




الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique Et Populaire
وزارة التعليم العالي والبحث العلمي



Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

جامعة العربي التبسي - تبسة

Université Larbi Tébessi – Tébessa –

Faculté des Sciences et de la Technologie

Département de Génie Electrique

MEMOIRE

Présenté pour l'obtention du **diplôme de Master Académique**

En : Génie Electrique

Spécialité : Réseaux et Télécommunications

Par : TERAA Narjes

Thème :

Classification des particules en utilisant les signaux ultrasonores basée sur la transformée en paquet d'ondelettes et le score de Fisher

Présenté et soutenu publiquement, le 11 /06 / 2022, devant le jury composé de :

Mr GATTAL Azzedine.

MCB.

Président.

Mr FERROUDJI Karim.

MCB.

Encadreur.

Mme OUACIFI Malika.

MAA.

Examinatrice.

Promotion : 2022/2021

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

Dédicace

*Aux plus magnifiques femmes de l'univers, à mon paradis, à la lune de ma vie, à ma mère
MAAFA Fatîha,*

*A mon modèle, à mon héros, à la force de ma vie la personne la plus chère à mon cœur, mon
super père TĒRAA Houcine,*

*Malgré qu'aucune dédicace ne pourra traduire mon profond amour et gratitude pour
l'affection que vous m'avez offerte. Les sacrifices illimités, encouragements et prières ont été
pour moi source de zèle et gage de réussite. Que ce mémoire soit l'expression de ma profonde
tendresse et reconnaissance. J'espère être digne et à la hauteur de vôtres confiance et de vos
espérances. Je prie Allah pour vous jouir de bonne santé toute la vie et que vos vœux soient
exaucés.*

*A ma perle, à ma jolie sœur Nachoua. A mon cher frère, mon prince Wassim je prie Allah tout
puissant de vous protéger et de vous accorder la réussite et bonheur.*

*A ma tante distinguée, à ma grande sœur, ma tante Manel, qui m'a soutenu à chaque étape, et
à son mari Laouer Achour pour ses jolie encouragements.*

*A toute ma famille TĒraa et Maafa et surtout mes oncles Taher, Mokdad, Wahid, Zineddine,
et Mostapha.*

*A mon ami qui es toujours à mes côtés, m'ont toujours encouragé, qui me donnent de la
vivacité, l'encouragement... que dieu vous protéger et de vous accorder toujours le succès et le
bonheur et tous que vous aimez.*

Je dédie ce travail à ma bien-aimée, mon amie, ma chère Guebli Meriem.

A mes chères amies, Naima, Salîha, Safwa, Rania, Ilhem, Safa, Meriem, et tous mes amis.

*A tous mes enseignants, du primaire jusqu'à présent. Je vous saurais gré du savoir que vous
m'avez transmis des connaissances que vous m'avez prodiguées. Que ce travail soit le
témoignage de ma gratitude et de ma grande estime.*

A tous les personnes que m'aime.

TĒRAA Narjes

Remerciement

Tout d'abord je remercie le bon Dieu Puissant de la bonne santé, la volonté et de la patience qu'il m'a donné tout au long de mes études.

*Dans les premières lignes de ce mémoire, je tiens à exprimer mes remerciements et mes gratitude au directeur de ce mémoire, Docteur « **FERROUDJI Karim** », pour vos patience, disponibilité, compétence, et surtout vos judicieux conseils, vos suggestions, et vos encouragements incessants qui ont contribué à alimenter mes réflexions.*

Je tiens à exprimer mes gratitude aux membres de jury qui ont bien voulu examiner ce travail:

*Mr **GATTAL Azzedine**, le président de jury,*

Vous me faites un grand honneur en acceptant de siéger au jury de ce mémoire.

*Mme **OUACIFI Malika**, l'examinatrice de jury,*

Je suis très honorée de vous compter parmi les jurys et je vous remercie vivement d'avoir accepté de juger ce travail.

Mes profondes gratitude à tous les enseignants du département Génie électrique, qui me ont encouragés à donner le meilleur de me-même en me assurant une formation aussi meilleure que possible.

Un remerciement spécial aux étudiants de master 2 Réseaux et Télécommunication.

Enfin, je tiens à remercier chaleureusement tous ceux qui me connaissent.

Veillez trouver dans ce travail, l'assurance de ma gratitude et de mon respect.

MERCI

TERAA Narjes



Liste des symboles et acronymes

A :

- **ART** : Théorie de la résonance adaptative « adaptative resonance theory ».
- **AVC** : Accident vasculaire cérébral.

C :

- **CNN** : Réseau de neurone convolutif « convultilive neural network ».

D :

- **DWT** : Transformée en ondelettes discrètes
- **DS** : Spot Doppler.

E :

- **E** : Energie.

F :

- **F** : Fonction d'activation.
- **FFNN**: Forward Neural Network.
- **FLN** : Réseau de liaison fonctionnelle.

I :

- **IA** : Intelligence Artificielle.

M :

- **MLP**: Perceptron multicouche « multi layer perceptron ».

P :

- **PRF**: Fréquence de répétition d'impulsion « pulse repetition frequency ».
- **PNN** : Réseau de neurone probabiliste « probabilistic neural network ».

R :

- **RBF** : Réseau a fonction de base radiale « Radial Basis Fonction ».
- **RF** : Radiofréquence.
- **RN** : Réseau neuronal.

- **RNA** : Réseaux de neurones artificiels.

S :

- **Spread** : Largeur de la gaussienne.

T :

- **TCD** : Doppler transcrânien.
- **TOD** : Décomposition en ondelettes discrètes.
- **TOP** : Décomposition en paquets d'ondelettes.

U :

- **US** : Ultrasonore continue.

W :

- **WPT** : Wavelet Packet Transform.

ω_j : Poids.

σ_j : Largeur.

μ_j : Centre.

μ_i : La moyenne de la caractéristique f_i .

n_j : Le nombre d'échantillons dans la $j^{\text{ème}}$ classe.

$\mu_{i,j}, \sigma^2_{i,j}$: sont la moyenne et la variance de la caractéristique f_i dans la classe j , respectivement.



Liste des tableaux

Chapitre I : Etat de l'art sur l'embolie et techniques de détection.

Tableau I. 1. Caractéristiques physiques d'ultrason 12

Chapitre II : Réseaux de Neurones artificielle.

Tableau II. 1. Comparaison entre neurone Biologique et artificiel 18

Tableau II. 2. Correspondance RNA - domaines d'application..... 20

Tableau II. 3. Les fonctions de transfert $a = f(n)$ 21

Chapitre III : Résultats et discussion.

Tableau III.1: Les caractéristiques utilisées dans la classification. 45

Tableau III.2. Paramètres optimisés des réseaux RBF pour la concentration de 5 μ L..... 47

Tableau III.3. Paramètres optimisés des réseaux RBF pour la concentration de 10 μ L..... 47

Tableau III.4. Taux de classification de toutes les caractéristiques pour concentration de 5 μ l..
..... 48

Tableau III.5. Taux de classification de toutes les caractéristiques pour concentration de
10 μ l..... 48

Tableau III.6. Taux de classification de chaque caractéristique pour concentration de 5 μ l.. 49

Tableau III.7. Taux de classification de chaque caractéristique pour concentration de 10 μ l. 50

Tableau III.8. Sélection des caractéristiques pour la concentration du (5 μ l).....54

Tableau III.9. Sélection des caractéristiques pour la concentration du (10 μ l).....55

Tableau III.10. Etude comparative avec la référence.....57

Liste des figures

Chapitre I : Etat de l'art sur l'embolie et techniques de détection.

Figure I. 1. Exemple d'une embolie.....	3
Figure I. 2. Bulle obstruant le flux artériel terminal dans un vaisseau cérébral.....	4
Figure I. 3. Embolie gazeuses à cause des bulles d'air dans le sang des plongeurs.....	4
Figure I. 4. Développement d'un thrombus : A. Hanche, C. cuisse. B jambe.....	5
Figure I. 5. Schéma d'un poumon avec embolie pulmonaire	6
Figure I. 6. Échographie d'un signal Doppler micro-embolique	8
Figure I. 7. Schéma de principe du Doppler continu	8
Figure I. 8. Schéma de principe du Doppler pulse	9
Figure I. 9. Signal d'embolisation partielle en forme d'onde Doppler.	11
Figure I.10. Oscillations symétriques (linéaires) et asymétriques (non linéaires) d'une microbulle soumise à une onde de pression	14

Chapitre II : Réseaux de Neurones artificielle.

Figure II. 1. Un neurone biologique et ses principaux composants.....	16
Figure II. 2. Modèle d'un neurone artificiel	17
Figure II. 3. Correspondance entre neurones biologiques et neurones artificiels.....	18
Figure II. 4. Fonctions de transfert : (a) du neurone «seuil» ; (b) du neurone «linéaire», et (c) du neurone «sigmoïde».	24
Figure II. 5. Couche de S neurones.....	25
Figure II. 6. Réseau de neurones sans couche cachée.....	25
Figure II. 7. Réseau de neurones avec couche cachée.	26
Figure II. 8. Réseaux de neurones avec plusieurs nœuds de sortie.....	27
Figure II. 9. Structure d'un réseau de neurone multicouche.....	28
Figure II. 10. Fonction sigmoïde.....	29
Figure II. 11. Représentation d'un RBF.....	32
Figure II. 12. Réseau de Neurone RBF.....	33
Figure II. 13. La structure de radiale base fonctions RBF.....	43

Chapitre III : Résultats et discussion.

Figure III.1. Schéma général du modèle de classification par réseau neuronal basé sur la WPT	38
Figure III.2. Dispositif expérimentale	39
Figure III.3. Image échographie pour la concentration des microbulles de 5µl	40

Figure III.4. Image échographique pour la concentration des microbulles de 10 μ l	40
Figure III.5. Signaux normalisés	41
Figure III.6. Arbre de la décomposition en paquets d'ondelettes (T.O.P).....	42
Figure III.7. Schéma de la représentation du nœud père et nœud fils	42
Figure III.8. Décomposition de signaux d'emboles gazeux et de signaux d'emboles solides	43
Figure III.9. Les coefficients de chaque nœud de la décomposition WPT.....	44
Figure III.10. Score de Fisher avec concentration de microbulles (5 μ l).....	52
Figure III.11. Score de Fisher avec concentration de microbulles (10 μ l).....	53
Figure III.12. Sélection des caractéristiques avec Fisher score et RBF la concentration du (5 μ l)	55
Figure III.13. Sélection des caractéristiques avec Fisher score et RBF la concentration du (10 μ l)	56

Résumé :

On parle d'embolie pour désigner tout élément anormal transporté par le sang et bloquant la circulation sanguine. Ce corps étranger insoluble telle qu'une bulle de gaz, un caillot de sang, ou un morceau de thrombus provoque l'embolie ce qui peut bloquer les vaisseaux sanguins. La classification des embolies a une grande importance clinique pour le choix du traitement approprié pour le patient.

Ce mémoire aborde la classification des embolies en utilisant les signaux ultrasonores basée sur la transformée en paquet d'ondelettes, les méthodes de l'intelligence artificielle et le score de Fisher.

Plusieurs méthodes utilisant le traitement des signaux Doppler ont été utilisées pour la détection et la classification des embolies. Malheureusement, ces méthodes ont montré leurs limites pour la distinction entre les embolies et les artefacts. Nous suggérons dans ce mémoire d'exploiter les signaux ultrasonores rétrodiffusés par l'embolie au lieu des signaux Doppler.

Mots clé: Ultrasonores, transformée en paquet d'ondelettes, embolie, le score de Fisher, l'intelligence artificielle, classification.

Summary:

An embolus is any abnormal element carried by the blood and blocking the blood flow. This insoluble foreign body such as a gas bubble, a blood clot, or a piece of thrombus causes embolism which can block blood vessels.

This work discusses the classification of emboli using ultrasound signals based on the wavelet packet transform, artificial intelligence methods, and the algorithm of Fisher score.

Several methods using Doppler signal processing have been used for emboli detection and classification. Unfortunately, these methods have shown limitations in distinguishing between emboli and artifacts. In this study, we suggest to exploit the ultrasound signals backscattered by the embolus instead of Doppler signals.

Keywords: Ultrasonic, the wavelet packet transform, embolism, Fisher score, artificial intelligence, classification.

ملخص :

نتحدث عن الانسداد لتحديد أي عنصر غير طبيعي ينتقل عن طريق الدم ويمنع الدورة الدموية. هذا الجسم الغريب غير القابل للذوبان مثل فقاعة الغاز أو الجلطة الدموية أو قطعة من الجلطة يسبب الانسداد الذي يمكن أن يسد الأوعية الدموية. تصنيف الصمات له أهمية إكلينيكية كبيرة لاختيار العلاج المناسب للمريض ، وتتناول هذه الأطروحة تصنيف الصمات باستخدام إشارات الموجات فوق الصوتية على أساس التحويل الحزمة الموجية وطرق الذكاء الاصطناعي ودرجة فيشر. تم استخدام عدة طرق باستخدام معالجة إشارة دوبلر للكشف عن الصمات وتصنيفها. لسوء الحظ ، أظهرت هذه الأساليب حدودها للتمييز بين الصمات والتحف. نقترح في هذه الأطروحة استغلال إشارات الموجات فوق الصوتية المتناثرة من الصمات بدلاً من إشارات دوبلر..

الكلمات المفتاحية:

الموجات فوق الصوتية ، تحويل الحزمة الموجية ، الانسداد ، مقياس فيشر ، الذكاء الاصطناعي ، التصنيف.

Table des matières

Dédicace :.....	iii
Remerciement :.....	iv
Liste des symboles et acronymes :.....	v
Liste des tableaux.....	vii
Liste des figures :.....	viii
Résumé :.....	x
Introduction Générale :.....	1

Chapitre I : Etat de l'art sur l'embolie et techniques de détection.

I.1. Introduction :.....	3
I.2. Définition d'embolie :.....	3
I.3. Type d'embolies :	3
I.3.1. Embolie artérielle :	3
I.3.2. Embolie gazeuse :.....	4
I.3.3. Embolie pulmonaire :	5
I.4. Causes d'embolie :.....	6
I.5. Techniques de détection :.....	7
I.5.1. Effet de Doppler :.....	7
I.5.1.1. Mode d'utilisation doppler :	8
I.5.1.2. Techniques de détection d'embolie utilisant les signaux Doppler :	10
I.5.2. Les ultrasons :.....	11
I.5.2.1. Techniques de détection et de classification d'embolie utilisant les signaux ultrasons :.....	13
I.6. Agents de contraste pour l'ultrason graphie :	14
I.7. Conclusion :	15

Chapitre II : Réseaux de Neurones artificielle.

II.1. Introduction:	16
II.2.1. Principe :.....	16
II.2.2. Définition :.....	17
II.2.3. Histoire des réseaux de neurones artificiels :.....	19
II.2.4. Domaine d'application des réseaux de neurones (RNA) :	19
II.2.5. Fonction de transfert :	21
II.2.6. Fonctionnement :	24
II.2.7. Architectures de réseaux de neurones :.....	25

II.2.8. Apprentissage des réseaux de neurones :	27
II.3. Types de réseaux de neurones :	28
II.3.1. Le perceptron multicouche (Multi Layer Perceptron MLP) :	28
II.3.1.1. Définition :	28
II.3.1.2. Architecture du réseau :	28
II.3.1.3. Fonction de transfert :	29
II.3.1.4. Apprentissage de model MLP :	29
II.3.1.5. Algorithme de rétro-propagation :	30
II.3.2. Réseaux à fonction radial de base (RBF radial basis fonction) :	32
II.3.2.1. Présentation des réseaux RBF :	32
II.3.2.2. Principe de RBF :	32
II.3.2.3. Architecture de RBF :	33
II.3.2.4. Fonction de transfère :	34
II.3.2.5. Apprentissage de modèles RBF :	35
II.4. Conclusion :	35

Chapitre III : Résultats et discussion.

III.1. Introduction :	11
III.2. Algorithme de détection :	36
III.3 Etude expérimentale (Acquisition des signaux):	39
III.4. Extraction des caractéristiques :	41
III.4.1. La Transformée en paquets d'ondelettes : (WPT : Wavelet Packet Transform)	41
III.4.2. Energie :	45
III.5. Classification sans réduction de dimension :	46
III.5.1. Exactitude (Accuracy) :	46
III.5.2. Classification en utilisant toutes les caractéristiques:	46
III.5.3. Classification en utilisant chaque caractéristique séparément:	49
III.6. Classification avec la réduction de la dimension :	51
III.6.1. Score de Fisher :	51
III.7. Etude comparative :	57
III.8. Conclusion :	58
Conclusion Générale :	59
Références et Bibliographies :	61



*INTRODUCTION
GENERALE*

Introduction Générale :

Les phénomènes emboliques restent l'une des principales causes des troubles graves et parfois mortels dans les pays développés et la plupart des pays en développement. Depuis les années 60, les chercheurs en échographie ont démontré que les embolies gazeuses peuvent être détectées à l'aide d'ondes ultrasonores. Cependant, ce n'est que dans les années 1990 qu'il a été révélé que les emboles solides, composés de thrombus ou d'agrégats plaquettaires, pouvaient également être détectés par ultrasons [1].

