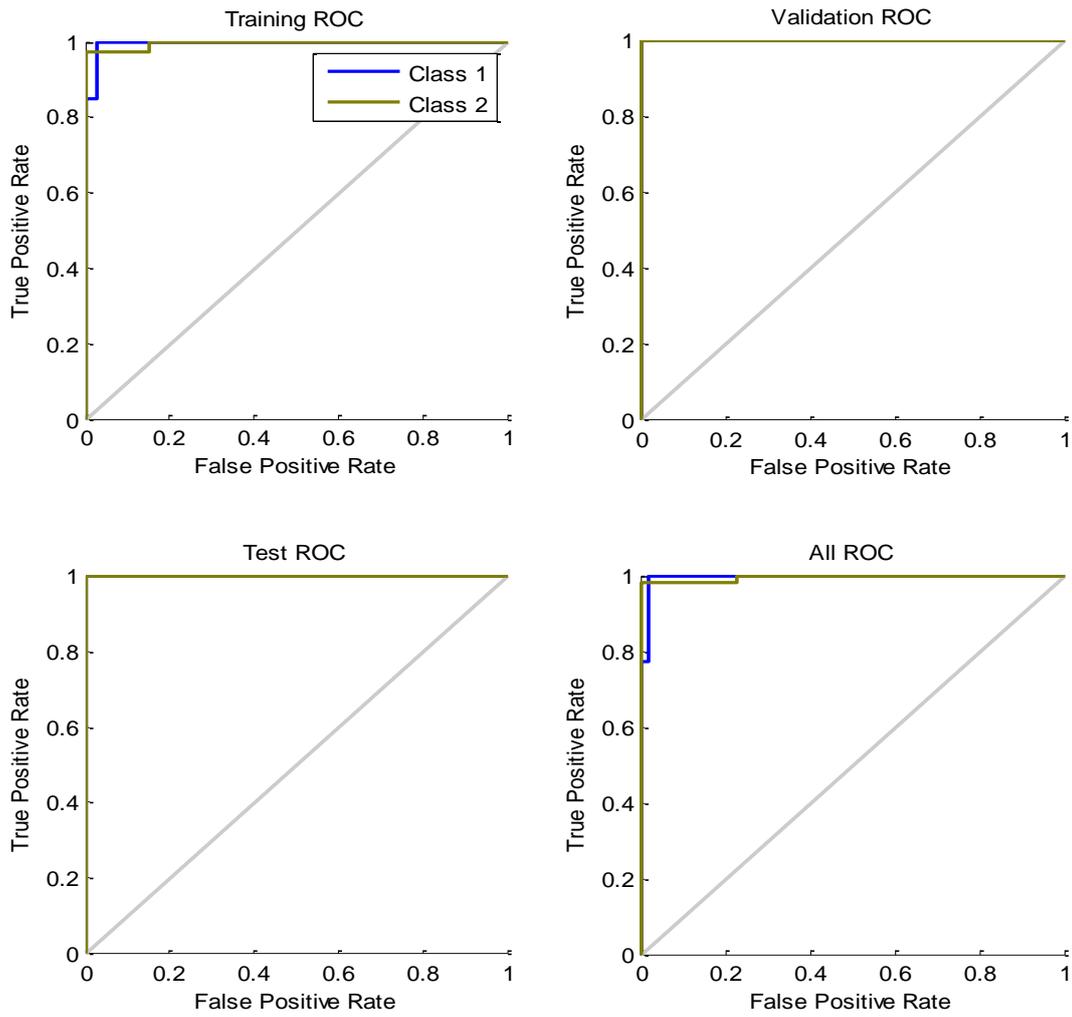


Figure 4. 12 : Courbes ROC pour la classification des textures avec prétraitement.
(Base de données BRODATZ).

