

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE

Ministère de l'Enseignement Supérieur et de la Recherche
Scientifique



École Nationale Polytechnique
Département d'Electronique
Laboratoire Signal et Communication



Mémoire En vue de l'obtention du
diplôme master en Electronique

Etudié par :
ACHAIBOU Amina

Thème :

**Systemes de classification des signaux
biomédicaux EEG basé sur l'énergie
d'ondelettes relative, l'entropie relative et
les réseaux de neurones**

Soutenu devant le jury composé de :

Mourad HDADI
Hicham BOUSBIA-SALAH
Assya BOUSBIA- SALAH
Mourad ADNANE

président du jury
promoteur
co-promoteur
examinateur

septembre 2014

ملخص:

في هذا العمل، اقترحنا طريقة للتصنيف التلقائي لإشارات التخطيط الدماغى إلى مجموعتين (أشخاص مرضى وآخرون عاديون). وفي هذا السياق، مجموعة من الميزات الإحصائية استخرجت من معاملات الموجات (DWT) ولقد تم استعمال شبكة العصبونات الاصطناعية للتصنيف.

الكلمات المفتاحية: EEG, DWT,FFBPNN

Abstract:

In this work, we have proposed different methods of automatic classification of EEG signals that are classified into two classes: normal and epileptic subjects. In this study, statistical characteristics were computed from (DWT) coefficients. Finally, we have used neural network FFBPNN to classify EEG signals.

Key word: EEG, DWT,FFBPNN

Résumé :

Dans ce travail, nous avons proposé plusieurs méthodes de classification automatique de signaux EEG en cas normaux et cas épileptiques. Dans ce cadre, des caractéristiques statistiques ont été extraites à partir des coefficients de (DWT). Enfin, on a utilisé les réseaux de neurones pour la classification.

Mots clés : EEG, DWT, FFBPNN

Sommaire

Introduction.....	03
1. L'Electroencéphalogramme (EEG).....	04
1.1.Exploration de l'activité électrique cérébrale.....	04
1.2.Historique d'électroencéphalogramme (EEG).....	04
1.3.Définition (Utilité des Electroencéphalogrammes).....	05
1.4.Les ondes d'EEG et leurs significations pratiques.....	06
1.5.L'acquisition des signaux EEG.....	08
1.6.Prétraitement des signaux EEG.....	09
1.7.Chaîne de traitement des signaux EEG.....	09
2. Théorie de la transformée en ondelettes.....	10
2.1.Théorie de la transformée en ondelettes.....	10
2.2.Implémentation de la Transformée en Ondelettes.....	13
2.3.Multi résolution.....	14
3. Extraction des paramètres statistiques.....	15
3.1.Paramètres caractéristiques statistiques.....	15
3.2.Paramètres caractéristiques non statistiques.....	16
4. Classification.....	17
4.1. Notion d'apprentissage.....	17
4.2. Notion de classification.....	18
4.3. Les réseaux de neurones artificiels.....	19
5. Performances de classification.....	25
5.1. Précision.....	25
5.2. Sensibilité.....	25
5.3. Spécificité.....	25
5.4. Taux d'erreur.....	26
6. Résultats et discussions.....	26
6.1. Phase de prétraitement (application de la DWT aux signaux EEG).....	27
6.2. Phase d'extraction des paramètres caractéristiques.....	30
6.3. Phase de la classification (par les réseaux neurones).....	34
7. Conclusion.....	37
Annexe A.....	39
Annexe B.....	40
Bibliographie.....	41

Dédicace

*Je dédie ce travail à mes parents,
à mes frères,
à tous les membres de ma famille,
et à tous mes amis.*

Introduction

Dans ce travail, on a proposé une technique de détection des troubles d'épilepsie à travers les signaux d'électroencéphalogramme (EEG) en utilisant la transformée en ondelettes discrète (DWT) pour le prétraitement et les réseaux de neurones pour la détection.

L'EEG est une technique qui permet d'identifier les troubles neurologiques comme l'épilepsie. Dans la plupart des cas, l'identification professionnelle se fait manuellement, ce qui rend la tâche plus difficile lors de la présence d'une grande base de données d'où il est nécessaire de trouver une méthode qui facilite la détection. Dans ce travail, on a proposé un processus automatique pour identifier les patients portant des troubles épileptiques ou non. Et pour cela, on a utilisé la transformée en ondelettes pour l'extraction de caractéristiques et la génération des paramètres statistiques via les coefficients de décomposition en ondelettes. Ainsi les réseaux de neurones (ANN) à algorithme de réaction positive sont utilisés pour la classification.

Ce mémoire est structuré comme suit :

La première partie décrit l'électroencéphalographie (EEG) et ses différents rythmes (définition, acquisition, prétraitement)

La seconde partie est consacrée à l'étude de l'une des principales techniques d'analyse temps-fréquence : la transformée en ondelettes et la description succincte des ondelettes utilisées pour l'analyse des signaux électroencéphalographiques.

La troisième partie décrit les différents paramètres caractéristiques extraits par les coefficients d'ondelettes.

Dans la quatrième section, on présentera la méthode de classification automatique supervisée telle que les réseaux de neurones (FFBPNN).

La cinquième partie illustre les tests et résultats obtenus : le calcul des performances et l'évaluation statistique des résultats de classification et en terminera par une conclusion qui résume toute la procédure de ce travail.

1. L'Electroencéphalogramme(EEG)

1.1 Exploration de l'activité électrique cérébrale

Il existe plusieurs types de modalités pour explorer les activités cérébrales, la figure 1.1 [1] illustre la variabilité des résolutions temporelles et spatiales parmi les méthodes d'exploration cérébrales (techniques d'imagerie et techniques électro-physiologiques). En principe ces méthodes peuvent être groupées en deux classes : l'imagerie et l'exploration électro-physiologique. Nous citons plus particulièrement les méthodes électro-physiologiques, et on s'intéresse surtout à l'électroencéphalogramme (EEG), qui est le point de départ de notre travail. Les autres méthodes sont les suivantes : La magnétoencéphalographie (MEG), l'EEG invasive qui est la stéréo électroencéphalographie (SEEG) et l'électro-corticographie (ECoG).

