



الجمهورية الجزائرية الديمقراطية الشعبية

Republique Algerienne Democratique 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 : Réseau et Télécommunication

Par : SAOULI Zaid

Sujet

Analyse et caractérisation des microbulles par radiofréquence et transformée par ondelettes discrète

Evalué , le 09/06/2021 , par le jury composé de :

M. BENTAHAR TAREK
M. FERROUDJI KARIM
Mme OUACIFI MALIKA

MCB
MCB
MAA

Président
Rapporteur
Examinatrice

Promotion : 2020/2021

DÉDICACE

NOUS DÉDIONS CE MÉMOIRE.

A NOS CHERS PARENTS

POUR LEUR PATIENCE, LEUR AMOUR, LEUR SOUTIEN ET LEURS

ENCOURAGEMENTS.

A MES FRÈRES

A MES SŒURS

A TOUTE LA FAMILLE

A MES AMIS ET MES CAMARADES

SANS OUBLIER TOUS LES PROFESSEURS QUE SOIT DU PRIMAIRE, DU
MOYEN,

DU SECONDAIRE OU DE L'ENSEIGNEMENT SUPÉRIEUR

REMERCIEMENT

AU DÉBUT, MERCI DIEU(الحمد لله)

MES REMERCIEMENTS S'ADRESSENT À MON ENCADRANT, CO-RESPONSABLE DE CE MASTER, L'ENSEIGNANT FERROUDJI KARIM, MAÎTRE DE CONFÉRENCE-B- À L'UNIVERSITÉ LARBI TÉBÉSSI -TÉBESSA, POUR AVOIR ACCEPTÉ DE DIRIGER CE TRAVAIL. SON SOUTIEN, SES COMPÉTENCES ET SA CLAIRVOYANCE M'ONT ÉTÉ D'UNE AIDE INESTIMABLE.

JE SOUHAITE REMERCIER MOATAZ MESSINI POUR TOUTE L'AIDE QU'IL M'A APPORTÉ.

JE TIENS À REMERCIER SINCÈREMENT LES MEMBRES DU JURY QUI ME FONT LE GRAND HONNEUR D'ÉVALUER CE TRAVAIL.

UN MERCI SPÉCIAL À MON PÈRE DE MOHAMMED BOUCIRI POUR SES RELECTURES, SES CORRECTIONS ET SON ATTENTION BIENVEILLANTE DANS CE TRAVAIL.

MES REMERCIEMENTS LES PLUS CHALEUREUX VONT À TOUS MES CAMARADES AU MASTER 2 RÉSEAU ET TÉLÉCOMMUNICATION UNIVERSITÉ LARBI TÉBÉSSI -TÉBESSA, AINSI QUE TOUS MES AUTRES CAMARADES DE CETTE UNIVERSITÉ POUR LEUR PRÉSENCE DANS LES MOMENTS DIFFICILES ET LES EXCELLENTS MOMENTS QUE J'AI PASSÉS AVEC EUX TOUT AU LONG DE CETTE ANNÉE.

MERCI

SAOULI ZAID

Liste des symboles

Liste des symboles.

AVC : Accident vasculaire.

PRF : Fréquence de répétition d'impulsion « pulse repetition frequency ».

DCT (TCD) : Doppler transcrânienne.

DWT : Transformé en ondelette discrète.

DS : Speckle doppler.

RF : Radio fréquence.

THI : Imagerie harmonique tissulaire.

Corr (e) : Coefficient de corrélation.

C1 : Classe 1.

C2 : Classe 2.

FFT : Transformé de fourrier rapide « Fast Fourier transform ».

IA : Intelligence artificielle.

RNA : Réseau de neurone artificielle.

RN : Réseau de neurone.

MLP : Perceptron multicouche « multi layer perceptron ».

ART : Théorie de la résonance adaptative « adaptative resonance theory ».

PNN : Réseau de neurone probabiliste « probabilistic neural network ».

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

RBF : Réseau a fonction de base radial « Radial Basis Fonction ».

FLN : Réseau de liaison fonctionnelle.

FFNN : Réseau de neurone feed forward « feed forward neural network».

F : Fonction d'activation.

E : Critère quadratique.

ω_j : Poids.

σ_j : Largeur.

μ_j : Centre.

SVD : Décomposition en valeur singulier.

TP: True Positive

TN: True Negative

FP: False Positive

FN: False Negative

Spread : Largeur de la gaussienne.

MN : Nombre de neurone.

ACC: Accuracy

Liste des tableaux

Chapitre II : Réseaux de neurones

Tableau II-1:Correspondance RNA - domaines d'application 32

Chapitre III : Classification des emboles par réseau de neurone à fonction radiale de base.

Tableau III-1: Les caractéristiques des signaux gaz et solide de 5 μ l. 52

Tableau III-2: Les caractéristiques des signaux gaz et solide de 10 μ l 52

Tableau III-3:Matrice de confusion pour le modèle de classification binaire..... 54

Tableau III-4: Division de la base de données en ensembles. 56

Tableau III-5:Paramètres optimisés du réseau RBF en utilisant les huit caractéristiques come entrées (concentration 5 μ l)..... 58

Tableau III-6:Paramètres optimisés du réseau RBF en utilisant les huit caractéristique come entrées (concentration 10 μ l)..... 59

Tableau III-7:Exactitudes (accuracy)de chaque caractéristique pour concentration de 5 μ l... 60

Tableau III-8:Exactitudes (accuracy) de chaque caractéristique pour concentration de 10 μ l. 60

Tableau III-9:Exactitudes (accuracy) de toutes les caractéristiques pour concentration de... 61

Tableau III-10:Exactitudes (accuracy) de toutes les caractéristiques pour concentration de 10 μ l..... 61

Tableau III-11:Matrice de confusion du test pour concentration 5 μ l..... 62

Tableau III-12: Matrice de confusion du test pour concentration 10 μ l..... 62

Tableau III-13:Etude comparative avec les résultats obtenus dans la référence [4]. 64

Liste des figures

Chapitre I : Etat de l'art sur le phénomène d'embolie et les approches de caractérisation d'embolie par ultrason.

Figure I -1: Bulle obstruant le flux artériel terminal dans un vaisseau cérébral	19
Figure I -2: Développement d'un thrombus : A. Hanche, C. cuisse. B jambe.....	20
Figure I -3: Schéma d'un poumon avec embolie pulmonaire.....	20
Figure I -4: Sonogramme et énergie à court-terme de signaux Doppler micro-emboliques...	22
Figure I -5: Sonogramme du signal Doppler micro-embolique [10].	24
Figure I -6: Oscillations symétriques (linéaires) et asymétriques (non linéaires) d'une microbulle soumise à une onde de pression[21]	27

Chapitre II : réseaux de neurones

Figure II-1: Correspondance entre neurones biologiques et neurones artificiels.	30
Figure II-2: Réseau de neurones sans couche cachée.	33
Figure II-3: Les réseaux de neurones feed-forwarded	33
Figure II-4: Réseau de neurones avec couche cachée.....	34
Figure II-5: Réseaux de neurones avec plusieurs nœuds de sortie.	34
Figure II-6: Réseaux de neurones avec plusieurs couches cachés.....	37
Figure II-7: Fonction sigmoïde.	38
Figure II-8: Partition de l'espace d'entrée de dimension 2 réalisée par un Perceptrons comportant comme un ET booléen	39
Figure II-9: La structure du réseau RBF.	42

Chapitre III : Classification des embolies par réseau de neurone à fonction radiale de base.

Figure III-1: Schéma du système de classification basé sur DWT et RBF.	47
Figure III-2: Signaux normalisés.	48
Figure III-3: Exemples DWT de signal RF rétrodiffusé utilisant Daubechies (db6) comme ondelette mère pour la concentration 5 µl. (a) gaz, (b) solide.....	50
Figure III-4: Exemples DWT de signal RF rétrodiffusé utilisant Daubechies (db6) comme ondelette mère pour la concentration 10 µl. (a) gaz, (b) solide.....	51
Figure III-5: Diagramme du système de classification.....	53
Figure III-6: Optimal parameters using Cross validation strategy.	55
Figure III-7: Validation croisée : (a) concentration 5µl, (b) concentration 10µl.....	57

Figure III-8: Sortie de test du réseaux RBF pour la concentration 5 μ l.	63
Figure III-9: Sortie de test du réseaux RBF pour la concentration 10 μ l.	63

ANNEX

Figure A -1: Dispositif expérimentale.	70
Figure A -2: Image échographie pour la concentration des microbulles de 5 μ l.	71
Figure A -3: Image échographie pour la concentration des microbulles de 10 μ l.	72
Figure A -4: Signal RF extrait des images échographiques (concentration 5 μ l).	73
Figure A -5: Signal RF extrait des images échographiques (concentration 10 μ l).	73
Figure A -6: Image échographie normalisée de 5 μ l.	74
Figure A -7: Image échographie normalisée de 10 μ l.	74
Figure A -8: Signaux normalisés.	75

بسم الله الرحمن الرحيم

Résumé :

Étant donné que la détection visuelle et l'analyse des signaux emboliques radiofréquences par des experts est subjective pour l'expérience de l'observateur et prend également beaucoup de temps, le développement de systèmes d'aide à la décision informatisés visant à caractériser des particules, qu'il s'agisse des embolies solides ou gazeuses, a une grande importance clinique pour le choix du traitement approprié pour le patient..

Ce mémoire propose un système de classification automatique des microbulles circulantes dans les vaisseaux sanguins en utilisant les techniques de l'intelligence artificielle et les signaux ultrasonores radiofréquences au lieu des signaux Doppler traditionnellement utilisés. Nous exploitons la transformée en ondelettes discrète (DWT) pour caractériser le comportement des embolies solides et gazeuses.

Mot clés : embolie, radiofréquence, ultrason, transformée en ondelettes discrète embolie, intelligence artificielle.

ملخص :

نظراً لأن الاكتشاف المرئي وتحليل إشارات الصمة بالترددات الراديوية من قبل الخبراء أمر شخصي لتجربة المراقب ويستغرق أيضاً وقتاً طويلاً ، فإن تطوير أنظمة دعم القرار المحوسب التي تهدف إلى توصيف الجسيمات سواء كانت صلبة أو غازية له أهمية إكلينيكية كبيرة في اختيار العلاج المناسب للمريض.

تقترح هذه الرسالة نظام تصنيف آلي للفقاعات الدقيقة المنتشرة في الأوعية الدموية باستخدام تقنيات الذكاء الاصطناعي وإشارات الموجات فوق الصوتية بالترددات الراديوية بدلاً من إشارات الدوبلر المستخدمة تقليدياً. نستغل التحويل المويجي المنفصل (DWT) لتوصيف سلوك الصمات الصلبة والغازية.

الكلمات المفتاحية: الصمة ، الترددات الراديوية ، الموجات فوق الصوتية ، الانسداد المويجي المنفصل ، الذكاء الاصطناعي

Summary:

Since the visual detection and analysis of radiofrequency embolic signals by experts is subjective to the observer's experience and also time consuming, the development of computerized decision support systems aimed at characterizing particles whether solid or gas emboli is of great clinical importance in choosing the appropriate treatment for the patient.

This study proposes an automatic classification system for microbubbles circulating in blood vessels using artificial intelligence techniques and radiofrequency ultrasound signals instead of the Doppler signals traditionally used. We exploit the discrete wavelet transform (DWT) to characterize the behavior of solid and gas emboli.

Keywords: embolus, radiofrequency, ultrasound, discrete wavelet embolism, artificial intelligence.

Table des matières

Dédicace	2
Remerciement.....	3
Liste des symboles	4
Liste des tableaux	6
Liste des figures	7
Résumé.....	9
Introduction Générale.....	15

Chapitre I : Etat de l'art sur le phénomène d'embolie et les approches de caractérisation d'embolie par ultrason.

1.Introduction	18
2.Définition d'embolie	18
3.Type d'embolies.....	18
3.1. Embolie gazeuse.....	18
3.2. Embolie pulmonaire	19
Causes de l'embolie pulmonaire.....	19
3.3. Embolie artérielle:	20
3.4. Embolie cérébrale:.....	21
3.5. Embolie rétinienne:	21
3.6. Embolie septique:.....	21
3.7. Embolie amniotique :	21
3.8. Embolie graisseuse:.....	21
4. Causes d'embolie :	21
5. Techniques de détection :.....	22
5.1 Techniques de détection d'embolie utilisant les signaux Doppler	23
6. Interaction entre les bulles de gaze et l'ultrason	26
6.1. Agents de contraste pour l'ultrason graphie :	26
7. Conclusion :.....	27

Chapitre II : réseaux de neurones

1. Introduction	29
2. Réseaux de neurones artificiels	29
2.1. Histoire des réseaux de neurones artificiels	29
2.2. Définition	30
-Comparaison des neurones pour montrer la différence entre les neurones biologiques et artificiels :	30
2.3 Domaine d'application.....	31
2.5. Fonctionnement.....	32
2.7. Apprentissage des réseaux de neurones	35
3. Types de réseaux de neurones	35
3.1. Le perceptron multicouche (Multi Layer Perceptron MLP)	36
3.1.1 Définition	36
3.1.2 Architecture du réseau.....	36
3.1.3. Fonction de transfert.....	37
3.1.4. Apprentissage de model MLP	38
3.1.5.Algorithme de rétropropagation	40
3.2 Réseaux à fonction radiale de base (RBF radial basis fonction).....	41
3.2.1.Principe de RBF	41
3.2.2.Architecture de RBF	41
3.2.3.Fonction de transfère.....	43
3.2.4 .Apprentissage de modèles RBF	43
4.CONCLUSION	45

Chapitre III : Classification des emboles par réseau de neurone à fonction radiale de base.

1.Introduction	47
Partie I : Extraction des caractéristiques en utilisant DWT	47
1.L'utilisation de la DWT pour l'extraction des caractéristiques	48
2.1. Transformation en ondelettes	48
2.2.Extraction de caractéristiques.....	49

Part II : Classification par RBF “Radial Basis Function Neural Networks	53
1. Principe du système de classification.....	53
2.Critères de prissions	54
2.1.Matrice de confusion :.....	54
2.2.Accuracy.....	55
3.Sélection de modèle (validation croisée)	55
4. Classification par RBF	59
4.1.Déroulement de test.....	59
4.2.Discussion des résultats :.....	60
7.Conclusion.....	65
Conclusion Générale :	67
ANNEX.....	70
Référence et bibliographie :	77

INTRODUCTION GENERALE

Introduction Générale :

Le corps humain est considéré comme un matériau riche pour la recherche scientifique en raison de sa complexité, en particulier de son système vasculaire, considéré comme un réseau très complexe. Ce dernier s'appuie sur un système qui contient des milliers de petits pipelines utilisés pour le transport qui sont affectés par la fréquence cardiaque et le sang vital vers de nombreuses destinations. Toute erreur dans ce système, malgré le taux d'erreur négligeable, est une préoccupation majeure. Parmi ces cas se trouve le phénomène d'embolie.

L'embolie est toute blocage qui se produit dans un vaisseau sanguin par un corps étranger. Il peut être une bulle de gaz, un caillot de sang, un globule de graisse, une masse de bactéries ou un autre corps étranger.

Le phénomène d'embolie est parmi les troubles les plus mortel et les plus dangereux. Les conséquences qui peuvent résulter de ces embolies sont un accident vasculaire cérébral ou une crise cardiaque, et c'est ce qui rend si important d'avoir un système de détection et de classification automatique [1].

L'idée de détecter des vannes avec un système automatique n'est pas née aujourd'hui: dans les années 1960, des scientifiques ont prouvé que l'utilisation des ultrasons nous permettait de détecter des emboles de gaz. Cependant, ce n'est que dans les années 1990 qu'il a été révélé que les emboles solides, composés de thrombus ou d'agrégats de plaquettes, pouvaient également être détectés à l'aide des ultrasons. Pour la détection des emboles, il existe plusieurs techniques, dont la technique Doppler qui est réalisée à travers le crâne (TCD). C'est une technique basée sur l'échographie et utilisée pour évaluer la vitesse du flux sanguin en temps réel [2].

Le système Doppler est basé sur l'émergence de signaux transitoires de haute intensité, qui sont utilisés comme indicateurs de la présence d'emboles.

Dans les accidents vasculaires cérébraux, la détection d'embolie à l'aide des méthodes Doppler transcrânien (TCD) a montré ses limites pour distinguer les emboles et les artefacts, et plus important encore pour faire la différenciation entre les microemboles solides et gazeuses à l'aide des signaux TCD rétrodiffusés [3].

C'est pourquoi nous avons eu recours à une nouvelle approche qui repose sur l'analyse des signaux ultrasonores par radiofréquence (RF) au lieu des signaux Doppler traditionnels utilisés. Afin de prouver l'efficacité du traitement radiofréquence du signal ultrasonore pour classer les microbulles, une étude expérimentale a été menée dans le laboratoire INSERM

(France). Pour imiter le comportement ultrasonore des gaz microscopiques, des microbulles Sonovue sont utilisées. Un matériau (avec les mêmes propriétés que le tissu humain) contenant un tube d'un diamètre de 0,8 mm est utilisé pour se rapprocher de la taille d'un vaisseau humain. Étant donné que les embolies solides présentent des propriétés acoustiques comparables à celles des tissus biologiques, le matériau imitant les tissus entourant le vaisseau est choisi pour imiter le comportement des embolies solides. Un scanner échographe est utilisé pour extraire les signaux diffusés. Le but de cette étude est d'exploiter l'intelligence artificielle, qui est représentée dans la mise en place d'un système capable de classer automatiquement des microembolies (gaz et solides) en traitant les signaux. Dans ce mémoire, nous avons utilisé un type de réseau neuronal artificiel pour la tâche de classification qui s'appelle le Réseau à Fonctions Radiales de Base (Radial Basis Functions RBF).

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 se compose de trois chapitres. Dans le premier chapitre, nous avons présenté une étude générale du problème de l'embolie et de ses types. Les causes de l'embolie sont également mises en évidence dans cette section. Une revue de la littérature sur les Réseaux de Neurones est présentée dans le deuxième chapitre. 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 arborés dans cette section.

Quant à la présentation des résultats, c'est dans Chapitre III, où nous nous sommes appuyés sur le réseau de neurones RBF pour classer les micro-embolies. Afin d'atteindre l'objectif, qui est de vérifier la validité de l'approche proposée, après avoir obtenu les résultats, nous les avons comparés avec les résultats obtenus dans autre étude récemment publiée sur les mêmes signaux RF rétrodiffusés [4].

À la fin de ce mémoire, nous avons présenté un processus de clôture général dans lequel nous résumons tous les résultats du travail effectué, tout en fournissant quelques perspectives.

**CHAPITRE I : ETAT DE L'ART SUR LE
PHENOMENE D'EMBOLIE ET LES
APPROCHES DE CARACTERISATION
D'EMBOLE PAR ULTRASON**

1.Introduction

L'un des plus gros problèmes auxquels le système vasculaire est confronté est l'embolie. Plusieurs techniques exploitant le traitement des signaux Doppler ou ultrasonores ont été utilisées pour la détection et la classification des emboles.

Les méthodes, couramment utilisées pour la détection des emboles, sont basées sur le traitement des signaux Doppler. Malheureusement, ces méthodes présentent certaines limites pour distinguer entre l'embolie et les artefacts. Dans ce chapitre nous allons présenter les types d'embolie, les techniques de détection et de classification et l'interaction entre les microbulles et les ultrasons.

2.Définition d'embolie :

L'embolie est la circulation d'un corps étranger (exogène ou endogène) dans le courant circulatoire et son arrêt dans un vaisseau trop petit pour lui livrer passage. Le corps étranger prend le nom d'embolie. Les embolies se forment en raison d'un accident vasculaire cérébral, de bulles de gaz ou d'un morceau de graisse, etc. Il existe plusieurs tests pour déterminer l'étendue des artères obstruées, y compris l'échographie.

3.Type d'embolies :

Les trois catégories générales dans lesquelles l'embolie est définie sont : embolie gazeuse, artérielle et pulmonaire. Les plus connus sont les embolies pulmonaires.

3.1. Embolie gazeuse :

Les accidents de décompression, qui se traduisent par la formation endogène de bulles et sont donc fréquemment assimilés à des embolies gazeuses (EG). La définition de l'EG est ainsi restreinte à la migration suite à une brèche vasculaire, de bulles de gaz dans la circulation sanguine, qu'elles soient symptomatiques ou non. Le gaz concerné est le plus souvent l'air, mais l'oxygène, le gaz carbonique, l'azote, le protoxyde d'azote, l'argon et l'hélium peuvent être responsables d'EG.