La nature de l'embolie (emboles solides ou gazeux) est essentielle pour prédire les complications cliniquement significatives. Par exemple, les patients sous pontage pour la chirurgie à cœur ouvert sont connus pour rencontrer des emboles gazeux mais peuvent également avoir des emboles solides dus à une maladie cardiovasculaire préexistante. La plupart des études diagnostiquent le risque pour ces patients en comptant le nombre d'emboles détectés pendant la chirurgie sans considérer comment la nature pourrait influencer le résultat. Ces emboles peuvent induire des dommages immédiats comme un accident vasculaire cérébral ou une crise cardiaque, d'où l'importance d'un système de détection et de classification automatique [1].

Il existe plusieurs méthodes pour la détection des emboles. L'une de ces technologies est le Doppler transcrânien (TCD). Le TCD est une méthode échographique non invasive utilisée pour évaluer la vitesse du flux sanguin en temps réel. Actuellement, les techniques basées sur le Doppler transcrânien reposent sur l'apparition de signaux transitoires de haute intensité, qui sont utilisés comme indicateurs de la présence d'emboles. Cependant, le défi reste de faire la distinction entre les emboles et les artefacts, et plus important encore de faire la distinction entre les microemboles solides et gazeuses en utilisant les signaux TCD rétrodiffusés [7].

Pour cette raison, au lieu du signal Doppler traditionnel, nous proposons une nouvelle approche de classification des microembolies basée sur l'analyse des signaux ultrasonores.

L'objectif de cette étude est de créer un système automatisé de classification des microemboles (gaz et solides) basées sur les méthodes de traitement de signaux ultrasonores et en utilisant les techniques de l'intelligence artificielle et la décomposition en paquets d'ondelettes. Nous avons employé dans ce mémoire le Réseau à Fonctions Radiales de Base (Radial Basis Functions RBF) qui est un type des réseaux de neurones artificiels pour la tâche de classification.


La base de données sur laquelle nous allons valider notre modèle proposé est fournie par le laboratoire INSERM U930 de l'université François Rabelais de Tours (France), dans le cadre du projet de coopération France/Algérie : INSERM/DPGRF 2007-2008.

Ce mémoire est divisé en trois chapitres. Dans le premier chapitre, nous avons présenté une étude générale sur le problème et les types d'embolie. Les causes de l'embolie sont également mises en évidence dans cette section. De plus, nous présentons les techniques de détection d'embolie par ultrason, les propriétés non linéaires de l'interaction entre les ultrasons et la bulle de gaz.

Le deuxième chapitre présente une revue de la littérature sur les méthodes d'intelligence artificielle. Deux types de Réseaux de Neurones à savoir ; le perceptron multicouche (Multi Layer Perceptron MLP) et le Réseaux à Fonction Radiale de Base (Radial Basis Functions RBF) sont abordés dans cette section.

Nous avons présenté la discussion des résultats dans le chapitre trois, où nous exploitons la transformée en paquets d'ondelettes (WPT) pour caractériser le comportement des embolies solides et gazeuses. Nous avons utilisé l'algorithme WPT qui présente des coefficients d'approximations et des coefficients de détails de la décomposition des deux signaux (gaz et solide). A partir de ces coefficients, plusieurs caractéristiques peuvent être déterminées. Ces caractéristiques sont utilisées comme entrée au classificateur RBF en utilisant la technique de score de Fisher pour sélectionner les caractéristiques les plus pertinentes. Par la suite une étude comparative, avec autres travaux récemment publiés, est effectuée pour valider la méthode proposée.

Finalement, ce mémoire est achevé par une conclusion générale qui résume les résultats du travail effectué ainsi que quelques perspectives envisagées.



CHAPITRE I :
ETAT DE L'ART SUR L'EMBOLIE ET
TECHNIQUE DE DETECTION

I.1. Introduction :

La détection et la classification des emboles restent un domaine de recherche prometteur en raison de la relation entre les constatations d'occlusion et la nature des emboles (embolies gazeuses ou solides). Tandis que l'embolie est considérée comme un problème majeur qui peut affecter le système de vaisseaux sanguins. Plusieurs méthodes utilisant le Doppler ou le traitement du signal ultrasonore ont été utilisées pour détecter et classer les embolies. Malheureusement, les techniques basées sur le traitement du signal Doppler couramment utilisées pour détecter les embolies présentent certaines limites dans la distinction entre embolie et artefacts. Ce chapitre décrit les types d'embolie, les techniques de détection et de classification, les ultrasons et les agents de contraste pour l'ultrasonographie.

I.2. Définition d'embolie :

L'embolie est la migration intravasculaire d'un corps étranger, appelé embole. L'embole, qui dans 95% des cas est un caillot de sang, suit habituellement la direction du courant sanguin normal. Dans les autres cas, l'embole peut être des microbulles de gaz ou bien des petits morceaux de graisse [1].




Figure I.1 : Exemple d'une embolie.

I.3. Type d'embolies :

L'embolie est définie par trois catégories générales. Embolie artérielle, gazeuse et pulmonaire. L'embolie pulmonaire est la plus connue.

I.3.1. Embolie artérielle :

Il s'agit d'un embole gazeux ou solide qui s'est formé dans une artère. Une fois lâché dans la circulation il va finir par se bloquer dans une artère dont le calibre est inférieur à sa taille. Le sang ne pouvant plus passer, la circulation est interrompue dans le territoire desservi par cette artère.

Plus le caillot est gros, plus importants seront les troubles. Les troubles et accidents qui en résultent dépendent de la localisation. Les embolies artérielles touchent le plus souvent le cerveau (embolie cérébrale) ou les membres inférieurs [2].

I.3.2. Embolie gazeuse :

L'embolie gazeuse est une pathologie généralement accidentelle. Elle peut être liée à un traitement : pendant ou à la suite d'une intervention chirurgicale, ou de certains gestes médicaux (pose de voies veineuses centrales, hémodialyse, cœlioscopie...) [3,4]. Elle se produit également en cas d'accident de décompression, notamment en plongée sous-marine. (Voir **Figure I.3**). L'embolie gazeuse fait alors suite à une remontée trop rapide du plongeur vers la surface, sans respecter les paliers de décompression [3].

L'embolie gazeuse entraîne souvent une obstruction du flux sanguin à travers le cœur et un œdème pulmonaire (inflammation des vaisseaux sanguins pulmonaires). De plus, cela peut provoquer un œdème cérébral (inflammation du cerveau), une insuffisance cardiaque, ou un accident vasculaire cérébral [5].

Il convient de distinguer l'embolie veineuse (pénétration du gaz dans le système veineux) et l'embolie gazeuse artérielle (gaz situé au niveau du réseau artériel) [3].




Figure I.2 : Bulle obstruant le flux artériel terminal dans un vaisseau cérébral [8].




Figure I.3 : Embolie gazeuses à cause des bulles d'air dans le sang des plongeurs

I.3.3. Embolie pulmonaire :

L'embolie pulmonaire est due à une occlusion totale ou partielle de l'artère pulmonaire ou de ses branches due à un thrombus de la circulation veineuse (près de 90 cas de phlébite de jambe ou pelvienne) [3].

L'occlusion de l'artère pulmonaire par une embolie, ou élément solide, dans l'artère pulmonaire. Dans la plupart des cas, une embolie est un caillot sanguin. Cependant, d'autres éléments peuvent devenir des embolies lorsqu'ils pénètrent dans la circulation sanguine [6], quoi que beaucoup plus rarement :

- Des fragments de plaques d'athérosclérose (cholestérol attaché à la muqueuse des vaisseaux sanguins)
- Des fragments de tissus infectés ou des parasites.
- Fragment de moelle osseuse après fracture osseuse.
- Gaz (p. ex. injections intraveineuses contenant des bulles d'air).
- Morceaux de tumeurs cancéreuses.
- Liquide amniotique (lors de l'accouchement).




Figure I.4 : Développement d'un thrombus : A. Hanche, C. cuisse. B jambe [7].

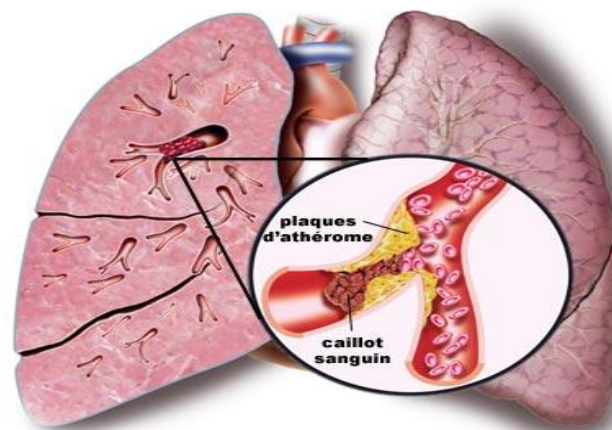


Figure I.5 : Schéma d'un poumon avec embolie pulmonaire.

La plupart des cas d'embolie pulmonaire, l'embolie est un caillot de sang qui s'est récemment formé dans une veine profonde de la jambe (surtout au niveau de la cuisse) (voir **Figures I.4** et **Figures I.5**), moins fréquemment dans les veines pelviennes ou la cavité du cœur. Ainsi, 70% des cas d'embolies pulmonaires sont une complication de la thrombophlébite (communément appelée « phlébite ») des veines profondes des jambes. Pour embolies pulmonaires, médecins recherchent systématiquement une prédisposition à la phlébite [6].

I.4. Causes d'embolie :

Des embolies ont été signalées dans divers domaines cliniques. Les causes possibles d'obstruction comprennent :

- **Le tabagisme :** comme c'est le cas avec la fumée de cigarette et les vapeurs de cigarette électronique, l'ingestion rapide de nicotine par inhalation peut provoquer des spasmes artériels, qui peuvent interférer avec la circulation sanguine par embolie gazeuse [2].
- **Chirurgie cardiaque :** chirurgie cardiaque : L'embolie artérielle est généralement une complication d'une maladie cardiaque, formant un caillot sanguin dans la cavité cardiaque [2].
- **Angiographie cérébrale :** les complications neurologiques consécutives à l'angiographie sont supposées résulter d'une micro-embolie. La plupart d'entre elles sont des emboles gazeux et elles sont produites lors du rinçage du cathéter et de l'injection de contraste [9].

- **Valve cardiaque artificielle** : Le remplacement de la valve cardiaque artificielle, en particulier lors de l'utilisation de dispositifs mécaniques, est associé au développement de micro embolies. Il peut s'agir de micro embolies fibrineuses ou plaquettaires, ou de bulles produites par cavitation autour de la prothèse [9].
- **Fibrillation auriculaire** : Une arythmie cardiaque qui provoque la formation de sang stagnant dans l'oreillette. Ce sang peut former des caillots sanguins qui peuvent pénétrer dans le système circulatoire [9].
- **Plongée et thérapie à haute pression** : les bulles libérées dans les tissus ou la circulation sanguine pendant l'exercice par compression ou décompression sont considérées comme un précurseur du mal de décompression. Ils peuvent toucher les nerfs, les artères, les veines et muscles [9].

D'autres facteurs associés à l'embolie comprennent le cancer, une intervention chirurgicale antérieure, une jambe ou une hanche cassée, une prédisposition génétique aux cellules sanguines qui augmentent le risque de caillots sanguins, pendant ou en raison d'une intervention chirurgicale, ou en raison de certaines procédures médicales (placement de la voie veineuse centrale, etc.) [9].

I.5. Techniques de détection :

L'embolie est le mécanisme le plus courant d'accident vasculaire cérébral (AVC) et une cause importante de complications neurologiques au cours de la chirurgie et des procédures interventionnelles. Plusieurs méthodes ont été utilisées pour détecter embolies à l'aide de signaux Doppler ou de signaux ultrasonores.

I.5.1. Effet de Doppler :

L'effet Doppler a été découvert en 1842 par le physicien autrichien Christian Doppler. Son hypothèse est basée sur le changement de fréquence du son lorsque la source ou l'observateur est déplacé. Les applications qui utilisent l'effet Doppler incluent l'astronomie, la mesure de la température, l'imagerie radar et médicale et la mesure du débit sanguin [10].

Le principe de l'effet Doppler repose sur deux facteurs : la « source » et « l'observateur ». Le son émis par une source se déplaçant à une fréquence donnée est capté par l'observateur à la fréquence décalée à la fréquence émise, donc ce décalage est la fréquence Doppler (due au mouvement relatif entre l'observateur et la source d'onde).

Actuellement, les techniques basées sur le Doppler transcrânien reposent sur l'apparition de signaux transitoires de haute intensité, qui sont utilisés comme indicateurs de la présence d'emboles [11] (Voir **Figure I.6**).




Figure I.6 : Échographie d'un signal Doppler micro-embolique [12].

I.5.1.1. Mode d'utilisation doppler :

En pratique, l'effet Doppler peut être utilisé selon deux modes : mode continu et mode pulsé. Avec le développement de la technologie d'imagerie par ultrasons, le Doppler bidimensionnel et le Doppler couleur basés sur le principe du Doppler pulsé sont apparus [13].

a) Doppler continu :

Le Doppler continu possède deux transducteurs au niveau du capteur, le premier émet un faisceau ultrasonore continu (US) et le second transducteur capte également le signal réfléchi aussi d'une façon continue. L'écho réfléchi par le sang en mouvement malgré l'atténuation est reçu à une fréquence décalée par rapport au rayonnement dû à l'effet Doppler.




Figure I.7 : Schéma de principe du Doppler continu [14].

b) Le doppler pulsé :

Un système Doppler pulsé comprend un transducteur monocristallin qui émet alternativement un faisceau ultrasonore et reçoit un faisceau réfléchi. Le retard entre deux impulsions définit la fréquence de répétition, également appelée PRF (PRF pulse repeat frequency). Entre ces deux impulsions, le signal réfléchi est analysé pendant une très courte période de temps que l'on peut appeler "fenêtre d'écoute". Le délai entre la fin de l'impulsion et le début de la "fenêtre d'écoute" détermine la profondeur de l'analyse du signal Doppler sélectionné (il s'agit de la profondeur du volume de l'échantillon). Le temps d'analyse du signal réfléchi, c'est-à-dire la largeur de la « fenêtre d'écoute », détermine la taille du volume d'échantillonnage [14, 15].

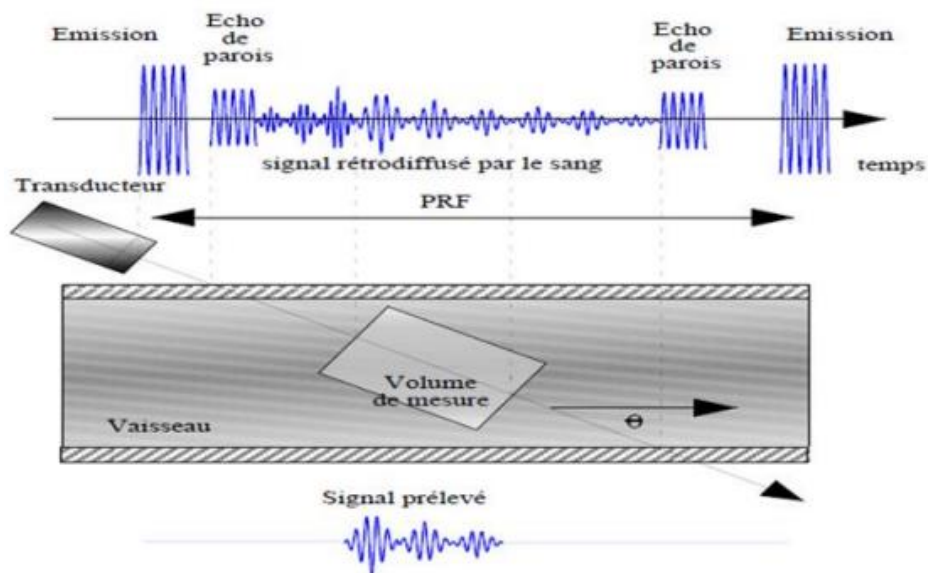


Figure I.8 : Schéma de principe du Doppler pulse [13].

- La PRF détermine la profondeur du champ d'exploration : pour explorer des champs profonds cette PRF doit être basse, pour explorer des champs superficiels on peut l'augmenter.
- Cette PRF détermine également la sensibilité aux flux : une sensibilité aux flux lents nécessite une PRF basse (environ 700 à 800 Hz pour les flux veineux et les petits flux parenchymateux).
- Pour bien analyser les flux rapides, la PRF doit être élevée (de l'ordre de 2 à 4 kHz) [14, 15].

I.5.1.2. Techniques de détection d'embolie utilisant les signaux Doppler :

Le Doppler transcrânien (TCD) a été développé au début des années 1980 par Aaslid et coll. décrit en détail par Jorgensen et coll. Le TCD est parmi les techniques les plus utilisées pour la détection des embolies : c'est un test d'échographie physiologique avec une sécurité et une efficacité établie. Bien que des dispositifs d'imagerie puissent être utilisés pour représenter la visualisation structurale du flux intracrânien superposé, le résultat final fourni par l'imagerie duplex ou TCD non imageur échantillonne les variables de flux physiologique à travers l'évaluation de la forme d'onde spectrale [16].

Maintenant l'échographie Doppler transcrânienne (TCD) est reconnue comme un outil utile pour détecter les micro-embolies. La capacité de l'échographie Doppler à détecter une embolie circulatoire a été décrite pour la première fois dans les années 1960 avec une circulation extracorporelle et une décompression hyperbare expérimentale [16]. En règle générale, l'artère cérébrale moyenne est sondée avec un appareil TCD qui transmet des fréquences de 2 MHz à 2,5 MHz.

La sonde Doppler est correctement fixée sur l'os temporal et la profondeur du volume d'échantillon Doppler est réglée entre 50 mm et 55 mm.