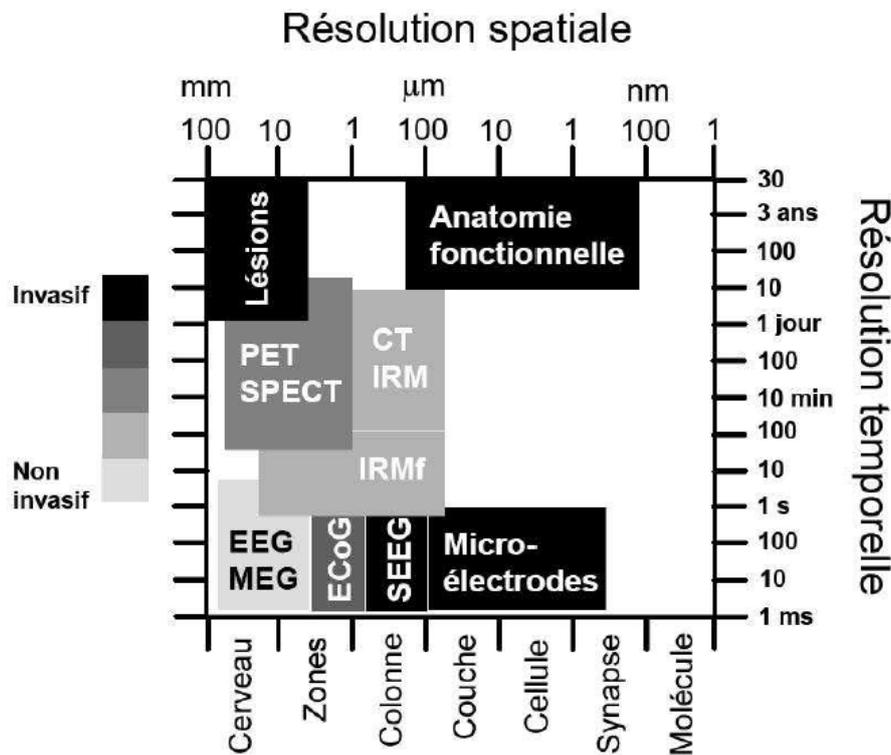


Figure 1.1:Schéma comparatif des résolutions temporelles et spatiales et du caractère invasif des différentes techniques d'imagerie cérébrale (EEG, IRM, IRMf, MEG, SEEG, TDM, TEMP, TEP)[1]

1.2 Historique d'électroencéphalogramme (EEG)

L'invention de l'électroencéphalographie est généralement attribuée au physiologiste allemand Hans Berger, qui commença à l'étudier dans les années 1920 et enregistra le premier signal d'activité cérébrale en 1929. Ses travaux furent repris et complétés par le britannique Edgar

Douglas Adrian, qui obtient en 1932 le prix Nobel de physiologie. L'EEG ne s'est vraiment développé et répandu dans la pratique médicale courante, en particulier dans la pratique épileptologique, que dans les années 1950.

Historiquement les courbes d'EEG étaient tracées sur des rouleaux de bandes de papier millimétré afin d'être relues ensuite par les médecins neurologues pour y déceler d'éventuels signes. Aujourd'hui, le signal est numériquement converti et traité par ordinateur.

Le développement de l'EEG en clinique date de l'apparition des amplificateurs différentiels au début des années 1960. Les EEG sont actuellement utilisés afin de diagnostiquer des foyers épileptiques, des tumeurs cérébrales, des lésions. Ils permettent aussi de trouver l'origine de migraines, de problèmes d'étourdissements, ou de somnolence.

1.3 Définition (Utilité des Electroencéphalogrammes)

L'électroencéphalogramme (EEG) est un examen qui enregistre l'activité électrique du cerveau en utilisant une technique non invasive pour mesurer les courants générés par les cellules nerveuses (neurones). Il est considéré comme le moyen le plus utilisé pour mettre en évidence l'activité électrique du cerveau, et particulièrement l'activité épileptique proprement dite. Comparé aux autres techniques d'investigation, L'EEG fournit des informations en temps réel et avec une très bonne résolution temporelle, de l'ordre de la milliseconde (figure 1.1). Il demeure incontournable pour le diagnostic et la classification des épilepsies. Berger a mis cela en évidence chez l'être humain en 1924 [2].

L'EEG est le résultat d'une différence de potentiel mesurée entre deux points. L'enregistrement entre deux points se fait grâce à des électrodes placées sur le cuir chevelu.

La (figure 1.2) présente un exemple d'un enregistrement d'EEG. Ces potentiels varient au cours du temps et forment des rythmes. La morphologie des tracés dépend de l'état d'activation des neurones enregistrés et cet état d'activation va se traduire par des variations de fréquence et d'amplitude des ondes enregistrées.

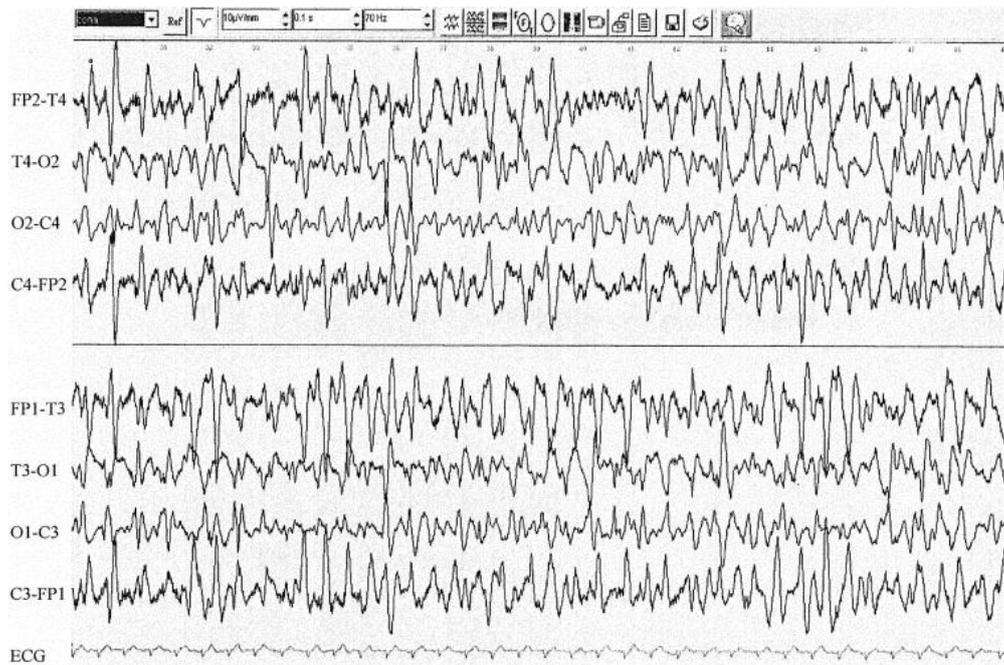


Figure 1.2 : Exemple d'un enregistrement des signaux EEG.

1.4 Les ondes d'EEG et leurs significations pratiques

Un rythme cérébral désigne une oscillation électromagnétique dans une bande de fréquences donnée, résultant de de l'activité électrique cohérente d'un grand nombre de neurones du cerveau telle que observé en électroencéphalographie (EEG).

Les caractéristiques des rythmes cérébraux dépendent de l'individu selon l'état psychologique, pathologique ou normal, et son enregistrement nous permet de caractériser des maladies neurologiques, telle que l'épilepsie. Ces rythmes cérébraux sont classés selon leur fréquence en 5 groupes : delta (0.5–4Hz), thêta (4–8Hz), alpha (8–13Hz), bêta (13–30Hz) et gamma (supérieur à 30Hz) [3].