L'incidence estimée par la détection des bulles par des techniques de type échographie et/ou Doppler est très supérieure à l'incidence jugée sur le retentissement clinique de ces mêmes épisodes emboliques.

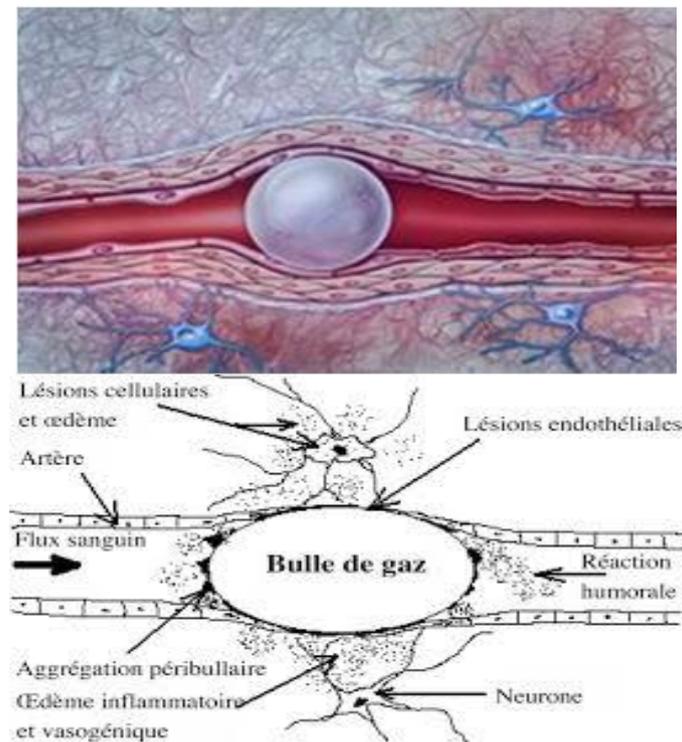


Figure I -2: Bulle obstruant le flux artériel terminal dans un vaisseau cérébral.

3.2. Embolie pulmonaire :

L'embolie pulmonaire est le blocage d'une ou plusieurs artères qui alimentent les poumons. Ce blocage est généralement causé par un caillot sanguin (phlébite ou thrombose veineuse) qui est passé d'une autre partie du corps (généralement des jambes) aux poumons.

L'embolie pulmonaire peut survenir chez les personnes en bonne santé.

L'embolie pulmonaire peut être extrêmement dangereuse pour notre santé. L'utilisation opportune de médicaments anticoagulants peut réduire considérablement le risque de décès

Causes de l'embolie pulmonaire

Un caillot de sang qui se forme dans les veines profondes des jambes, du bassin ou des bras est appelé thrombose veineuse profonde. Lorsque le caillot ou une partie du caillot atteint les poumons par la circulation sanguine, il bloque la circulation pulmonaire, ce qui est appelé embolie pulmonaire.

Parfois, l'embolie pulmonaire peut être causée par de la graisse, des bulles d'air ou des cellules tumorales dans la moelle osseuse de l'os fracturé.

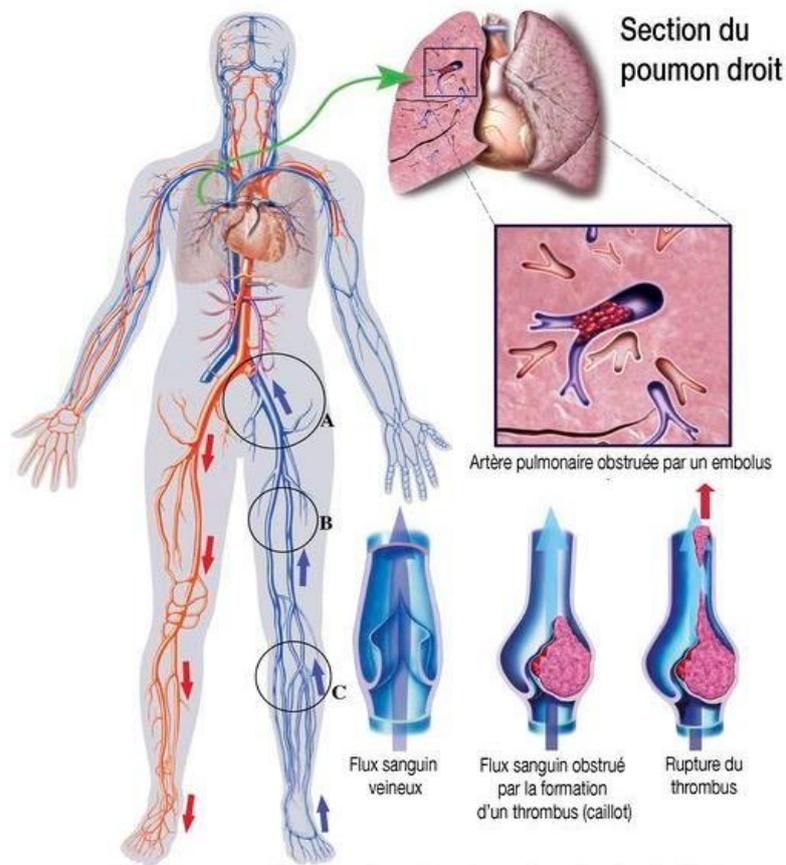


Figure I-3: Développement d'un thrombus : A. Hanche, C. cuisse. B jambe.

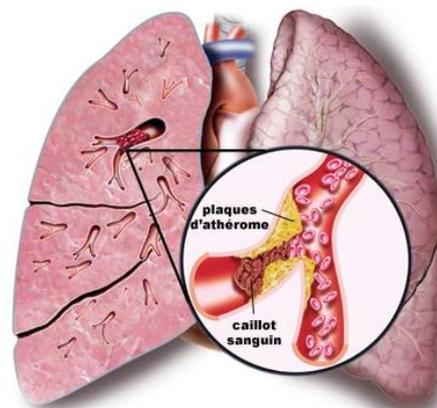


Figure I-4:Schéma d'un poumon avec embolie pulmonaire.

3.3. Embolie artérielle:

Il s'agit d'une embolie gazeuse ou solide qui se forme dans l'artère. Une fois posté, il sera bloqué dans une artère dont le diamètre est inférieur à sa taille. Le trafic dans la zone desservie par l'artère est interrompu. Plus le caillot sanguin est gros, plus le problème est grave. Les maladies et accidents qui en résultent dépendent du lieu. L'embolies artères touchent le plus souvent le cerveau (embolie cérébrale) ou les membres inférieurs [5].

3.4. Embolie cérébrale:

Si un caillot sanguin pénètre dans le cerveau, il peut provoquer un infarctus cérébral ou une ischémie cérébrale transitoire.

3.5. Embolie rétinienne:

Le thrombus est trop petit pour bloquer les grosses artères, mais il bloque les plus petits vaisseaux sanguins qui alimentent la rétine à partir du fond. Cela provoque une perte soudaine de la vision d'un œil.

3.6. Embolie septique:

L'embolie survient lorsque des particules provenant d'une infection humaine pénètrent dans le sang et bloquent les vaisseaux sanguins.

3.7. Embolie amniotique :

Toutes les embolies ne sont pas constituées de sang coagulé. Pendant la grossesse, l'utérus est rempli de liquide amniotique, qui peut protéger le fœtus. Le liquide amniotique peut former des embolies, qui peuvent pénétrer dans les poumons et provoquer une embolie amniopulmonaire.

3.8. Embolie graisseuse:

Si des particules de graisse ou d'autres particules de la moelle osseuse pénètrent dans le sang, elles peuvent bloquer les vaisseaux sanguins comme des caillots sanguins ou des bulles d'air.

4. Causes d'embolie :

La plupart des embolies pulmonaires sont causées par des caillots sanguins qui se forment dans les jambes (généralement le bas des jambes), appelés thrombose veineuse profonde (TVP), qui se détache du lit vasculaire et migre vers les poumons, bloquant les artères pulmonaires et les vaisseaux sanguins.

Cependant, les caillots sanguins ne sont pas la seule cause d'embolie pulmonaire. En effet, les petites artères pulmonaires peuvent également être recouvertes par une goutte de graisse (lors d'une fracture), des bulles d'air (mal de décompression lors de la plongée), une goutte de liquide amniotique (lors de l'accouchement), des cellules tumorales (cellules tumorales), des

emboles athéroscléreuses (Fragments de plaque athéroscléreuse) voire des emboles purulentes ou parasitaires (en cas d'infection sévère) [6].

5. Techniques de détection :

L'embolie est le mécanisme le plus courant qui cause un accident vasculaire cérébral (AVC). La détection des accidents vasculaires cérébraux est d'une grande importance car ils correspondent à la deuxième cause de décès dans le monde. Plusieurs techniques ont été utilisées : le signal Doppler ou le signal ultrasonore pour détecter les embolies.

Le système Doppler transcrânien est utilisé pour détecter les signaux de microembolies. À ce jour, les dispositifs commerciaux utilisés par le clinicien ne permettaient pas de détecter tous les microembolies. On s'attend à ce que les nouveaux détecteurs réduisent le taux de fausses alarmes.

La détection des AVC est un problème de santé publique qui touche plus de 180 000 personnes chaque année. Le système Doppler transcrânien est le seul appareil capable de détecter les microembolies dans le cerveau. L'équipement commercial existant n'est pas encore capable de détecter automatiquement tous les microembolies [7].

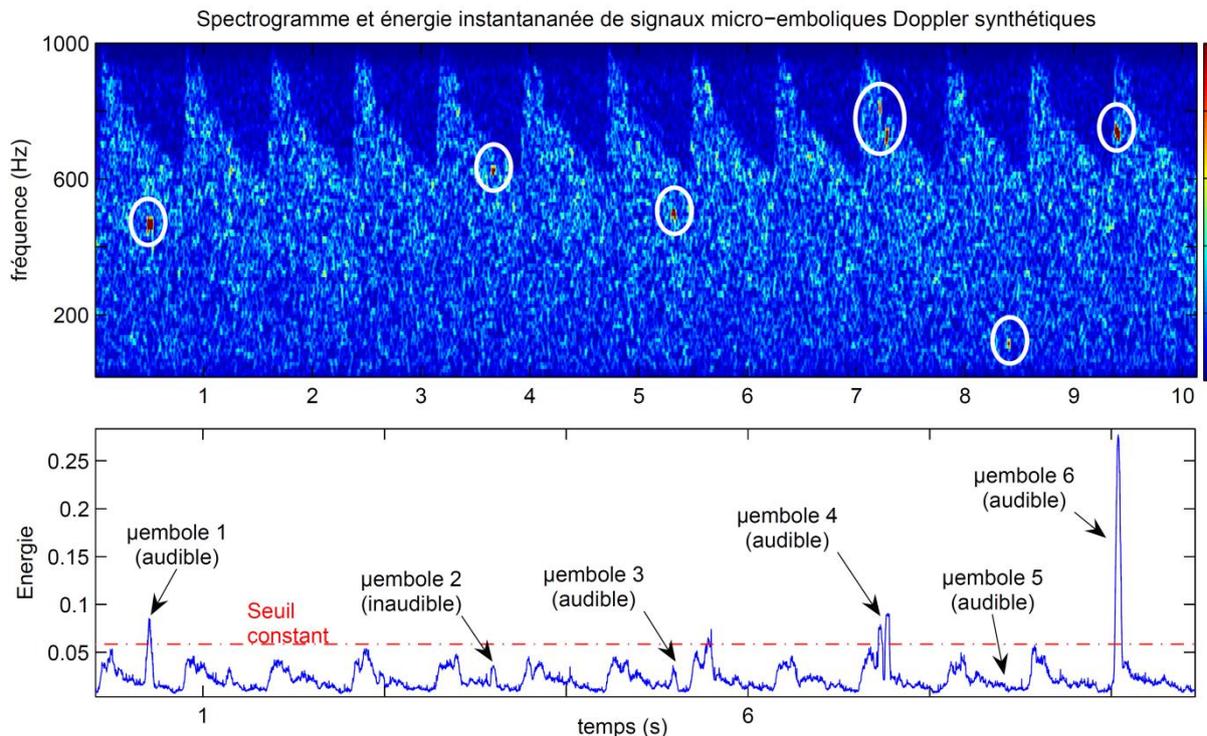


Figure I-5: Sonogramme et énergie à court-terme de signaux Doppler micro-emboliques.

5.1 Techniques de détection d'embolie utilisant les signaux Doppler

Aujourd'hui, le Doppler transcrânien (TCD) est considéré comme un instrument précieux pour la détection des microembolies

Le TCD utilise une transmission ultrasonore pulsée haute puissance et basse fréquence d'environ 2 MHz pour traverser le lit osseux

L'utilisation du Doppler de puissance semble également aider à la détection des vaisseaux sanguins intracrâniens. Enfin, les agents de contraste injectés par voie systémique peuvent améliorer les études échographiques des vaisseaux sanguins sous-jacents.

-Les limites des techniques Doppler (TCD) dans la classification des embolies solides et gazeux

Au cours des dernières décennies, l'industrie des ultrasons a connu d'énormes progrès technologiques, tels que l'utilisation de la technologie Doppler sophistiquée pour la mesure du débit sanguin ou l'utilisation de transducteurs à réseau phasé 2D pour l'imagerie tridimensionnelle en temps réel. Cela est en partie dû aux avantages de l'échographie par rapport aux autres méthodes de diagnostic, notamment son faible coût, son temps réel et sa sécurité.

L'une de ces dernières techniques échographiques est le Doppler transcrânien (TCD). Le TCD est une méthode échographique non invasive pour l'évaluation en temps réel de la vitesse du flux sanguin des principales artères intracrâniennes basales.

Depuis 1968, l'échographie Doppler est proposée pour détecter l'embolie gazeuse. Dans les années 1980, le développement du Doppler transcrânien a permis le suivi de la recherche sur le mal de décompression et de l'intervention chirurgicale (chirurgie de l'artère carotide, circulation extracorporelle) largement utilisé en clinique, puis utilisé chez les patients prothétiques [8, 9].

Actuellement, les techniques basées sur le Doppler transcrânien sont basées sur l'apparition de signaux transitoires de haute intensité, qui sont utilisés comme indicateurs de la présence d'embolies [2].

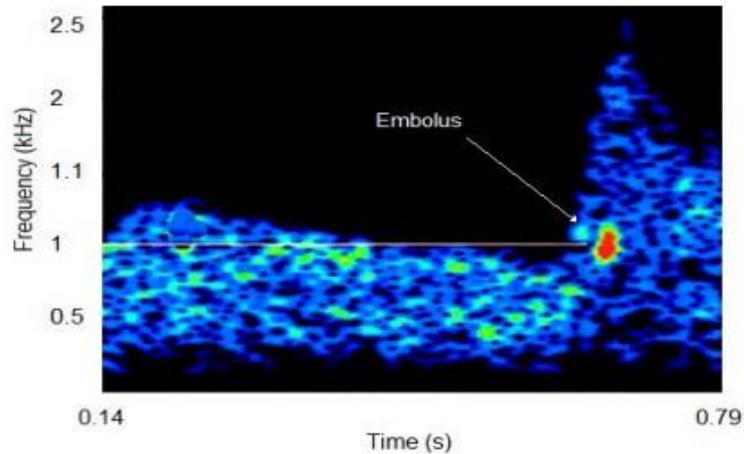


Figure I-6: Sonogramme du signal Doppler micro-embolique [10].

Les recherches d'E. Roy et al. utilisent la notation temps-fréquence des spectrogrammes pour détecter automatiquement l'embolie cyclique [11]. Cependant, ils ont déclaré que les signaux Doppler trouvés dans les applications cliniques sont plus complexes que leurs signaux Doppler et que leurs résultats ne sont applicables qu'à leurs signaux analogiques.

Dans l'article de Lu Pingrong et coll, la DWT de sept chiens a été testé pour détecter le signal Doppler de l'embolie veineuse [12]. Cette méthode peut être utilisée pour la détection des embolies, mais l'algorithme n'est pas adapté à la détection des petites embolies, car les embolies utilisées dans leur étude sont plus grandes que celles trouvées chez l'homme.

Jean-Marc Girault et al. proposent une méthode de détection de thrombus basée sur une méthode de traitement de signaux. Dans leur méthode, ils ont comparé le signal d'embolisation Doppler avec son modèle autorégressif, puis ont construit les informations de décision contenant la signature du signal microembolique [13].

Nizamettin Aydin et coll, utilisent la transformation en ondelettes discrète pour étudier les signaux audio Doppler transcrâniens afin de détecter les signaux emboliques [14]

Les résultats de ces deux méthodes [14, 13] sont prometteurs, mais le défi reste de savoir comment distinguer les embolies des artefacts, en particulier l'utilisation de signaux TCD rétrodiffusés pour distinguer les microembolies solides et gazeux [3-15]. La nature de l'embolie avant d'effectuer une intervention neuroprotectrice est un critère diagnostique important. C'est le cas de l'endartériectomie carotidienne et de la chirurgie cardiaque, où les embolies aériennes et solides sont très compliquées. Le TCD peut être utilisé pour la détection, mais il est difficile de distinguer les microembolies solides des gazeux [3-15]

L'embolie solide est plus destructrice que l'embolie gazeuse et implique différentes stratégies de traitement [16]. En fait, l'embolie gazeuse est considérée comme un indicateur de risque et sa détection consiste à rechercher la cause de l'embolie. Cependant, lorsque des embolies solides sont détectées, un traitement anticoagulant ou anticoagulant est généralement administré.

Bien que de nombreux développements technologiques aient été réalisés dans le domaine de la détection de microembolie, il est encore impossible de distinguer de manière fiable l'embolie gazeuse de l'embolie solide en utilisant la technologie Doppler. L'utilisation de la méthode Doppler pour classer les microembolies gazeuses et solides repose sur l'apparition d'un signal transitoire de haute intensité, qui est utilisé comme indicateur de la présence d'embolie [3-15]. Cependant, il existe actuellement une stratégie définie de suppression des signaux microemboliques de faible intensité. Par conséquent, la suppression a priori de ces signaux emboliques (SE) peut réduire la valeur prédictive et la sensibilité de l'ensemble du processus [17]. Une étude récente a révélé qu'il existe une relation considérable entre les signaux micro-emboliques de faible et de haute intensité, ce qui suggère que ces SE rejetés, en raison de leur faible intensité, sont réels et peuvent prédire l'apparition future de SE de haute intensité [18].

De plus, les techniques basées sur le Doppler sont fortement affectées par le mouvement de la tête du patient, la toux ou tout autre artefact de mouvement qui provoque le déplacement de la sonde, ce qui peut générer des signaux similaires à des embolies solides ou des embolies gazeuses [19].

Par conséquent, nous proposons une nouvelle méthode basée sur l'analyse des signaux ultrasonores de radiofréquence (RF) rétrodiffusés au lieu des signaux Doppler. Afin de vérifier la praticabilité du traitement du signal ultrasonore radiofréquence pour la détection et la classification des microembolies, un dispositif *in vitro* a été développé dans le Laboratoire INSERM-France [4,20]. Les microbulles Sonovue sont utilisées pour simuler le comportement ultrasonique des embolies gazeuses. Afin de se rapprocher de la taille des vaisseaux sanguins humains, un fantôme d'écoulement d'un tube d'un diamètre de 0,8 mm est nécessaire. Le matériau imitant les tissus entourant le vaisseau est choisi pour imiter le comportement des embolies solides.

Afin de distinguer avec précision l'embolie gazeuse et l'embolie solide, nous utilisons les caractéristiques non linéaires de l'embolie gazeuse sous excitation ultrasonore.

Nous utilisons la transformée en ondelettes discrète (DWT) et les réseaux de neurones artificiels pour détecter et classer les micro embolies.

De nombreux chercheurs ont rapporté que la transformée en ondelettes discrète (DWT) est plus efficace que la transformée de Fourier rapide pour l'analyse et la détection des signaux emboliques [21, 8, 22].

5.2. Techniques de détection d'embolie utilisant les signaux ultrasons

La technologie Doppler peut être affectée par tout mouvement causé par le mouvement de la tête d'un patient, la toux ou toute vibration qui provoque le délogement de la sonde, ce qui conduit à la production de signaux similaires à une empreinte solide ou invasive.

Le signal ultrasonore radiofréquence (RF) rétrodiffusés montre que le comportement des bulles de gaz est non linéaire, ce comportement permet de faire la distinction entre les particules solides et gazeuses [21].