Principe de la méthode Doppler pour la détection des particules :

Le principe est simple, lorsqu'une particule en mouvement (particule ou gaz) traverse le volume d'échantillon Doppler, l'inadéquation d'impédance entre l'embolie et les têtes médianes environnantes provoque une augmentation du signal Doppler reçu qui peut être clairement distinguée du signal de flux de fond [16].

Le TCD utilise des ultrasons pulsés haute puissance et basse fréquence à environ 2 MHz à fin de traverser toute la table osseuse. S'il existe une fenêtre échographique, l'échographie Doppler transcrânienne permet d'analyser le taux de circulation sanguine dans les principales artères à la base du crâne. L'artère cérébrale moyenne est le vaisseau le plus facile à enregistrer. Son flux convergé vers le capteur et aligné avec la ligne de tir Doppler sont collectés à une profondeur de 30 à 60 mm de la fenêtre temporelle [17]. L'utilisation d'énergie Doppler semble également faciliter la détection des vaisseaux intracrâniens. Enfin, l'injection systémique d'agents de contraste a le potentiel d'améliorer l'étude ultrasonore des vaisseaux basaux [17].




Figure I.9 : Signal d'embolisation partielle en forme d'onde Doppler [18].

- ✓ Une étude de "David Russell, MD; Rainer Brucher" utilise un système Doppler transcrânien multifréquence pour détecter et distinguer automatiquement les micro-embolies cérébrales solides et gazeuses. La plupart des microembolies trouvés dans cette première étude sur les valves cardiaques mécaniques sont classés comme des gaz, alors que la plupart sont classés comme des solides chez les patients présentant une sténose de l'artère carotide [19].
- ✓ Une étude de "Hugh S. Marcus et Martin Punter" a montré que TCD peut seulement détecter de manière fiable, mais ne pas différencier les embolies gazeuses et solides [16].
- ✓ Une nouvelle étude par "Nizamettin Aydin, FarokhMarvasti, Senior, and Hugh S. Markus" propose un système de détection basé sur la transformée en ondelettes discrètes (DWT). Cette méthode implique l'utilisation de l'échographie Doppler pour détecter l'embolie et la distinguer des artefacts dus à la migration tissulaire et des signaux de haute intensité du flux sanguin normal (spot Doppler (DS)) [20]. Bien que les résultats de ces deux approches [21,20] soient très prometteurs, le problème de la distinction entre embolies et artefacts demeure, en particulier, la distinction entre micro-embolies solides et gazeux à l'aide des signaux de rétrodiffusion TCD.

I.5.2. Les ultrasons :

L'ultrason est une onde sonore et la méthode de propagation de l'énergie est effectuée sans mouvement de matière. Les ondes ultrasonores sont émises par des objets en mouvement par un mouvement oscillatoire et se propagent sous forme d'ondes mécaniques qui sont réfléchies

(écho), réfractionnées et interférées. La propagation des ondes ultrasonores ne peut se produire que dans des substances (gaz, liquides ou solides). Les ultrasons provoquent des changements de pression locaux dans un milieu élastique croisé. L'ultrasonique se caractérise par sa vitesse, son impédance et sa fréquence. Dans ce cas, l'onde subira diverses transformations en fonction des propriétés du milieu matériel étudié [22]. Parmi les caractéristiques physiques d'ultrason, on peut citer :

Tableau I.1 : Caractéristiques physiques d'ultrason.

Caractéristique physique	Etat
Fréquence f(Hz)	20KHz-100MHz
Période T(s)	$T=1/f=c. T$
Longueur d'onde λ (m)	$\lambda=c/f = c.T$
Célérité C(m/s)	$C = \lambda.f = \lambda/T$
Intensité I(watt/cm ²)	Energie transportée par unité de surface $I= Pc^2/2pc$
Niveau sonore L (dB)	Entre deux ondes ultrasonores (I_1, I_2) $L=D=10\log (I_2/I_1)$

- La différence de rayonnement électromagnétique ne peut se propager dans le vide mais uniquement dans le milieu élastique.
- L'exposition aux ultrasons peut être étudiée en deux catégories selon sa transmission dans l'air ou les milieux liquides. On peut dire que l'exposition aux ondes ultrasonores

dans l'air se produit dans de nombreuses applications industrielles telles que le nettoyage par ultrasons, les dispositifs acoustiques et de signalisation, etc.

- D'autre part, l'exposition aux ultrasons transmis dans les liquides peut être utilisée dans des procédures diagnostiques, thérapeutiques ou chirurgicales.
- Les ultrasons actuellement utilisés à des fins de diagnostic ont des effets délétères chez l'homme, mais l'utilisation croissante des ultrasons chez les femmes enceintes est préoccupante si le fœtus est connu pour être sensible à d'autres agents physiques ou chimiques [23].

I.5.2.1. Techniques de détection et de classification d'embolie utilisant les signaux ultrasons :

Les méthodes basées sur Doppler sont très sensibles aux artefacts de tout mouvement qui provoque un mouvement de la tête du patient, une toux ou un mouvement de la sonde, ce qui peut produire des signaux similaires aux embolies solides ou gazeuses [22].

Le signal ultrasonore radiofréquence (RF) réfléchi par l'embolie contient des informations de plus sur l'embolie que le signal Doppler traditionnellement utilisé. Les bulles présentent un comportement non linéaire dans certaines conditions d'excitation ultrasonore, qui est utilisée pour distinguer les micro-embolies solides et gazeuses [24].

- ✓ Une étude expérimentale faite par « N. Benoudjit, K. Ferroudji, A. Bouakaz, M. Bahaz » utilise les signaux radiofréquence (RF) rétrodiffusés par les embolies. Le but de cette étude était d'analyser les signaux RF au lieu des signaux Doppler pour classer les embolies [24]. Cette étude a montré le potentiel de l'utilisation du traitement du signal RF pour mieux classer les embolies en tant que solides ou gaz.
- ✓ Nous proposons dans cette étude une nouvelle approche basée sur l'analyse des signaux radiofréquences ultrasonores (RF) au lieu des signaux Doppler pour la détection et la classification des micro-embolies. La base de données sur laquelle nous allons valider les modèles proposés est fournie par le laboratoire INSERM U930 de l'université François Rabelais de Tours (France), dans le cadre du projet de coopération Algérie/France DPGRF/INSERM 2007-2008.

I.6. Agents de contraste pour l'ultrasonographie :

Les agents de contraste sont des microbulles de gaz plus petites que les globules rouges. L'injection intraveineuse de ces agents de contraste a pour but d'améliorer les images échographiques.

Les agents de contraste ultrasonores modifient les propriétés physiques des tissus et donc le comportement des ondes ultrasonores qui les traversent. Ces bulles se compriment et se dilatent en réponse aux ondes ultrasonores. Pour une petite pression acoustique, la taille des microbulles change proportionnellement à l'amplitude de la pression acoustique, ce régime est dite symétrique (voir **Figure I.10**).

Pour des pressions sonores importantes, les microbulles vibrent plus et de manière non linéaire, la compression et l'expansion des bulles sont de forte amplitude et asymétriques (la taille de la bulle change fortement et de manière non linéaire avec l'amplitude de la pression acoustique), produisant de ce fait des fréquences pas présentes lors de l'émission du faisceau ultrasonore. Ces composantes fréquentielles non linéaires sont appelées harmoniques et ce phénomène représente la base de l'imagerie harmonique [24].

Ce comportement non linéaire bulle gazeux est exploité dans ce travail pour distinguer les micros emboles gazeux des solides.

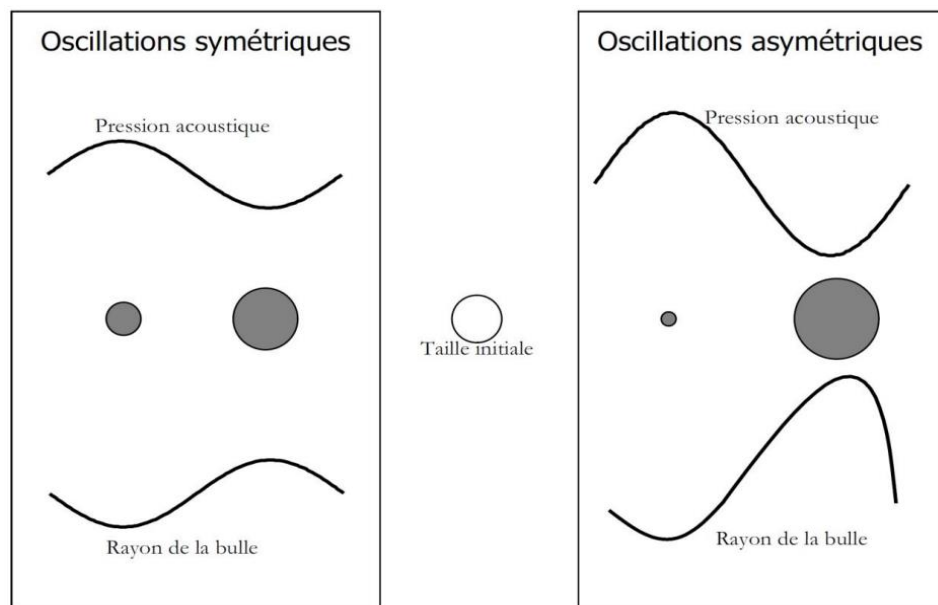



Figure I.10 : Oscillations symétriques (linéaires) et asymétriques (non linéaires) d'une microbulle soumise à une onde de pression [24].

I.7. Conclusion :

Dans ce chapitre nous avons présentés les principaux types d'embolie, ses causes ainsi que les techniques actuelles utilisées pour détecter et classifier des emboles, Les techniques traditionnelles sont largement basées sur les techniques Doppler. Malheureusement, la technique de traitement Doppler, qui est couramment utilisée pour la détection des emboles, présente certaines limites pour distinguer les emboles des artefacts et plus précisément de différencier les emboles solides et gazeux. Par conséquent, nous proposons dans ce mémoire une autre approche basée sur l'analyse des signaux ultrasonores radiofréquence (RF) au lieu des signaux Doppler pour la détection et la classification des micro emboles en exploitant le comportement non linéaire des bulles gazeuses.



CHAPITRE II :
RESEAUX DE NEURONES
ARTIFICIELLES

II.1. Introduction:

L'intelligence artificielle (IA), également connue sous le nom d'apprentissage automatique ou d'intelligence computationnelle, est la science et l'ingénierie de la création de machines intelligentes conçues de manière à ce que les ordinateurs effectuent des tâches qui étaient auparavant considérées comme impliquant l'intelligence humaine. L'IA facilite et reproduit les actions et les décisions des humains sans défauts humains, tels que la fatigue, l'émotion et le temps limité. En règle générale, les techniques d'intelligence artificielle utilisent des échantillons d'apprentissage afin de créer un modèle qui permet des prédictions fiables.

Dans ce chapitre, nous allons aborder les réseaux de neurones artificiels, ses concepts et leur apprentissage, Et aussi on va détailler les deux méthodes de classification «Multi Layer Perceptron MLP » et «Radial Basis Fonction RBF».

II.2. Réseaux de neurones artificiels :

II.2.1. Principe :

L'origine des réseaux de neurones vient de l'essai de modélisation du neurone biologique par Warren McCulloch et Walter Pitts [26]. Ils supposent que l'impulsion nerveuse est le résultat d'un calcul simple effectué par chaque neurone et que la pensée née grâce à l'effet collectif d'un réseau de neurones interconnectés [26].




Figure II.1 : Un neurone biologique et ses principaux composants [28].

II.2.2. Définition :

Les réseaux de neurones artificiels (RNA) sont des réseaux de processeurs hautement interconnectés, des éléments qui fonctionnent en parallèle. Chaque processeur élémentaire calcule une seule sortie sur la base des informations reçues. Toute structure hiérarchique de réseaux est évidemment un réseau [25].




Figure II.2 : Modèle d'un neurone artificiel [23].

Un réseau neuronal (RN) est un système de manipulateurs non linéaires interconnectés qui reçoivent un signal externe via une entrée et fournissent un signal de sortie. Ces réseaux sont des métaphores pour le traitement parallèle et distribué de la structure et de l'information cérébrales, et contiennent plusieurs éléments de traitement appelés neurones. Chaque neurone fonctionne indépendamment des autres neurones, créant un système parallèle hautement interconnecté dans son ensemble. Les informations détenues par le réseau de neurones sont réparties sur tous les composants et ne se présentent pas sous forme de symboles dans une partie de la mémoire [27].

Le réseau de neurones n'est pas programmé pour effectuer telle tâche. Il est formé avec les données acquises, grâce à des mécanismes d'apprentissage qui agissent sur les composants du réseau pour effectuer de manière optimale la tâche d'intérêt [27].

On peut vérifier la correspondance entre les propriétés pertinentes du neurone biologique et du neurone artificiel (Voir **Figure II.3**).




Figure II.3 : Correspondance entre neurones biologiques et neurones artificiels [25].

Quelques comparaisons entre les deux neurones montrés dans le **Tableau II.1:**

Tableau II.1 : Comparaison entre neurone Biologique et artificiel [27].

Système nerveux	Réseau neural Artificiel
Neurone	Traitant élément, nœud, neurone artificiel, neurone abstrait.
Le corps cellulaire (soma)	Niveau de l'activation, fonction de l'activation, fonction du transfert, la fonction de la sortie.
Axone	La communication avec d'autre neurone.
Synapse	Poids multiplicatif.

II.2.3. Histoire des réseaux de neurones artificiels :

- Les études des réseaux de neurones artificiels datent depuis les années 1940. Grâce aux développements des recherches sur le cerveau et la disponibilité des outils de simulation, les chercheurs étudièrent des ensembles de neurones formels interconnectés [31].
- En 1957, le Perceptron fut inventé. Il s'agit du plus ancien algorithme d'apprentissage automatique (Machine Learning), conçu pour effectuer des tâches de reconnaissance de patterns complexes. C'est cet algorithme qui permettra plus tard aux machines d'apprendre à reconnaître des objets sur des images [25].
- Ces réseaux, déjà développées à l'époque, permettaient d'effectuer quelques opérations logiques simples. Jusqu'aux années 1980, la recherche était freinée par la limitation théorique du perceptron [31].
- Hopfield lança de nouveau en 1982 la recherche dans ce domaine après avoir montré l'analogie entre les RNA et les systèmes physiques [31].
- Après les années 1990, quelques travaux scientifiques ont vu le jour dans le domaine de la robotique, parmi ces applications, on trouve la commande des systèmes d'entraînement et des systèmes de positionnement de haute performance [31].
- Il aura fallu attendre le début des années 2010, avec l'essor de la grande base de données et du traitement massivement parallèle, pour que les scientifiques des données disposent des données et de la puissance de calcul nécessaires pour exécuter des réseaux de neurones complexes [25].
- En 2012, lors d'une compétition organisée par Image Net, un Réseaux de Neurone est parvenu pour la première fois à surpasser un humain dans la reconnaissance d'image [25].
- A présent, les réseaux de neurones artificiels ne cessent de s'améliorer et d'évoluer de jour en jour [25].

II.2.4. Domaine d'application des réseaux de neurones (RNA) :

Actuellement, les réseaux de neurones ont de nombreuses applications dans des domaines très variés, notamment:

- **Application au contrôle :**

Grâce à leurs propriétés (rapport de traitement, capacité d'adaptation, et de généralisation, etc...). Les réseaux de neurones sont appliqués au contrôle intelligent. Par exemple

nombreuses expériences ont été faites pour appliquer les réseaux de neurones ; Ces applications peuvent être classifiés en plusieurs méthodes, telles que : le contrôle supervisé, le contrôle inverse et le contrôle neuronal adaptatif [27].

✓ **Application à la planification :**

L'optimisation est souvent souhaitée pour les opérations ou la planification de la marque. Par conséquent, l'utilisation du modèle Hop Field et du modèle Kohonen semble être très utile pour résoudre les problèmes d'optimisation [27].

✓ **Application au traitement du signal :**

La société NESTOR a développé un réseau de neurones qui identifie une cible à coup sûr (100% de réussite) et reconnaît du bruit avec un taux de réussite de 95%. Cette application a été construite à partir de signaux sonars et des traits caractéristiques de ces signaux déterminés par les experts comme utiles pour identifier une cible en environnement bruité [27, 29].

Le réseau agit dans ce cas comme un filtre pour éliminer le bruit. Aussi utilisée pour traitement de la parole, identification de sources, filtrage, classification... [29].

✓ **Application au diagnostic :**

Les réseaux de neurones sont bien adaptés pour résoudre les problèmes de diagnostic en utilisant la classification automatique des signaux et des modèles. Il existe de nombreuses applications des réseaux de neurones pour le diagnostic de pannes, en particulier pour le diagnostic de pannes de machines électriques [27].

Voici des exemples d'applications de chaque modèle dans le tableau suivant:

Tableau II.2 : Correspondance RNA - domaines d'application [27].

Caractéristiques Fonctionnelles	Type de RNA
Reconnaissance de formes	MLP, Hopfield, Kohonen, PNN
Mémoires associatives	Hopfield, MLP récurrents, Kohonen
Optimisation	Hopfield, ART, CNN
Approximation de fonctions	MLP, RBF

Modélisation et control	MLP, MLP récurrent, FLN
Traitement d'images	CNN, Hopfeild
Classification et clustering	MLP, Hopfeild, RBF, ART, PNN

II.2.5. Fonction de transfert :

Il y a plusieurs fonctions différentes de transfert pouvant être utilisées comme fonctions d'activation des neurones sont répertoriées dans le **Tableau II.3**. Les trois fonctions les plus utilisées sont la fonction « seuil » (en anglais, « hard limit »), « linéaire », « sigmoïde ».