- **Les ondes alpha** : ont une fréquence de 8 à 13 Hz et une amplitude qui varie entre 30 jusqu'à 50 μ V. Elles se rencontrent principalement dans les régions occipito-pariétales [5]. Elles apparaissent dans l'EEG de presque tous les individus normaux en état de veille ou au repos les yeux fermés. Elles disparaissent complètement pendant le sommeil. Elles caractérisent un **état de conscience** apaisé que l'on retrouve particulièrement lors d'une méditation légère ou d'une séance de relaxation.

- **Les ondes bêta** : ont une fréquence de 14 à 30 Hz, d'amplitude faible inférieure à $20\mu\text{V}$, occupent les régions moyennes des deux hémisphères souvent de manière asynchrone. Elles apparaissent généralement lorsque le système nerveux est actif et sont donc associées à la stimulation sensorielle et à l'activité mentale. Elles sont présentes particulièrement en période d'activité intense, de concentration ou d'anxiété. Comme elles peuvent être masquées par les rythmes alpha qui sont plus énergétiques.

- **Les ondes thêta** : ont une fréquence de 4 à 7 Hz et une amplitude de 10 à $50\mu\text{V}$. Elles se forment suite à l'interaction entre les populations du cortex et de l'hippocampe [6]. Elles se rencontrent surtout sur les régions temporales dans certaines fonctions cognitives et lors de l'endormissement [7].

- **Les ondes gamma** : ces ondes sont un type d'occurrence plus rare qui ont une amplitude très faible et une fréquence variant entre 20 Hz et 60 Hz, elles sont associées à des fonctions motrices et cognitives (perception, raisonnement, langage, mémoire). La détection de ces rythmes peut être employée pour la confirmation de certaines pathologies.

- **Les ondes delta**

Les ondes delta se situent dans la gamme de 0,5 à 4 Hz, avec des amplitudes variables. Elles sont principalement associées à un sommeil profond, et à l'état de veille.

- **Les ondes de types μ** : ou rythme en arceaux, sont une particularité du rythme alpha [5]. Elles sont retrouvées dans les basses fréquences de l'alpha et sont observées principalement dans les zones centrales lors de l'exécution d'un mouvement. Elles sont considérées comme étant caractéristiques du rythme alpha moteur.

La figure 1.3 illustre les principaux rythmes de l'activité cérébrale.

Pour les rythmes delta et thêta (les ondes lentes), peuvent témoigner d'un processus pathologique lésionnel ou fonctionnel sous-jacent. Dans les épilepsies partielles, elles sont fréquentes et souvent localisées dans la même région que le foyer épileptique inter-critique (les ondes thêta et delta sont largement présentes lors des variations du niveau de vigilance et, dans ces conditions, leur apparition n'est pas pathologique).

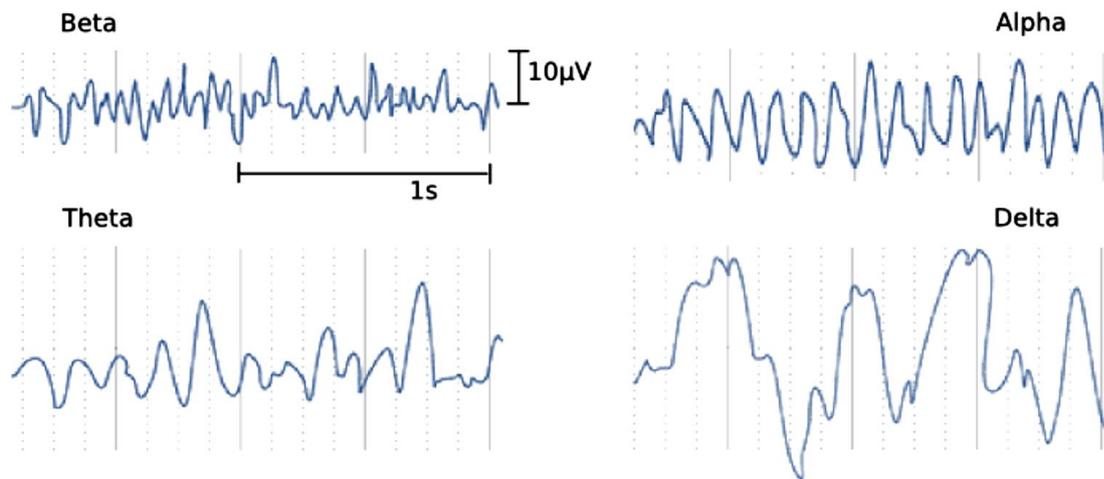


Figure 1.3 : les rythmes corticaux [1]

1.5 L'acquisition des signaux EEG

L'obtention d'un signal EEG comporte plusieurs étapes en utilisant un matériel d'acquisition. Il est composé de.

- Un bonnet d'électrodes pour capter l'activité électrique,
- une tête, boîte d'entrée des connecteurs reliés aux électrodes du casque,
- un amplificateur afin d'amplifier les signaux EEG qui sont de l'ordre du microvolt,
- un filtre analogique coupe-bande de 50Hz permettant la suppression des parasites dus au courant électrique,
- un convertisseur analogique numérique, il faut alors respecter le théorème de Shannon pour le choix de la fréquence d'échantillonnage. La période d'échantillonnage temporel est classiquement entre 0.5ms et 2ms, c'est-à-dire 2000 à 500 points par seconde et par électrode, ce qui d'après Shannon permet d'enregistrer des signaux de fréquence de 1000 à 250Hz,
- un système de visualisation et d'écriture sur disque.

L'ensemble de ces éléments est représenté sur la (figure 1.4).

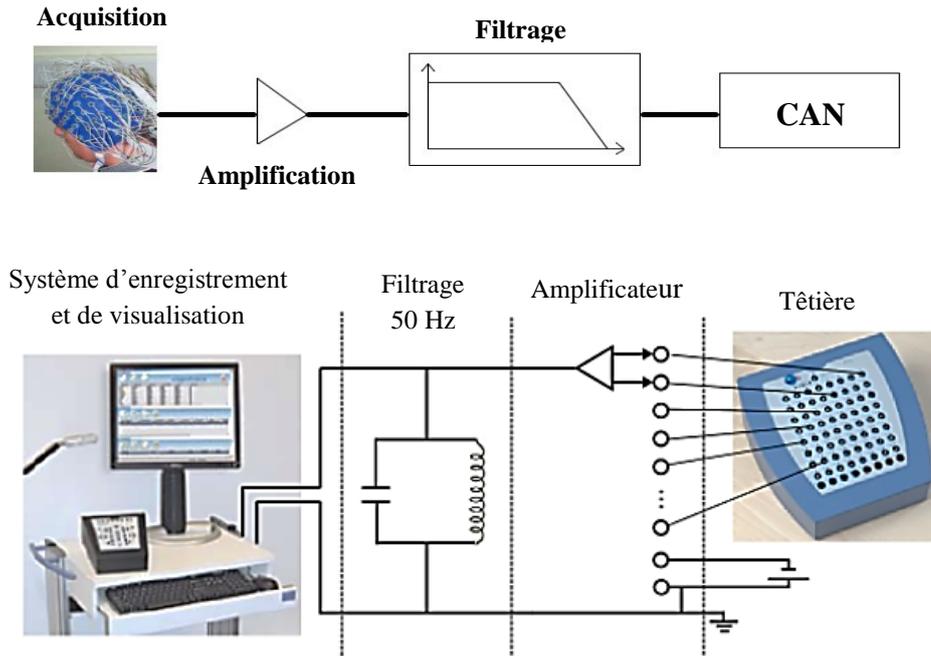


Figure 1.4 : Acquisition du signal EEG.