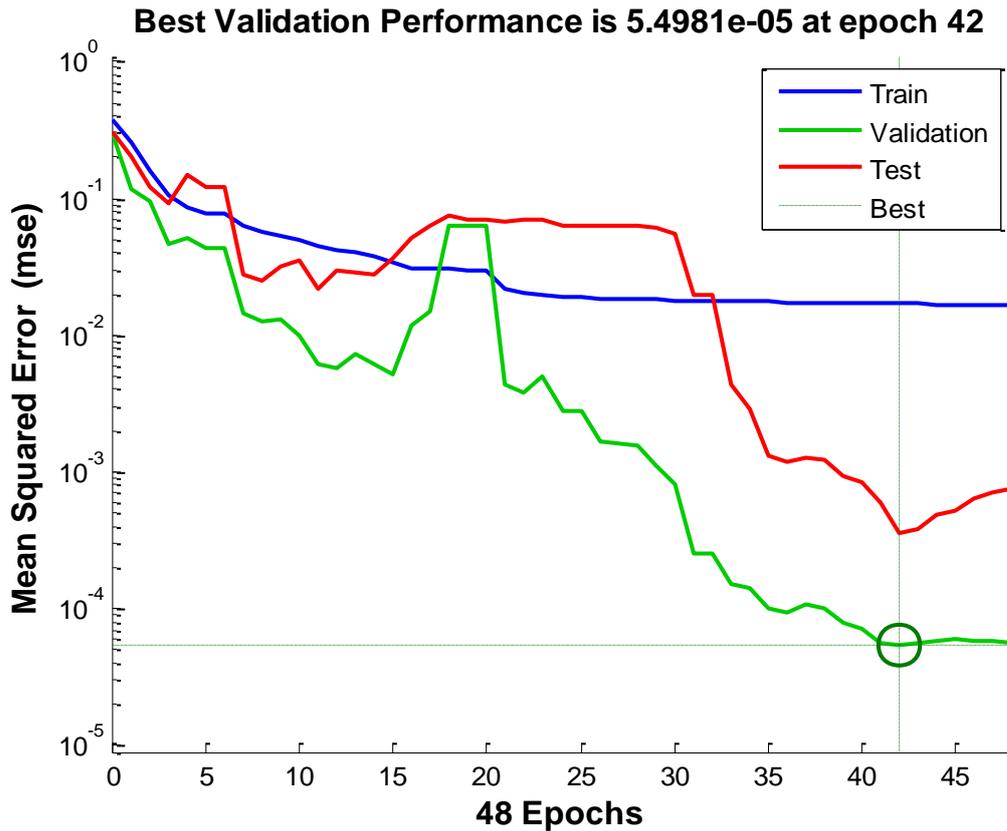


Figure 4.13 : Validation des performances de l'apprentissage, test et validation pour la classification des textures avec prétraitement. (Base de données BRODATZ).

Nous avons sauvegardés les paramètres de réseau RNA du meilleur taux de classification pour la base de données OUTEX (80.6%) obtenu avec le modèle de réseau RNA par défaut (10 neurones dans une seule couche cachée) Figure 4.6 et les performances sont évaluées par Les matrices de confusion et les courbes ROC.

La figure 4.14 illustre la confusion de la matrice, la figure 4.15 illustre les courbes ROC et la figure 4.16 illustre les performances d'apprentissage, de test et de validation sans prétraitement de filtre intermédiaire.



Figure 4.14: Matrice de confusion pour la classification des textures des résultats sans prétraitement. (Base de données OUTEX).