Comme son nom l'indique, la fonction seuil applique un seuil à son entrée. Pour être plus précis, une entrée négative ne passe pas le seuil, alors la fonction renvoie la valeur 0 (on peut interpréter ce 0 comme faux), tandis que l'entrée positive ou nulle dépasse le seuil et la fonction renvoie 1 (vrai). Utilisée dans le contexte d'un neurone, cette fonction est illustrée à la **Figure II.4.a**. On remarque alors que le biais b dans l'expression de (**équation II.1**) détermine l'emplacement du seuil sur l'axe $W^T p$, où la fonction passe de 0 à 1 [23].

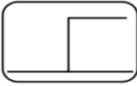
$$a = \text{hardlim}(W^T p - b) \quad (\text{II.1})$$

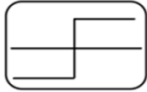
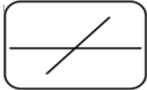

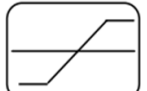
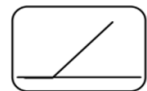
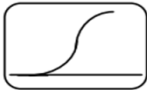
$W^T p$: L'axe d'emplacement.

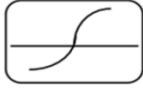
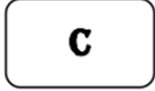
b : le biais.

Le **Tableau II.3** suivant résume les fonctions de transfert couramment utilisées :

Tableau II.3 : Les fonctions de transfert $a = f(n)$ [23].

Nom de la fonction	Relation d'entrée / sortie	Icône
Seuil	$a = 0$ Si $n < 0$ $a = 1$ Si $n \geq 0$	

Seuil symétrique	$a = -1$ Si $n < 0$ $a = 1$ Si $n \geq 0$	
Linéaire	$a = n$	
Linéaire saturée	$a = 0$ Si $n < 0$ $a = n$ Si $0 \leq n \leq 1$ $a = 1$ Si $n > 1$	
Linéaire saturée symétrique	$a = -1$ Si $n < -1$ $a = n$ Si $-1 \leq n \leq 1$ $a = 1$ Si $n > 1$	
Linéaire positive	$a = 0$ Si $n < 0$ $a = n$ Si $n \geq 0$	
Sigmoïde	$a = \frac{1}{1+e^{-n}}$	

Tangente hyperbolique	$a = \frac{e^{-n} - e^n}{e^{-n} + e^n}$	
Compétitive	$a = 1$ si n maximum $a = 0$ autrement	

- ✓ La fonction linéaire est très simple, elle affecte directement son entrée à sa sortie :

$$a = n \quad (\text{II.2})$$

Appliquée dans le contexte d'un neurone, cette fonction est illustrée à la **Figure II.4.b**.

Dans ce cas, la sortie du neurone correspond à son niveau d'activation dont le passage à zéro se produit lorsque $w^T p = b$.

- ✓ La fonction de transfert sigmoïde est quant à elle illustrée à la **Figure II.4.c**. Son équation est donnée par :

$$a = \frac{1}{1 + e^{-n}} \quad (\text{II.3})$$

Elle est similaire à une fonction seuil ou à une fonction linéaire, selon que l'on est éloigné ou proche de b , respectivement. La fonction seuil est non linéaire car il y a une discontinuité lorsque $W^T p = b$.

D'autre part, une fonction linéaire est complètement linéaire. Elle n'inclut aucun changement de pente. La sigmoïde est un compromis intéressant entre les deux précédents. Enfin, notez que la fonction « tangente hyperbolique » est une version symétrique de la sigmoïde [23].




Figure II.4: Fonctions de transfert : (a) du neurone «seuil» ; (b) du neurone «linéaire», et (c) du neurone «sigmoïde» [23].

II.2.6. Fonctionnement :

Le réseau neuronal contient un grand nombre de processeurs parallèles dans couches consécutives. La première couche prend des informations brutes en entrée, tout comme le nerf optique traite les données visuelles humaines. Chaque couche successive reçoit les données de la couche précédente plutôt que les données brutes, tout comme les neurones distaux du nerf optique reçoivent des signaux voisins. La dernière couche produit le résultat.

Chaque nœud de traitement a sa petite bulle de connaissances, composée notamment de ce qu'il a vu et des règles programmées à l'origine ou définies par lui-même. Les couches sont étroitement interconnectées : chaque nœud d'une couche n est connecté à de nombreux nœuds de la couche $n-1$ (ses entrées) et de la couche $n+1$ qui seront à leur tour les entrées de ces nœuds-là. Il peut y avoir un ou plusieurs nœuds dans la couche de sortie dont provient la réponse lisible [30].

Les réseaux de neurones sont remarquables par leur adaptabilité : ils se modifient avec la formation initiale, et les exécutions ultérieures leur donnent encore plus d'informations sur le monde qui les entoure. Le modèle d'apprentissage le plus élémentaire se concentre sur la pondération du flux d'entrée, c'est-à-dire l'évaluation par chaque nœud de l'importance de l'entrée de chaque nœud prédécesseur. L'entrée qui contribue à la bonne réponse a un coefficient plus élevé [30].

II.2.7. Architectures de réseaux de neurones :

Les réseaux de neurones sont des réseaux de plusieurs neurones, généralement organisés en couches. Pour construire une couches de S neurones, il suffit de les assembler comme le montré la **Figure II.5**. Tous les neurones S d'une même couche sont connectés à l'entrée R. Ensuite, disons que les couches sont totalement connectées [23].

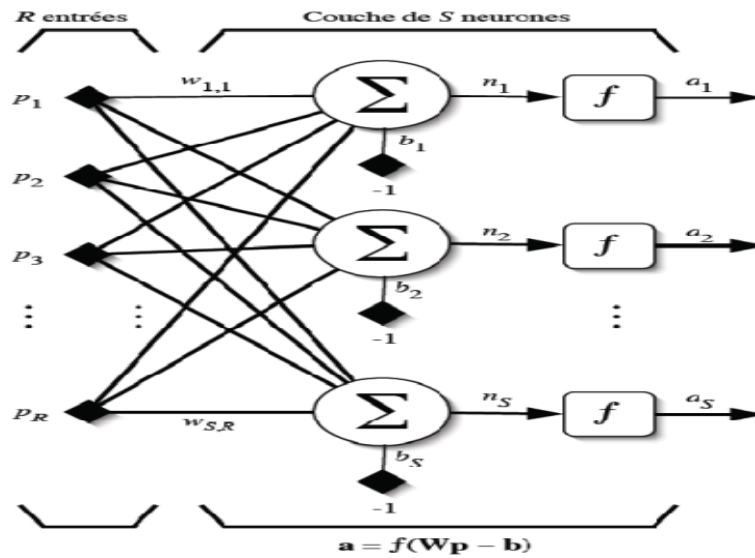


Figure II.5 : Couche de S neurones [23].

La structure la plus simple est celle où les nœuds sont répartis en deux couches : une couche d'entrée et une couche de sortie. Les nœuds de la couche d'entrée ont une seule entrée et une seule sortie, égale à l'entrée (voir **Figure II.6**).

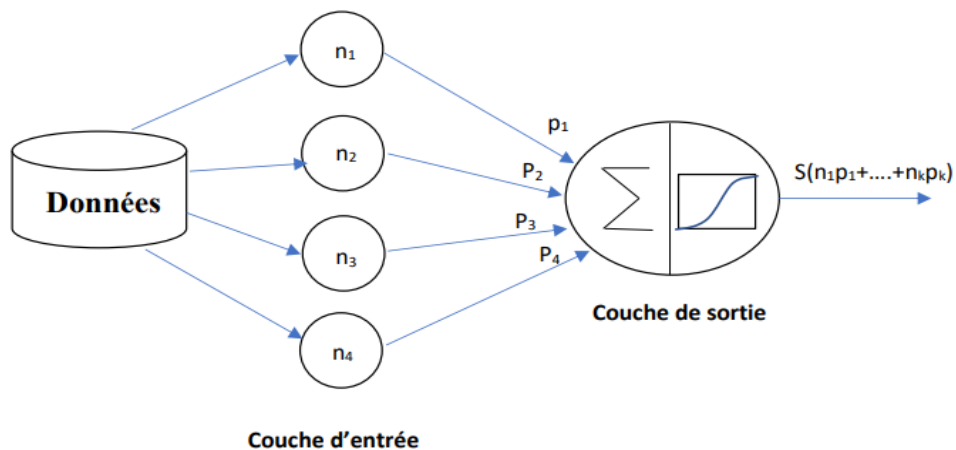


Figure II.6 : Réseau de neurones sans couche cachée.

Dans ce cas, le modèle obtenu est une régression linéaire ou logistique selon que la fonction de transfert est linéaire ou logistique, et les poids du réseau sont les coefficients de la régression. On augmente le pouvoir de prédiction en ajoutant une ou plusieurs couches cachées entre les couches d'entrée et de sortie **Figure II.7** bien que le pouvoir de prédiction augmente avec le nombre de couche cachée et de nœuds dans ces couches, ce nombre doit néanmoins être le plus petit possible afin que le réseau de neurones ne se contente pas de mémoriser l'ensemble d'apprentissage mais puisse le généraliser, en évitant ce que l'on appelle le « sur-apprentissage », qui survient lorsque les poids ne font « qu'apprendre » les particularités de l'ensemble d'apprentissage au lieu d'en découvrir les structures générales. Ceci arrive lorsque la taille de l'ensemble d'apprentissage est trop faible par rapport à la complexité du modèle, c'est-à-dire ici la complexité de la topologie du réseau **Figure II.7**.




Figure II.7 : Réseau de neurones avec couche cachée.

Indépendamment de l'existence d'une couche cachée, la couche de sortie du réseau peut parfois avoir plusieurs nœuds, lorsqu'il y a plusieurs classes à prédire **Figure II.8**.

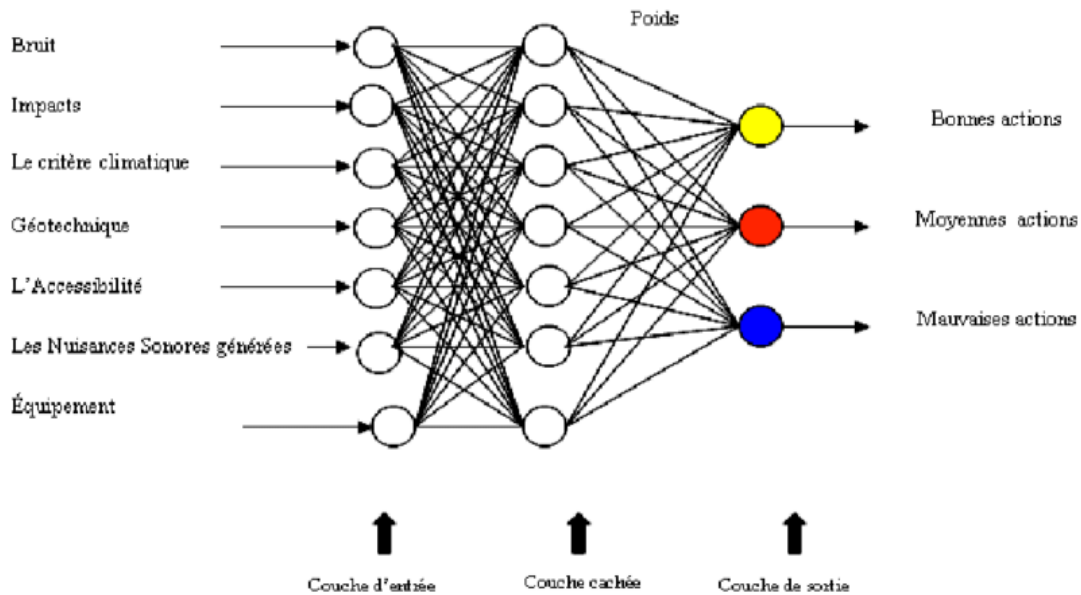


Figure II.8 : Réseaux de neurones avec plusieurs nœuds de sortie.

- **Couche d'entrée :** les neurones de cette couche reçoivent les valeurs d'entrée du réseau et les transmettent aux neurones cachés. Chaque neurone reçoit une valeur, il ne fait pas donc de sommation [23].
- **Couches cachées :** chaque neurone de cette couche reçoit l'information de plusieurs couches précédentes, effectue la sommation pondérée par les poids, puis la transforme selon sa fonction d'activation. Par la suite, il envoie cette réponse aux neurones de la prochaine couche [23].
- **Couche de sortie :** elle joue le même rôle que les couches cachées. La seule différence entre ces deux types de couches est que les sorties des neurones de la couche de sortie ne sont pas connectées à d'autres neurones [23].

II.2.8. Apprentissage des réseaux de neurones :

L'apprentissage est un processus d'adaptation des paramètres d'un système pour donner une réponse désirée face à une entrée ou stimulation externe.

La phase d'apprentissage est la propriété la plus importante et intéressante dans les réseaux de neurones, elle est suivie d'une mémorisation qui consiste à modifier les poids des connexions jusqu'à ce que les poids ne se modifient plus que d'une façon infirme autrement dit jusqu'à l'obtention du comportement désiré [32].

II.3. Types de réseaux de neurones :

II.3.1. Le perceptron multicouche (Multi Layer Perceptron MLP) :

II.3.1.1. Définition :

Le perceptron multicouche est un réseau de neurones acyclique (Forward Neural Network - FFNN) structuré en couches. Par conséquent, un perceptron multicouche se compose d'une couche d'entrée, d'une ou plusieurs couches dites cachées entre les deux et d'une couche de sortie. Pour chaque couche, tous ses nœuds sont connectés à l'ensemble des nœuds de la couche précédente.

La **Figure II.9** Donne une représentation d'un perceptron multicouche avec deux couches cachées [32]. Les neurones de la première couche calculent leurs sorties qui sont transférées aux neurones de la deuxième couche, etc.... Ces sorties ne sont pas visibles en dehors de la grille (couche cachée). C'est la dernière couche qui produit les sorties du réseau [1].

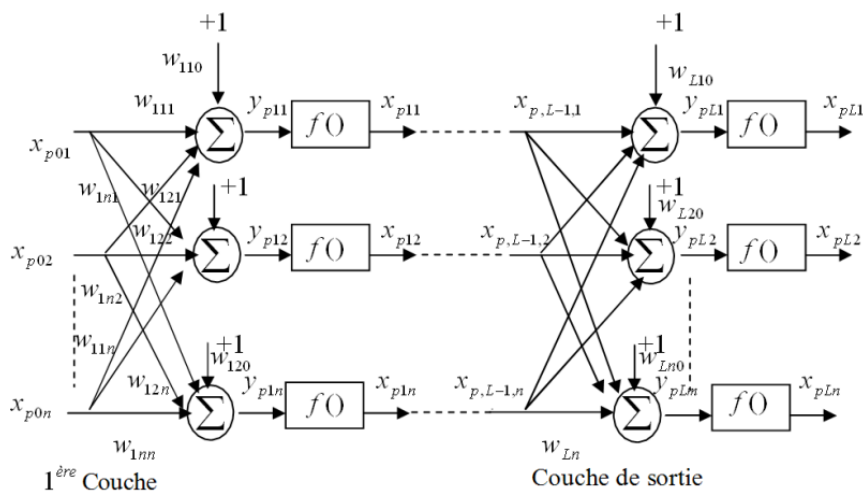


Figure II.9 : Structure d'un réseau de neurone multicouche [23].

II.3.1.2. Architecture du réseau :

L'architecture du modèle de réseau neuronal perceptron multicouche est constituée d'un réseau d'éléments de traitement ou de nœuds disposés en couches. Il nécessite généralement trois couches ou plus de nœuds de traitement :

La couche d'entrée accepte les variables d'entrée utilisées dans la procédure de classification, une ou plusieurs couches masquées et une couche de sortie avec un nœud par classe.

Lorsque les données d'un motif d'entrée sont présentées au niveau de la couche d'entrée, les nœuds de réseau effectuent des calculs dans les couches successives jusqu'à ce qu'une valeur de sortie soit calculée à chacun des nœuds de sortie. Ce signal de sortie doit indiquer quelle

est la classe appropriée pour les données d'entrée, c'est-à-dire nous nous attendons à avoir une valeur de sortie élevée sur le nœud de classe correct et une valeur de sortie faible sur tous les autres.

Chaque nœud de traitement d'une couche particulière est généralement connecté à chaque nœud de la couche supérieure et inférieure [36].

II.3.1.3. Fonction de transfert :

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.

Généralement, même fonction d'activation F (le plus souvent sigmoïde) pour toutes les unités des couches cachées son équation est donnée par l'équation (II.3).




Figure II.10 : Fonction sigmoïde [23].

II.3.1.4. Apprentissage de model MLP :

Le perceptron multicouche utilise un algorithme d'apprentissage supervisé pour calculer l'erreur de sortie pour les couches cachées.

En pratique, l'apprentissage du réseau consiste à calculer les poids des connections entre les cellules en vue de minimiser un critère quadratique E en sortie [35].

$$E = \frac{1}{2} \sum_{p=1}^N E_p \quad (\text{II.4})$$

$$E_p = \frac{1}{2} \sum_{j=1}^s (Q[j][p] - O[j][p]) \quad (\text{II.5})$$

Dans les applications réelles, on ne connaît pas l'allure de la fonction d'erreur E dans l'espace des poids, ce qui a pour conséquence que, lorsque l'algorithme d'optimisation non linéaire converge, on n'est jamais assuré que le minimum ainsi obtenu est global.