1.6 Prétraitement des signaux EEG

Pendant l'enregistrement des signaux d'électroencéphalogramme, différents types de bruits d'origines diverses peuvent être superposés au signal d'origine. Le prétraitement des signaux EEG s'impose pour l'extraction du signal utile, à partir du signal noyé dans le bruit.

Différentes méthodes peuvent être appliquées dans le domaine temporel, fréquentiel ou temps-fréquence.

Dans notre cas, nous allons développer et appliquer une méthode de décomposition et de filtrage en même temps en se basant sur la théorie des ondelettes.

1.7 Chaîne de traitement des signaux EEG

La chaîne typique de traitement des signaux, en particulier les EEG, est composée des phases suivantes:

- prétraitement ou conditionnement des données,
- Transformation, c'est la phase la plus délicate de la chaîne puisque le signal subit une série de transformation afin de le préparer à l'étape de prise de décision.
- Décision.

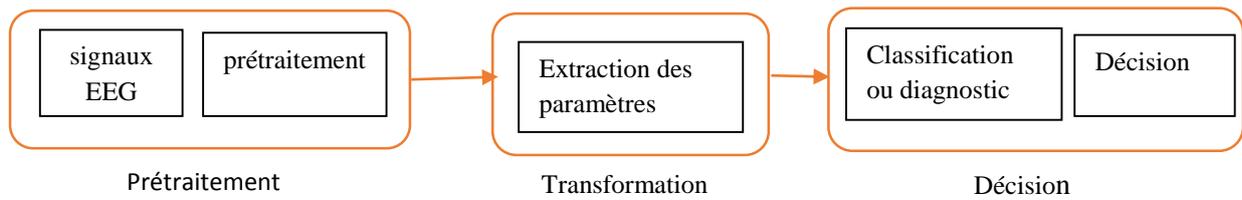


Figure 1.5 : chaîne de traitement automatique des signaux EEG

2. La transformée en ondelettes (outils de Traitement des Electroencéphalogrammes)

L'étude de l'activité cérébrale nécessite une analyse quantitative des oscillations codant le transfert de l'information d'une population neuronale à une autre. Ces oscillations, enregistrées au moyen d'EEG, sont des événements transitoires, imprévisibles même statistiquement. Une analyse des variations fréquentielles permettrait de décrire ces événements.

2.1. Théorie de la transformée en ondelettes

2.1.1. Introduction

En traitement du signal, le Temps et la Fréquence constituent les deux principaux domaines de représentation de l'information. L'outil de base est la Transformée de Fourier (TF) qui a joué un grand rôle dans le domaine de traitement du signal. Cette transformation, propose une analyse globale du signal mais ne représente aucune notion de localisation temporelle. Pour cela, les scientifiques ont introduit la T.F. à fenêtre glissante dans le temps mais cette extension a rencontré encore des problèmes car une fois la fenêtre choisie, la résolution en temps et en fréquence est fixée. D'où la naissance de la Transformée en Ondelettes comme solution pour la non satisfaction de la transformée de Fourier. Elle est couramment utilisée dans différents domaines du traitement de signal, incluant l'analyse de l'image et de parole et ainsi que diverses applications dans le domaine biomédical.

Cette transformation permet de minimiser les pertes d'information dans le cas de transmission (compression) ou de débruitage des signaux (filtrage).

2.1.2. la transformée en ondelettes continus

Dans cette section, nous rappelons brièvement la formulation de la Transformation en Ondelettes continue pour l'analyse d'un signal.

La Transformation en Ondelettes continue (CWT) d'un signal $f(t)$ correspond au calcul de l'intégrale suivante.

$$Wf(u, s) = \langle f, \psi_{u,s} \rangle = \int_{-\infty}^{+\infty} f(t) \frac{1}{\sqrt{s}} \psi^* \left(\frac{t-u}{s} \right) dt \quad (1)$$

Avec $\psi_{u,s}(t)$ est l'ondelette mère définie par :

$$\psi_{u,s}(t) = \frac{1}{\sqrt{s}} \psi \left(\frac{t-u}{s} \right) \quad (2)$$

Les paramètres de translation u et de dilatation s sont les deux arguments de la transformée en Ondelettes.

$Wf(u, s)$ sont les coefficients de la TO qu'on peut interpréter comme la projection du signal $f(t)$ sur la famille de vecteurs ψ

L'emploi de la CWT souffre de la redondance, ainsi l'utilisation des algorithmes rapides sont nécessaires pour appliquer cette Transformation.

2.1.3. Condition d'application :

La fonction ondelette $\psi(t)$ doit vérifier les propriétés mathématiques suivantes :

- Fonction à énergie finie, $E = \int_{-\infty}^{+\infty} |\psi(t)|^2 dt < \infty$
- Condition d'admissibilité, $C_\psi = \int_0^{+\infty} \frac{|\hat{\psi}(f)|^2}{f} df < \infty$

Autrement dit $\hat{\psi}(0) = 0$ ou $\hat{\psi}(f) = TF(\psi(t))$

- Et ayant un nombre n de moment nuls $\int_{-\infty}^{+\infty} t^k \psi(t) dt = 0$ pour $0 \leq k < n$

Le degré de décroissance d'une ondelette est décrit par le nombre de moments nuls.

2.1.4. Localisation temps- fréquence

La propriété de localisation temps- fréquence est limitée par le théoreme d'incertitude de Heisenberg suivant :

Si f est fonction dans L^2 , alors on peut définir l'écart type σ_t en temps et l'écart type σ_w en fréquence de sa transformée de fourier. Ces paramètres vérifient l'inégalité suivante :

$$\sigma_t^2 \sigma_w^2 \geq \frac{1}{4}$$

On est donc contraint à un compromis entre résolution temporelle et résolution fréquentielle.

Dans le cas limite de sinusoïde, σ_w est nul et σ_t est infini.

En tenant compte du principe d'incertitude, il est donc impossible d'avoir une fonction L^2 qui soit à support compact en temps et en fréquence, la localisation en temps- fréquence n'est donc atteignable qu'en écart type.