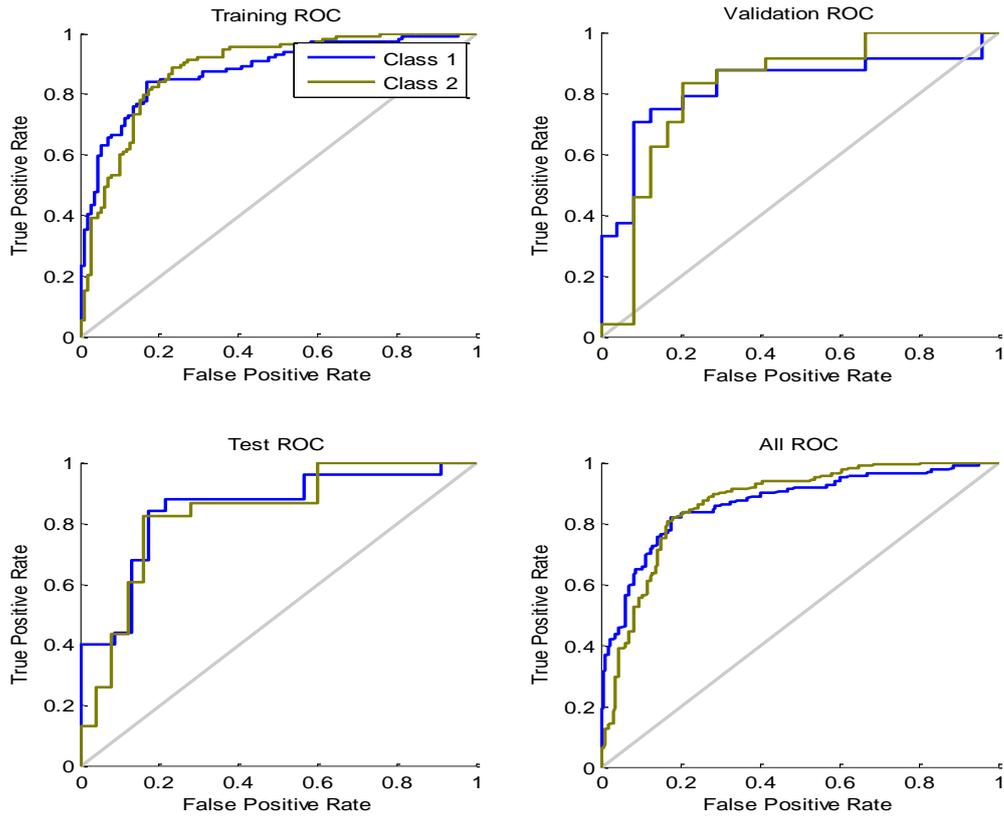


Figure 4. 15: Courbes ROC pour la classification des textures sans prétraitement (Base de données OUTEX).

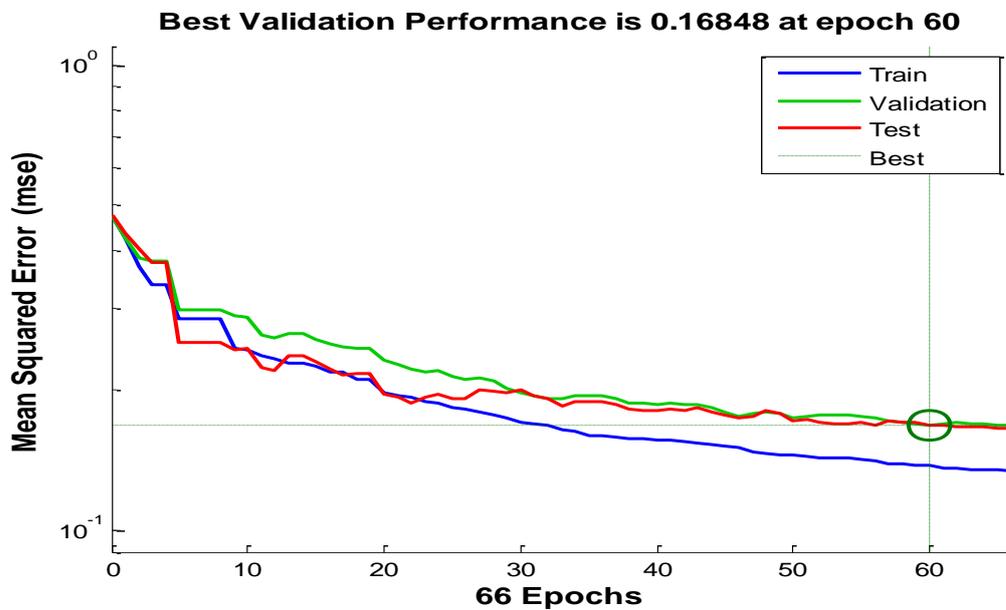


Figure 4. 16 : Validation des performances de l'apprentissage, test et validation pour la classification des textures sans prétraitement (Base de données OUTEX).