L'algorithme d'apprentissage du Perceptron à une seule couche. Initialisation des poids et du seuil S à des valeurs (petites) choisies au hasard.

- ✓ Présentation d'une entrée $E_i = (e_1, \dots, e_n)$ de la base d'apprentissage.
- ✓ Calcul de la sortie obtenue x pour cette entrée:

$$a = \sum(W_i \cdot e_i) - S \quad (\text{II.7})$$

$$x = \text{signe}(a) \quad (> 0 \text{ alors } x = +1 \text{ sinon } a \leq 0 \text{ alors } x = -1)$$

- ✓ Si la sortie x du Perceptron est différente de la sortie désirée d_i pour cet exemple d'entrée E_i alors modification des poids (μ le pas de modification) :

$$W_i(t + 1) = W_i(t) + \mu \cdot ((d_i - x) \cdot e_i) \quad (\text{II.8})$$

Rappel : $d_i = +1$ si E est de la classe 1, $d_i = -1$ si E est de la classe 2 et $(d_i - x)$ est une estimation de l'erreur.

- ✓ Tant que tous les exemples de la base d'apprentissage ne sont pas traités correctement (modification des poids), retour à l'étape 2.

Le Perceptron a une seule couche ne peut résoudre que les problèmes dont les données sont linéairement séparable. Cette limitation a été résolue avec la découverte de l'algorithme de rétro-propagation.

II.3.1.5. Algorithme de rétro-propagation :

La rétro-propagation consiste à rétro-propager l'erreur commise par un neurone à ses synapses et aux neurones qui y sont reliés. Pour les réseaux de neurones, on utilise habituellement la rétro-propagation du gradient de l'erreur [33].

- **1^{ère} étape :** Initialiser les poids W_{ij} et les seuils internes des neurones à des petites valeurs aléatoires.
- **2^{ème} étape :** Présenter le vecteur d'entrée et de sortie désirée.
- **3^{ème} étape :** Calculer :

* La somme des entrées des neurones de la couche cachée en utilisant l'expression

$$v = f \left(\sum_{i=0}^{n-1} W_i X_i - \theta \right) \quad (\text{II.9})$$

* Les sorties de neurones de la couche cachée en utilisant l'expression

$$\delta_j^l = \sum_{i=1}^n W_{ji}^l X_i + \theta_j^l \quad (\text{II.10})$$

* La somme des entrées des neurones de la couche de sortie en utilisant l'expression

$$I_j = f^l(S_j^l) = f^l\left(\sum_{i=1}^n W_{ij}^l X_i \theta_j^l\right) \quad (\text{II.11})$$

* Les sorties des réseaux en utilisant l'expression

$$S_K^R = \sum_{j=1}^n I_j + \theta_K^R \quad (\text{II.12})$$

➤ **4^{ème} étape** : Calculer l'erreur pour les neurones de la couche de sortie en utilisant l'expression

$$S_K^R = (y_K - R_K)(S_K^R) \quad (\text{II.13})$$

➤ **5^{ème} étape** : Réinjecter l'erreur de sortie en utilisant l'expression

$$\delta_j^l = f_j^l(S_j^l) \sum \delta_K^R W_{Kj}^R \quad (\text{II.14})$$

➤ **6^{ème} étape** : Ajuster :

* Les poids de la couche de sortie en utilisant l'expression

$$W_{Kj}^R(n+1) = W_{Kj}^R(n) + \mu \delta_K^R I_j \quad (\text{II.15})$$

* Les poids de la couche cachée en utilisant l'expression

$$W_{ji}^l(n+1) = W_{ji}^l(n) + \mu \delta_i^l X_i \quad (\text{II.16})$$

➤ **7^{ème} étape** : Calculer E l'erreur en utilisant l'expression

$$E_p = \frac{1}{2} \sum_{K=1}^T (y_K - R_K)^2 \quad (\text{II.17})$$

➤ **8^{ème} étape** : Si la condition sur l'erreur $E - E_p < \varepsilon$ est atteinte, aller à la **9^{ème} étape** sinon aller à la **6^{ème} étape** et refaire le calcul pour une autre époque.

➤ **9^{ème} étape** : FIN.

II.3.2. Réseaux à fonction radial de base (RBF radial basis function) :

II.3.2.1. Présentation des réseaux RBF :

Les réseaux de neurones à fonction radiale peuvent être utilisés pour une large gamme d'applications, principalement parce qu'ils peuvent se rapprocher de n'importe quelle fonction régulière et que leur apprentissage est plus rapide par rapport au perceptron multicouche [36].

L'idée générale des réseaux RBF dérive de la théorie d'approximation des fonctions, ces réseaux sont une architecture Feed forward puissante. Ce type de réseaux a été introduit pour la première fois par Hardy, et la théorie correspondante a été développée par Powell, ensuite, ces réseaux ont pris le terme de réseaux de neurones grâce à Broomhead et Lowe. Sans oublier les œuvres de MOODY et DARKEN (1989) d'une part, et de POGGIO et GIROSI (1990) d'autre part [34].

La raison de son application vient du fait que le réseau utilise des fonctions gaussiennes standard qui sont à symétrie radiale. Son apprentissage est basé sur l'algorithme K-means et l'algorithme des moindres carrés [34].




Figure II.11 : Représentation d'un RBF.

II.3.2.2. Principe de RBF :

Le réseau de type RBF est un réseau à trois couches dérivé de la méthode d'interpolation [37], et est un modèle connexionniste facile à mettre en œuvre et assez facile à comprendre. Cette technique s'est avérée rapide, efficace et facile, en particulier pour les applications de classification et de régression.

Le principe est d'estimer le comportement souhaité à travers un ensemble de fonctions (appelées fonctions noyau). La fonctionnalité de base de la méthode RBF est locale. Autrement dit, il ne fournit une réponse significative que dans la plage d'influence limitée par le seuil de distance. Ce seuil est défini autour du point, noyau (ou centre). La distance euclidienne est couramment utilisée pour mesurer la distance :

$$d(x) = \|x - c_i\| \quad (\text{II.18})$$

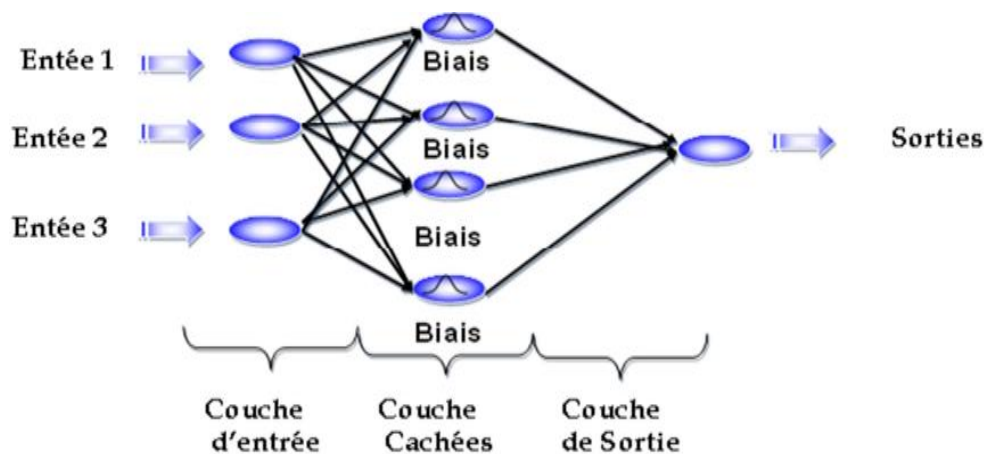


Figure II.12 : Réseau de Neurone RBF.

II.3.2.3. Architecture de RBF :

L'architecture est la même que pour les MLP cependant, les fonctions de base utilisées ici sont des fonctions Gaussiennes.

Un RBF est constitué uniquement de 3 couches :

- ✓ **La couche d'entrée :** elle retransmet les inputs sans distorsion.
- ✓ **La couche cachée du réseau RBF :** couche cachée qui contient les neurones RBF.
- ✓ Les neurones sont des gaussiennes.
- ✓ **La couche de sortie :** simple couche qui contient une fonction linéaire.
- ✓ Chaque couche est connectée à la suivante.

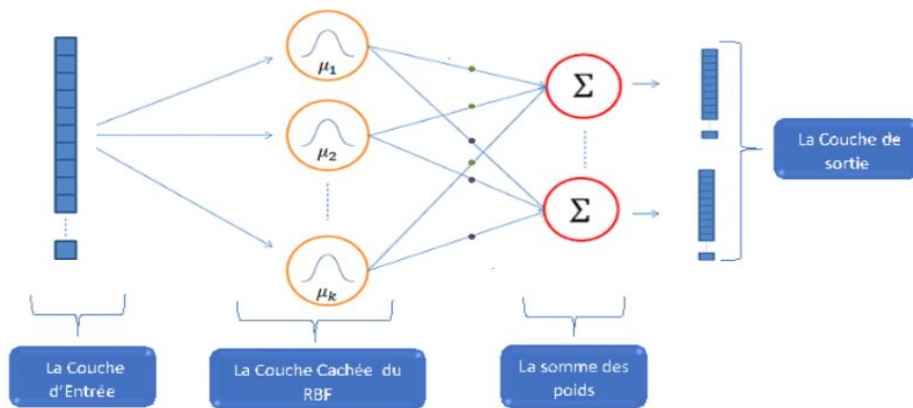


Figure II.13: La structure de radiale base fonctions RBF.

Chaque neurone RBF calcule une mesure de la similitude entre l'entrée et son vecteur prototype (tiré de l'ensemble d'apprentissage). Les vecteurs d'entrée qui sont plus similaires au prototype renvoient un résultat plus proche de 1.

Il existe différents choix possibles des fonctions de similitude, mais le plus populaire est basé sur le gaussien.

II.3.2.4. Fonction de transfère :

La fonction de base radiale (RBF) c'est la fonction ϕ symétrique au centre μ_j :

$$\phi_j(x) = \phi(\|x - \mu_j\|) \quad (\text{II.19})$$

La fonction gaussienne est une RBF avec la norme euclidienne et $\phi(r) = e^{-r^2/2\sigma^2}$ est de centre [39].

Un réseau RBF calcule une combinaison linière de la fonction radial μ_j :

$$y(x) = \sum_{j=1}^N W_j \phi(\|x - \mu_j\|, \sigma_j) \quad (\text{II.20})$$

Donc on distingue trois paramètres principaux sont :

- Les centres μ_j
- La largeur σ_j
- Les poids ω_i

Les combinaisons linéaires de gaussiennes sont utilisées pour construire des approximations de fonctions. A la fin des années 80, la présentation de ces modèles comme des réseaux connexionnistes a suscité un regain d'intérêt motivé en grande partie par la possibilité d'utiliser un algorithme d'apprentissage très rapide (sans recourir à des techniques

d'optimisation non linéaire comme dans le cas du Perceptron multicouche), donnant en général des résultats voisins des meilleurs modèles connexionnistes [39].

L'apprentissage de modèle RBF est supervisé donc il faut disposer d'un échantillon de l exemple (x_i, y_i) .

Les RBF sont utilisé pour résoudre des tâches de :

- ✓ Discrimination avec $y_i \in \{-1, 1\}^c$
- ✓ Régression ou prévision de signal (monovariété $y_i \in \mathbb{R}^c$, multivariété, $y_i \in \mathbb{R}^c$)

II.3.2.5. Apprentissage de modèles RBF :

L'apprentissage des RBF est divisé en partie non supervisé et partie supervisé Il consiste à régler quatre paramètres principaux [38] :

- Le nombre de neurones dans l'unique couche cachée ou le nombre des gaussiennes.
- La position des centres de ces gaussiennes μ .
- La largeur de ces gaussiennes σ (spread dans notre cas).
- Les poids de connexions entre les neurones cachés ω .

II.4. Conclusion :

Nous venons de voir dans ce chapitre des différents modèles de réseaux de neurones, c'est-à-dire une vue globale sur les réseaux de neurones. Nous nous sommes intéressés ensuite à la description des réseaux de neurones RBF et MLP. Ces méthodes fonctionnent en deux étapes: l'apprentissage et le test. Le chapitre suivant est consacré à la classification des emboles en utilisant le réseau RBF.



CHAPITRE III :
RESULTATS ET DISCUSSION

III.1. Introduction :

Nous allons aborder dans ce chapitre la classification des microembolies (les deux classes sont : gaz et solide) en utilisant un algorithme WPT (Wavelet Packet Transform : transformée en paquet d'ondelette) et les réseaux de neurones artificiel. WPT décompose les signaux RF en différentes bandes de fréquences et identifie quelles caractéristiques conduisent à une meilleure performance de reconnaissance. Plusieurs caractéristiques sont évaluées à partir des coefficients de détail et d'approximation, qui seront utilisées plus tard comme entrée au classificateur. La classification est l'un des domaines de recherche et d'application les plus actifs dans les réseaux de neurones. Ces derniers sont considérés comme un classificateur robuste. Ce chapitre résume les résultats de classification à partir d'un réseau de neurone à fonction radiale de base « RBF ».

Par la suite, et en raison de la malédiction de la dimensionnalité, nous utilisons la méthode de Score Fisher une technique pour réduire la dimensionnalité (sélection de caractéristiques),. Cette dernière étape est essentielle car les algorithmes de réduction de dimensionnalité améliorent la précision de la classification en sélectionnant les caractéristiques les plus pertinentes pour la tâche de classification.

III.2. Algorithme de détection :

La **Figure III.1** présente le schéma général du modèle de classification par réseau neuronal basé sur la WPT utilisé dans ce chapitre. Les signaux RF rétrodiffusés d'entrée sont d'abord détectés et collectés (acquisition du signal). Dans l'étape d'extraction des caractéristiques et pour chaque signal gazeux ou solide, une matrice de caractéristiques est construite. Cette est utilisée comme entrée du modèle RBF qui fournit en sortie une valeur de 1 ou 0 pour les embolies gazeuses ou solides respectivement.

- Classe 1 : embolie gaz représenté par un « 1 ».
- Classe 2 : embolie solide représenté par un « 0 ».

Le schéma général du modèle de classification par réseau neuronal basé sur la WPT utilisé dans ce chapitre est illustré à la **Figure III.1**. Les signaux RF rétrodiffusés sont d'abord détectés et collectés (acquisition du signal). Dans un deuxième temps, les coefficients WPT des signaux sont collectés. Les signaux d'entrée sont décomposés en un nombre optimal de bandes de fréquences à l'aide de la WPT. Par conséquent, il est essentiel de sélectionner une ondelette mère appropriée pour le signal analysé. Il est à noter que la meilleure ondelette mère

sur les mêmes types de signaux RF rétrodiffusés est Daubechies (db6) d'après les travaux dans la référence [40].

Dans la troisième étape, après avoir appliqué WPT sur les signaux RF rétrodiffusés, un vecteur de caractéristiques est construit à partir de l'énergie de chaque niveau de décomposition. Dans la dernière étape, toutes ces caractéristiques sont d'abord utilisées comme entrées du modèle de classification sans méthode de sélection des caractéristiques. Deuxièmement, en raison de la malédiction de la dimensionnalité, nous utilisons une technique de réduction de la dimensionnalité : la méthode du score de Fisher. Cette approche est motivée par le fait que les algorithmes d'apprentissage automatique les plus puissants ont tendance à s'embrouiller lorsqu'ils reçoivent un grand nombre de caractéristiques [41].

Pour les problèmes de classification binaire, il est important de valider le modèle de classification avec la technique de validation croisée. Avant de construire le modèle de classification, les échantillons sont divisés en trois sous-ensembles: ensemble d'apprentissage, ensemble de validation et ensemble de test. L'ensemble de test est utilisé uniquement pour l'évaluation du modèle sélectionné par la technique de validation croisée, tandis que l'ensemble de validation est utilisé pour régler les paramètres de classificateur. Par conséquent, l'algorithme n'a accès qu'aux ensembles d'apprentissage et de validation, l'ensemble de test n'est pas pris en compte dans le processus de sélection du meilleur modèle.