Pour qu'une famille de vecteurs forme une base de L^2 , il est raisonnable de s'attendre à ce que leurs boîtes Heisenberg recouvrent le plan temps-fréquence.

2.1.5. Boite de Heisenberg

On représentera la « localisation temps-fréquence » d'une fonction de base sous la forme d'une « boîte de Heisenberg », située dans le plan temps-fréquence (figure 2.1), qui est un rectangle de dimensions σ_t et σ_ω , centré sur le point de coordonnées (u, ξ) .

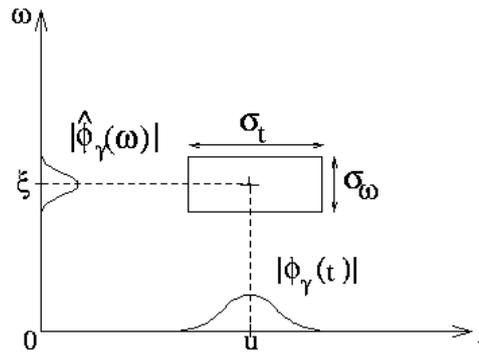


Figure 1.6 : Boite de Heisenberg

2.1.6. Transformation en Ondelettes Discrètes

La forme discrète de la CWT, décrite par l'équation (1), est la transformée en Ondelettes Discrète DWT suivante :

$$Wf(u, s) = \sum_{n=0}^{N-1} f(n) \psi_{u,s}(n) \quad (3)$$

Si on adopte la résolution temps fréquence, à l'aide de DWT un signal échantillonné est décomposé en composantes basse et haute fréquences.

Pour $s = 2^j$, et $u = k2^j$, les nouveaux paramètres du pavage du plan temps fréquence sont j et k ou j indique le niveau de résolution. L'équation (2) devient

$$\psi_{i,j} = 2^{-\frac{j}{2}} \psi(2^j t - k) \quad (4)$$

En utilisant la WT orthogonale, on peut reconstruire le signal original $f(t)$ à partir des coefficients de la $Wf(j,k)$.

2.2. Implémentation de la Transformée en Ondelettes

La transformée en ondelettes se calcule par des algorithmes rapides. Ceux-ci effectuent une transformation discrète par des convolutions circulaires, elles-mêmes calculées par FFT.

Parmi les principaux algorithmes employés pour calculer une étape de décomposition de DWT sont le banc des filtres et le schéma de Lifting, dans notre cas, on va présenter la première méthode qui convient à notre étude.

2.2.1. Algorithme de Mallat composé d'un banc de filtre (MBF)

L'algorithme de Mallat à base de banc de filtres (MBF) est l'algorithme standard de DWT.

La figure 2 illustre une étape de décomposition de cet algorithme en utilisant un filtre passe bas $h(n)$ et un filtre passe haut $g(n)$ en quadrature qui représente la fonction d'échelle $\varphi(t)$ et l'ondelette $\psi(t)$ respectivement, suivi d'une étape de sous échantillonnage.

En fait c'est ici qu'interviennent les ondelettes puisqu'à chaque paire de filtres sont associées une ondelette et une fonction d'échelle.

La décomposition d'un signal par la transformée en ondelettes est alors réalisable au moyen d'un banc de filtre à réponse impulsionnelle finie à 2 canaux, a_n^{j+1} itérée sur la bande basse fréquence (figure 2.2).

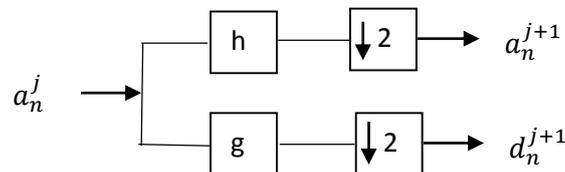


Figure 2.2 : décomposition par banc de filtre

A l'étape j les signaux décomposés sont :

- Les coefficients d'échelle (ou l'approximation) a_n^{j+1} de l'entrée a_n^j dont le signal reconstruit A_j constitue la composante de basse fréquence.

$$a_n^{j+1} = \sum_m h(2n - m)a_n^j(5)$$

- Les coefficients d'ondelette (ou le détail) d_n^{j+1} de l'entrée a_n^j dont le signal reconstruit D_j constitue la composante de haute fréquence.

$$d_n^{j+1} = \sum_m g(2n - m)a_n^j(6)$$

Pour ne pas perdre d'information, ces deux filtres doivent être complémentaires ; les fréquences coupées par l'un doivent être conservées par l'autre. On dit que les deux filtres forment une paire de filtres miroirs en quadrature.

Les filtres d'ondelettes g et h vérifient la relation suivante :

$$g(L - 1 - n) = (-1)^n h(n)$$

Avec L : la taille du filtre (nombre de coefficients).

n : l'indice indiquant le coefficient du filtre, considéré.

2.3. Multi résolution

Plus de niveaux de décomposition peuvent être obtenus en réitérant la démarche sur les signaux basse fréquence : c'est l'analyse multi résolution illustrée par la figure (2.3). Cette analyse sert à produire par filtrage et décimation successifs une série de signaux correspondants à une résolution de plus en plus fine.

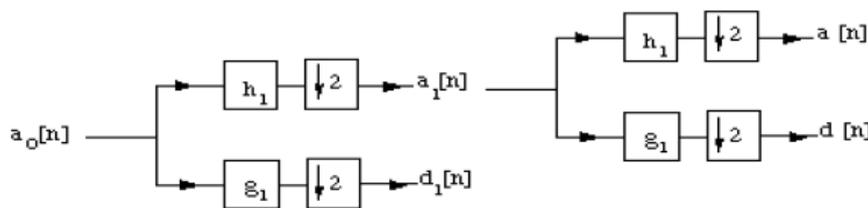


Figure 2.3 : analyse de multi résolution (décomposition)

Le résultat de cette procédure est un ensemble des signaux transformés à bandes de fréquence réduites. Ainsi, le traitement par ondelette peut être vu comme un ensemble de filtre passe bande de mêmes largeurs dans une échelle logarithmique comme le montre la figure (2.4)

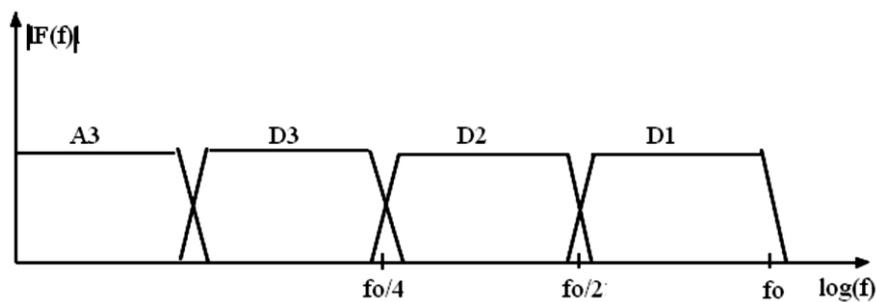


Figure 2.4 : Représentation fréquentielle des coefficients D_i

En allant des échelles les plus grossières vers les échelles les plus fines, on accède à des représentations de plus en plus précises du signal décomposé. L'analyse s'effectue en calculant la différence entre échelles, c'est-à-dire les détails à une résolution donnée.