La figure 4.17 illustre la confusion de la matrice, la figure 4.18 illustre les courbes ROC et la figure 4.19 illustre les performances d'apprentissage, de test et de validation avec prétraitement de filtre intermédiaire.



Figure 4.17 : Matrice de confusion pour la classification des textures des résultats avec prétraitement. (Base de données OUTEX).

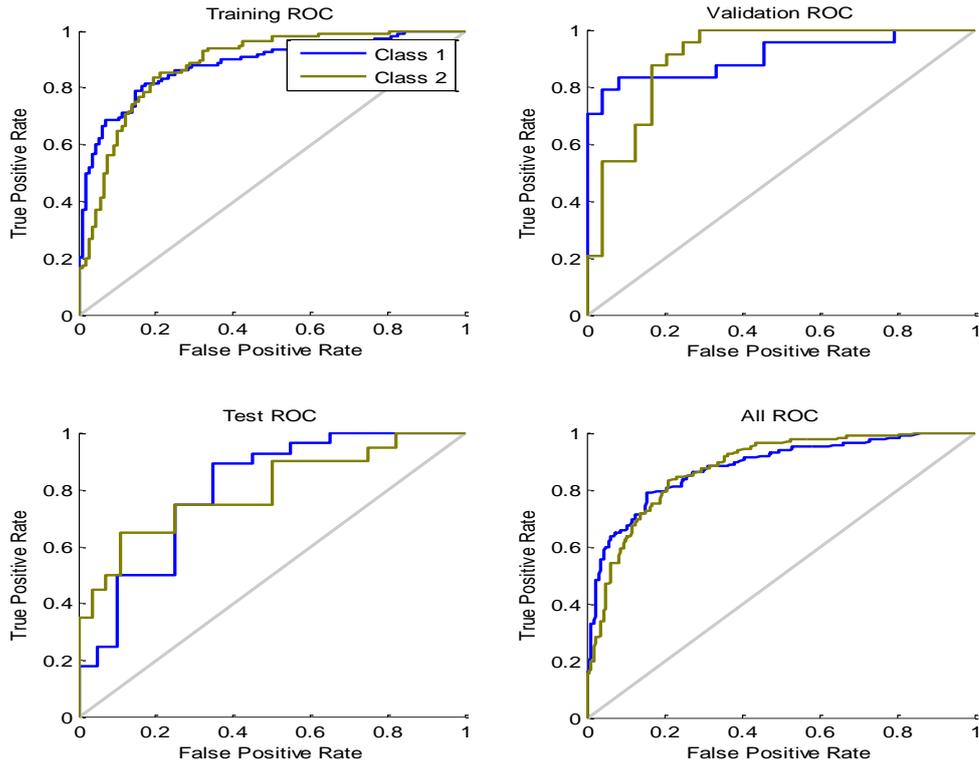


Figure 4.18: Courbes ROC pour la classification des textures avec prétraitement (Base de données OUTEX).