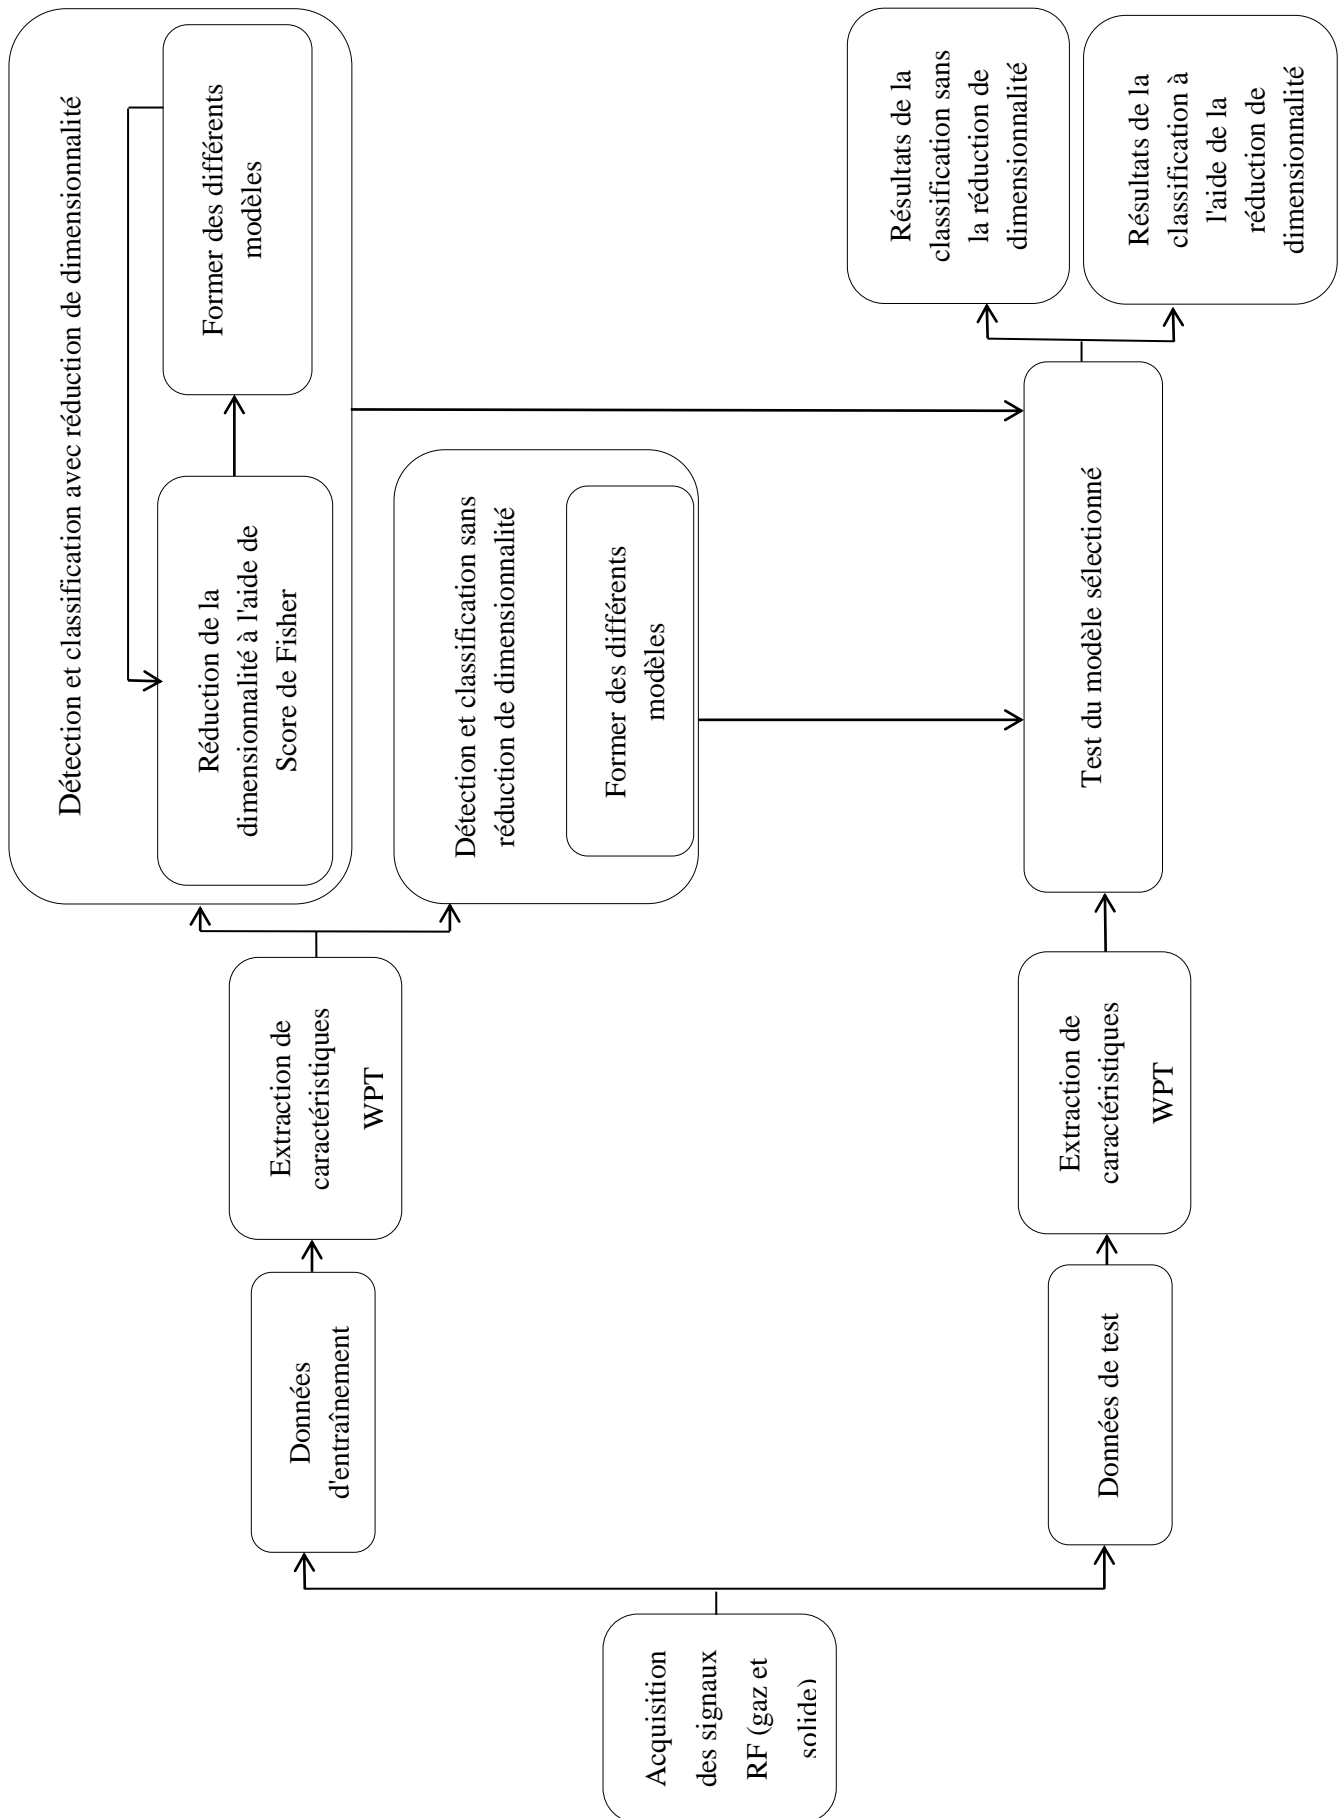


Figure III.1: Schéma général du modèle de classification par réseau neuronal basé sur la WPT.

III.3 Etude expérimentale (Acquisition des signaux):

L'étude expérimentale de l'acquisition des signaux échos a été développée au laboratoire INSERM U930 de l'Université François Rabelais Tours, France en 2008 par [24].

Le dispositif expérimental consiste en un fantôme (qui a les mêmes caractéristiques que le tissu humain) d'écoulement Doppler contenant un tube de 0,8 mm de diamètre. Le tube de 0,8 mm a été choisi car sa taille est proche de celle d'un vaisseau humain (**Figure III.2**). Afin d'imiter le comportement ultrasonique des embolus gazeux, des agents de contraste constitués de microbulles sont utilisés dans la configuration expérimentale. Un flux continu transporte les microbulles de gaz de type SonoVue à travers le vaisseau insonifié. SonoVue a été utilisé car c'est le seul agent de contraste disponible commercialement en Europe.

Cependant, les embolus solides présentent des propriétés acoustiques comparables à celles du tissu biologique. Ainsi, le matériau imitant les tissus entourant le vaisseau est choisi pour imiter le comportement des embolus solides.




Figure III.2: Dispositif expérimentale [24].

Les ondes ultrasonores sont générées avec un scanner Siemens Antares. Les acquisitions sont effectuées à une fréquence d'émission de 1,82 MHz avec une fréquence d'échantillonnage de 20 MHz.

Deux concentrations de microbulles sont utilisées: $5\mu\text{l}$ et $10\mu\text{l}$ [24]. Les régions d'intérêt où les signaux RF correspondant aux emboles gazeux et solides sont représentées sur les **Figure III.3** et **III.4**.




Figure III.3: Image échographique pour la concentration des microbulles de $5\mu\text{l}$.




Figure III.4: Image échographique pour la concentration des microbulles de $10\mu\text{l}$.

Deux base de données sont utilisées dans ce travail, chaque base contient 102 échantillons (51 emboles gazeux et 51 emboles solides). Ces données sont utilisées pour créer un certain

nombre de caractéristiques discriminantes exploitées pour la détection et la classification des microemboles en circulation.

La Figure suivante illustre les signaux RF gaz et solide normalisés pour les deux concentrations des microbulles. La base de données construite comprend 51 signaux gaz et 51 signaux solides pour chaque concentration.




Figure III.5: Signaux normalisés.

Ces signaux sont utilisés par la suite dans la section extraction des caractéristiques.

III.4. Extraction des caractéristiques :

Dans les problèmes de classification, nous cherchons toujours à atteindre le meilleur taux de classification en fonction des caractéristiques requises. L'extraction de caractéristiques affecte fortement la performance et la conception du modèle de classification. L'extraction de caractéristiques vise à décrire les signaux acquis à l'aide d'un certain nombre de caractéristiques discriminantes utiles pour la classification. Dans ce mémoire, l'extraction de caractéristique est basée sur la transformée en paquet d'ondelette (WPT).

III.4.1. La Transformée en paquets d'ondelettes : (WPT : Wavelet Packet Transform)

La décomposition en paquets d'ondelettes est une généralisation de l'analyse multi résolution. Elle consiste à décomposer le signal sur un arbre de fonctions de base obtenues à

partir de l'ondelette mère. Et comme pour la décomposition en ondelettes discrètes (T.O.D), il s'agit toujours de décomposer un signal au moyen d'un filtre passe-bas et d'un filtre passe-haut complémentaires. La différence réside dans le fait que les différents signaux de détails vont également faire l'objet à chaque itération d'une décomposition selon le même principe. La décomposition en paquets d'ondelettes peut donc être représentée sous la forme d'un arbre binaire [42].

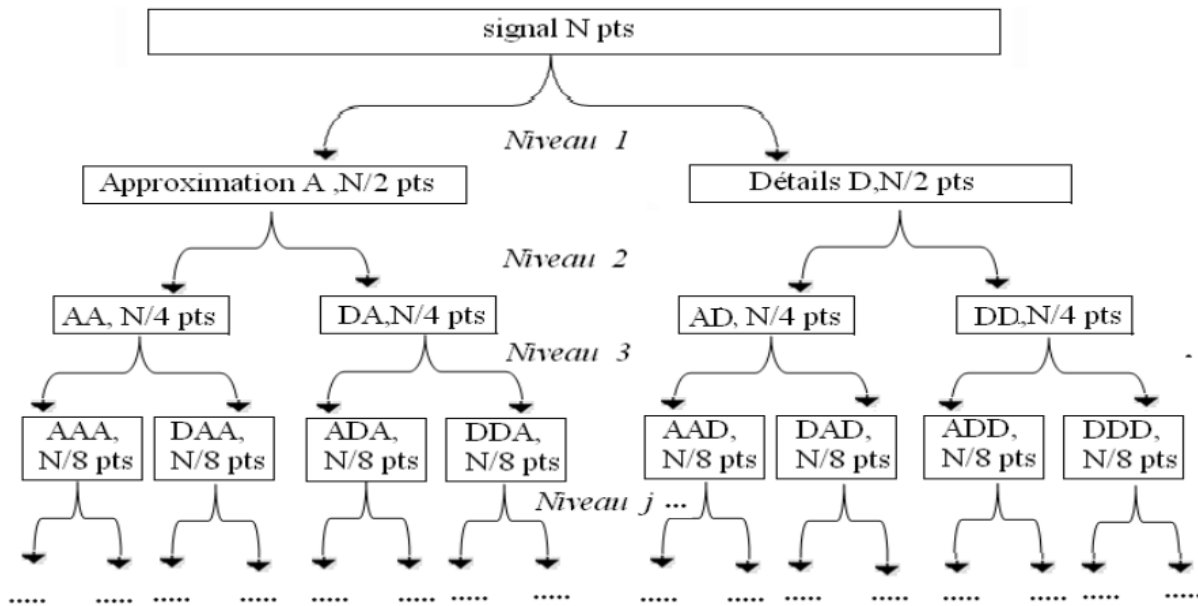


Figure III.6 : Arbre de la décomposition en paquets d'ondelettes (T.O.P) [42].

Pour chaque nœud intermédiaire de l'arbre (nœud père), on calcule un signal d'approximation (A) et un signal de détails (D). Deux signaux sont appelés nœuds fils. Chaque fils constitue ensuite un nœud père qui engendre à son tour deux fils, et ainsi de suite [42].




Figure III.7: Schéma de la représentation du nœud père et nœud fils [42].

Ainsi, au $j^{\text{ème}}$ niveau de décomposition, on obtient 2^j signaux de longueur $N/2^j$ chacun [42].

La **Figure III.8** montre un exemple de décomposition de signaux d'emboles gazeux et de signaux d'emboles solides utilisant la fonction d'ondelette Daubechies (db6) (trois niveau de décomposition).




Figure III.8 : Décomposition de signaux d'emboles gazeux et de signaux d'emboles solides.

Les coefficients de chaque nœud de la décomposition WPT est calculée pour chaque niveau (voir **Figure III.9**).

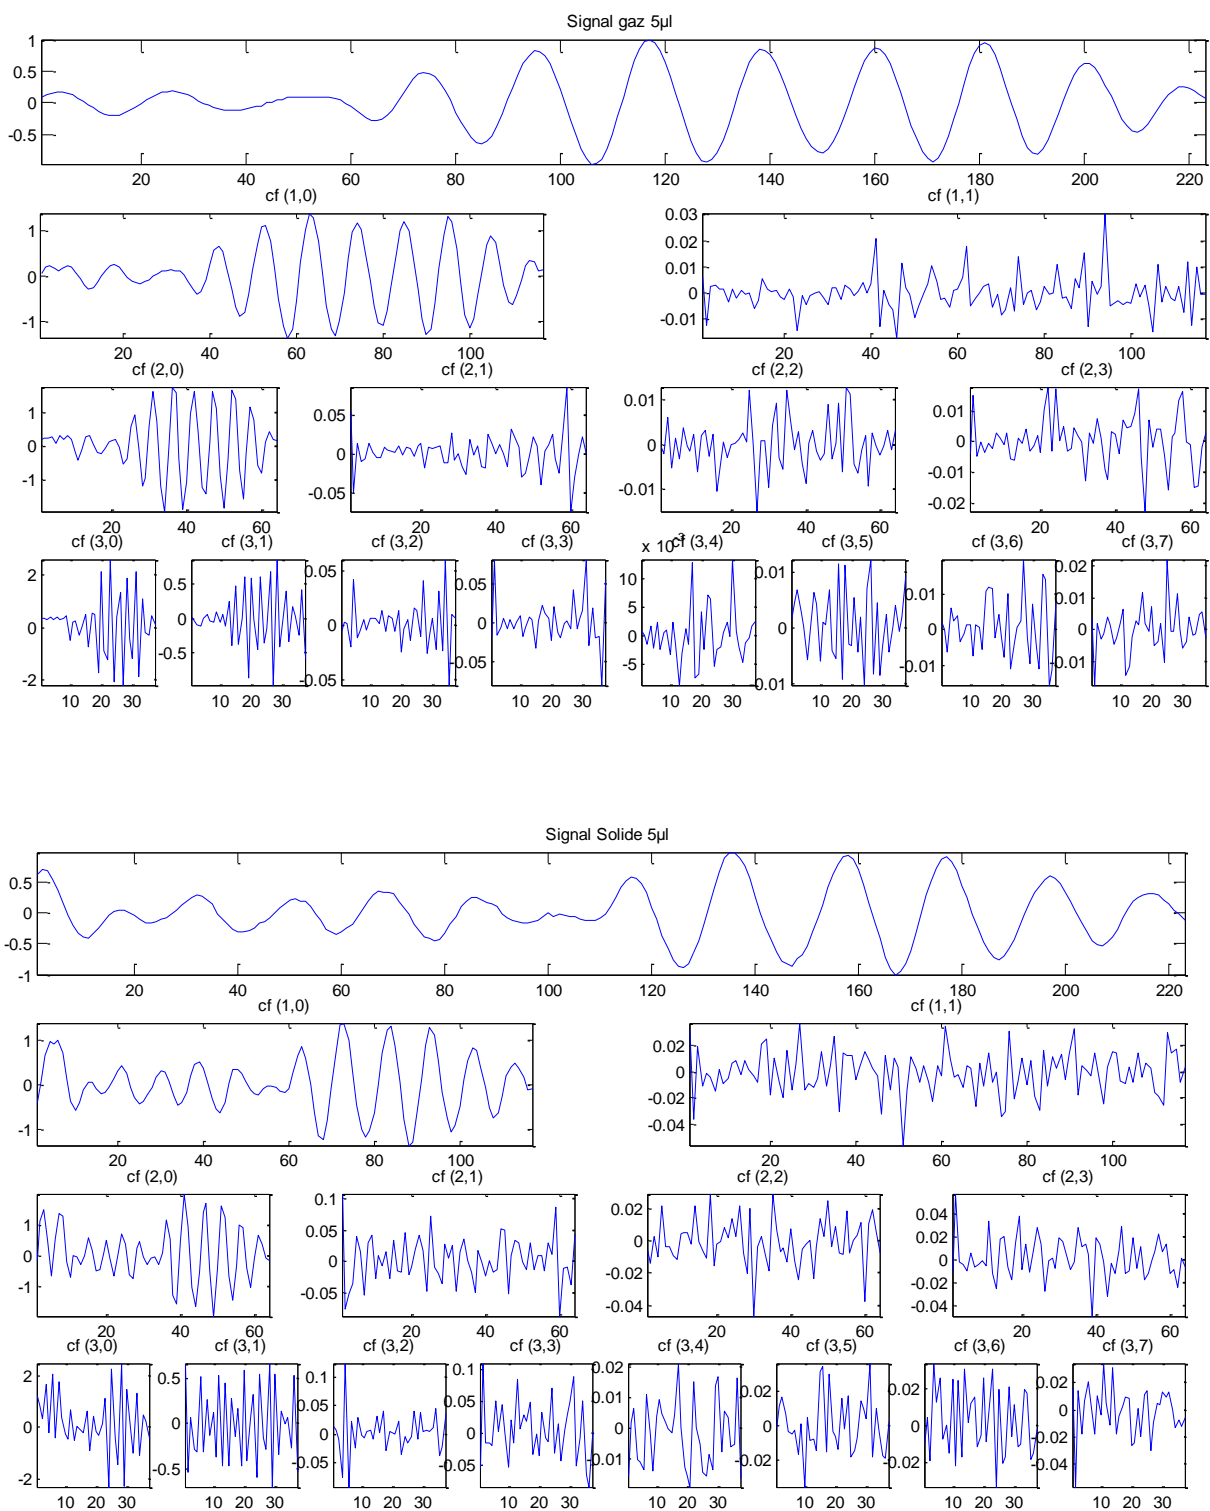


Figure III.9 : Les coefficients de chaque nœud de la décomposition WPT.