3. Extraction des paramètres statistiques :

L'utilisation des signaux EEG pour identifier les tâches mentales et détecter les différentes pathologies en particulier l'épilepsie repose sur deux points clés : l'extraction des paramètres caractéristiques et la classification [33].

L'extraction est l'étape qui suit la décomposition, elle vise à décrire les signaux EEG par quelques valeurs pertinentes appelées « caractéristiques », ces ensembles des caractéristiques sont des fonctions soit statistiques ou non statistiques elles sont calculés pour chaque niveau de décomposition (chaque sous bande).

3.1. Paramètres caractéristiques statistiques

- **La variance** : la variance est définie comme une mesure de la dispersion d'un ensemble de points de données X_i autour de leur valeur moyenne, elle est définie comme suit :

$$y = \frac{\sum(X-\mu)^2}{n} \quad (3.3)$$

Où : μ est la moyenne de l'ensemble X_i , n est le nombre d'échantillons.

- **La densité spectrale de puissance (DSP)** : C'est la quantité d'énergie par unité de fréquence. L'intégrale de la DSP sur une bande de fréquence donnée calcule la puissance moyenne du signal sur cette bande de fréquence. La DSP est calculée par le module au carré de la transformée de Fourier de la série temporelle du signal :

$$S = |X|^2/T \quad (3.4)$$

Où : X est la transformée de Fourier d'un signal $x(t)$

Les valeurs maximum et minimum estimées à partir de DSP de chaque sous-bande du signal peuvent être considérées comme des caractéristiques pour la classification.

- **Le maximum** : Traduit la plus grande valeur qu'atteint le signal.
- **Le minimum** : Traduit la plus petite valeur qu'atteint le signal.
- **La gamme** : Traduit la distance entre la valeur maximale et minimale du signal.

Dans cette étude ces paramètres statistiques ont été utilisés pour représenter la distribution temps-fréquence des signaux EEG

3.2. Paramètres caractéristiques non statistiques

- **Energie relative :**

L'énergie a chaque niveau de décomposition est l'énergie des coefficients d'approximation et de détail définie par les équations suivantes

$$E_j = \sum_k |D_j(k)|^2$$

$$E_{N+1} = \sum_k |A_j(k)|^2$$

Les énergies moyennes des coefficients de détail et d'approximation sont définies par les équations suivantes

$$\bar{E}_j = \frac{1}{N_j} \sum_k |D_j(k)|^2$$

$$\bar{E}_{N+1} = \frac{1}{N_j} \sum_k |A_j(k)|^2$$

Et donc l'énergie totale de signal après décomposition est obtenue par l'équation suivante

$$E_{\text{total}} = \sum_{j=1}^{N+1} \bar{E}_j \quad j = 1, \dots, N + 1$$

En effet l'énergie relative (RWE) est définie par la formule suivante

$$\rho_j = \frac{\bar{E}_j}{E_{\text{total}}}$$

Telle que $\sum_j \rho_j = 1$ et la distribution ρ_j représente la densité temps fréquence.

- **Entropie relative :**

WEN = $-\sum \rho_j \log \rho_j$ ou le WEN représente l'information qui caractérise la distribution énergétique du signal en chaque bande de fréquence.

Dans ce travail, on va se baser sur ces deux derniers paramètres et pour chaque niveau de décomposition on calcule ces paramètres ce qui donne pour chaque paramètre une matrice (n.m) telle que n est le nombre de niveau de décomposition et m est le nombre des signaux EEG pris en traitement,

4. Classification

4.1. Notion de classification

La classification est l'une des techniques les plus utilisées en médecine. Elle constitue le principe de base de plusieurs systèmes d'aide au diagnostic.

La classification est une opération de structuration qui vise à organiser un ensemble d'observation en groupes homogènes et contrastés afin de faciliter l'analyse des informations et d'effectuer des prédictions [9]. Il s'agit donc dans notre cas d'affecter un ensemble d'objets (enregistrement des encéphalogrammes) à une classe selon un descripteur de celle-ci. Cette description est effectuée grâce à des propriétés ou des conditions typiques propres aux classes. Les objets sont alors classés suivant qu'ils vérifient ou non ces conditions ou propriétés.

La classification est effectuée grâce à des propriétés ou des conditions typiques propres aux classes. Les objets sont alors classés suivant qu'ils vérifient ou non ces conditions ou propriétés. Il existe une multitude de méthodes de classification qui sont utilisées pour classer les signaux EEG parmi ces méthodes, on cite :

- ANN : Artificial Neural Network [10]
- ANFIS : Adaptive Neuro-Fuzzy Inference System [11]
- KNN: K-Nearest Neighbors classification algorithm [12]
- RBFNN : Radial Basis Function Neural Network [13]
- RNN : Recurrent Neural Network [14]
- SVM: Machine à Vecteurs Support [15]

La classification des sujets épileptiques et normaux en fonction de certains paramètres qui caractérisent leurs signaux EEG se base sur des règles d'apprentissage, c'est la notion qu'on va détailler dans le paragraphe suivant.

4.2. Notion d'apprentissage :

- **L'apprentissage artificiel**, est une branche de l'intelligence artificielle qui peut être mise à contribution pour appréhender les problèmes de prédictions [10]. On peut classer les méthodes

d'apprentissage artificiel en deux grandes familles : l'apprentissage non supervisé et l'apprentissage supervisé.

- Dans **l'apprentissage non supervisé**, l'algorithme va lui-même, sans information supplémentaire, catégoriser les variables d'entrées. Ce type d'apprentissage permet l'élaboration d'une représentation interne de l'espace des données d'entrée en identifiant une structure statistique sous-jacente des variables sous une forme plus ou moins simple.

- **L'apprentissage artificiel supervisé**, de façon générale consiste à créer un modèle de prédiction (classification ou prévision) à partir d'une base d'apprentissage comprenant les exemples d'entrée ainsi que les sorties désirées associées. Les paramètres du modèle vont ainsi s'adapter en comparant à chaque fois les sorties obtenues et les sorties désirées, d'où l'appellation supervisé [16].

Une fois le modèle obtenu par une base d'apprentissage, l'utilisation d'une base de test, comprenant des nouveaux exemples non utilisés pendant l'apprentissage, permet de mesurer les performances de la méthode.

Pour la classification des signaux EEG, classiquement, elle est réalisée par la deuxième famille.