6. Interaction entre les bulles de gaze et l'ultrason

6.1. Agents de contraste pour l'ultrason graphie :

Les microbulles sont les agents de contraste et sont plus petites que les globules rouges. Pour obtenir une image des ondes sonores améliorées, ces agents de contraste sont injectés par voie intraveineuse. Les agents de contraste ultrasoniques modifient les propriétés physiques des tissus et donc le comportement des ondes ultrasonores qui les traversent.

Pour de petites pressions sonores, la taille de la bulle microscopique varie linéairement avec l'amplitude de la pression acoustique. Pour de grandes pressions sonores, l'amplitude de la pression et de l'expansion des bulles de gaz est élevée et asymétrique (la taille de la bulle change fortement, non linéairement avec l'expansion de la pression acoustique) ce qui génère des composantes de fréquence non linéaires, appelées harmoniques [21].

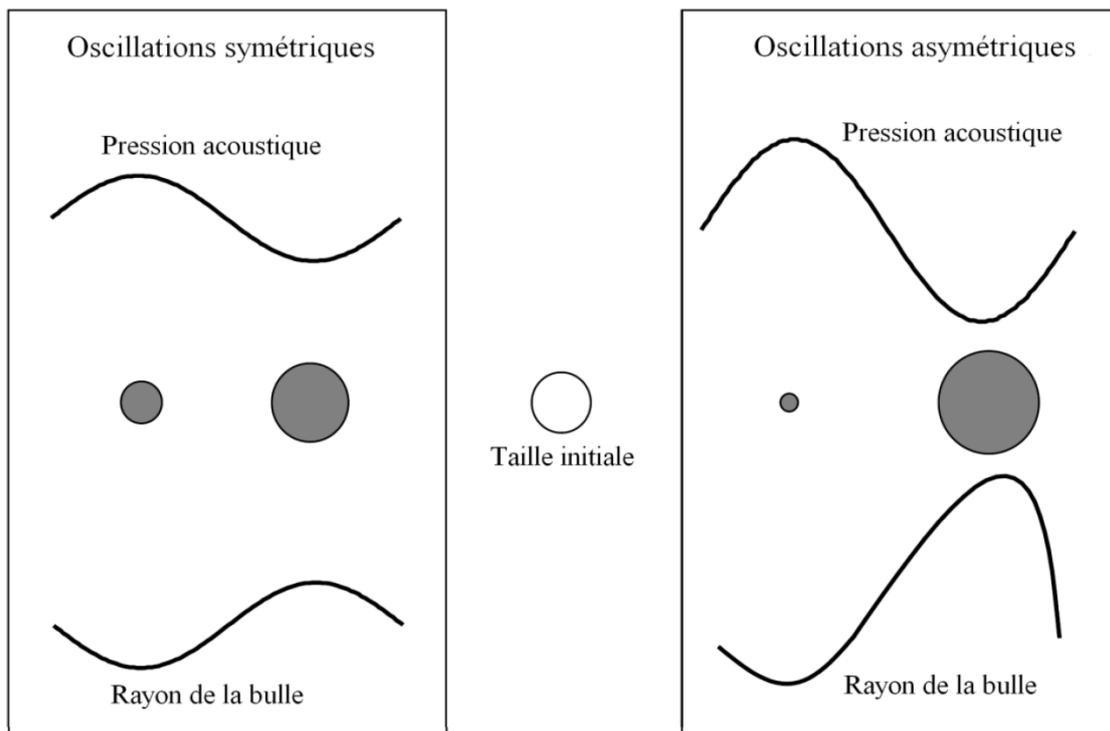


Figure I-7: Oscillations symétriques (linéaires) et asymétriques (non linéaires) d'une microbulle soumise à une onde de pression[21].

7. Conclusion :

Ce chapitre présente les principaux types d'embolie ainsi que les techniques actuellement employées pour la classification des microembolies dans la circulation sanguine. Les techniques traditionnelles sont largement basées sur les techniques Doppler. Malheureusement, ces méthodes ont montré certaines limites pour déterminer clairement la nature des microembolies en circulation. Par conséquent, nous proposons une autre approche basée sur l'analyse des signaux ultrasonores radiofréquences (RF) au lieu des signaux Doppler pour la détection et la classification des microembolies en circulation en exploitant le comportement non linéaire des bulles gazeuses.

CHAPITRE II : RESEAUX DE NEURONES

1. Introduction :

Depuis une dizaine d'années, l'utilisation des réseaux de neurones artificiels (RNA) s'est développée dans de nombreuses disciplines (sciences économiques, écologie et environnement, biologie et médecine...). Ils sont notamment appliqués pour résoudre des problèmes de classification, de prédiction, de catégorisation, d'optimisation, de reconnaissance des formes et de mémoire associative (Drew et Monson, 2000) [23]. Dans le cadre du traitement des données, les RNA constituent une méthode d'approximation de systèmes complexes, particulièrement utile lorsque ces systèmes sont difficiles à modéliser à l'aide des méthodes statistiques classiques. Les RNA sont également applicables dans toutes les situations où il existe une relation non linéaire entre une variable prédictive et une variable prédite. Par leur nature et leur fonctionnement, les RNA peuvent détecter les interactions multiples non linéaires parmi une série de variables d'entrée, ils peuvent donc gérer des relations complexes entre les variables indépendantes et les variables dépendantes

2. Réseaux de neurones artificiels :

2.1. Histoire des réseaux de neurones artificiels :

En 1943, le neurophysicien Warren McCulloch et le Walter Pitts de l'Université de Chicago ont eu l'idée de réseaux de neurones. Les chercheurs ont conclu que l'activation neuronale est l'unité de base de l'activité cérébrale et ils ont publié cette théorie dans un article de la revue "Brain Theory " [24].

Les scientifiques ont inventé l'algorithme Perceptron, pour l'apprentissage automatique, qui est conçu pour effectuer des tâches complexes de reconnaissance de formes, et vous pourrez apprendre à reconnaître des objets sur des images à l'aide de cet algorithme, et cette invention remonte à 1957.

La puissance de calcul à l'époque était insuffisante pour traiter les données nécessaires au fonctionnement normal du réseau neuronal. Cela a conduit à une interruption prolongée de la recherche scientifique dans le domaine des réseaux de neurones.

En 2010, il y a eu un bond en avant dans les données informatiques, qui a permis de créer de grandes bases de données et des traitements parallèles à grande échelle. Cela a permis aux scientifiques d'exploiter des réseaux de neurones complexes.

Les scientifiques se sont intéressés aux réseaux de neurones après avoir vaincu les humains lors d'un concours organisé par Image Net en 2012. Cela a forcé les scientifiques à diriger tous leurs efforts pour améliorer continuellement les réseaux de neurones artificiels [24].

2.2. Définition :

Les RNA sont des processeurs élémentaires fortement connectés. Chaque processeur élémentaire calcule une sortie unique sur la base des informations qu'il reçoit, leur fonctionnement se fait en parallèle [24].

Le réseau de neurones (RN) reçoit des signaux de l'extérieur par ses entrées et délivre des signaux de sortie, ces (RN) sont une métaphore des structures cérébrales et de traitement parallèle et distribué d'information et comportent plusieurs éléments de traitement appelé neurone. Le fonctionnement des neurones est indépendant les uns des autres de sorte que l'ensemble est un système parallèle fortement interconnecté. L'information détenue par le réseau de neurone est non localisée dans une partie de mémoire, mais elle est distribuée à travers l'ensemble des constituants. Comme le réseau de neurone est entraîné sur des données acquises, il ne se programme jamais pour réaliser une ou telle tâche [25].

On peut examiner la correspondance entre les propriétés propres de neurones biologiques et neurones artificiels comme le montre la Figure II-1 [14].

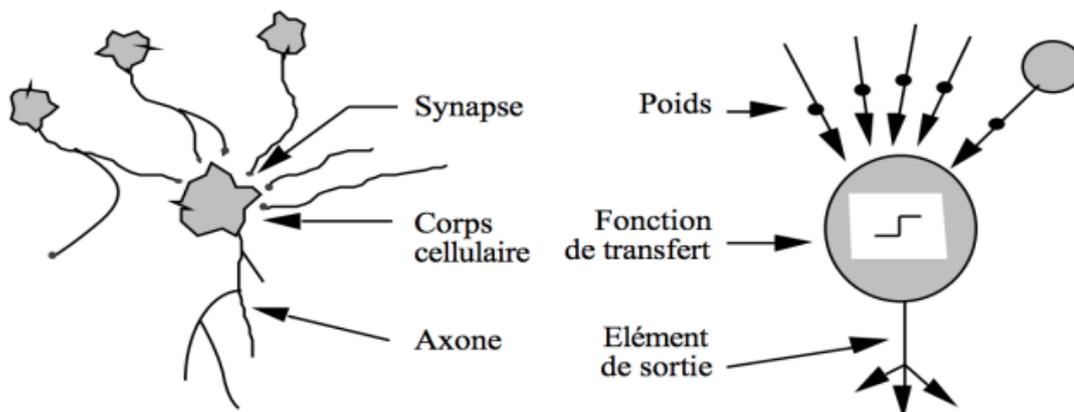


Figure II - 1: Correspondance entre neurones biologiques et neurones artificiels.

-Comparaison des neurones pour montrer la différence entre les neurones biologiques et artificiels :

•*Système nerveux :*

-Neurone

-Le corps cellulaire (soma)

-Axone

-Synapse

° **Réseau neural Artificiel :**

- Traitant élément, nœud, neurone artificiel, neurone abstrait.

- Niveau de l'activation, fonction de l'activation, fonction du transfert, la fonction de la sortie

- La communication avec d'autre neurone

- Poids multiplicatifs

2.3 Domaine d'application :

Différent domaines et secteurs appliquent aujourd'hui les réseaux de neurones parmi eux on cite :

❖ *Application au traitement du signal :*

Dans ce cas, le réseau agit comme un filtre pour éliminer le bruit. Il est également utilisé pour le traitement de la parole, la reconnaissance de source, le filtrage, la classification ... [26].

❖ *Application à la planification :*

Pour la planification des opérations ou des marques l'optimisation est souvent souhaitée .A cet effet pour la résolution des problèmes d'optimisation l'utilisation du modèle de Hop Field et du modèle de Kohonen paraît très utiles [25].

❖ *Application de contrôle:*

En raison de leurs caractéristiques (cadence de traitement, adaptabilité et capacité de généralisation, etc.), le réseau neuronal est appliqué au contrôle intelligent. Par exemple, de nombreuses expériences ont été menées pour appliquer des réseaux de neurones. Ces applications peuvent être divisées en plusieurs méthodes, par exemple: contrôle de supervision. Contrôle inverse et contrôle neuronal adaptatif [25].

❖ *Application en diagnostic:*

Les réseaux de neurones (AR) utilisent la classification automatique des signaux et les formes, donc ils sont bien adaptés à la résolution des difficultés de diagnostic. Dans ce cas, on peut distinguer de nombreuses applications des réseaux de neurones dans le diagnostic des défauts, notamment dans le diagnostic des défauts moteurs [25].

Des exemples d'applications de chaque modèle sont illustrés dans le tableau suivant (Tableau II-1) [25] :

Tableau II-2:Correspondance RNA - domaines d'application

Caractéristiques Fonctionnelles	Type de RNA
Reconnaissance de formes	MLP, Hopefield, Kohonen, PNN
Mémoires associatives	Hopefird, MLP récurrents, Kohonen
Optimisation	Hopefeild, ART, CNN
Approximation de fonctions	MLP, RBF
Modélisation et control	MLP, MLP récurrent, FLN
Traitement d'images	CNN, Hopefeild
Classification et clustering	MLP, Hopefield, RBF, ART, PNN

2.5. Fonctionnement :

Un réseau neuronal est constitué d'un grand nombre de processeurs qui fonctionnent en parallèle et en couches successives. L'entrée de la première couche reçoit des informations brutes, 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 éloignés du nerf optique reçoivent les signaux des neurones voisins. La dernière couche produit le résultat.

Chaque nœud de traitement a une petite bulle de connaissances qui lui est propre, en particulier ce qu'il voit et les règles initialement programmées ou définies par lui-même. Les couches sont étroitement interconnectées: chaque nœud de la même couche est connecté à de nombreux nœuds de la couche $n-1$ (son entrée) et de la couche $n + 1$, que seront a leur tour l'entrée de ces nœuds-là. Il peut y avoir un ou plusieurs nœuds dans la couche de sortie dont provient la réponse lisible [27].

Les réseaux neuronaux sont reconnus par leur capacité d'adaptation : ils se modifient eux-mêmes en fonction de l'entraînement initial et les exécutions suivantes leur apportent encore plus d'informations sur le monde qui les entourent. Le modèle d'apprentissage est axé sur, l'évaluation par chaque nœud de l'importance des entrées provenant de chacun de ses prédécesseurs. L'indice le plus for est celui des entrées de bon resulta [27].

2.6. Architectures de réseaux de neurones :

Le nombre de couches et de nœuds et la façon d’être connectés nous donne l’architecture du réseau neuronal. Le choix de cette architecture déterminera grandement les résultats qui seront obtenus, et constitue le point délicat dans la mise en œuvre d’un réseau de neurones. Les nœuds qui sont répartis en deux couches (une entrée et une sortie) donnent une structure simple. Les nœuds de la couche d’entrée ont une seule entrée et une seule sortie, égale à l’entrée (voir Figure II-2).

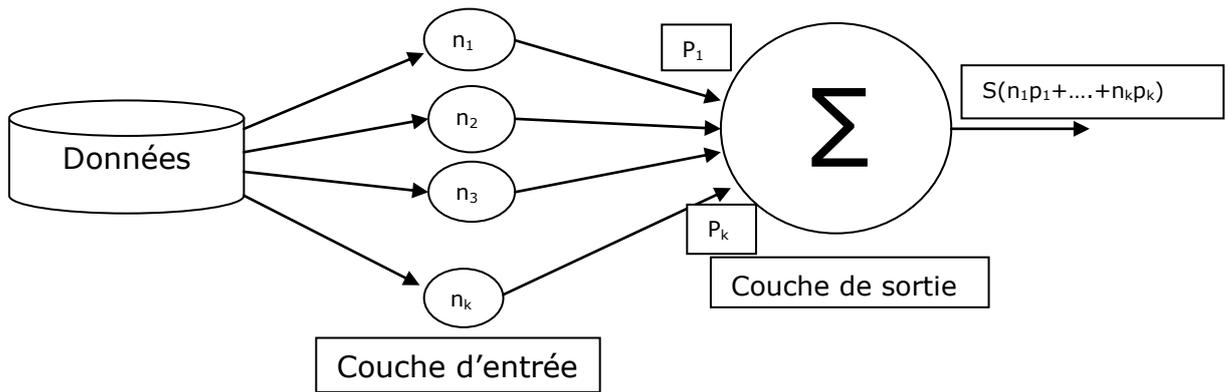


Figure II - 2: Réseau de neurones sans couche cachée.

A l’entrée des nœuds de sortie aboutissent les nœuds de la couche d’entrée avec une fonction de combinaison et une fonction de transfert. 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.

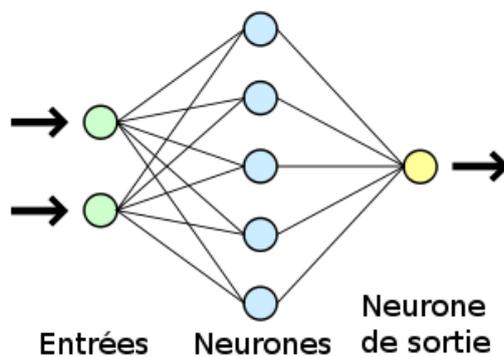


Figure II-3: Les réseaux de neurones feed-forwarded.

Le pouvoir de prédiction est augmenté par l'ajout d'une ou plusieurs couches cachées entre les couches d'entrée et de sortie (Figure II-4).

Cette augmentation du pouvoir de prédiction doit être étudiée 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 « sur-apprentissage », 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-4).

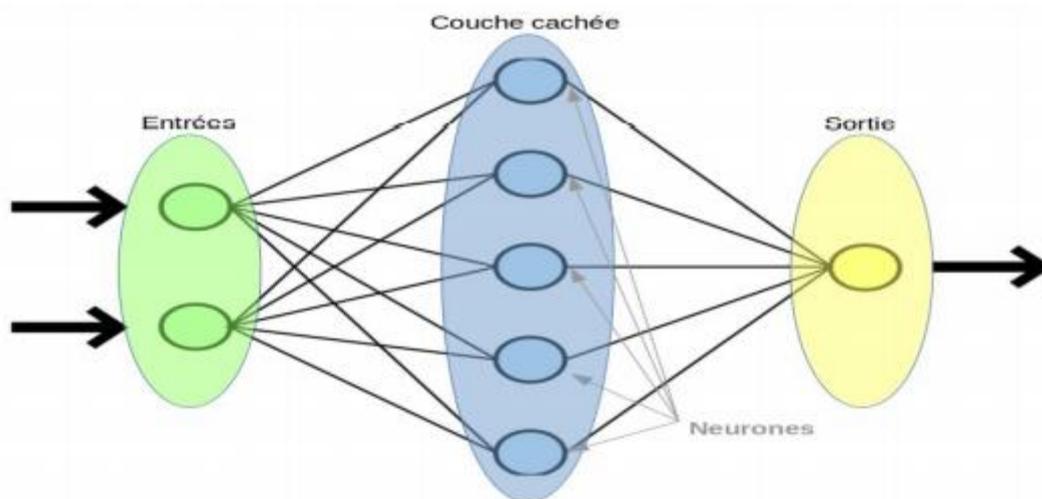


Figure II - 4: Réseau de neurones avec couche cachée.

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-5)

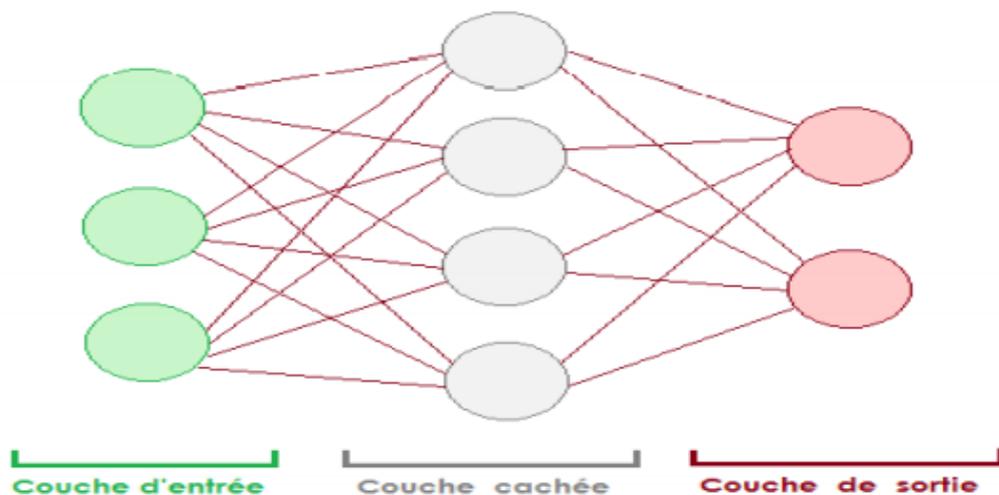


Figure II - 5: Réseaux de neurones avec plusieurs nœuds de sortie.

2.7. Apprentissage des réseaux de neurones:

Le processus d'adaptation des paramètres d'un système pour donner une réponse désirée face à une entrée ou stimulation externe est appelée apprentissage il constitue la phase la plus importante et intéressante dans les réseaux de neurones. La phase d'apprentissage 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 infime autrement dit jusqu'à l'obtention du comportement désiré [26].

Cependant, il existe trois méthodes d'apprentissage différentes. Dans le cas d'un apprentissage supervisé, l'algorithme s'entraîne sur un ensemble de données étiquetées et le modifie jusqu'à ce qu'il puisse traiter l'ensemble de données pour obtenir le résultat souhaité.

Dans le cas d'un apprentissage non supervisé, les données ne seront pas étiquetées. Le réseau neuronal analyse l'ensemble de données et la fonction de coût lui indique à quelle distance du résultat attendu. Ensuite, le réseau s'ajuste pour améliorer la précision de l'algorithme.

Enfin, grâce à la méthode d'apprentissage amélioré, le réseau de neurones est renforcé pour obtenir des résultats positifs, et des sanctions lui sont imposées pour obtenir des résultats négatifs. C'est ainsi qu'il peut apprendre au fil du temps, tout comme les humains apprennent progressivement de leurs erreurs [28].