Les paramètres de détail et d'approximation ne sont pas directement utilisés comme entrées au modèle de classification. L'énergie est calculée pour les coefficients de détail et d'approximation de tous les niveaux de décomposition.

III.4.2. Energie :

L'énergie des signaux est calculée comme une caractéristique dans cette étude. Étant donné que l'apparition d'embolies gazeuses augmente souvent l'énergie du signal, il est typique d'utiliser de l'énergie pour la détection de microembolies [1].

L'énergie est calculé à partir des données à l'aide d'une relation mathématique, qui dépend de la somme des valeurs absolues des coefficients, et est obtenu par :

$$E = \sum_{j=1}^N |Cfs|^2 \quad (\text{III.1})$$

Cfs : Les coefficients de chaque nœud de la décomposition WPT.

Finalement on obtient 14 caractéristiques pour chaque concentration des microembolies comme montré dans le tableau suivant :

Tableau III.1: Les caractéristiques utilisées dans la classification.

Caractéristiques	
1	Energie nœud 11
2	Energie nœud 10
3	Energie nœud 20
4	Energie nœud 21
5	Energie nœud 22
6	Energie nœud 23
7	Energie nœud 30
8	Energie nœud 31
9	Energie nœud 32

10	Energie nœud 33
11	Energie nœud 34
12	Energie nœud 35
13	Energie nœud 36
14	Energie nœud 37

III.5. Classification sans réduction de dimension :

La classification sans réduction de dimension est divisée en deux parties, (i) Classification en utilisant toutes les caractéristiques comme entrées au classificateur RBF, (ii) classification en utilisant chaque caractéristique séparément comme entrée. Nous avons invoqué le même classificateur RBF (défini au Chapitre II).

III.5.1. Exactitude (Accuracy) :

La performance de la classification est évaluée en fonction de l'exactitude (Accuracy) Totale, exactitude Gaz et exactitude solide.

L'exactitude (Accuracy) est une mesure largement utilisée pour mesurer la performance d'un classificateur. L'exactitude (aussi appelé taux de classification) est le pourcentage des échantillons correctement classés :

$$\text{Exactitude} = \frac{\text{Nombre des échantillons bonnes classés}}{\text{Nombre totale des échantillons}}$$

III.5.2. Classification en utilisant toutes les caractéristiques:

Dans cette section nous allons présenter au classificateur RBF les 14 caractéristiques, calculées dans la section précédente, comme entrées.

Pour chaque valeur de nombre de neurone et de spread (largeur de la gaussienne) on calcul l'exactitude en utilisant l'ensemble de validation. Le nombre de neurone et la valeur de spread qui correspondent au meilleur taux de classification sont utilisés pour calculer l'exactitude de test.

Les tableaux suivants illustrent les paramètres optimisés du réseau RBF en utilisant toutes les caractéristiques comme entrées.

Tableau III.2 : Paramètres optimisés des réseaux RBF pour la concentration de 5 μ L.

Concentration de 5 μ l		
Base de données	Base de l'apprentissage	40
	Base de test	28
	Base de validation	34
Nombre de neurones	Nbr de neurones dans la couche d'entrée	14
	Nbr de neurones dans la couche caché	8
	Nbr de neurones dans la couche de sortie	2
Largeur de la gaussienne RBF (spread)	14	
Exactitude de validation (%)	97.05	

Tableau III.3: Paramètres optimisés des réseaux RBF pour la concentration de 10 μ L.

Concentration de 10 μ l		
Base de données	Base de l'apprentissage	40
	Base de test	28
	Base de validation	34
Nombre de neurones	Nbr de neurones dans la couche d'entrée	14
	Nbr de neurones dans la couche caché	15

	Nbr de neurones dans la couche de sortie	2
Largeur de la gaussienne RBF (spread)	80	
Exactitude de validation (%)	100	

On présente au meilleur modèle obtenu dans la section précédente un ensemble de test qui est différent de celui d'apprentissage est de validation :

- 14 échantillons pour le gaz.
- 14 échantillons pour le solide.

En utilisant ces paramètres optimisés, toutes les caractéristiques sont utilisées comme entrées à l'algorithme RBF. Les résultats sont illustrés dans les **tableaux III.4** et **III.5**.

Tableau III.4 : Taux de classification de toutes les caractéristiques pour concentration de 5 μ l.

	Exactitude Totale	Exactitude gaz	Exactitude solide
Toutes les caractéristiques	78.57%	71.42%	85.71%

Tableau III.5: Taux de classification de toutes les caractéristiques pour concentration de 10 μ l.

	Exactitude Totale	Exactitude gaz	Exactitude solide
Toutes les caractéristiques	75%	85.71%	64.28%

Les taux de classification totale sont de 75% et 78.57% pour les deux bases de données (5 μ l et 10 μ l) respectivement en utilisant toutes les caractéristiques comme vecteur d'entrée. Par conséquent, le vecteur de caractéristiques est trop grand pour être traité correctement par le classificateur.

III.5.3. Classification en utilisant chaque caractéristique séparément:

Pour surmonter cette limitation, on présente à l'algorithme RBF de classification chaque caractéristique séparément et on calcul les taux de classification. Les résultats sont présentés dans les **Tableaux III.6** et **III.7**.

Tableau III.6 : Taux de classification de chaque caractéristique pour concentration de 5 μ l.

Caractéristiques		Exactitude Totale (%)	Exactitude gaz (%)	Exactitude solide (%)
1	Energie nœud 11	75	85.71	64.28
2	Energie nœud 10	67.85	64.28	71.42
3	Energie nœud 20	53.57	71.42	35.71
4	Energie nœud 21	64.28	78.57	50
5	Energie nœud 22	75	85.71	64.28
6	Energie nœud 23	71.42	85.71	57.14
7	Energie nœud 30	78.57	78.57	78.57
8	Energie nœud 31	75	85.71	64.28
9	Energie nœud 32	71.42	85.71	57.14
10	Energie nœud 33	53.57	64.28	42.85
11	Energie nœud 34	<u>78.57</u>	<u>92.85</u>	<u>64.28</u>
12	Energie nœud 35	75	92.85	57.14
13	Energie nœud 36	75	85.71	64.28
14	Energie nœud 37	75	92.85	57.14

Tableau III.7 : Taux de classification de chaque caractéristique pour concentration de 10 μ l.

Caractéristiques		Exactitude Totale (%)	Exactitude gaz (%)	Exactitude solide (%)
1	Energie nœud 11	71.42	64.28	78.57
2	Energie nœud 10	60.71	57.14	64.28
3	Energie nœud 20	64.28	78.57	50
4	Energie nœud 21	71.42	100	42.85
5	Energie nœud 22	71.42	64.28	78.57
6	Energie nœud 23	71.42	64.28	78.57
7	Energie nœud 30	42.85	57.14	28.57
8	Energie nœud 31	75	71.42	78.57
9	Energie nœud 32	<u>78.57</u>	<u>78.57</u>	<u>78.57</u>
10	Energie nœud 33	60.71	78.57	42.85
11	Energie nœud 34	71.42	64.28	78.57
12	Energie nœud 35	71.42	64.28	78.57
13	Energie nœud 36	71.42	64.28	78.57
14	Energie nœud 37	71.42	64.28	78.57

Les meilleurs taux de classification sont de 78.57%% et 78.57% pour les deux bases de données (5 μ l et 10 μ l) respectivement en utilisant chaque caractéristique séparément comme entrée. On observe donc une amélioration de taux de classification pour la concentration de 10 μ l.

Afin d'améliorer encore les taux de classification, nous effectuons dans la section suivante une classification basée sur la technique de sélection de caractéristiques (réduction de la dimensionnalité).

III.6. Classification avec la réduction de la dimension :

Dans la section précédente, nous avons vu que le vecteur de caractéristiques est trop grand pour être traité correctement par le classificateur pendant l'apprentissage. Pour surmonter cette limitation, et pour trouver les meilleurs caractéristiques, nous mettons en œuvre une technique de réduction de la dimensionnalité à l'aide de l'algorithme de score de Fisher.

III.6.1. Score de Fisher :

Le score de Fisher est un algorithme de sélection de caractéristiques, c'est l'une des techniques de sélection de caractéristiques supervisées largement utilisées en raison de ses bonnes performances globales.

Le score de Fisher recherche des caractéristiques efficaces pour la discrimination. Afin de sélectionner les caractéristiques les plus significatives, elles sont triées selon l'ordre décroissant de leur critère de Fisher. Il attribue le score le plus élevé à la caractéristique sur laquelle les points de données de différentes classes sont éloignés les uns des autres tout en exigeant que les points de données de la même classe soient proches les uns des autres. Par conséquent, l'algorithme de score de Fisher fournit une liste classée de toutes les caractéristiques [1].

Le critère d'évaluation utilisé dans Fisher Score peut être formulé comme suit :

$$SC_F(f_i) = \frac{\sum_{j=1}^c n_j (\mu_{i,j} - \mu_i)^2}{\sum_{j=1}^c n_j \sigma_{i,j}^2} \quad (\text{III.2})$$


Où :

μ_i : est la moyenne de la caractéristique f_i .

n_j : est le nombre d'échantillons dans la $j^{\text{ème}}$ classe.

$\mu_{i,j}, \sigma_{i,j}^2$: sont la moyenne et la variance de la caractéristique f_i dans la classe j , respectivement.

Les **Figures III.10** et **III.11** présente le score de Fisher pour chaque caractéristique, en rouge les caractéristiques sont triées selon l'ordre décroissant de leur critère de Fisher. L'ordre d'origine des caractéristiques est présenté en bleu.



Caractéristique	Score
11	0.6514
12	0.6456
14	0.6310
5	0.6268
13	0.6143
6	0.5855
1	0.5555
9	0.4754
8	0.4576
2	0.1638
4	0.1491
10	0.1120
3	0.0872
7	0.0026

Figure III.10 : Score de Fisher avec concentration de microbulles (5µl).

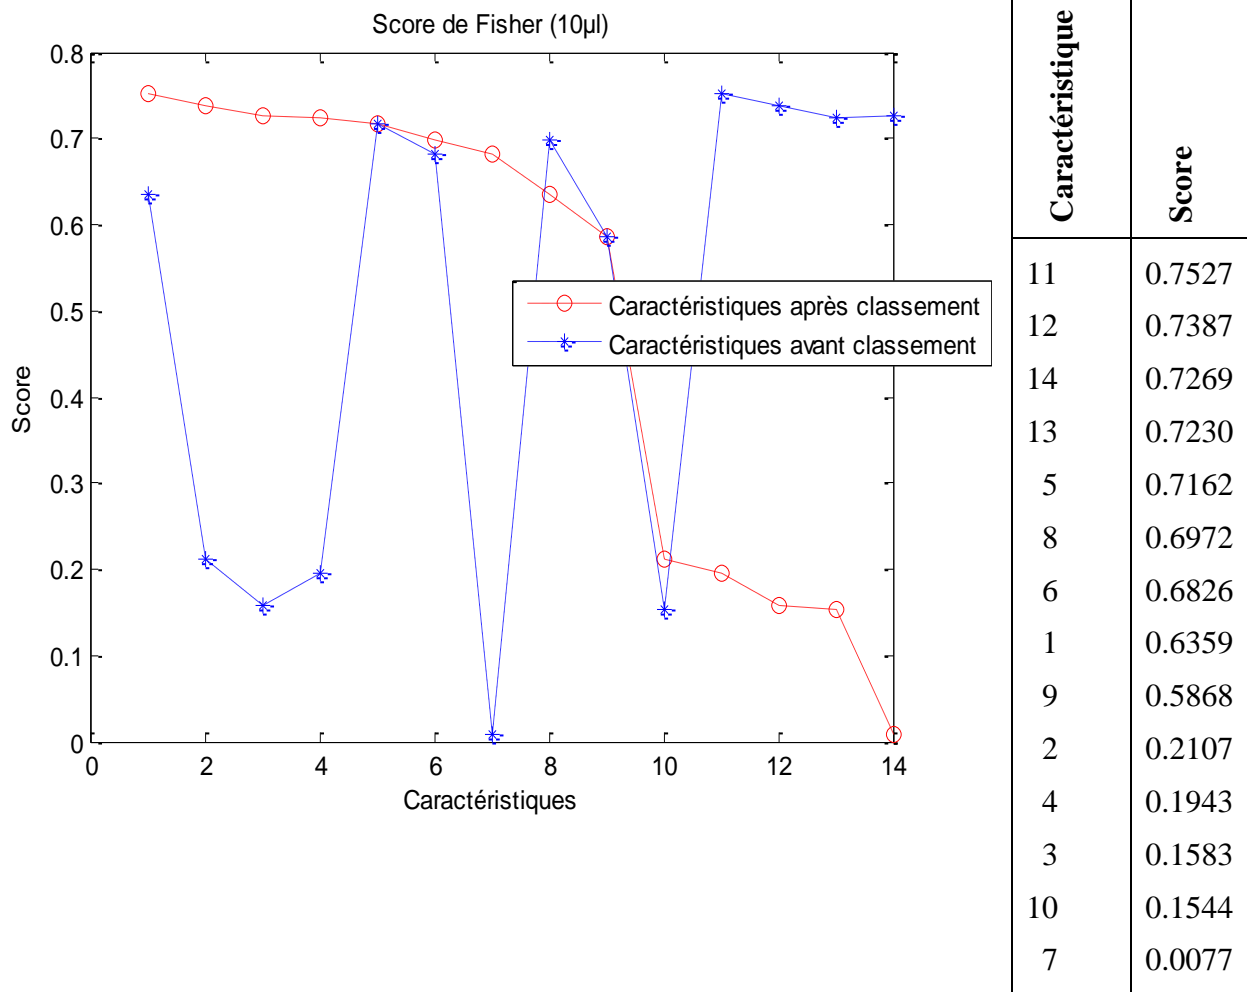


Figure III.11 : Score de Fisher avec concentration de microbulles (10 μ l).

Comme montré dans les **Figures III.10** et **III.11**, les caractéristiques sont classées par ordre décroissant, du plus haut au plus bas, en fonction de leur critère de Fisher correspondant, indépendamment de l'algorithme de classification. On remarque que pour les deux concentrations la caractéristique 11 (Energie nœud 34) donne les meilleurs scores de Fisher 0.6514 et 0.7527 pour les deux concentrations 5 μ l et 10 μ l respectivement.

Ensuite, la sélection du sous-ensemble de caractéristiques est effectuée en introduisant dans le classificateur la caractéristique ayant la valeur la plus élevée du critère de Fisher, puis en ajoutant la caractéristique classée suivante jusqu'à ce que toutes les caractéristiques classées soient ajoutées une par une. Nous choisissons l'ensemble de caractéristiques qui donne la meilleure exactitude de classification. Les résultats sont montrés dans les **Tableaux III.8** et **III.9** et dans les **Figure III.12** et **III.13**.

Tableau III.8: Sélection des caractéristiques pour la concentration du (5 μ l).

Caractéristiques	Exactitude Totale (%)	Exactitude gaz (%)	Exactitude solide (%)
11	78.57	92.85	64.28
11,12	71.42	85.71	57.14
11,12,14	75	85.71	64.28
11,12,14,5	85.71	85.71	85.71
11,12,14,5,13	85.71	85.71	85.71
11,12,14,5,13,6	<u>89.28</u>	<u>92.85</u>	<u>85.71</u>
11,12,14,5,13,6,1	82.14	78.57	85.71
11,12,14,5,13,6,1,9	78.57	78.57	78.57
11,12,14,5,13,6,1,9,8	82.14	100	64.28
11,12,14,5,13,6,1,9,8,2	85.71	85.71	85.71
11,12,14,5,13,6,1,9,8,2,4	82.14	85.71	78.57
11,12,14,5,13,6,1,9,8,2,4,10	89.28	78.57	100
11,12,14,5,13,6,1,9,8,2,4,10,3	82.14	78.57	85.71
11,12,14,5,13,6,1,9,8,2,4,10,3,7	75	57.14	92.85




Figure III.12: Sélection des caractéristiques avec Fisher score et RBF la concentration du (5 μ l).