- **L'algorithme d'apprentissage** permet de "prédire" une valeur cible étant donnée une ou des valeurs d'entrées. Dans le cas où cette valeur cible est discrète (dans un ensemble fini), la tâche réalisée par l'algorithme est appelée classification supervisée puisqu'il s'agit de trouver la classe correspondant à un exemple donné en entrée.

Soit $E = \{(X(t), y(t)) \in R^d \times R / 0 \leq t \leq N\}$ l'ensemble de données qui peut être une base d'apprentissage ou une base de test. $X(t)$ est le vecteur d'entrée à l'instant t , $X(t) \in R^d$. $y(t)$ représente la valeur cible correspondant à $X(t)$ et N le nombre d'exemples dans la base. Le but de l'algorithme d'apprentissage est de trouver une fonction f , la représentation mathématique du modèle obtenu, qui soit le plus proche possible de la fonction cible \tilde{f} . On notera que \tilde{f} reste toujours inconnue et dans de nombreux cas hypothétiques [17]. Le système pourra être évalué à la fin par l'erreur MSE :

$$MSE = \frac{1}{N} \sum_{t=0}^N (\hat{y}(t) - y(t))^2 \quad (4.1)$$

Où $\hat{y}(t)$ est la valeur prédite c'est-à-dire $f(X(t)) = \hat{y}(t)$ l'approximation de la valeur $y(t)$.

Pour la mise en œuvre de cet algorithme plusieurs méthodes ont été développées, dans ce travail, on s'intéressera à deux types de méthodes : les réseaux de neurones et les supports vecteurs machines.

4.3. Classification par les réseaux de neurones artificiels :

La première technique de classification appliquée est le réseau de neurones artificiels (RNA) qui est caractérisé par sa propriété d'approximation universelle, sa vitesse de décision et sa bonne capacité de généralisation.

4.3.1. fonctionnement général d'un réseau de neurone formel.

Un réseau de neurones artificiel est un modèle de calcul dont la conception est très schématiquement inspirée du fonctionnement des neurones biologiques. Le neurone est l'unité de traitement de base dans un réseau de neurones artificiel. Un neurone artificiel est composé des éléments suivants : les nœuds d'entrée, les connections synaptiques dont les forces sont représentées par des poids et la fonction d'activation φ qui relie toutes les entrées à la sortie de neurone.

La figure (4.6) présente le schéma d'un neurone biologique et la structure d'un neurone formelle

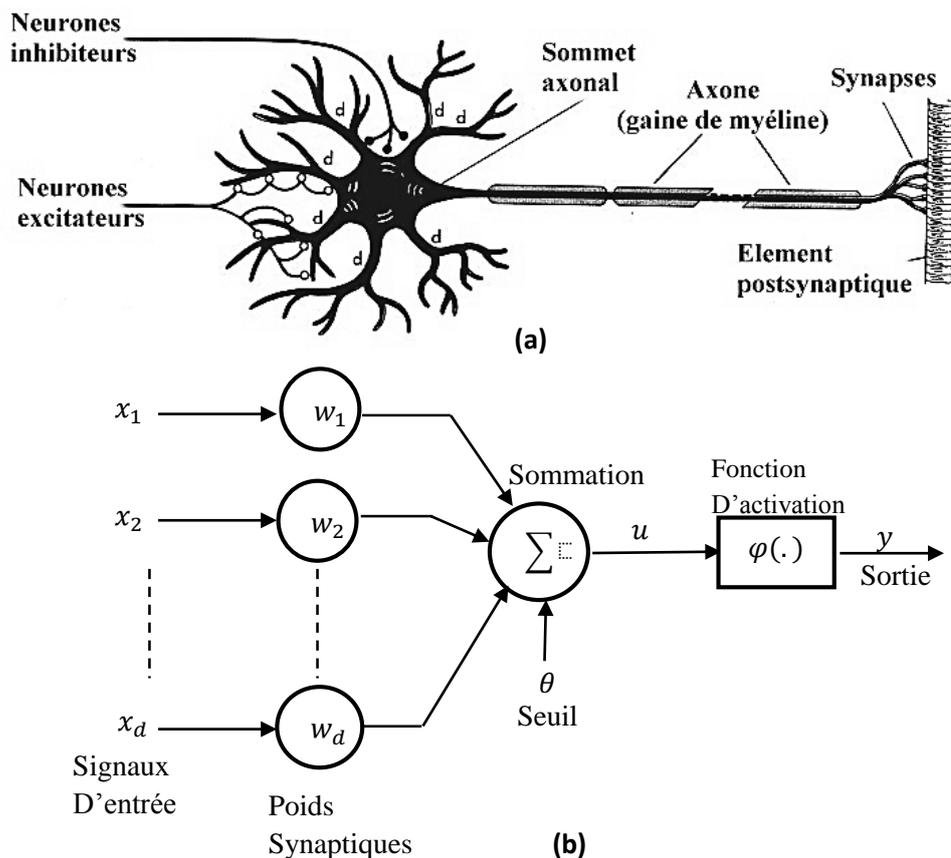


Figure 4.6 : (a) représente le neurone biologique et (b) représente la structure de base d'un neurone artificiel.

Le tableau suivant illustre la similitude existant entre le neurone biologique et le neurone formelle.

Tableau 4.1. Analogie entre les neurones biologiques et artificiels

Neurone biologique	Neurone artificiel	Représentation symbolique
Soma	Neurone	
Dendrite	Intrant (Input)	x_i ,X (intranet net)
Axone	Extrant (output)	Y
Synapse	Poids	W_i

Dans le réseau de neurones, les neurones sont fortement connectés entre eux et travaillent en parallèles. Ce neurone formel reçoit et émet des signaux binaires (0/1). La somme pondérée des signaux d'entrée, constituant l'activation du neurone, se transforme en sortie après son passage par une fonction de seuillage ou de transfert. Et donc la somme de toutes les entrées est comparée à un seuil θ . Si ce seuil est dépassé, le neurone s'active, sinon il ne transmet aucun signal [18].

Chaque neurone est une fonction non linéaire paramétrée telle que la fonction de transfert de chaque neurone est la suivante :

$$y = \varphi(u) \quad (4.24)$$

$$\text{Avec } u = \sum_{i=1}^d x_i w_i - \theta = XW - \theta \quad (4.25)$$

Où X et W sont les vecteurs d'entrée et de poids respectivement, φ est la fonction d'activation.

$X = [x_1, x_2, x_3, \dots, x_d]$: Le vecteur d'entrée

$W = [w_1, w_2, w_3, \dots, w_d]$: Le vecteur de poids

Les poids des connexions sont généralement estimés par minimisation d'un critère de moindres carrés, qui permet d'estimer les probabilités a posteriori.