3. Types de réseaux de neurones :

Le poids de toutes les clés synaptiques détermine la fonction du réseau neuronal. Le modèle est présenté à un sous-ensemble du réseau neuronal: la couche d'entrée. Lorsque nous appliquons le modèle au réseau, il cherche à atteindre un état stable. Lorsqu'elle est atteinte, la valeur d'activation du neurone de sortie constitue le résultat. Les neurones qui ne sont ni la couche d'entrée ni une partie de la couche de sortie sont appelés neurones cachés.

Les types de réseau de neurones diffèrent par plusieurs paramètres :

- la topologie des connexions entre les neurones ;
- la fonction d'agrégation utilisée (somme pondérée, distance pseudo-euclidienne...) ;
- la fonction de seuillage utilisée (sigmoïde, échelon, fonction linéaire, fonction de Gauss, ...) ;
- l'algorithme d'apprentissage (rétropropagation du gradient, cascade corrélation) ;

-d'autres paramètres, spécifiques à certains types de réseaux de neurones, tels que la méthode de relaxation pour les réseaux de neurones (e.g. réseaux de Hopfield) qui ne sont pas à propagation simple (e.g. Perceptron Multicouche).

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

3.1.1 Définition :

Le Perceptron multicouche (MLP) est un réseau neuronal artificiel, divisé en plusieurs couches, où les informations ne circulent que de la couche d'entrée à la couche de sortie. Par conséquent, il s'agit d'un réseau à sens direct. Chaque couche se compose d'un nombre variable de neurones, et les neurones de la dernière couche (appelée «sortie») sont la sortie de l'ensemble du système.

Le perceptron a été inventé en 1957 par Frank Rosenblatt du Cornell Aeronautical Laboratory. Dans la première version, le perceptron est une seule couche, avec une seule sortie connectée à toutes les entrées [29].

Pour chacune des couches, l'ensemble de ses nœuds est relié à l'ensemble des nœuds de la couche précédente. La 'Figure II-6' Donne une représentation d'un perceptron multicouches avec deux couches cachées [30].

3.1.2 Architecture du réseau :

Une architecture de réseau est un plan du réseau de communication informatique complet, ce qui fournit une base de cadre et de la technologie pour la conception, la construction et la gestion d'un réseau de communication. Il a généralement une structure en couches. Il nécessite généralement trois couches ou plus de nœuds de traitement, la couche d'entrée accepte les variables d'entrée utilisées dans le processus de classification, une ou plusieurs couches masquées et une couche de sortie avec un nœud par classe.

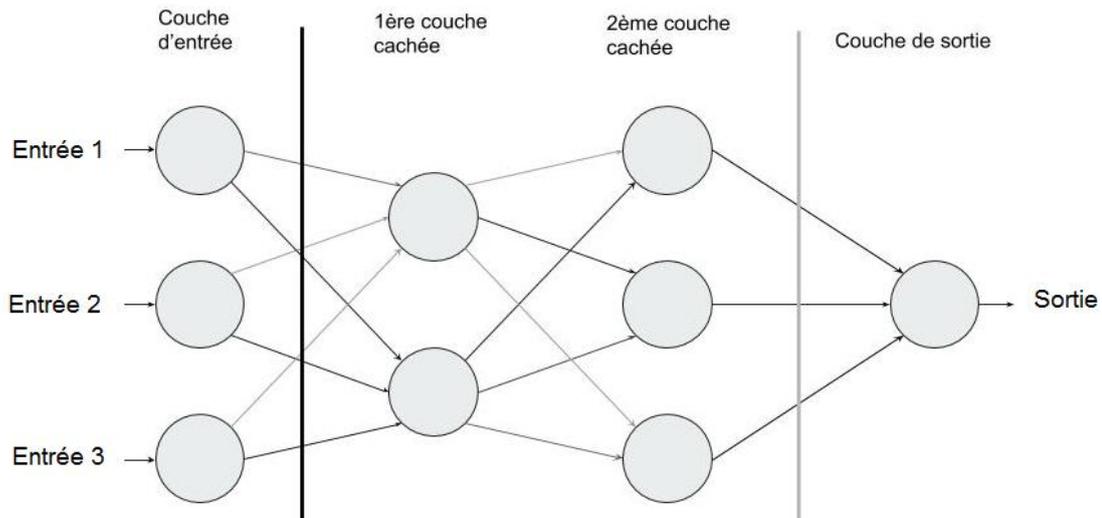


Figure II - 6: Réseaux de neurones avec plusieurs couches cachés.

Le perceptron multicouche se structure de la même façon. L'information entre par une couche d'entrée et sort par une couche de sortie. À la différence du perceptron simple, le perceptron multicouche dispose entre la couche en entrée et la couche en sortie une ou plusieurs couches dites « cachées ». Le nombre de couches correspond aux nombres de matrices de poids dont dispose le réseau. Un perceptron multicouche est donc mieux adapté pour traiter les types de fonctions non-linéaires. 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 [31].

Le nombre de couches correspond aux nombres de matrices de poids dont dispose le réseau. Un perceptron multicouche est donc mieux adapté pour traiter les types de fonctions non-linéaires.

3.1.3. Fonction de transfert :

La fonction mathématique appliquée à un signal en sortie d'un neurone artificiel est la fonction d'activation dans le domaine des réseaux de neurones artificiels

La fonction de toutes les unités de la couche cachée dans MLP a la même fonction d'activation F et son équation est la suivante:

$$a = 1/(1 + \exp^{-n}) \quad (\text{II.1})$$

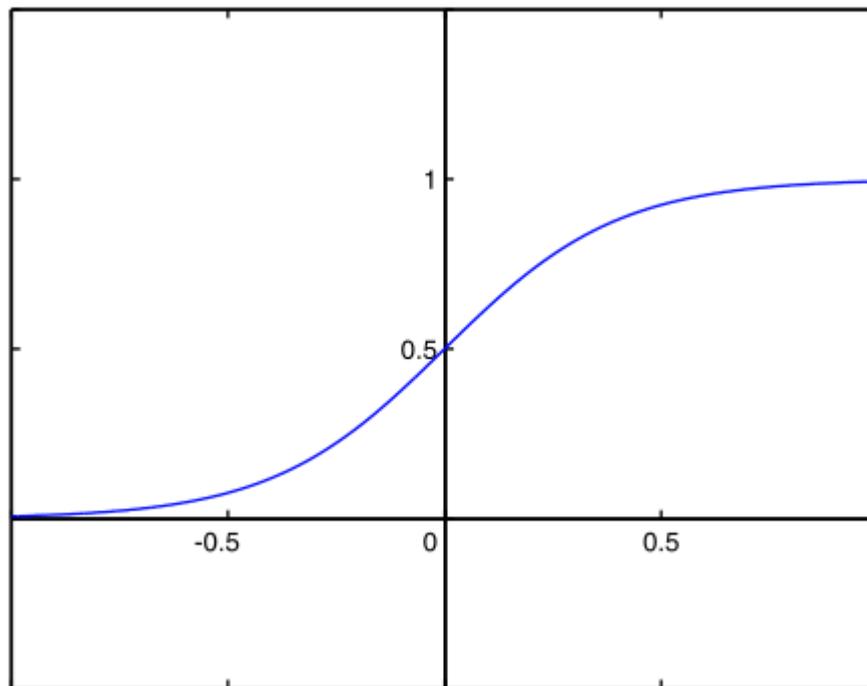


Figure II - 7: Fonction sigmoïde.

3.1.4. Apprentissage de model MLP :

L'un des grands avantages du développement d'un réseau de neurones pour obtenir le comportement souhaité est sa capacité à apprendre par la modification du comportement. La perception multicouche utilise un algorithme d'apprentissage modéré, afin de calculer l'erreur de sortie des couches cachées.

Pratiquement, l'apprentissage du réseau consiste à calculer les poids des connections entre les cellules en vue de minimiser un critère quadratique E en sortie [32].

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

$$E_p = \frac{1}{2} \sum_{j=1}^s (Q[j][p] - O[j][p]) \quad (\text{II.3})$$

Nous ne pouvons pas savoir à quoi la forme de la fonction d'erreur E dans les applications réelles

La valeur minimale atteinte est une valeur universelle, de sorte que la zone de poids ne peut pas du tout être déterminée, et cela est dû à la convergence de l'algorithme d'optimisation non linéaire.

Algorithme d'apprentissage du perceptron monocouche. Initialisation de la somme des poids du seuil S à une (petite) valeur choisie au hasard.

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

$$a = \sum (w_i \cdot e_i) - s \quad (\text{II.4})$$

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

- ❖ Les poids sont ajustés (ajustement par pas μ), si la sortie x du Perceptron est différente de la sortie dl requise pour cet exemple de l'entrée EI :

$$(t + 1) = w_i(t) + \mu \cdot ((dl - x) \cdot e_i) \quad (\text{II.5})$$

Rappel : $dl = +1$ si E est de la classe 1, $dl = -1$ si E est de la classe 2 et $(dl - x)$ 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 réalise une partition de son espace d'entrée en 2 classes (1 et 2) selon la valeur de sa sortie (+1 ou -1). La séparation de ces deux zones est effectuée par un hyperplan (Figure II-8). L'équation de la droite séparatrice est :

$$w_1 \cdot e_1 + w_2 \cdot e_2 - S = 0 \quad (\text{II.6})$$

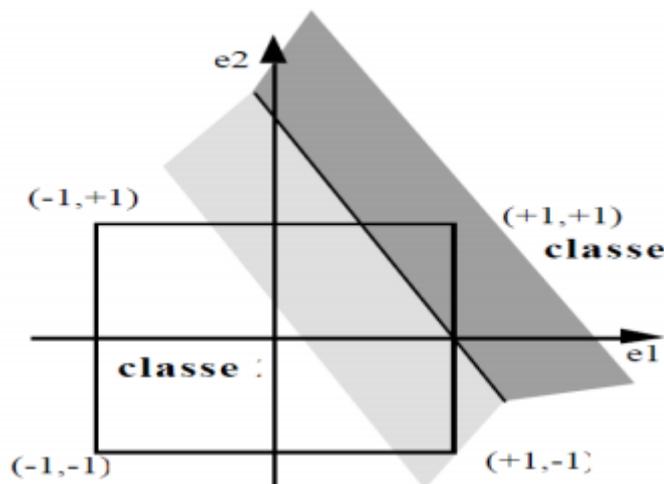


Figure II - 8: Partition de l'espace d'entrée de dimension 2 réalisée par un Perceptron comportant comme un ET booléen

La découverte de l'algorithme de rétropropagation nous a permis de résoudre le problème de la séparation linéaire des données. Si les données sont linéairement séparables, une seule couche de Perceptron est nécessaire.

3.1.5. Algorithme de rétropropagation :

- Pas 1 : Initialisation des poids W_{ij} et des seuils internes des neurones à des petites valeurs aléatoires.

- Pas 2 : Présentation du vecteur d'entrée et de sortie désirée.

- Pas 3 : Calcul :

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

$$y = f(\sum_{i=0}^{n-1} W_i X_i) \quad (\text{II.7})$$

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

$$\delta_j^l = \sum_{j=1}^n W_{ji}^l X_i + \theta_j^l \quad (\text{II.8})$$

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

$$I_j = f^l(S_j^l) = f^l(\sum_{j=1}^n W_{ji}^l X_i + \theta_j^l) \quad (\text{II.9})$$

- Les sorties des réseaux en utilisant l'expression

$$S_K^R = \sum_{Kj}^R I_j + \theta_K^R \quad (\text{II.10})$$

- Pas 4 : Calcul de l'erreur pour les neurones de la couche de sortie en utilisant l'expression

$$\theta_K^R = (y_K - R_K) f_K^R(S_K^R) \quad (\text{II.11})$$

- Pas 5 : Réinjection de l'erreur de sortie en utilisant l'expression

$$\delta_j^l = f_j^l(S_j^l) \sum \delta_K^R W_{Kj}^R \quad (\text{II.12})$$

- Pas 6 : Ajustement : - Les poids de la couche de sortie en utilisant l'expression

$$W_{Kj}^R(n+1) = W_{Kj}^R(n) + \mu \delta_K^R I_j \quad (\text{II.13})$$

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

$$W_{ji}^l(n+1) = W_{ji}^l(n) + \mu \delta_i^l X_i \quad (\text{II.14})$$

- Pas 7 : Calcul de l'erreur en utilisant l'expression

$$Ep = \frac{1}{2} \sum_{K=1}^T (y_K - R_K)^2 \quad (\text{II.15})$$

- Pas 8 : Si la condition sur l'erreur $E - E_p < \epsilon$ est atteinte, aller à l'étape 9 sinon aller à l'étape 6 et refaire le calcul pour un autre époque.
- Pas 9 : FIN.

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

Les réseaux à fonctions de base radiales (RBF) sont des modèles connexionnistes simples à mettre en œuvre sont assez intelligibles, très utilisés pour la régression et la discrimination. Leurs propriétés théoriques et pratiques ont été étudiées en détail depuis la fin des années 80, il s'agit certainement, du modèle connexionniste le mieux connu.

Le modèle de réseau RBF est piloté par la réponse de régulation locale observée dans les neurones biologiques. Les neurones aux caractéristiques de réponse localement régulées peuvent être trouvés dans plusieurs parties du système nerveux. Par exemple, les cellules du cortex visuel sont sensibles aux barres pointant dans une certaine direction ou à autres caractéristiques visuelles dans une petite partie du champ visuel. (Girosi, 1990). Les caractéristiques de réponse de ces neurones accordés localement sont limitées à un petit espace d'entrée. La base théorique de la méthode RBF réside dans le domaine de l'interpolation de fonctions multi-variées.

3.2.1.Principe de RBF :

Le principe RBF consiste d'approcher un comportement désiré par une collection de fonctions (appelées fonctions-noyau). Les fonctions-noyau de la méthode RBF sont locales, c'est-à-dire qu'elles ne donnent des réponses utiles que dans un domaine d'influence délimité par un seuil de distance. Ce seuil est défini autour d'un point, le noyau (ou centre). La distance Euclidienne est généralement utilisée pour la mesure de distance :

$$d(x) = \|x - c_i\| \quad (\text{II.16})$$

3.2.2.Architecture de RBF :

La fonction gaussienne est la fonction principale utilisée ici. Pour **MLP**, la syntaxe est la même

Un RBF est constitué uniquement de 3 couches :

- ❖ Couche d'entrée: Classification du vecteur d'entrée et du vecteur dimensionnel n , pour chaque neurone RBF le vecteur d'entrée entier est présenté.

- ❖ Couche cachée du réseau RBF: Au niveau de chaque neurone RBF, le vecteur «prototype», qui est un vecteur pour l'ensemble d'apprentissage, est stocké. La valeur de comparaison génère chaque neurone RBF avec son vecteur d'entrée prototype entre 0 et 1 (comme mesure de similitude). Si le premier paramètre est égal à l'entrée, alors la sortie de ces neurones RBF est 1. La réponse tombe exponentiellement à zéro. Plus la distance entre l'entrée et le prototype est augmentée.

La valeur «d'activation» est également appelée valeur de réponse des cellules nerveuses. Quant à la valeur représentative du centre de la courbe en cloche, le vecteur prototype est appelé le «centre» de la cellule nerveuse.

- ❖ Couche de sortie : Un groupe de nœuds aura la sortie réseau et chaque nœud doit être classé par catégorie. Chaque nœud compte un type de point de sortie pour la classe associée. Et en attribuant des éléments à la catégorie avec les scores les plus élevés est la méthode de prise de décisions de classification. Chaque couche est connectée à la couche suivante.

La sortie du neurone RBF multipliée par son poids de connexion est la résultante du réseau est un mélange linéaire.

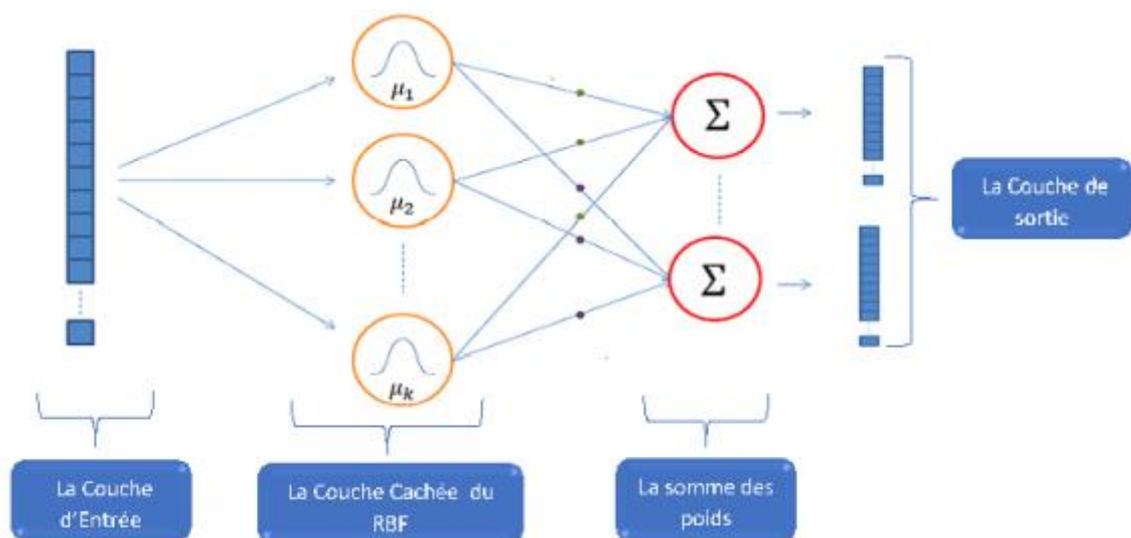


Figure II - 9: La structure du réseau RBF.

Chaque neurone RBF calcule la similitude entre l'entrée et son vecteur prototype (obtenu à partir de l'ensemble d'apprentissage). Un vecteur d'entrée plus similaire au prototype renvoie

un résultat plus proche de 1. Il existe de nombreuses options possibles pour la fonction de similarité, mais la plus populaire est basée sur Gaussian.

3.2.3.Fonction de transfère :

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

$$\phi_j(x) = \phi(\|x - \mu_j\|) \quad (\text{II.17})$$

Avec $\| \cdot \|$ est une norme

La fonction gaussienne est une RBF avec la norme euclidienne $\phi(r) = e^{-r^2/2\sigma^2}$ est de centre [34].

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

$$f(x) = \sum_{j=1}^N W_j \phi(\|x - \mu_j\|, \sigma_j) \quad (\text{II.18})$$

Donc on distingue trois paramètres principaux sont :

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

Afin de construire une approximation de la fonction, nous utilisons une combinaison linéaire gaussienne. Les modèles présentés sous forme de réseaux de communication ont retenu l'attention à la fin des années 1980, et ceci est dû au recours à des algorithmes d'apprentissage très rapides plutôt qu'à l'utilisation de techniques d'optimisation non linéaires. pour fournir en général les meilleurs contacts adjacents grâce au modèle idéologique [33].

3.2.4 .Apprentissage de modèles RBF :

L'apprentissage des modèles RBF est supervisé : il faut disposer d'un échantillon de l exemples (x_i, y_i) . Comme les Perceptrons multicouches (MLP), les RBF sont utilisés pour résoudre tant des tâches de discrimination (en général en choisissant $y_i \in \{-1, 1\}^C$) que des tâches de régression ou prévision de signal (monovarié $y_i \in \mathbb{R}$ ou multivarié $y_i \in \mathbb{R}^C$).

RBF a de nombreuses corrélations avec différentes méthodes, et il utilise ces méthodes pour reconnaître les modèles. Cela conduit à une corrélation claire dans l'étude de l'approximation des emplois [21].

Il existe des normes de bases composées d'une partie supervisée et d'une partie non supervisée, ce sont des sections pour l'apprentissage dans le RBF, qui comportent quatre critères principaux [34] :

- La quantité de neurones présents dans la seule 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 .

1. Pour déterminer expérimentalement le nombre de neurones par caché nous utilisons les techniques de validation utilisées

2. Calcule des poids

Nous utilisons l'équation suivante

$$y = H\omega + e \quad (\text{II.19})$$

➤ H est une matrice de $[L, N]$ donne les réponses des N centres RBF sur le l exemple.