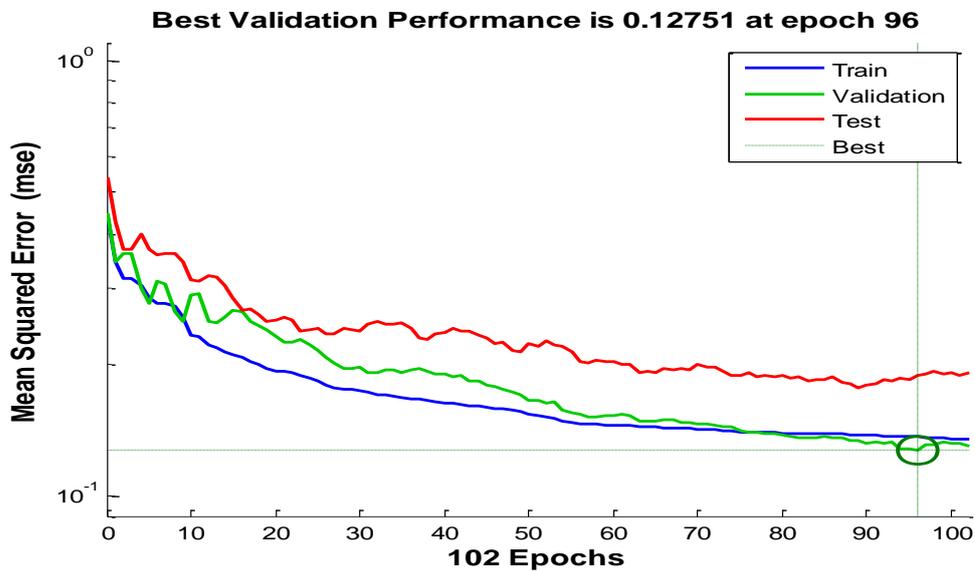


Figure 4. 19: Validation des performances de l'apprentissage, test et validation pour la classification des textures avec prétraitement (Base de données OUTEX).

Les résultats obtenus avec la base de données BRODATZ(textures de niveaux de gris) indique un taux de bonne classification de 95.8% sans prétraitement et indique un taux de très bonne classification de 99.0% avec prétraitement et les résultats obtenus avec la base de données OUTEX (textures de niveaux de couleur) indique un taux de bonne classification de 80.6% sans prétraitement et indique un taux de bonne classification de 81.3% avec prétraitement, alors pour bonne classification nous avons besoin d'effectuer un filtrage sur les images ou un prétraitement.

Nous avons remarqués que le taux de la classification pour la base BRODATZ (textures de niveaux de gris) est le meilleur par rapport à la base OUTEX (textures de niveaux de couleur)

Le tableau suivant regroupe les différents résultats de taux de classification (TC%) avec et sans prétraitement de filtrage (filtre Médian) :

Tableau 4.2 : les différents taux de classification (TC%) avec et sans prétraitement de filtrage (filtre Médian) (Base de données BRODATZ et OUTEX), pour l'ondelette (db1)

	Base de données	Trainin g	Test	Validatio n	All	Itératio n	Performanc e
Sans prétraitement	BRODATZ	98.5%	85.7 %	92.9%	95.8 %	50	0.10059
	OUTEX	81.7%	77.1 %	79.2%	80.6 %	60	0.16848
Avec prétraitement	BRODATZ	98.5 %	100%	100%	99.0 %	42	5.4981e-05
	OUTEX	82.1%	72.9 %	85.4%	81.3 %	96	0.12751

Nous avons présenté dans notre travail une combinaison de caractéristiques pour la classification de texture au moyen d'un réseau de neurones de reconnaissance de motifs. L'évaluation des résultats est évaluée à l'aide de la matrice de confusion et des courbes ROC (caractéristiques de fonctionnement du récepteur). Le vecteur d'attributs de quatre

paramètres sélectionnés (moyenne, variance, énergie et entropie); ces caractéristiques sont extraites de l'image approximée de la transformation en ondelettes discrète (DWT), par l'ondelette de Daubechies (Db1), avec et sans prétraitement au moyen du filtre médian standard.

Pour évaluer notre approche proposée, nous avons choisi deux classes de la base de données Brodatz et de la base de données OUTEX.

La matrice de confusion donne le nombre d'échantillons utilisés dans chaque classe, le nombre d'échantillons correctement classés dans leur classe et le nombre d'échantillons mal classés. Pour le même cas, Les analyses des caractéristiques de fonctionnement du récepteur (ROC : Receiver Operating Characteristics) ont été effectuées pour comparer les performances de ces caractéristiques afin de distinguer les différentes classes. Le graphique des courbes ROC est donné à la figure 4.12 (Base de donnée BRODATZ) et la figure 4.18 (Base de donnée OUTEX). Une courbe ROC a été générée en utilisant un seuil de glissement sur les caractéristiques sélectionnées et en calculant la sensibilité et la spécificité pour chaque seuil. La vraie fraction positive (TPF : True Positive Fraction) ou sensibilité est la proposition des cas anormaux correctement identifiés par la caractéristique. La fraction faux positif (FPF : False Positive Fraction) est la partie des cas normaux incorrectement identifiés par le classificateur comme anormaux.. Enfin, la figure 4.13 (Base de donnée BRODATZ) et la figure 4.19 (Base de donnée OUTEX) présentent les performances de chaque itération et mentionne la meilleure validation des performances de $5.4981e-0.5$ obtenue à la 42^{ème} itération pour la base de donnée BRODATZ et de 0.12751 obtenue à la 96^{ème} itération pour la base de donnée OUTEX. Tous ces chiffres; la matrice de confusion, les courbes ROC et les performances présentent les résultats pour l'apprentissage, les tests et la validation.