Tableau III.9 : Sélection des caractéristiques pour la concentration du (10 μ l).

Caractéristiques	Exactitude Totale (%)	Exactitude gaz (%)	Exactitude solide (%)
11	71.42	64.28	78.57
11,12	82.14	78.57	85.71
11,12,14	82.14	78.57	85.71
11,12,14,5	82.14	85.71	78.57
11,12,14,5,13	<u>92.85</u>	<u>100</u>	<u>85.71</u>
11,12,14,5,13,6	89.28	100	78.57
11,12,14,5,13,6,1	89.28	100	78.57
11,12,14,5,13,6,1,9	89.28	100	78.57
11,12,14,5,13,6,1,9,8	89.28	92.85	85.71
11,12,14,5,13,6,1,9,8,2	82.14	85.71	78.57

11,12,14,5,13,6,1,9,8,2,4	71.42	78.57	64.28
11,12,14,5,13,6,1,9,8,2,4,10	75	85.71	64.28
11,12,14,5,13,6,1,9,8,2,4,10,3	75	78.57	71.42
11,12,14,5,13,6,1,9,8,2,4,10,3,7	75	85.71	64.28




Figure III.13 : Sélection des caractéristiques avec Fisher score et RBF la concentration du (10 μ l).

Les **Figures III.12** et **III.13** montrent l'évolution du taux de classification en fonction de nombre de caractéristiques sélectionnées en utilisant le score de Fisher et le réseau RBF. Pour la concentration de microbulle de 5 μ l la meilleure exactitude (89.28%) est obtenue en utilisant six caractéristiques. Pour la concentration de microembole de 10 μ l le meilleur taux de classification (92.85%) est obtenu en utilisant cinq caractéristiques.

Pour les deux concentrations des microbulles, une amélioration significative dans les taux de classification est observée en utilisant la méthode de sélection de caractéristiques. D'après

les **Figures III.13** et **III.14** le taux de classification diminue lorsque le nombre de caractéristiques sélectionnées augmente, ce qui prouve que l'apprentissage peut être détérioré par des caractéristiques non pertinentes.

III.7. Etude comparative :

Pour valider l'approche proposée, une étude comparative est effectuée entre notre modèle et autres techniques récemment publiée [24] utilisant les mêmes signaux RF rétrodiffusés dont ils ont exploité la transformé de Fourier pour analyser les microembolies gaz et solide. La comparaison est illustrée dans le **Tableau III.10**.

Tableau III.10: Etude comparative avec la référence [24].

Concentration des microbulles 5 μ l			
	Technique proposée WPT/Fisher.S/RBF	Référence [24] Fourier/ RBF	Référence [24] Fourier/ MLP
Exactitude totale (%)	<u>89.28</u>	<u>89.28</u>	<u>89.28</u>
Exactitude gaz (%)	92.85	92.85	78.57
Exactitude solide (%)	85.71	85.71	100
Concentration des microbulles 10 μ l			
	Technique proposée WPT/Fisher.S/RBF	Référence [24] Fourier/ RBF	Référence [24] Fourier/ MLP
Exactitude totale (%)	<u>92.85</u>	<u>92.85</u>	89.28
Exactitude gaz (%)	100	85.71	78.57
Exactitude solide (%)	85.71	100	100

D'après le **Tableau III.10**, notre modèle a réussi de trouver des taux de classification comparables par rapport aux résultats citée dans la référence [24] pour les deux concentrations des embolies 5 μ l et 10 μ l.

III.8. Conclusion :

Dans ce chapitre nous avons présenté en détail les résultats obtenus par notre modèle proposé. Ce dernier utilise le score de Fisher dans la tâche de sélection de caractéristiques et le réseau RBF dans la tâche de classification. Les résultats indiquent que la réduction de la dimensionnalité (sélection de caractéristiques) permet non seulement de trouver l'ensemble de caractéristiques le plus pertinent qui donne le taux de classification le plus élevé, mais aussi de réduire la taille du vecteur de caractéristiques donc la complexité du modèle.

Les résultats montrent l'utilité d'utiliser les signaux ultrasonores au lieu des signaux Doppler dans le domaine détection et la classification des micro-emboles. En effet, nous avons obtenue des taux de classification de 89.28 % et 92.85% pour les deux concentrations des microbulles de 5 μ l et 10 μ l respectivement. Ces résultats sont comparables aux résultats trouvés dans la référence [24].



CONCLUSION GÉNÉRALE

Conclusion Générale :

Dans notre système sanguin circulatoire les embolies peuvent causer des graves dommages tels qu'un accident vasculaire cérébral ou une crise cardiaque, d'où l'importance du système de classification automatique se reflète.

Dans des conditions spécifiques de l'onde d'excitation ultrasonore, les bulles gazeuses montrent un comportement non linéaire ce qui est exploité dans ce travail pour distinguer les microembolies gazeuses des solides. Par conséquent, nous avons suggéré dans cette étude de se concentrer sur les signaux d'ultrasons radiofréquence rétrodiffusés par les embolies car ils contiennent des informations supplémentaires sur l'embolie que le signal Doppler couramment utilisé.

Ce mémoire a abordé une étude sur la façon dont les problèmes de microembolies peuvent être caractérisés. Une nouvelle approche est proposée pour la classification des microembolies à l'aide des signaux ultrasonores, la transformée des paquets d'ondelette, la technique d'intelligence artificielle et aussi le score de Fisher.

Le réseau RBF opère en deux phases consécutives : une phase de conception et une phase de généralisation. La première phase consiste à choisir l'architecture optimale du modèle pour pouvoir s'adapter à différentes conditions d'entrée. Cette phase utilise la technique de validation croisée pour sélectionner les paramètres optimaux du classificateur. Une fois l'apprentissage du modèle est terminé, il passe en phase de généralisation pour réaliser la classification. Il est à noter que la performance du modèle, durant cette phase, est estimée sur une partie des données (ensemble de test) qui n'a pas été utilisée lors de sa construction.

Le modèle proposé a atteint un taux de classification de 89.28 % pour la concentration des microbulles de 5 μ l 92.85% pour la concentration de 10 μ l. Les résultats ont démontré l'opportunité de classer les embolies en utilisant les signaux ultrasonores tout en exploitant le comportement non linéaire des embolies gazeuses.

La base de données sur laquelle nous allons valider notre approche est fournie par le laboratoire INSERM U930 de l'université François Rabelais de Tours (France), dans le cadre du projet de coopération France/Algérie : INSERM/DPGRF 2007-2008.


Pour de l'approche proposée, une étude comparative est effectuée entre notre modèle et autres techniques récemment publiée [24] utilisant les mêmes signaux RF rétrodiffusés dont

ils ont exploité la transformé de Fourier pour analyser les microembolés gaz et solide. La comparaison est illustrée dans le **Tableau III.10**.

Une étude comparative entre le modèle proposé et une étude relativement récente [24], afin de valider les résultats trouvés. Il est à noter que l'étude dans la référence [24] utilise les mêmes signaux RF rétrodiffusés et analyse les signaux gaz et solide en utilisant la transformé de Fourier. Notre approche présente des taux de classification similaires à ceux trouver dans l'étude citée par [24].

Ce mémoire offre un aperçu sur l'utilisation des signaux ultrasonores au lieu des signaux Doppler pour classer les microembolés. Bien que l'utilité clinique nécessite encore une évaluation et une validation en diagnostic pratique.

L'extension immédiate de l'étude présentée dans ce mémoire est l'utilisation des techniques de sélection des caractéristiques et de classification plus pertinentes pour améliorer les taux de classification.



REFERENCES ET BIBLIOGRAPHIES

Références et Bibliographies :

- [1] FERROUDJI, Karim. Particle characterization by ultrasound using artificial intelligence methods. Thèse de doctorat. Université El Hadj Lakhdar de Batna. 2017.
- [2] ABBOTT, William M., MALONEY, Randolph D., MCCABE, Charles C., et al. Arterial embolism: a 44-year perspective. *The American Journal of Surgery*, 1982, vol. 143, no 4, p. 460-464.
- [3] JUDGE, Ciaran, MELLO, Sarah, BRADLEY, David, et al. A systematic review of the causes and management of ischaemic stroke caused by nontissue emboli. *Stroke research and treatment*, 2017, vol. 2017, p.1-8.
- [4] BRUYÈRE, M., ALBALADEJO, P., DROUPY, S., et al. Embolie gazeuse au cours d'une néphrectomie élargie par rétropéritonéoscopie. In : *Annales francaises d'anesthesie et de reanimation*. Elsevier Masson, 2001. p. 36-39.
- [5] SOUDAY, V, ASFAR, P., et MUTH, C. M. Prise en charge diagnostique et thérapeutique des embolies gazeuses. *Réanimation*, 2003, vol. 12, no 7, p. 482-490.
- [6] PRANDONI, Paolo, LENSING, Anthonie WA, et PRINS, Martin H. Pulmonary embolism in patients hospitalized for syncope. *The New England journal of medicine*, 2017, vol. 376, no 5, p. 497.
- [7] JEAN-PHILIPPE Rivière. Thrombose, phlébite, embolie : quels sont vos risques? 2003 from:[http://www.doctissimo.fr/html/sante/mag_2003/sem01/mag0627/sa_6870_thrombose_risques.htm].
- [8] MUTH Claus M, and SHANK Erik S. Gas embolism. *New England Journal of Medicine*, 2000, vol. 342, no 07, p. 476-482.
- [9] PALANCHON, Peggy Christiane. *Ultrasound harmonic classification of microemboli*. Livre. Erasmus University Rotterdam. 2004.
- [10] BROWNE, Jacinta E. A review of Doppler ultrasound quality assurance protocols and test devices. *Physica Medica*, 2014, vol. 30, no 7, p. 742-751.
- [11] LAROVERE Kerri L and O'BRIEN Nicole F. Transcranial Doppler Sonography in Pediatric Neurocritical Care. *Journal of Ultrasound in Medicine*, 2015, vol. 34, no 12, p. 2121-2132.

-
- [12] BRUCHER Rainer and RUSSELL David. Automatic online embolus detection and artifact rejection with the first multifrequencytranscranial Doppler. *Stroke*, 2002, vol. 33, no 08, p. 1969-1974.
- [13] MARTINS, Bo. 2D Ultrasound Imaging with Pulsed Wave Doppler or Color Flow Imaging. U.S. Patent Application No 16/080,366, 14 févr. 2019.
- [14] GIRAULT, Jean Marc. Apport des techniques du traitement du signal à l'analyse et détection de signaux emboliques. Thèse de doctorat. Université François-Rabelais de Tours. 1999.
- [15] GRENIER, N. et CLAUDON, M. Bases physiques du Doppler. *Echo-doppler, Société Française de la Radiologie.*, 1995, vol. 1, no 1, p. 13.
- [16] MARKUS, Hugh S. et PUNTER, Martin. Can transcranial Doppler discriminate between solid and gaseous microemboli? Assessment of a dual-frequency transducer system. *Stroke*, 2005, vol. 36, no 8, p. 1731-1734.
- [17] PINET, C., BOUSSUGES, A., et OREHEK, J. Le doppler transcrânien : une technique méconnue en pneumologie pour le diagnostic des shunts anatomiques droit-gauche. *Revue des maladies respiratoires*, 2001, vol. 18, no 3, p. 331-332.
- [18] Terverkrijging van de graad van doctor aan de Erasmus Universiteit Rotterdam op gezag van de Rector Magnificus Prof. dr. S.W.J. Lamberts, en volgens het besluit van het College voorPromoties. *Ultrasound Harmonic Classification of Microemboli*.
- [19] RUSSELL, David et BRUCHER, Rainer. Online automatic discrimination between solid and gaseous cerebral microemboli with the first multifrequencytranscranial Doppler. *Stroke*, 2002, vol. 33, no 8, p. 1975-1980.
- [20] AYDIN, Nizamettin, MARVASTI, Farrokh, et MARKUS, Hugh S. Embolic Doppler ultrasound signal detection using discrete wavelet transform. *IEEE Transactions on Information Technology in Biomedicine*, 2004, vol. 8, no 2, p. 182-190.
- [21] MARKUS, Hugh, LOH, Alex, et BROWN, Martin M. Detection of circulating cerebral emboli using Doppler ultrasound in a sheep model. *Journal of the neurological sciences*, 1994, vol. 122, no 1, p. 117-124.

- [22] FERROUDJI, Karim. Classification des particules par ultrason et réseaux de neurones artificiels (Application aux embolies). Thèse de Magister. Université El Hadj Lakhdar de Batna. 2010.
- [23] LICHTENSTEIN, Daniel. L'échographie générale en réanimation. Livre. Springer Science & Business Media 2002.
- [24] BENOUDJIT, Nabil, FERROUDJI, Karim, BAHAZ, Mohamed, et al. In vitro. Micro-emboli classification using neural network models and RF signals. *Ultrasonics*, 2011, vol. 51, no 3, p. 247-252.
- [25] TOUZET, Claude. Les réseaux de neurones artificiels, introduction au connexionnisme. Livre. Collection de l'EERIE. 1992.
- [26] BAGHLI, Lotfi. Thèse de doctorat. Contribution à la commande de la machine asynchrone, utilisation de la logique floue, des réseaux de neurones et des algorithmes génétiques. Université Henri Poincaré, Nancy-I en Génie Electrique. 14 Janvier 1999.
- [27] MARINKOVIĆ, Zlatica, CRUPI, Giovanni, CADDEMI, Alina, et al. A review on the artificial neural network applications for small-signal modeling of microwave FETs. *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields*, 2020, vol. 33, no 3, p. e2668.
- [28] YANN, Boniface, NICOLAS P, Rougier. Introduction aux réseaux de neurones artificiels. *Sciences Cognitives*, Université De Lorraine. Janvier 2012.
- [29] ERTUĞRUL, Ömer Faruk. A novel type of activation function in artificial neural networks: Trained activation function. *Neural Networks*, 2018, vol. 99, p. 148-157.
- [30] DA SILVA, Ivan Nunes, SPATTI, Danilo Hernane, FLAUZINO, Rogerio Andrade, et al. Artificial neural network architectures and training processes. In : *Artificial neural networks*. Springer, Cham, 2017. p. 21-28.
- [31] CHAOUI, Hicham. Conception et comparaison de lois de commande adaptative à base de réseaux de neurones pour une articulation flexible avec non-linéarité dure. Mémoire présenté de la maîtrise en génie électrique. Université de Québec à Trois -Rivières. Décembre 2002.
- [32] GELLY, Grégory. Réseaux de neurones récurrents pour le traitement automatique de la parole. Thèse de doctorat. 2017.
- [33] M. Yessin AMMAR «Mise en oeuvre de réseaux de neurones pour la modélisation de cinétiques réactionnelles en vue de la transposition Batch/Continu». Thèse de Doctorat de l'I.N.P. Toulouse. Juillet 2007.
- [34] Marc Parizeau « Réseaux de neurones » Thèse doctorat. Université LAVAL. 2004.

-
- [35] MOHAMMADI, Javad, ATAEI, Mohammad, KAKAEI, R. Khalo, et al. Prediction of the production rate of chain saw machine using the multilayer perceptron (MLP) neural network. *Civ. Eng. J*, 2018, vol. 4, no 7, p. 1575-1583.
- [36] BENOUDJIT Nabil and VERLEYSSEN Michel. On the kernel widths in radial-basis function networks. *Neural Processing Letters*, 2003, vol. 18, no 02, p. 139-154.
- [37] LIN, Hongjun, DAI, Qunyun, ZHENG, Lili, et al. Radial basis function artificial neural network able to accurately predict disinfection by-product levels in tap water: Taking haloacetic acids as a case study. *Chemosphere*, 2020, vol. 248, p. 125999.
- [38] ZAAROUR, Nour. Modélisation d'un canal minier Ultra Large Bande (UWB) en utilisant les réseaux de neurones Artificiels RBF. Thèse de doctorat. Université du Québec en AbitibiTémiscamingue. 2013. Références et Bibliographiques 104.
- [39] AYALA, Helon Vicente Hultmann, HABINEZA, Didace, RAKOTONDRABE, Micky, et al. Nonlinear black-box system identification through coevolutionary algorithms and radial basis function artificial neural networks. *Applied Soft Computing*, 2020, vol. 87, p. 105990.
- [40] FERROUDJI Karim, BAHAZ Mohamed, BENOUDJIT Nabil, and BOUAKAZ Ayache. Selection of a suitable mother wavelet for microemboli classification using SVM and RF signals. In : 24th International Conference on Microelectronics (ICM), IEEE, 2012. p. 1-4.
- [41] ROSSI Fabrice, LENDASSE Amaury, FRANÇOIS Damien, WERTZ Vincent, and VERLEYSSEN Michel. Mutual information for the selection of relevant variables in spectrometric nonlinear modelling. *Chemometrics and intelligent laboratory systems*, 2006, vol. 80, no 02, p. 215-226.
- [42] MEZIANI Fadia, Analyse du degré de sévérité pathologique des signaux phonocardiogrammes (PCGs) par application des transformées d'ondelettes, Thèse de doctorat. UNIVERSITE ABOU BEKR BELKAID TLEMCEN, juin 2013.