➤ y est un vecteur regroupe les sorties y_i sur l'ensemble d'apprentissage et e est le vecteur d'erreur le critère à optimiser

$$E = e^T e \quad (\text{II.20})$$

Si l'on ajoute un terme de régularisation de type ridge régression qui pénalise les solutions avec de grand valeur des poids on écrit

$$E = e^T e + \lambda \omega^T \omega \quad (\text{II.21})$$

La solution obtient par un calcul classique de pseudo-inverse

$$\omega = (H^T H + \lambda I)^{-1} H^T y \quad (\text{II.22})$$

Où I est la matrice identité de taille .

Nous utilisons pour résoudre le système d'équation des valeurs singulières (SVD) car il résiste aux mauvais problèmes de conditionnement numérique.

3. Estimation non supervisée du centre

Pour connaître les coordonnées de l'emplacement du Centre Gaussien, nous avons eu recours à un processus étiqueté de manière non supervisée, ce qui signifie que pour l'évaluation du centre μ_j , nous n'utiliserons pas la valeur cible y_i .

Ils peuvent être considérés ou interprétés comme des compensateurs ou des représentants de la densité de probabilité des données. Ensuite, on peut arriver à des solutions locales. Le résultat de mettre une petite quantité de données, mais quand il y a un nombre important de points, on peut mettre beaucoup de noyaux [35].

Cette technique, telle qu'elle est connue dans la communauté scientifique, s'appelle la quantification vectorielle, et nous appelons le point médian le point auquel l'information est résumée. Nous basant sur les centres de gravité, nous pouvons faire plusieurs divisions des groupes contenant les données en un nombre plus petit [35].

4. Estimation supervisée des largeurs

Pour déterminer comment les noyaux adjacents se chevauchent, cela équivaut à déterminer la largeur du noyau. Afin de pouvoir les estimer à plusieurs reprises, nous devons déterminer les centres. À l'aide d'expériences de validation, nous avons pu déterminer la largeur de la fonction gaussienne.

Le nombre de classes dans la couche de sortie correspond au nombre de neurones, et dans notre cas, nous avons deux classes:

- **Classe 1** : embolie gazeuses représentée par un « 1 ».
- **Classe 2** : embolie solide représentée par un « 0 ».

4.CONCLUSION

Les réseaux de neurones artificiels, inspirés du comportement du cerveau humain, permettent de créer de l'intelligence artificielle. Notamment appliqués en datamining principalement à travers l'apprentissage non supervisé, ils servent à prédire, à identifier et à classifier les données. Le chapitre suivant est consacré à la classification des emboles par l'utilisation de la méthode de réseau de neurone à fonction radiale de base.

**CHAPTER III : CLASSIFICATION DES
EMBOLES PAR RESEAU DE NEURONE A
FONCTION RADIALE DE BASE.**

1.Introduction :

De nombreux chercheurs ont rapporté que pour la détection et l'analyse emboliques, la transformée en ondelette discrète (DWT) donne des résultats meilleurs que la transformation de Fourier rapide. Par conséquent, pour analyser le signal ultrasonore renvoyé par les emboles, nous utilisons l'approche DWT.

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 (voir ANNEX).

Dans la première partie, nous parlerons de : (Extraction des caractéristiques en utilisant DWT), nous utilisons l'algorithme DWT basé sur la fonction d'ondelette sélectionnée pour décomposer les signaux RF en différentes bandes de fréquences et identifier les caractéristiques qui conduisent à des meilleurs performances.

Puis dans la deuxième partie de ce chapitre, nous parlerons de la classification par RBF. Cette partie résume les résultats de classification à partir d'un réseau de neurone à fonction radiale de base « RBF ».

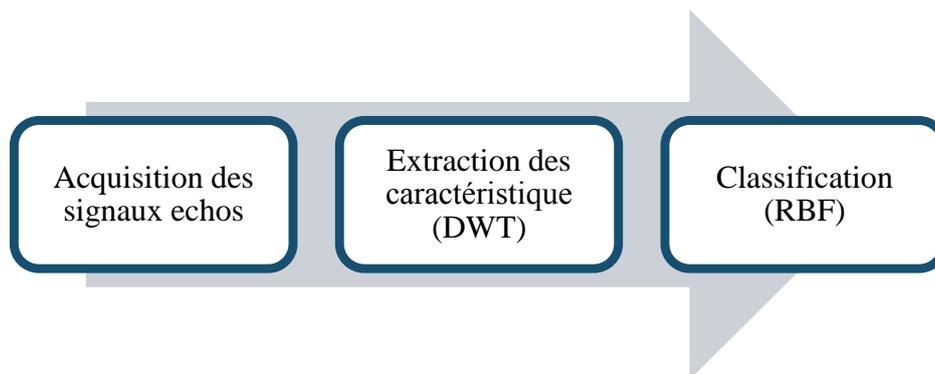


Figure III -1: Schéma du système de classification basé sur DWT et RBF.

Partie I : Extraction des caractéristiques en utilisant DWT

L'utilisation de DWT nous permet d'obtenir des échelles de temps et des fréquences différentes en analysant les ondelettes. Cela résulte d'une conversion du signal RF normalisé rétrodiffusé transformé.

A L'entrée Les signaux RF rétrodiffusés sont d'abord détectés et collectés (acquisition de signaux). À la seconde étape, les coefficients DWT des signaux sont collectés. Le signal d'entrée est décomposé en un nombre optimal de bandes de fréquences utilisant DWT. Par conséquent, il est essentiel de sélectionner un ondelette pour le signal analysé. L'adéquation des filtres et des ordres d'ondelettes est déterminé expérimentalement. La meilleure ondelette

mère sur le même types de signaux RF rétrodiffusés est Daubechies (db6) [36]. Dans la troisième étape, après l'application DTW sur les signaux RF rétrodiffusés, plusieurs caractéristiques sont évaluées à partir du coefficients de détail et approximation. Dans la dernière étape, toutes ces caractéristiques sont utilisées comme entrées pour le modèle classification (RBF).

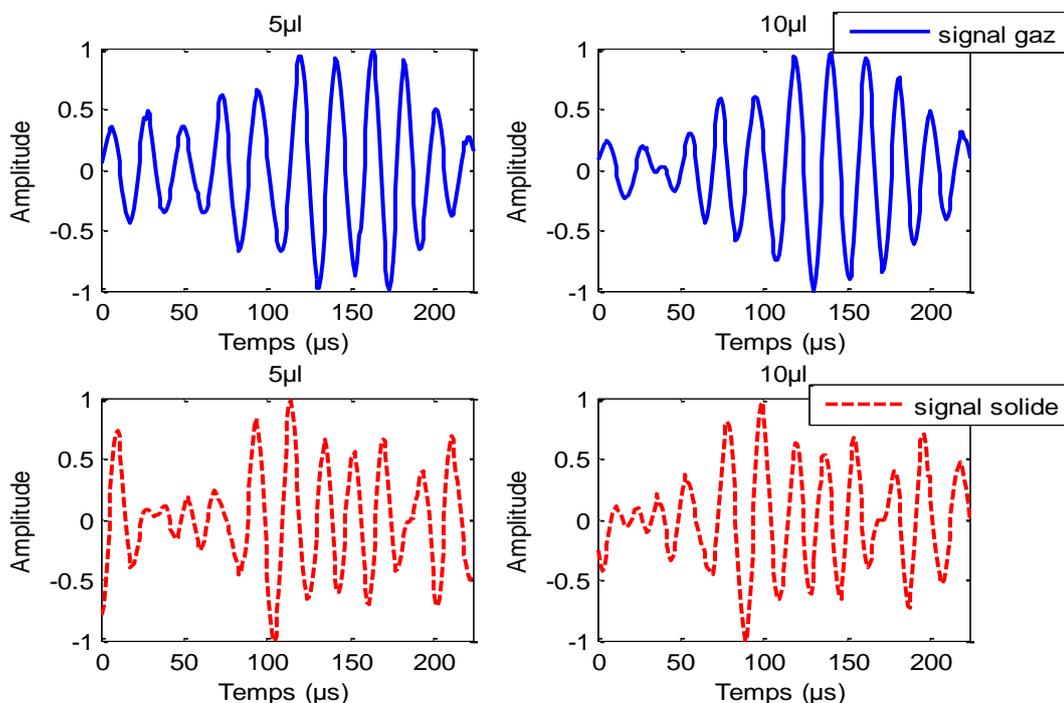


Figure III -2: Signaux normalisés.

La Figure III-2 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 (voir ANNEX). Ces avec ces signaux que nous allons appliquer la transformé DWT pour décomposer les signaux en un nombre de signaux détail et approximation.

1.L'utilisation de la DWT pour l'extraction des caractéristiques

2.1. Transformation en ondelettes

La transformée en ondelettes est un processus linéaire qui décompose un signal en composantes qui apparaissent à différentes échelles [14, 37]. L'idée de base de la transformée en ondelettes est de représenter tout signal arbitraire $x(t)$ comme une superposition d'un ensemble d'ondelettes ou de fonctions de base. Ces fonctions de base (ondelettes) sont

obtenues à partir d'une seule ondelette prototype appelée ondelette mère par dilatation (mise à l'échelle) et translation (décalages). La transformée en ondelettes d'un signal continu $x(t)$ est définie comme [14, 37]:

$$C(a,b)=\int_{\mathbb{R}} x(t) \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) dt \quad (\text{III.1})$$

où, les indices $c(a, b)$ sont appelés coefficients d'ondelettes du signal $x(t)$, a est la dilatation et b est la translation, $\Psi(t)$ est la fonction de transformation (l'ondelette mère). Les basses fréquences sont explorées avec une faible résolution temporelle tandis que les hautes fréquences avec une haute résolution temporelle. La transformée en ondelettes discrète (DWT) d'un signal est représentée par rapport à une ondelette mère et mappe des signaux d'énergie finie continue à une grille bidimensionnelle de coefficients [21,37]. L'échelle a dans le cas de la transformée en ondelettes discrète devient $a=a_0^m$, et la translation b devient $b=nb_0a_0^m$ [14, 37]. Le DWT d'un signal discret de longueur N est défini comme:

$$c(m, n) = \frac{1}{\sqrt{a}} \sum_{k=0}^{N-1} s(k) \Psi\left(\frac{k-nb_0a_0^m}{a_0^m}\right) \quad (\text{III.2})$$

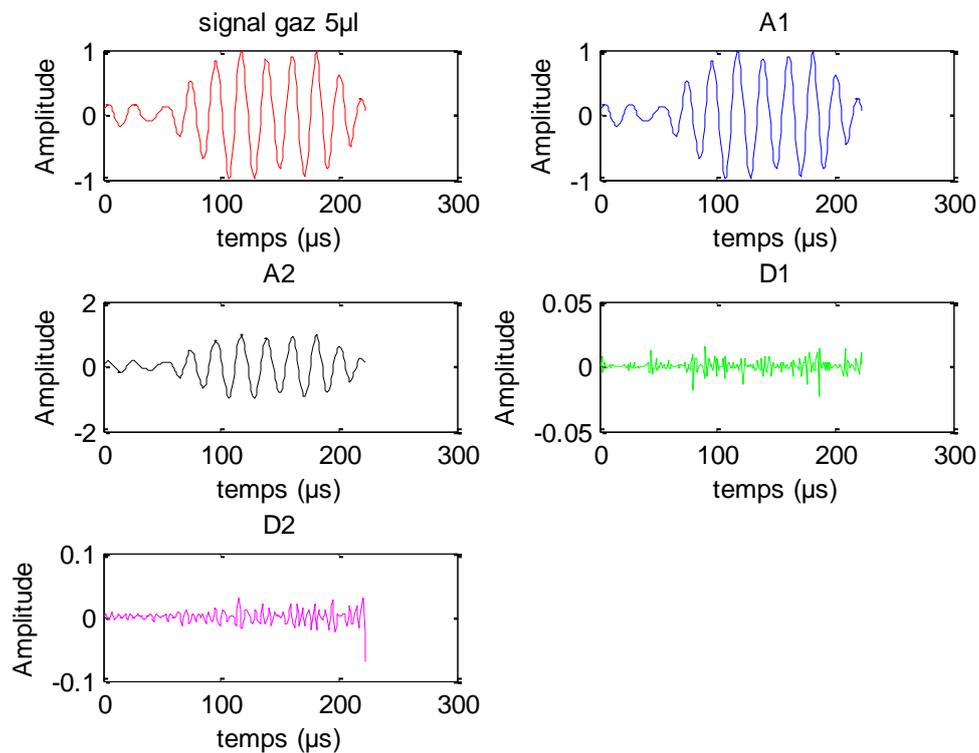
DWT d'un signal discret donne un ensemble de coefficients comprenant tous les coefficients détaillés et les derniers coefficients d'approximation [14, 37].

2.2.Extraction de caractéristiques

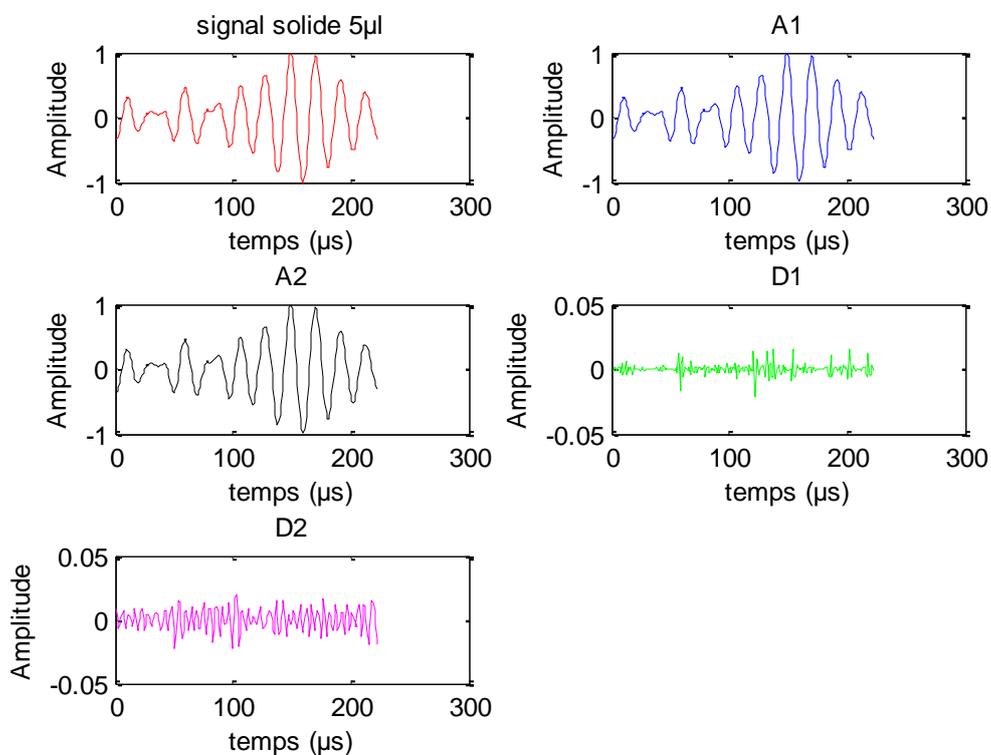
En utilisant DWT, le signal RF normalisé rétrodiffusé peut être transformé en différentes échelles temps-fréquence grâce à l'analyse des ondelettes. DWT utilise deux filtres : un filtre passe-haut et un filtre passe-bas. Le filtre passe-haut génère une version détaillée du rétrodiffusion du signal RF (D : haute fréquence), tandis que le filtre passe-bas produit sa version approximative (A : basse fréquence).

Dans notre étude, nous décomposons le signal RF de rétrodiffusion $x(t)$ en deux niveaux. Les fonctions d'ondelettes utilisées pour cette étude sont des fonctions DWT standard disponibles dans la boîte à outils Matlab Wavelet [38] à savoir Daubechies (db6). Il est à noter que la meilleure ondelette mère sur les mêmes types de signaux RF rétrodiffusés est Daubechies (db6) d'après les travaux K. Ferroudji et al. [36]. Un exemple de décomposition des signaux d'embolie gazeuse et d'embolie solide en utilisant Daubechies (db6) comme ondelette mère est illustré dans les Figures III.3 et III.4. Le détail et l'approximation des coefficients ne sont pas directement utilisés comme entrées pour le classificateur. Plusieurs caractéristiques sont

évaluées à partir des coefficients de détail et d'approximation. Il est à noter que pour chacun des coefficients DWT, deux caractéristiques (énergie et Shannon-entropie) sont calculées.

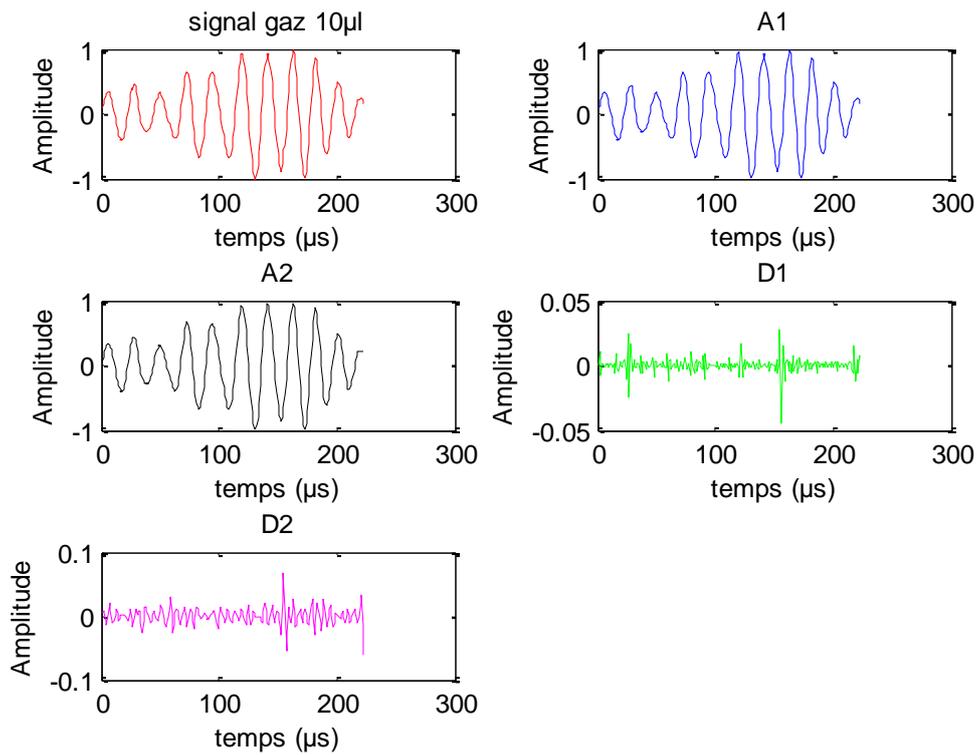


(a)

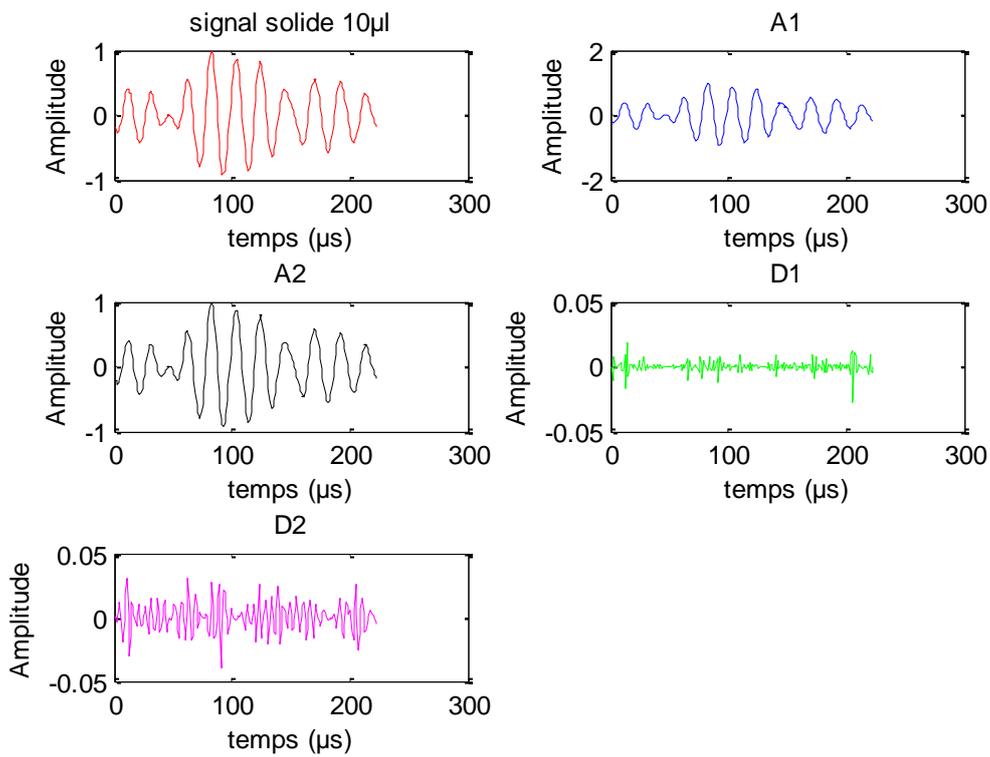


(b)

Figure III-3: Exemples DWT de signal RF rétrodiffusé utilisant Daubechies (db6) comme ondelette mère pour la concentration 5 μl . (a) gaz, (b) solide.