Pour la base de donnée BRODATZ la meilleure validation des performances est obtenue à la 50^{ème} itération et est égale à 0.10059 pour le cas sans prétraitement et le cas avec prétraitement est de $5.4981e-0.5$ atteint à la 42^{ème} itération.

Pour la base de donnée OUTEX la meilleure validation des performances est obtenue à la 60^{ème} itération et est égale à 0.16848 pour le cas sans prétraitement et le cas avec prétraitement est de 0.12751 atteint à la 96^e itération.

En conclusion de nos résultats, la classification au niveau de gris est meilleure que la classification au niveau de couleur et la classification avec prétraitement est meilleure que sans prétraitement, nous ne pouvons ignorer l'effet du prétraitement dans les résultats de la classification de texture. Les résultats sont satisfaisants.

6 Conclusion

Dans notre travail, nous avons proposé une nouvelle méthode afin d'extraire les paramètres les plus significatives qui permettent de classer notre base de données en utilisant le classificateur ANN dans le domaine des ondelettes. Nous avons choisi quatre fonctionnalités. Les caractéristiques sont extraites avec et sans prétraitement à l'aide du filtre médian standard. Dans chaque cas, utiliser le classificateur ANN pour classer les textures Brodatz et les texture OUTEX en classe un ou en classe deux. Nous avons obtenu des résultats de classification satisfaisants en termes de précision sur les deux bases de données de texture Brodatz et OUTEX. Notre comparaison montre que les résultats avec prétraitement sont meilleurs que sans prétraitement. Donc, l'étape de prétraitement est très importante et ne peut être ignorée, et montre que la classification au niveau de gris est meilleure que la classification au niveau de couleur.

Ces excellents résultats indiquent que la méthode proposée peut être appliquée à l'imagerie médicale pour classer les images saines des images pathologiques. Comme perspectives.

Conclusion générale

Nous avons présenté dans ce mémoire une méthode d'extraire les paramètres les plus significatives qui permettent de classification des textures basée sur les réseaux de neurones artificielle. Les caractéristiques sont extraites avec et sans prétraitement utilisant un filtre médian standard dans le domaine de l'ondelette.

Le but de cette étude est d'utilise la méthode la transformation en ondelettes discrète (DWT) d'extractions des caractéristiques de l'image de texture avec et sans étape de prétraitement .Cette méthode été appliquée sur deux types de base de données de texture BRODATZ(textures de niveaux de gris) et OUTEX (textures de niveaux de couleur) en utilisant un réseau de neurones artificiels RNA pour la classification et nous avons comparés la précision de la classification en évaluant les performances par les matrices de confusion et les courbes ROC.

Les résultats obtenus de notre étude appliquée sur la base de données permette de conclure :

- La simplicité de simulation est un avantage de cette méthode proposée car les caractéristiques peuvent être obtenues avec seulement quelques calculs et dans un temps d'exécution très petit.
- Tous les résultats sont satisfaisants variant entre un bon modèle de classification et un très bon.
- La méthode de la transformation en ondelettes discrète (DWT) est un bon modèle d'extraction des caractéristiques des textures pour la classification, Ceci et même si le technique utilisée est très sensibles aux bruits d'où la nécessité d'un filtrage convenable selon la nature d'images a étudiées et le domaine d'application.
- La méthode de la transformation en ondelettes discrète (DWT) fournissent les meilleures extractions des caractéristiques et elles sont les plus robustes pour la classification de la texture avec avoir l'utilisation d'un filtrage ou autre prétraitement sur les images.

- Les résultats avec prétraitement sont meilleurs que sans prétraitement. Donc, l'étape de prétraitement est très importante et ne peut être ignorée.
- La classification au niveau de gris est meilleure que la classification au niveau de couleur parce que la méthode proposée est efficace dans le domaine de niveaux de gris.
- Cette nouvelle méthode proposée peut être un modèle convenable pour l'analyse des textures; et cela prouve que les paramètres de l'image peuvent être utilisés comme caractéristiques d'une texture pour la classification.

Il est important de citer, que ce travail ouvre de nouvelles perspectives pour que notre modèle présenté peut être amélioré et pour cela nous proposons quelques perspectives :

Dans notre étude nous avons choisi deux classes de chaque base de données qui sont bien différentes de nature et c'est la raison pour laquelle que le taux de classification atteint 99.0% pour la base de données BRODATZE et 81.3% pour la base de données OUTEX avec l'étape de prétraitement et ce n'est pas le cas dans les domaines d'application où on trouve que les classes sont très proches de nature et très liées entre elles. Pour bien juger l'exactitude et de l'efficacité de cette méthode proposée il faut les appliquer dans des domaines bien définis où l'analyse de la texture est nécessaire pour une bonne classification par exemple le domaine : médicale (l'image IRM, échographie et radiographie), biomédicale, les images radar et satellite, ...etc.

Notre modèle a été évalué en utilisant une base de données BRODATZ (les images en niveaux de gris) et OUTEX (les images en niveaux de couleur) et nous avons choisi de travailler dans le domaine de niveaux de gris et dans le domaine de niveaux de couleur.

Et enfin nous proposons l'étude de cette méthode en utilisant d'autres types de classificateurs comme : les SVM (Machines à Vecteurs Supports) ou la Méta-euristique et de faire un apprentissage non supervisé.

Bibliographie

- [1] Slama Hachemi, « Etude comparative des méthodes d'extractions des paramètres pour la Classification des Textures », Mémoire Master, Université Mohamed Khider Biskra, 2018.
- [2] M. Aissou Bahaeddine, « Analyse des images satellitaires à haute résolution », Mémoire de Magistère, 2014.
- [3] Antoine Lefebvre, « Contribution de la texture pour l'analyse d'images à très haute résolution spatiale. », Thèse de doctorat, Université rennes 2 haute-Bretagne sous le sceau de l'Université européenne de Bretagne, 14 avril 2011.
- [4] Mr. Bagadi Abderrahmane, « Analyse de la texture à base de la transformée de Hermite », Mémoire de Magistère, 2016.
- [5] Rabia Nacim, « Revue des méthodes de segmentation d'images texturées : cas des images couleur », Mémoire de Magistère, Université de Mouloud Mammeri de Tizi-Ouzou, 2011.
- [6] Zehani Soraya, « Proposition d'Outils Analyse et de Classification de Texture : Application au diagnostic des tissus Osseux par Images Médicales », Thèse de doctorat, Université de Biskra, 2018.
- [7] Dhouha Attia, « Segmentation d'images par combinaison adaptative couleur/texture et classification de pixels », Thèse de Doctorat, Université de Technologie de Belfort-Montbéliard, 2013.
- [8] A. Schmitt, B. Le Blanc, M.-M. Corsini, C. Lafond and J. Bruzek, « Les réseaux de neurones artificiels », Bulletins et mémoires de la Société d'Anthropologie de Paris [Online], 13 (1-2) | 2001, Online since 14 January 2010, connection on 27 February 2020. URL : <http://journals.openedition.org/bmsap/4463>.
- [9] Berramdane Nour El houda, « Contribution à l'étude des infiltrations dans la digue du barrage en terre par la méthode des réseaux de neurones artificiels. », Mémoire de Master, Ecole National Supérieure D'hydraulique – Arbaoui A, Janvier 2018.