(a)



(b)

Figure III-4:Exemples DWT de signal RF rétrodiffusé utilisant Daubechies (db6) comme ondelette mère pour la concentration 10 µl. (a) gaz, (b) solide.

Énergie: Dans cette étude L'énergie des signaux est calculée comme une caractéristique. Étant donné que l'apparition d'embolie gaz augmente généralement l'énergie du signal, il est typique d'utiliser l'énergie pour la détection des microembolies [39].

$$\text{énergie : } E = \sum_{j=1}^n |x_{ij}|^2 \quad (\text{III.4})$$

Entropie de Shannon: L'entropie de Shannon est calculée comme une mesure du caractère aléatoire de l'énergie dans chaque niveau de décomposition en ondelettes [39].

$$\text{Shannon-entropie : } H = \sum_{j=1}^N x_{ij}^2 \log(x_{ij})^2 \quad (\text{III.5})$$

Toutes les caractéristiques sont appliquées individuellement sur les coefficients de détail et d'approximation de chaque niveau de décomposition.

Les tableaux III-1 et III-2 montrent les caractéristiques extraites des signaux gaz et solides et leurs classes correspondantes.

Tableau III-1 : Les caractéristiques des signaux gaz et solide de 5 μ l.

5ul								
Énergie					Entropies			
Gaz	EA1_g	EA2_g	ED1_g	ED1_g	eA1_g	eA2_g	eD1_g	eD2_g
solide	EA1_s	EA2_s	ED1_s	ED1_s	eA1_s	eA2_s	eD1_s	eD2_s

Tableau III-2 : Les caractéristiques des signaux gaz et solide de 10 μ l.

10ul								
Énergie					Entropies			
Gaz	EA1_g	EA2_g	ED1_g	ED1_g	eA1_g	eA2_g	eD1_g	eD2_g
solide	EA1_s	EA2_s	ED1_s	ED1_s	eA1_s	eA2_s	eD1_s	eD2_s

En conséquence, nous obtenons huit caractéristiques pour chaque signal RF rétrodiffusé (embole solide ou gazeuse). Ces caractéristiques sont utilisées comme entrées du classificateur.

Part II : Classification par RBF “Radial Basis Function Neural Networks

1. Principe du système de classification :

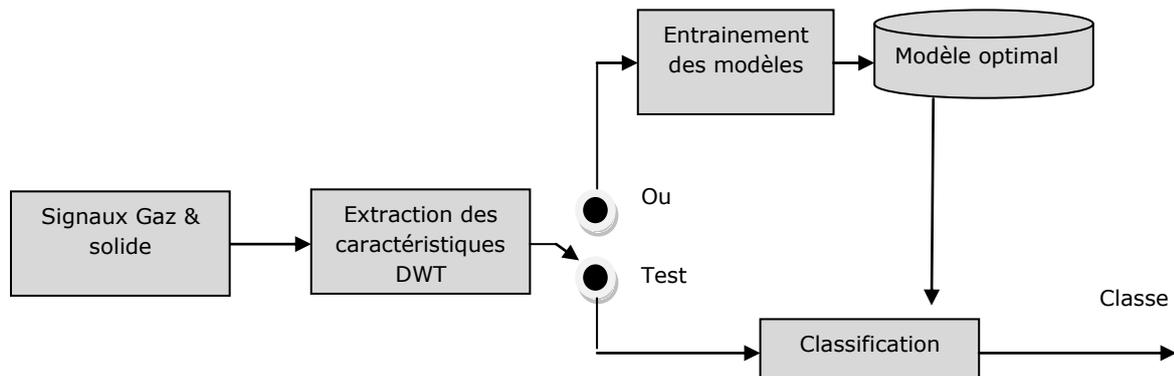


Figure III-5: Diagramme du système de classification

Le diagramme du système de classification est représenté sur la Figure III-5. Après application du DTW sur les signaux RF rétrodiffusés, plusieurs caractéristiques sont évaluées à partir des coefficients de détail et d’approximation. Les caractéristiques (entropie de Shannon et énergie) pour chaque coefficients sont utilisées comme entrées au classificateur RBF. Ce dernier fourni une valeur de 1 ou 0 pour les emboles gazes ou solides respectivement.

Le système de classification est divisé en deux étapes: la phase de conception et la phase de généralisation.

Phase de conception: C'est le processus de sélection de la structure optimale du modèle qui lui permet de s'adapter aux différentes conditions d'entrée. Dans cette étape l’algorithme utilise l’ensemble d'apprentissage pour la conception (voir la section 3.Sélection de modèle)

L'étape de généralisation: Une fois la conception du modèle est terminé, il passe en phase de test pour réaliser la classification. Il est à noter que l'algorithme n'a accès qu'à l'ensemble d'apprentissage et que l'ensemble de test est gardé invisible dans l'étape de test (voir la section 3.Sélection de modèle).

2. Critères de performances :

2.1. Matrice de confusion :

Afin d'évaluer les performances de notre modèle, nous utilisons les informations collectées à partir de la matrice de confusion (CM). CM illustre le nombre de prédictions correctes et incorrectes faites par le classificateur par rapport aux vraies étiquettes dans les données de test. En outre, les performances du modèle proposé sont évaluées en comparant les valeurs prédites avec les valeurs de classe réelles.

Tableau III-3: Matrice de confusion pour le modèle de classification binaire.

		Prédite	
		Emboles gazeuses	Emboles solides
Classe réelle	Emboles gazeuses	TP	FP
	Emboles solides	FN	TN

- True Positive (TP): Le classificateur prédit une étiquette comme embole gaz et la classe réelle est embole gaz.
- True Negative (TN): Le classificateur prédit une étiquette comme embole solide et la classe réelle est embole solide.
- False Positive (FP): Le classificateur prédit une étiquette comme embole solide et la classe réelle est embole gaz.
- False Negative (FN): Le classificateur prédit une étiquette comme embole gaz et la classe réelle est embole solide.

Si vous disposez d'un ensemble de données déséquilibré, il est toujours préférable d'utiliser la matrice de confusion comme critère d'évaluation de votre modèle d'apprentissage automatique.

2.2.Accuracy :

L'exactitude (en anglais Accuracy :ACC) est une métrique largement utilisée pour mesurer les performances d'un classificateur. ACC est le pourcentage d'étiquettes positives et négatives correctement classées.:

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (\text{III.5})$$

3.Sélection de modèle (validation croisée) :

La validation croisée est une méthode d'apprentissage automatique qui peut être utilisée pour sélectionner les paramètres optimaux pour un classificateur tout en évitant le surajustement du classificateur aux données d'apprentissage [40]. Nous utilisons la stratégie de validation croisée hold-out-set pour fixer les paramètres du classificateurs. Bien qu'il existe d'autres techniques de validation, y compris, mais sans s'y limiter, le bootstrap et le laisser-un de côté, nous nous concentrons sur l'approche de validation croisée la plus couramment utilisée dans ce mémoire [40]. La validation croisée Hold out-set fonctionne en divisant au hasard l'ensemble de données, en deux sous-ensembles d'entraînement et de test (hold-out-set). l'ensemble de test est masqué pendant la majeure partie du processus et il n'est utilisé que pour vérifier les performances finales. Après cela, nous générons aléatoirement de nouveaux ensembles de d'apprentissage et de validation à partir de l'ensemble d'entraînement initial. Les paramètres de classification qui aboutissent à un modèle avec la plus grande précision, en utilisant l'ensemble de validation, sont choisis comme le meilleur choix du problème de classification (voir figure III.6). Une fois les paramètres optimaux fixés, l'ensemble de test est utilisé pour valider le modèle sélectionné.

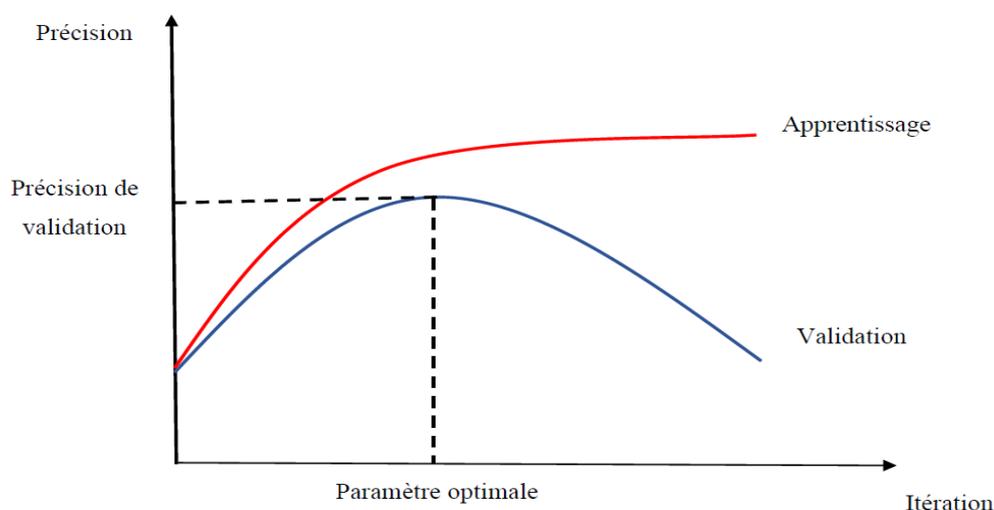


Figure III-6:Optimal parameters using Cross validation strategy.

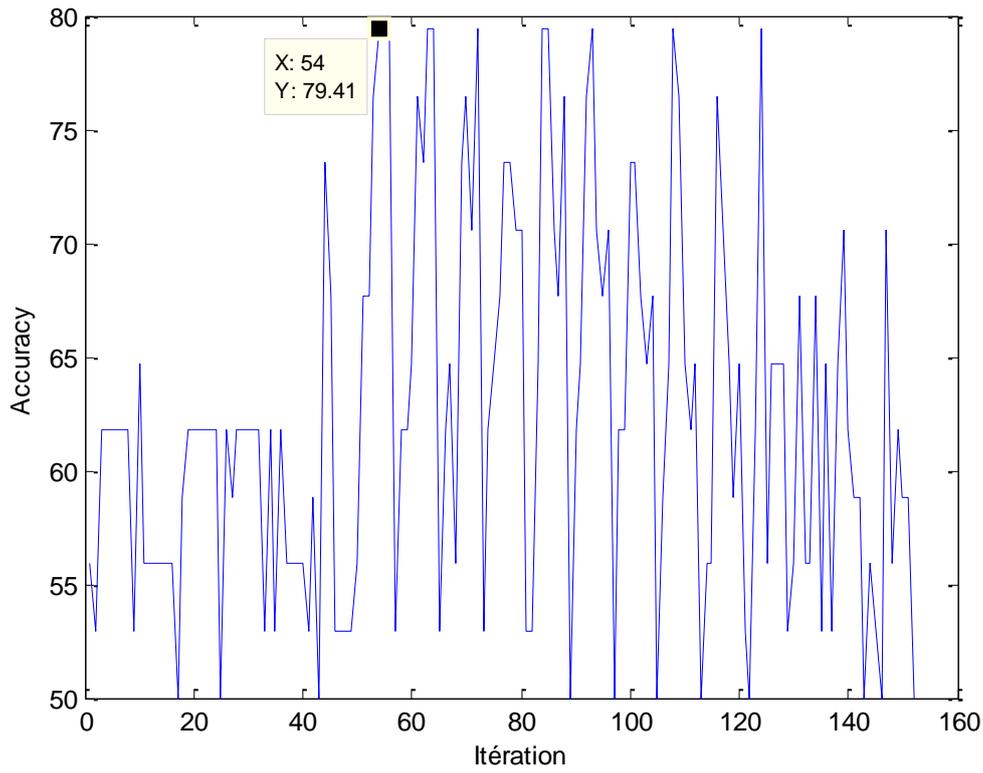
Dans notre cas, la base de données expérimental se compose de deux acquisitions, chacune contenant 102 échantillons (51 emboles solides et 51 emboles gazeuses). Afin d'évaluer la capacité prédictive d'un modèle, nous divisons au hasard l'ensemble de données en trois sous-ensembles ensemble d'apprentissage, ensemble de validation et ensemble de test. L'ensemble de test, environ un tiers (1/3) des données (14 emboles solides et 14 emboles gazeuses), est utilisé uniquement pour l'évaluation du modèle sélectionné par la technique de validation croisée, tandis que le reste des données appartient à l'ensemble d'apprentissage (utilisé pour construire les modèles) qui sera divisé en un ensemble d'apprentissage (environ deux tiers) et un ensemble de validation (environ un tiers). L'ensemble de validation est utilisé pour régler le paramètre des classificateurs.

Tableau III-4: Division de la base de données en ensembles.

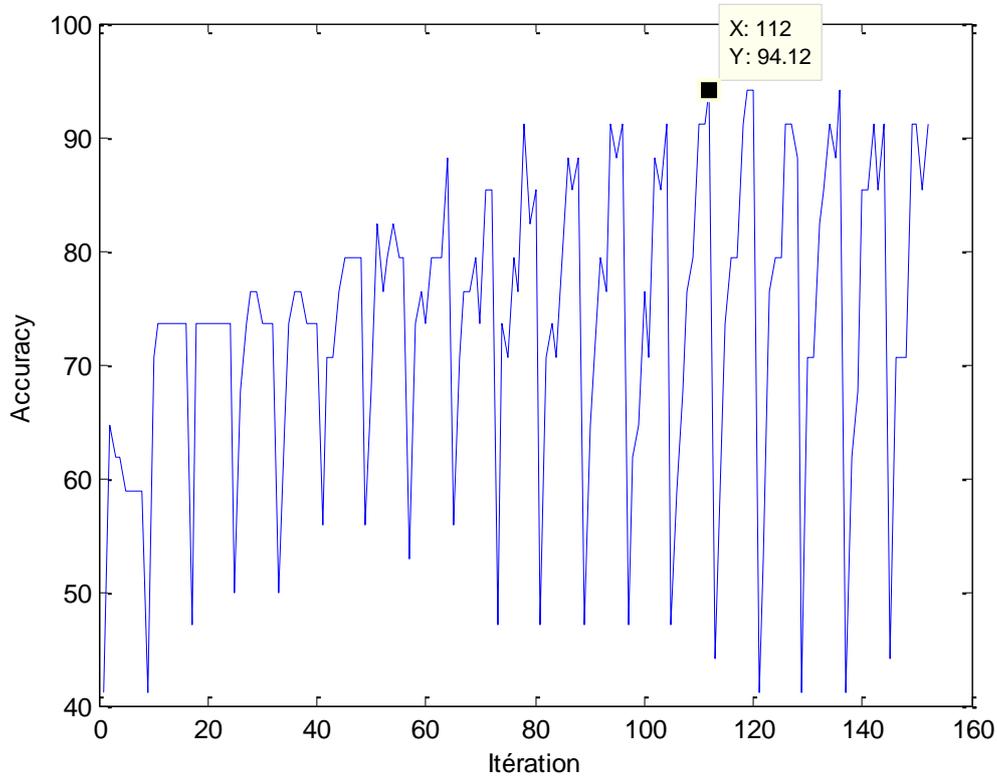
	Apprentissage	Validation	Test
GAZ	20	17	14
SOLIDE	20	17	14

Dans ce mémoire et afin d'évaluer les performances du système proposé, nous utilisons type d'algorithme de classification: Radial Basis Function Neural Networks (RBFN) .

Les nœuds d'entrée dans la couche d'entrée sont égaux à la dimension du vecteur d'entrée. Le nombre optimal de neurones dans la couche cachée ainsi que la largeur de la Gaussienne RBFN (spread) sont déterminés expérimentalement en utilisant une technique de validation croisée. La combinaison (nombre de neurones dans la couche cachée, spread de la Gaussienne RBFN) qui aboutit à un modèle avec la plus grande précision de validation est choisie comme le meilleur choix du problème de classification. Une fois les paramètres optimaux fixés, l'ensemble de test est utilisé pour valider le modèle RBFN sélectionné.



(a)



(b)

Figure III -7: Validation croisée : (a) concentration 5µl, (b) concentration 10µl.

Figure III-7 représente les courbes de validation croisée pour les concentrations de microbulles de 5 μ l et 10 μ l. Il est à noter que ces courbes sont obtenues en utilisant les huit caractéristique come entrées au classificateur RBF.

Pour chaque valeur de nombre de neurone et de spread on calcul l'exactitudes (Accuracy) en utilisant l'ensemble de validation. Pour la concentration de 5 μ l le meilleur Accuracy de validation est trouvé dans l'itération 54. Et comme le vecteur de nombre de neurone et le vecteur de spread sont sauvegardé de la même façon, donc l'itération 54 dans le vecteur de nombre de neurone et dans le vecteur de spread correspond aux paramètre optimales dans la concentration de 10 μ l, le meilleur Accuracy de validation est trouvé dans l'itération112 . Ces paramètres sont utilisés pour calculer l'exactitudes (Accuracy) de test. Les tableaux suivants illustrent les paramètres optimisés du réseau RBF.

Tableau III-5:Paramètres optimisés du réseau RBF en utilisant les huit caractéristiques come entrées (concentration 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	8
	Nbr de neurones dans la couche caché	8
	Nbr de neurones dans la couche de sortie	1
Largeur de la gaussienne RBF	40	
Accuracy de validation (%)	79.41	

Tableau III-6: Paramètres optimisés du réseau RBF en utilisant les huit caractéristique come entrées (concentration 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	8
	Nbr de neurones dans la couche caché	15
	Nbr de neurones dans la couche de sortie	1
Largeur de la gaussienne RBF	200	
Accuracy de validation (%)	94.12	

4. Classification par RBF

4.1. Déroulement de test :

On présente au meilleur modèle obtenu dans la section précédente un ensemble de test qui est différent de celui d'apprentissage est de validation (l'ensemble du test ne contribue pas dans la validation croisée) :

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

Les résultats sont présentés dans la section suivante.

4.2.Discussion des résultats :

Nous avons appliqué l'algorithme de classification dans le premier cas à chaque caractéristique séparément, et les résultats obtenus sont présentés dans les tableaux III - 7 et III - 8. Les meilleurs résultats sont représentés en gras.

Tableau III-7:Exactitudes (accuracy) de chaque caractéristique pour concentration de 5 μ l.

5ul								
(%)	EA1	EA2	ED1	ED2	eA1	eA2	eD1	eD2
Acc totale	64.28	67.85	42.85	67.85	50	57.14	50	71.42
Acc gaz	50	57.14	42.85	71.4286	28.57	50	42.85	71.42
Acc solide	78.57	78.57	42.85	64.28	71.42	64.28	57.14	71.42

Tableau III-8:Exactitudes (accuracy) de chaque caractéristique pour concentration de 10 μ l.

10ul								
(%)	EA1	EA2	ED1	ED2	eA1	eA2	eD1	eD2
Acc totale	53.57	53.57	39.28	82.14	57.14	57.14	50	82.14
Acc gaz	42.85	42.85	28.57	78.57	42.85	42.85	42.85	78.57
Acc solide	64.28	64.28	50	85.71	71.42	71.42	57.14	85.71

En utilisant chaque caractéristique séparément comme entrée au classificateur, on remarque que les valeur de l'Accuracy (taux de classification), n'ont pas dépassé **71.42%** et **82.14%** pour les deux concentrations 5 μ l et 10 μ l respectivement.

Pour surmonter cette limitation, on présente à l'algorithme RBF de classification toutes les caractéristiques comme entrées. Les résultats sont illustrés dans les Tableaux III-9 et III-10 :

Tableau III-9:Exactitudes (accuracy) de toutes les caractéristiques pour concentration de 5 μ l.