- [10] Bendaoud Youcef, « Prédiction Des Résistances Mécaniques Des Bétons à Base Des Ciments Composés En Utilisant Les Réseaux Neurones Artificiels. », Mémoire de Magistère, Université Constantine I, Juin 2014.
- [11] Claude TOUZET, « les Réseaux de Neurones Artificiels –Introduction au Connexionnisme-Cours, Exercices et Travaux Pratiques », Juillet 1992.
- [12] Abderrahim Hemamouche, « L’apport de l’analyse de texture et des réseaux de neurones dans la cartographie de l’utilisation du sol en milieu urbain (Cas de la ville de Sherbrooke) », Mémoire de Maîtrisées sciences (M .Sc.), Université de Sherbrooke Québec Canada, 2006.
- [13] Philippe Paquet, « L’utilisation des réseaux de neurones artificiels en finance», Faculté de droit d’Economie et de gestion rue de Blois-B.P.673945067 Orléans Cedex 2 1997.
- [14] F.Truchete, » Ondelettes pour le signal numérique », Edition Hermès, Paris 1998.
- [15] <https://fr.wikipedia.org/wiki/Ondelette>.
- [16] <http://www.lesmathematiques.net/phorum/read.php?17,509009,509129,quote=1#REPLY>
- [17] <http://gwyddion.net/documentation/user-guide-fr/wavelet-transform.html>.
- [18] Benfattoum Nora, Boudjenah Ibrahim, « Implémentation des ondelettes géométriques pour la segmentation d’images médicales», Mémoire de Master, Université M’hamed Bougara de Boumerdes, 2016.
- [19] <https://gilleschardon.fr/wavelets/wavelets.pdf>
- [20] https://en.wikipedia.org/wiki/Discrete_wavelet_transform
- [21] Hela Mahersia Sahbani, Kamel Hamrouni, et Nouredine Ellouze, « Identification de texture par fusion d’attributs multi-résolutionnels et invariants à la rotation », Laboratoire LSTS, Ecole Nationale d’Ingénieurs de Tunis (ENIT) ,2007.
- [22] Chikhaoui Ahmed Abdelkader Djillali, Kebir Abir, «compression D’Images Médicales Par Paquets D’Ondelettes», Mémoire de Master, Université Abou Bakr Belkaïd de Tlemcen, Mai 2016.

- [23] Par Mr. Bendelhoum Mohammed Sofiane, «Évaluation des performances des images compressées par l’algorithme Tod-Spiht, et transmises via le système MC-CDMA», Thèse de doctorat, Université Djillali Liabes de Sidi- Bel-Abbes, 2018.
- [24] Hela Mahersia Sahbani, Kamel Hamrouni, « segmentation d’images texturées par transformée en ondelettes et classification C-moyenne floue», Nationale d’Ingénieurs de Tunis (ENIT) ,2005.
- [25] Houacine Noura, Khelifa Nadia, « Classification des textures par les réseaux de neurones convolutifs », Mémoire de Master, Université Mouloud Mammeri de Tizi-Ouzou, 2018.
- [26] El Mahdi Brakni, «Réseaux de Neurones Artificiels Appliqués à la Méthode Electromagnétique Transitoire Infini TEM», Université du Quebec en Abitibi-Temiscamingue, Mai 2011.
- [27] <https://www.univ-tlemcen.dz/~benmammar/IA2.pdf>
- [28] <https://www.lemagit.fr/definition/Apprentissage-non-supervise>
- [29] https://fr.wikipedia.org/wiki/R%C3%A9tropropagation_du_gradient
- [30] Bourdim Samia, «Méthodes ondelettes et Bayé siennes pour le diagnostic : Application aux machines asynchrones», Université Ferhat Abbas-Setif Ufas (Algérie), Mémoire de Magister, 2011.
- [31] Yannick Oufella «Évolution du Concept de Front ROC et Combinaison de Classifieur» , Université de Rouen, 2 Septembre 2008,
<http://clement.chatelain.free.fr/docs/>.
- [32] “Matrice de confusion”, https://fr.wikipedia.org/wiki/Matrice_de_confusion
- [33] <https://developers.google.com/machine-learning/crash-course/classification/roc-and-auc?hl=fr>.
- [34] <https://jcrisch.wordpress.com/2015/05/04/valider-un-modele-statistique-avec-la-cross-validation/> .