5 μ l	
	Toutes les caractéristiques
Acc totale (%)	92.85
Acc gaz (%)	100
Acc solide (%)	85.71

Tableau III-10:Exactitudes (accuracy) de toutes les caractéristiques pour concentration de 10 μ l.

10 μ l	
	Toutes les caractéristiques
Acc totale (%)	92.85
Acc gaz (%)	100
Acc solide (%)	85.71

Après avoir utilisé toutes les caractéristiques comme entrées pour le classificateur, une amélioration des taux de classification est observée. Pour les deux concentrations on a obtenu une exactitude de 92.85%.

Les Tableaux III-11 et III-12 représente la matrice de confusion des embolies à l'aide de l'analyse RBF pour les deux concentrations des microbulles 5 μ l et 10 μ l.

Les matrices de confusion pour les deux concentrations des microbulles 5 μ l et 10 μ l sont montées dans les Tableaux III-11 et III-12.

Tableau III-11:Matrice de confusion du test pour concentration 5 μ l.

		Les résultats avec 5 μ l	
		Prédit	
		Bon classé	Mal classé
Classe actuel	Embole gaz	14	0
	Embole solide	12	2

Tableau III-12:Matrice de confusion du test pour concentration 10 μ l.

		Les résultats avec 10 μ l	
		Prédit	
		Bon classé	Mal classé
Class actuel	Embole gaz	14	0
	Embole solide	12	2

Les deux tableaux incluent un affichage du nombre de prédictions correctes et incorrectes que le modèle a faites par rapport aux valeurs cibles dans les données de test. Dans les deux concentrations de microbulles, le modèle de classification RBF proposé a réussi à classer 14 emboles gazeux sur 14 donc aucune embole gaz n'est mal classée et il a réussi à classer 12 emboles solides sur 14 donc 2 emboles solide sont mal classés

La matrice de confusion peut également être réalisée en figures, ceci est illustré sur les figures III-6 et III-7. Ces Figures illustrent les prédictions faites par le modèle RBF sur l'ensemble de test, où la valeur de sortie 1 correspond à l'embole gaz représentée par les étoiles et la valeur de sortie 0 correspond à l'embole solide représentée par les carrés

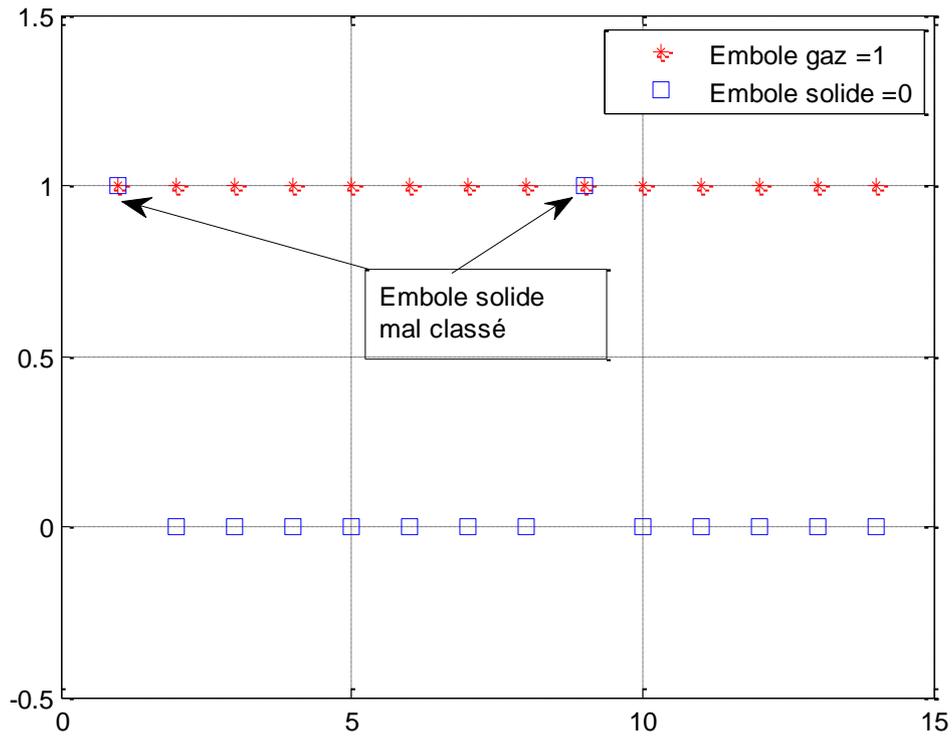


Figure III - 8: Sortie de test du réseaux RBF pour la concentration 5 μ l.

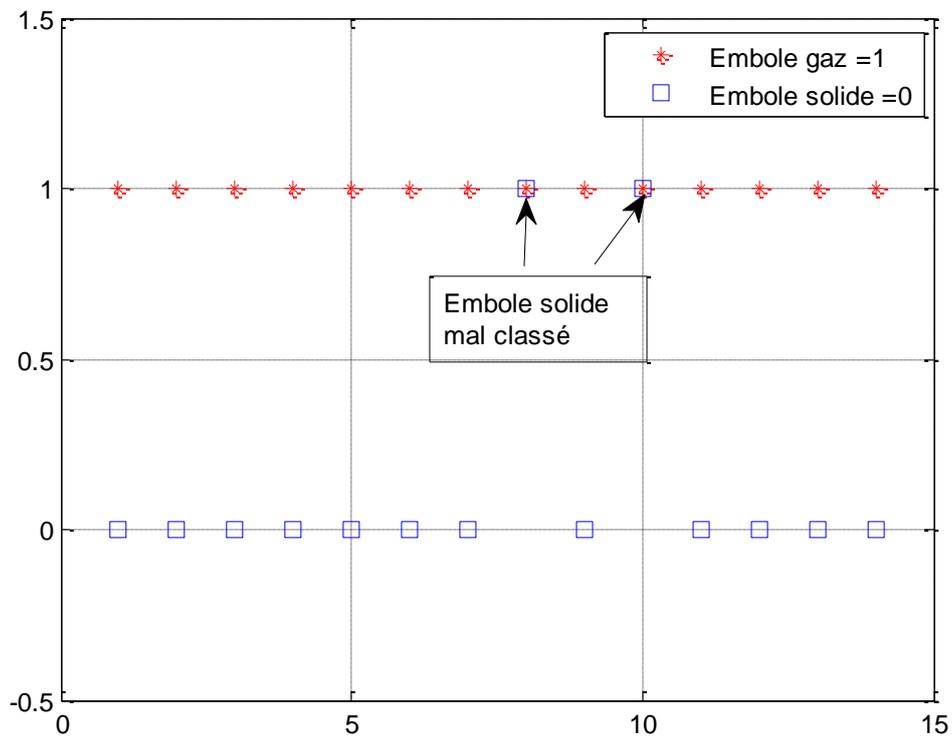


Figure III - 9: Sortie de test du réseaux RBF pour la concentration 10 μ l.

6. Etude comparative

Afin de valider les résultats obtenus par notre modèle; nous avons comparé les résultats obtenus l'approche proposée avec ceux obtenus dans une étude récemment publiée [4] sur les mêmes signaux RF rétrodiffusés dont ils ont utilisé la transformé de Fourier pour caractériser les emboles gaz et solide. Le pourcentage moyen de classification correcte des microemboles à l'aide de l'algorithme RBF pour deux concentrations de microbulles (5 μ l et 10 μ l) est indiqué dans le tableau III-13. Les meilleurs résultats sont montrés en gras.

Tableau III-13:Etude comparative avec les résultats obtenus dans la référence [4].

5 μ l			
	Approche proposée	Référence [4] modèle RBF	Référence [4] modèle MLP
ACC totale (%)	92.85	89.28	89.28
ACC gaz (%)	100	92.85	78.57
ACC solide (%)	85.71	85.71	100
10 μ l			
	Approche proposée	Référence [4] modèle RBF	Référence [4] modèle MLP
ACC totale (%)	92.85	92.85	89.28
ACC gaz (%)	100	85.71	78.57
ACC solide (%)	85.71	100	100

Ces résultats illustrent que l'approche proposée présente de meilleur résultats par rapport aux résultats citée dans la référence [4] pour la concentration des microbulles de 5 μ l, et des résultats comparables par rapport aux résultats citée dans [4] pour la concentration de 10 μ l

7.Conclusion :

Dans ce chapitre, nous avons discuté en détail les résultats obtenus à partir de notre modèle. Pour modéliser le processus de classification, nous avons utilisé le réseau de neurones RBF. L'approche proposée a démontrée que l'utilisation de la transformé DWT permet d'obtenir de meilleurs résultats de classification des microbulles pour la concentration de 5 μ l et des résultats comparables pour la concentration de 10 μ l par rapport aux résultats citée dans la référence [4] dont l'extraction des caractéristiques est basé sur la transformé de Fourier pour caractériser les emboles gaz et solide.

CONCLUSION GENERALE

Conclusion Générale :

La détection et la classification des embolies restent un domaine de recherche prometteur en raison de la corrélation entre les conséquences de l'embolie et la nature de l'embolie (embolie gazeuse ou solide). La détection et la classification des microembolies circulantes sont aujourd'hui considérées comme un défi majeur dans le domaine de la détection des embolies. Dans le corps humain; les embolies peuvent produire des dommages graves comme un accident vasculaire cérébral ou une crise cardiaque, par conséquent la classification des embolies est d'une grande importance clinique pour sélectionner le traitement approprié du patient

Plusieurs méthodes ultrasoniques utilisant le traitement Doppler ont été utilisées pour la détection et la classification des embolies comme matière solide ou gazeuse. Jusqu'à présent, les techniques Doppler ont montré certaines limites pour déterminer clairement la nature des microembolies en circulation.

Ce mémoire a présenté une étude sur la façon dont les problèmes de microembolies peuvent être détectés et caractérisés. Il a étudié une nouvelle approche de la détection et de la classification des microembolies à l'aide de signaux ultrasonores radiofréquences (RF) au lieu des signaux Doppler traditionnellement utilisés. Une technique de l'intelligence artificielle à savoir le réseaux de neurone RBF est exploitée dans 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 (voir ANNEX).

Une première preuve du concept de classification des embolies basée d'une technique d'extraction de caractéristiques temps-fréquence (transformée en ondelettes discrète) est démontrée.

L'analyse des signaux RF a été effectuée dans le domaine temps-fréquence (transformée en ondelettes discrète). L'entropie et l'énergie pour chaque coefficient de détail et d'approximation sont exploitées comme caractéristiques. Ces dernières, sont utilisées comme entrées au classificateur RBF qui fournit une valeur de 1 ou 0 pour les embolies gazeuses ou solides respectivement.

Le modèle proposé a atteint un taux de classification de 92.85% pour les deux concentrations des microbulles 5 μ l et 10 μ l. Les résultats ont démontré l'opportunité de classer les embolus en utilisant les signaux RF tout en exploitant le comportement non linéaire des embolus gazeux.

Afin d'atteindre l'objectif, qui est de vérifier la validité de l'approche proposée, après avoir obtenu les résultats, nous les avons comparés aux résultats sur les mêmes signaux RF rétrodiffusés, ce qui est une étude relativement récente utilisant la transformée de Fourier (FFT) pour caractériser les embolus gaz et solide [4].

Avec la capacité de bien localiser à la fois en temps et en fréquence de la transformée DWT par rapport à l'FFT, le modèle proposé (basé sur DWT) présente de meilleurs résultats par rapport aux résultats cités dans la référence [4] (basé sur FFT) pour la concentration des microbulles de 5 μ l, et des résultats comparables par rapport aux résultats cités dans [4] pour la concentration de 10 μ l. Néanmoins, il serait intéressant d'incorporer à la fois les approches FFT et DWT dans le même modèle de classification.

La technique suggérée dans cette étude s'avère efficace pour améliorer la classification. La mise en œuvre d'un tel algorithme dans des applications en temps réel rend également intéressante l'étude de la faisabilité des systèmes de détection de signaux d'embolie utilisant un signal RF. Cependant, d'autres validations dans des situations in vivo sont nécessaires pour démontrer l'avantage supplémentaire

ANNEX

ANNEX**Etude expérimentale :**

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.

Afin de vérifier l'utilité du traitement du signal ultrasonore RF pour la classification des microembolies, une configuration in vitro est développée. Il se compose d'un fantôme de flux Doppler contenant 3 tubes de 0,2, 0,4 et 0,8 mm de diamètre. Le tube de 0,8 mm est choisi car sa taille se rapproche de la taille d'un vaisseau humain (Figure A.1). Afin d'imiter le comportement ultrasonique des embolies gazeuses, des agents de contraste constitués de microbulles sont utilisés dans la configuration expérimentale. Par conséquent, un flux continu transportant des microbulles SonoVue [4] (microbulles de contraste) à travers le vaisseau insonifié est exploité dans le montage expérimental. La concentration de microbulles et le débit sont contrôlés par l'opérateur.

Cependant, les embolies solides présentent des propriétés acoustiques comparables à celles du tissu biologique, dans leur signal diffusé aucune composante harmonique ne peut être vue, par conséquent la diffusion des embolies solides est purement linéaire. Ainsi, le matériau imitant les tissus entourant le vaisseau est choisi pour imiter le comportement des embolies solides. De plus, les pressions acoustiques appliquées ne sont pas suffisamment élevées pour induire des effets de propagation non linéaires et ne génèrent aucune composante harmonique lors de la propagation des ultrasons.

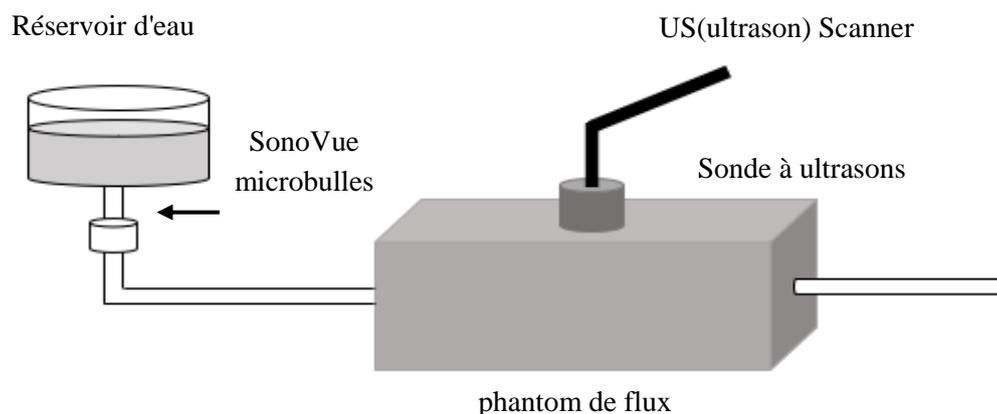


Figure A - 1: Dispositif expérimentale.

Les ondes ultrasonores sont générées par une sonde VF13-5 connectée à un scanner Siemens Antares (Anthares, Siemens, MV, CA). Les acquisitions sont effectuées à une fréquence d'émission de 1,82 MHz en mode d'imagerie harmonique tissulaire (THI) en utilisant une fréquence d'images de 14 ips et 20 MHz comme fréquence d'échantillonnage des signaux. La mise au point acoustique est réglée à 2 cm qui est la profondeur à laquelle les microbulles de contraste fluides sont situées. Les ondes ultrasonores sont transmises à deux intensités différentes correspondant à des indices mécaniques (MI) de 0,2 (faible MI) et de 0,6 (MI élevé).

L'interface de recherche utilisateur est utilisée pour saisir les signaux RF non filtrés vers un ordinateur personnel pour une analyse plus approfondie. Les microbulles sont administrées dans un volume de 200 ml d'Isoton. Deux concentrations d'agent de contraste sont utilisées: 5 μ l et 10 μ l [4]. Les régions d'intérêt où les signaux RF correspondant aux embolus gazeux et solides sont représentées sur la figure A.2.

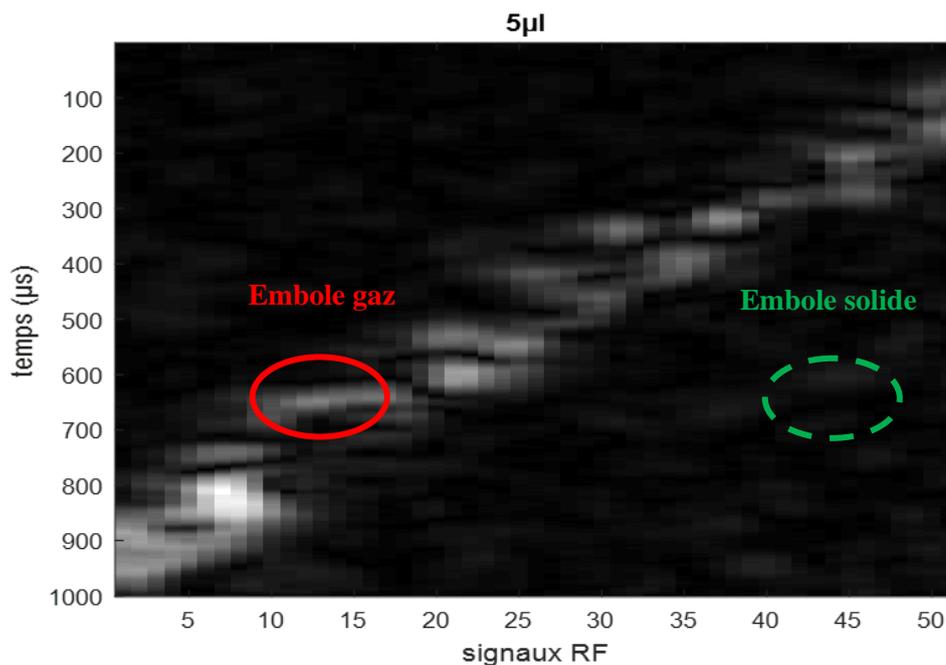


Figure A - 2: Image échographique pour la concentration des microbulles de 5 μ l.

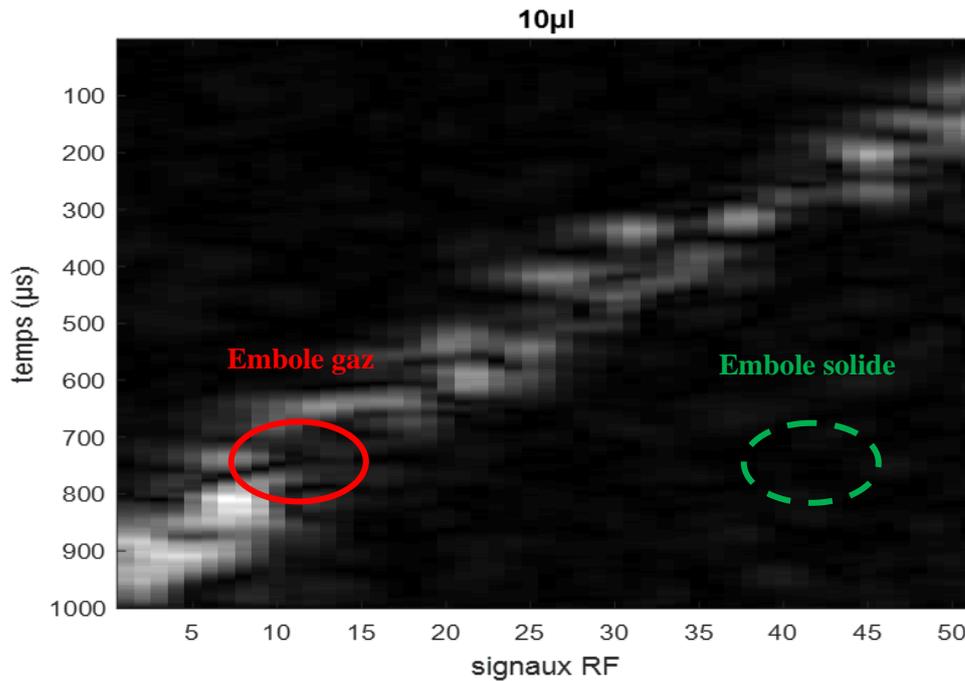


Figure A - 3 : Image échographie pour la concentration des microbulles de 10µl.

En conséquence, quatre bases de données sont obtenues, chaque ensemble de données se compose de 102 échantillons (51 emboles gazeuses et 51 emboles solides). Ces bases de données sont utilisées pour créer un certain nombre de caractéristiques discriminantes exploitées pour la détection et la classification des microemboles en circulation (voir chapitre III).

Des exemples des signaux de radiofréquence (RF) extraits des images ultrasonores sont présentés dans les **Figures A-4** et **A-5**. La représentation temporelle du signal RF change de forme là où il y a des microbulles (amplitude plus grandes).

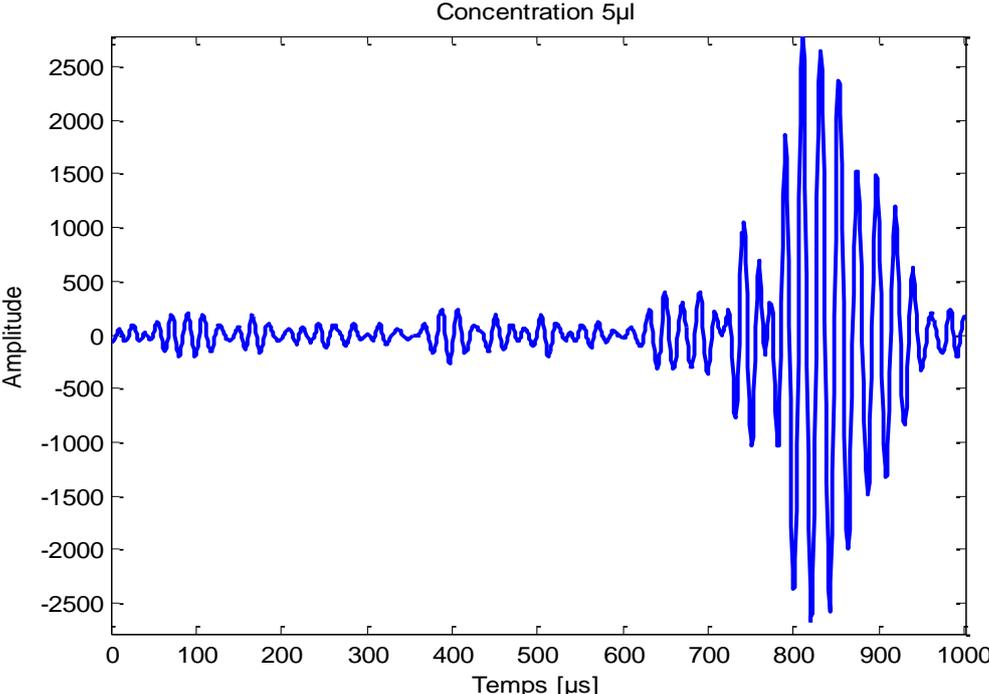


Figure A - 4: Signal RF extrait des images échographiques (concentration 5µl).

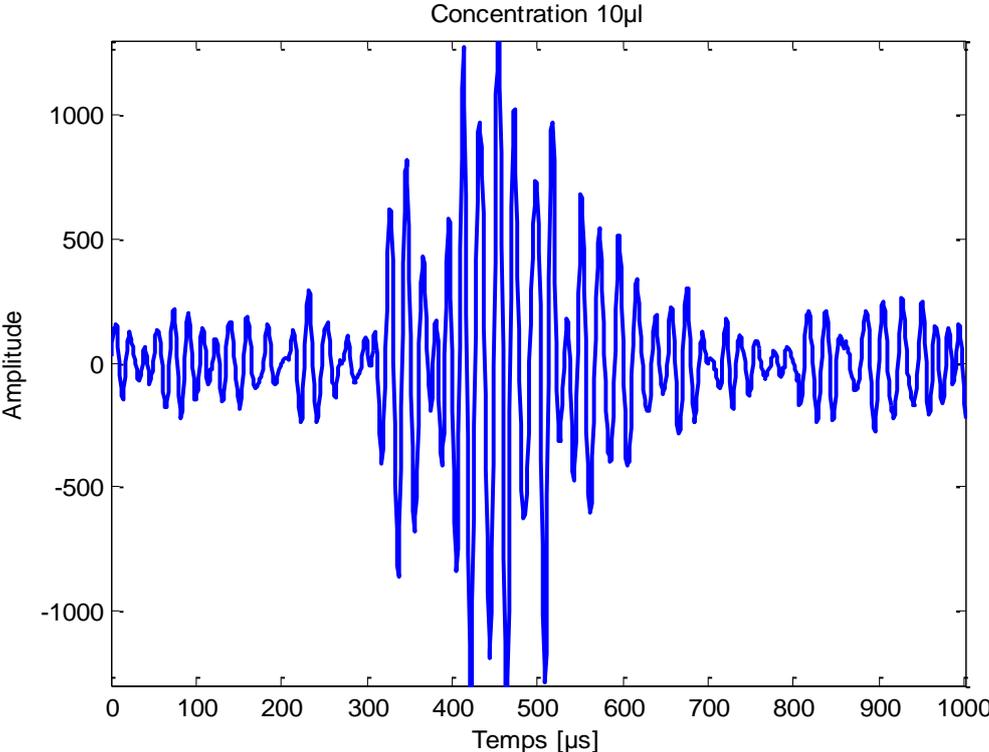


Figure A - 5: Signal RF extrait des images échographiques (concentration 10µl).

Pour se rapprocher de la réalité qui correspond à contraste trop faible entre le gaz et le tissu, une normalisation des signaux RF gaz (embole gaz) et les signaux solide (embole solide) a été effectué.

L'effet de la normalisation est montré sur les figures suivantes. Il est à pointer que la différenciation entre embole gazeuse et embole solide est très difficile.

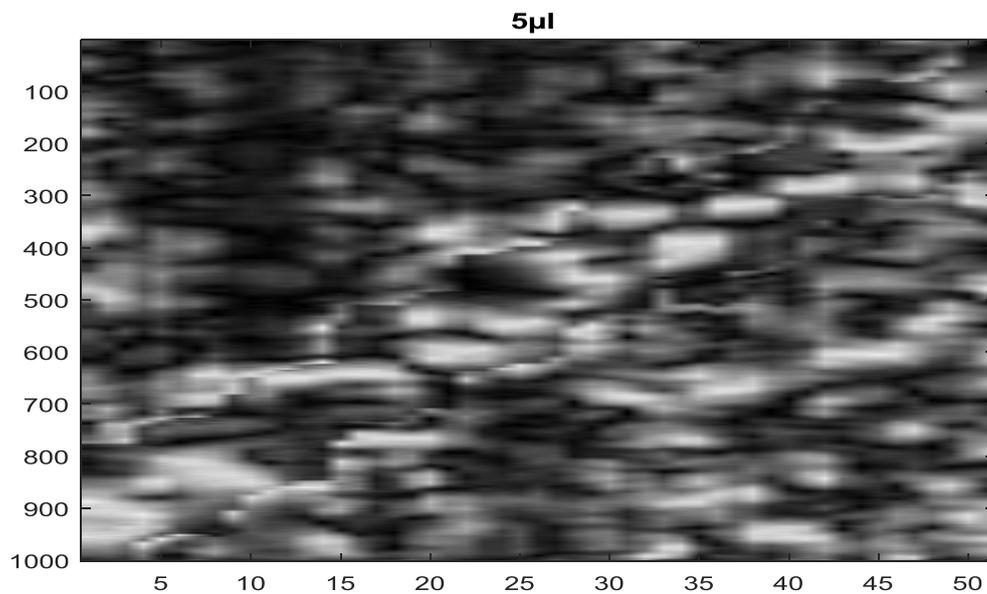


Figure A - 6: Image échographique normalisée de 5 μ l.

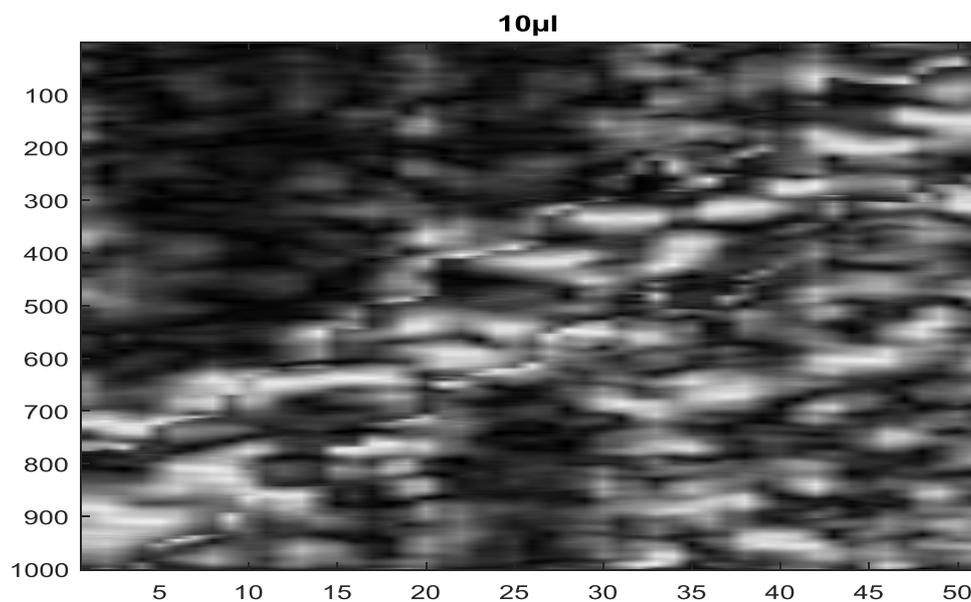


Figure A - 7: Image échographique normalisée de 10 μ l.

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.

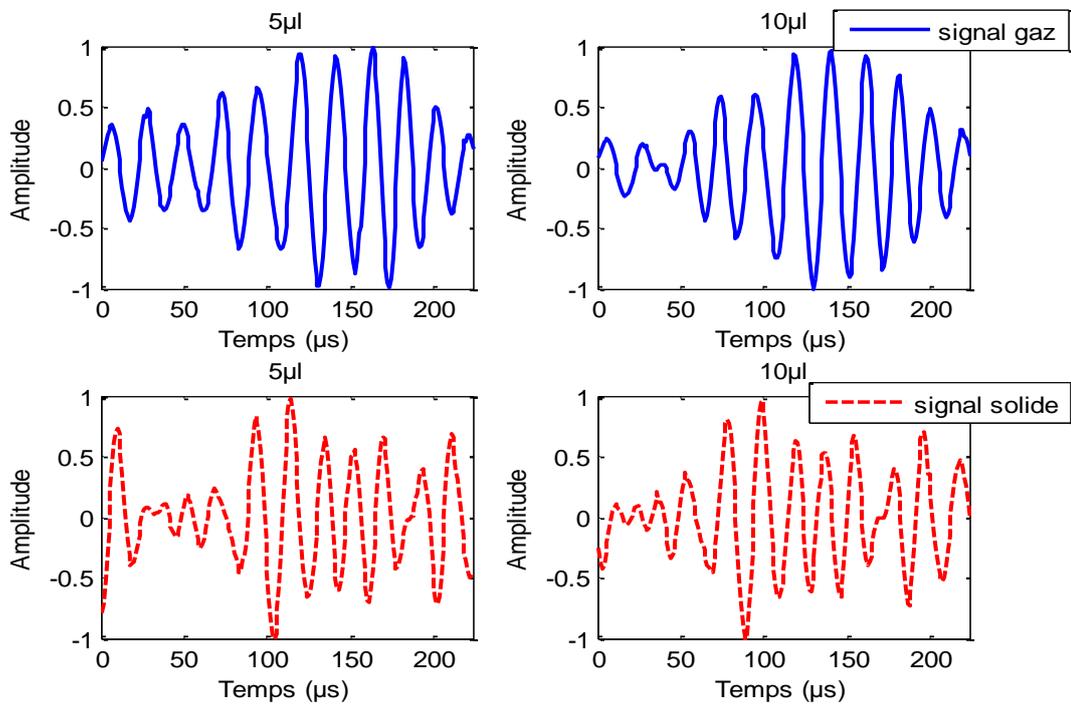


Figure A - 8: Signaux normalisés.

Dans le chapitre III, plusieurs caractéristiques sont extraites de ces signaux afin de décrire les ensembles de données acquis par un certain nombre de caractéristiques discriminantes bonnes pour la classification entre l'embole gaz et solide.

Référence et bibliographie

Référence et bibliographie :

- [1] PIPER, Keaton, ALGATTAS, Hanna, DEANDREA-LAZARUS, Ian A., et al. Risk factors associated with venous thromboembolism in patients undergoing spine surgery. *Journal of Neurosurgery: Spine*, 2017, vol. 26, no 1, p. 90-96.
- [2] LAROVERE, Kerri L. et O'BRIEN, Nicole F. Transcranial Doppler sonography in pediatric neurocritical care: A review of clinical applications and case illustrations in the pediatric intensive care unit. *Journal of Ultrasound in Medicine*, 2015, vol. 34, no 12, p. 2121-2132
- [3] 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.
- [4] BENOUDJIT, Nabil, FERROUDJI, Karim, BAHAZ, Mohamed, et al. In vitro microemboli classification using neural network models and RF signals. *Ultrasonics*, 2011, vol. 51, no 3, p. 247-252.
- [5] GUELDICH, Majdi, PISCITELLI, Mariantonietta, DERBEL, Haytham, et al. Floating thrombus in the ascending aorta revealed by peripheral arterial embolism. *Interactive cardiovascular and thoracic surgery*, 2020, vol. 30, no 5, p. 762-764.
- [6] COUTURAUD, Francis, BERTOLETTI, Laurent, PASTRE, Jean, et al. Prevalence of pulmonary embolism among patients with COPD hospitalized with acutely worsening respiratory symptoms. *JAMA*, 2021, vol. 325, no 1, p. 59-68.
- [7] GIRAULT, J.-M., MÉNIGOT, Sébastien, et GUIBERT, Benoît. Détection automatique de micro-embolies cérébrales grâce à un nouveau détecteur de variance conditionnelle. *IRBM*, 2012, vol. 33, no 3, p. 217-222.
- [8] NIJK, P. D., VAN REES VELLINGA, T. P., VAN LIESHOUT, J. M., et al. Diving accident-induced arterial gas embolism. *Nederlands tijdschrift voor geneeskunde*, 2017, vol. 161, p. D1459-D1459.
- [9] PADAYACHEE, T. S., PARSONS, S., THEOBOLD, R., et al. The detection of microemboli in the middle cerebral artery during cardiopulmonary bypass: a transcranial Doppler ultrasound investigation using membrane and bubble oxygenators. *The Annals of thoracic surgery*, 1987, vol. 44, no 3, p. 298-302.
- [10] BRUCHER Rainer and RUSSELL David. Automatic online embolus detection and artifact rejection with the first multifrequency transcranial Doppler. *Stroke*, 2002, vol. 33, no 08, p. 1969-1974.
- [11] ROY Emmanuel, MONTRÉSOR Silvio, ABRAHAM Pierre, and SAUMET JeanLouis. Spectrogram analysis of arterial Doppler signals for off-line automated HITS detection. *Ultrasound in medicine & biology*, 1999, vol. 25, no 03, p. 349-359.

- [12] LUI Ping-Wing, CHAN Brent CB, CHAN Francis HY, POON Paul WF, WANG Hsin, and LAM FK. Wavelet analysis of embolic heart sound detected by precordial Doppler ultrasound during continuous venous air embolism in dogs. *Anesthesia & Analgesia*, 1998, vol. 86, no 02, p. 325-331.
- [13] GIRAULT J-M, KOUAMÉ Denis, OUAHABI Abdeldjalil, and PATAT Frédéric. Microemboli detection: an ultrasound Doppler signal processing viewpoint. *IEEE Transactions on biomedical Engineering*, 2000, vol. 47, no 11, p. 1431-1439.
- [14] AYDIN Nizamettin, MARVASTI Farrokh, and MARKUS Hugh S. Embolic Doppler ultrasound signal detection using discrete wavelet transform. *IEEE Transactions on Information Technology in Biomedicine*, 2004, vol. 08, no 02, p. 182-190.
- [15] PALANCHON Peggy, BOUAKAZ Ayache, KLEIN Jan, and De JONG Nico. Multifrequency transducer for microemboli classification and sizing. *IEEE transactions on biomedical engineering*, 2005, vol. 52, no 12, p. 2087-2092.
- [16] BECATTINI Cecilia, AGNELLI Giancarlo, LANKEIT Mareike, MASOTTI Luca, PRUSZCZYK Piotr, CASAZZA Franco, VANNI Simone, NITTI Cinzia, KAMPHUISEN Pieter, and VEDOVATI Maria Cristina. Acute pulmonary embolism: mortality prediction by the 2014 European Society of Cardiology risk stratification model. *European Respiratory Journal*, 2016, vol. 48, no 03, p. 780-786.
- [17] VALTON Luc, LARRUE Vincent, LE TRAON Anne Pavy, MASSABUAU Pierre, and GÉRAUD Gilles. Microembolic signals and risk of early recurrence in patients with stroke or transient ischemic attack. *Stroke*, 1998, vol. 29, no 10, p. 2125-2128.
- [18] TELMAN G, SPRECHER E, and KOUPERBERG E. Potential relevance of lowintensity microembolic signals by TCD monitoring. *Neurological Sciences*, 2011, vol. 32, no 01, p. 107-111.
- [19] VUKOVIĆ Vlasta, LOVRENČIĆ-HUZJAN Arijana, and DEMARIN Vida. Microembolus Detection by Transcranial Doppler Sonography. Technical and Clinical Aspects. *Acta Clinica Croatica*, 2005, vol. 44, no 01, p. 33-45.
- [20] FERROUDJI Karim, BENOUDJIT Nabil, and BOUAKAZ Ayache. An automated microemboli detection and classification system using backscatter RF signals and differential evolution. *Australasian Physical & Engineering Sciences in Medicine*, 2017, vol. 40, no 01, p.85-99.
- [21] TRANQUART, François, BOUAKAZ, Ayache, et CORREAS, Jean-Michel. *Echographie de contraste : méthodologie et applications cliniques*. Livre. Springer, 2007.
- [22] AYDIN Nizamettin, PADAYACHEE Soundrie, and MARKUS Hugh S. The use of the wavelet transform to describe embolic signals. *Ultrasound in medicine & biology*, 1999, vol. 25, no 06, p. 953-958.
- [23] ABIODUN, Oludare Isaac, JANTAN, Aman, OMOLARA, Abiodun Esther, et al. State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 2018, vol. 4, no 11, p. e00938.

- [24] TOUZET, Claude. Les réseaux de neurones artificiels, introduction au connexionnisme. Livre. Collection de l'EERIE. 1992.
- [25] 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.
- [26] ERTUĞRUL, Ömer Faruk. A novel type of activation function in artificial neural networks: Trained activation function. *Neural Networks*, 2018, vol. 99, p. 148-157.
- [27] 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.
- [28] WANTO, Anjar, ZARLIS, Muhammad, HARTAMA, Dedy, et al. Analysis of Artificial Neural Network Backpropagation Using Conjugate Gradient Fletcher Reeves in the Predicting Process. In : *Journal of Physics: Conference Series*. IOP Publishing, 2017. p. 012018.
- [29] YOSHIDA, Yuki, KARAKIDA, Ryo, OKADA, Masato, et al. Statistical mechanical analysis of online learning with weight normalization in single layer perceptron. *Journal of the Physical Society of Japan*, 2017, vol. 86, no 4, p. 044002.
- [30] KWON, Kinam, KIM, Dongchan, et PARK, HyunWook. A parallel MR imaging method using multilayer perceptron. *Medical physics*, 2017, vol. 44, no 12, p. 6209-6224.
- [31] CASTRO, Wilson, OBLITAS, Jimmy, SANTA-CRUZ, Roberto, et al. Multilayer perceptron architecture optimization using parallel computing techniques. *PloS one*, 2017, vol. 12, no 12, p. e0189369.
- [32] MOHAMMADI, Javad, ATAIEI, 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.
- [33] 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..
- [34] 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
- [35] SCHWENKER, Friedhelm, KESTLER, Hans A., et PALM, Günther. Unsupervised and supervised learning in radial-basis-function networks. In: *Self-Organizing neural networks*. Physica, Heidelberg, 2002. p. 217-243.
- [36] 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.

- [37] ZHANG, Dengsheng. Wavelet transform. In : Fundamentals of Image Data Mining. Springer, Cham, 2019. p. 35-44.
- [38] HAND, David J. Principles of data mining. Drug safety, 2007, vol. 30, no 7, p. 621-622.
- [39] ERIŞTI Hüseyin, UÇAR Ayşegül, and DEMİR Yakup. Wavelet-based feature extraction and selection for classification of power system disturbances using support vector machines. Electric power systems research, 2010, vol. 80, no 07, p. 743-75
- [40] BERRAR, Daniel. Cross-validation. Encyclopedia of bioinformatics and computational biology, 2019, vol. 1, p. 542-545.