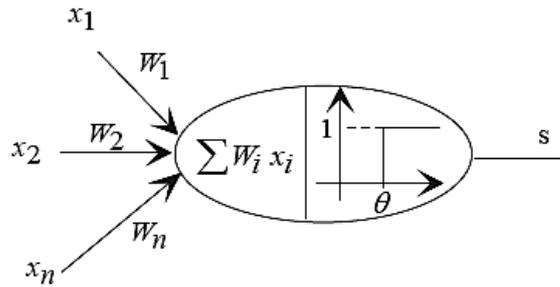


Figure 4.7 : illustration de fonctionnement de neurone biologique [18]

La fonction d'activation φ peut-être :

- La fonction signe : $\varphi(u) = \begin{cases} 1 & \text{si } u > 0 \\ -1 & \text{si } u \leq 0 \end{cases}$
- La fonction sigmoïde de paramètre λ : $\varphi(u) = \frac{1}{1+e^{-\lambda u}}$

Il y a aussi différentes autres fonctions qui peuvent être utilisées.

4.3.2. Architecteurs des réseaux de neurones.

Plusieurs types de réseaux de neurones existent. Selon la connectivité, On distingue deux grandes familles : les réseaux non bouclés et les réseaux bouclés [19].

La figure suivante représente les réseaux les plus utilisés

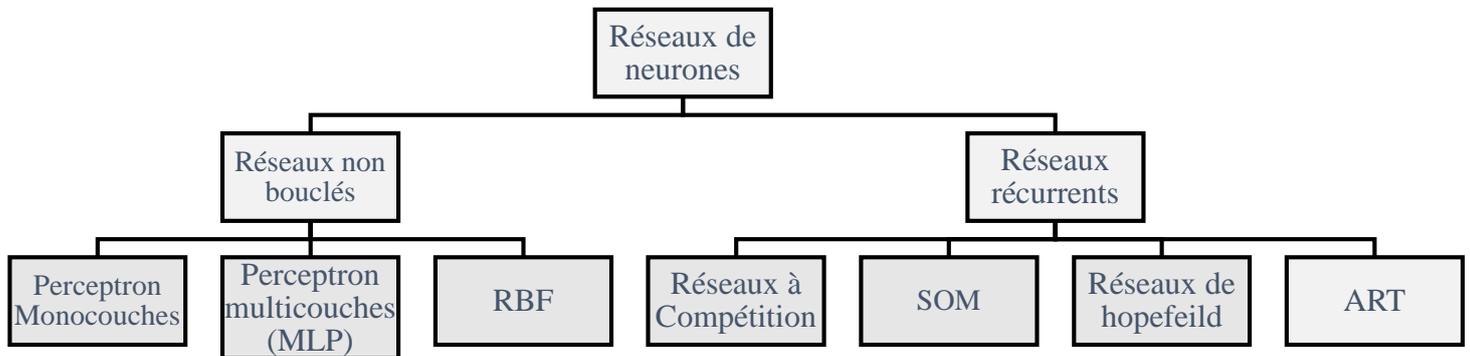


Figure 4.7 : Les réseaux les plus utilisés

La variante du réseau de neurones artificiels, qui va être appliquée dans ce travail, inclue la structure non bouclée ou ce qu'on appelle propagation directe "feedforward", à savoir le modèle de Perceptron Multicouches (MLP). Cette méthode a été utilisée par [20], [21].

4.3.3. Les réseaux « feedforward » à rétro propagation

Le FFNN est un réseau qui comprend trois variantes (MLP, PM, RBF), l'information dans ce type circule dans une seule direction, de l'entrée vers la sortie, il n'autorise pas le retour en arrière de l'information. Le temps ne joue aucun rôle fonctionnel dans un réseau de neurones non bouclé, pour cette raison, le FFNN est aussi qualifié que d'autres types de réseaux. L'algorithme d'apprentissage le plus utilisé pour les FFNN ainsi que leurs variantes est l'algorithme de la Rétro-Propagation du gradient, en anglais Back-Propagation (BP)[22]. C'est un algorithme qui est souvent utilisé dans la majorité des expériences dont le principe est de rétro-propager le gradient de l'erreur de la couche de sortie vers l'entrée.

On trouve souvent que la variante MLP est, en générale, la plus utilisée pour les applications biomédicales telles que la classification.

4.3.3.1. L'algorithme de rétro propagation

C'est un algorithme qui permet à un réseau multicouche d'apprendre par mises à jour des poids des différentes couches. Comme on va considérer des réseaux avec plus d'une unité de sortie, on va redéfinir l'erreur E :

$$E(\vec{w}) = \frac{1}{2} \sum_{d \in \text{exemples}} \sum_{k \in \text{sorties}} (\text{cible}_{kd} - \text{sortie}_{kd}) \quad (4.26)$$

De la même manière que nous avons considérée E comme une surface d'erreur pour les unités linéaires, nous allons chercher dans le cas de la rétro-propagation à minimiser la surface d'erreur avec notre nouvelle définition. Dans le cas de l'unité linéaire, nous n'avons qu'un seul extremum qui était le minimum global. Avec des unités sigmoïdes, nous allons avoir plusieurs extrema. Malheureusement, on n'est pas sûr que l'algorithme converge vers le minimum global, il peut converger vers un minimum local. En pratique cependant, la rétro-propagation donne de bons résultats.

On va décrire l'algorithme pour un réseau de sigmoïdes à deux couches, mais il est possible de l'étendre à un nombre quelconque de couches [23].

- **Créer un réseau à 2 couches de neurones**
- Initialiser les poids aléatoirement avec de petites valeurs. L'entrée de l'unité i dans l'unité j est notée x_{ij} et les poids de l'unité i à l'unité j sont notés w_{ij} .

Pour chaque e dans l'exemple :

Calculer la sortie de chaque neurone du réseau

Pour chaque unité k dans les neurones de sortie :

Calculer le terme d'erreur $\delta_k = sortie_k(1 - sortie_k)(cible_k - sortie_k)$

Pour chaque unité h dans neurones cachés :

Calculer le terme d'erreur $\delta_h = sortie_h(1 - sortie_h) \sum_{k \in sorties} w_{kh} \cdot \delta_k$

Pour chaque poids du réseau w_{ij} :

Mettre à jour les poids $w_{ij} = w_{ij} + \eta \cdot \delta_j \cdot x_{ji}$

Cet algorithme est spécifique aux réseaux de neurones à une couche cachée avec des unités sigmoïdes mais on peut facilement l'adapter à un nombre quelconque de couches cachées et pour des unités à fonction d'activation différentiables [23].

4.3.3.2. La variante Perceptron multicouches

Les réseaux Perceptron Multicouche (Multi Layer Perceptron : MLP) ont été utilisés pour résoudre des problèmes difficiles par apprentissage supervisé à partir d'un algorithme de "retro-propagation de l'erreur" qui se base sur la règle d'apprentissage par correction d'erreur. Le processus de rétro propagation d'erreur consiste à effectuer deux passages à travers les différentes couches du réseau : un passage direct et un passage rétrograde.

Pendant le passage direct, les poids synaptiques du réseau sont fixes, et on rétrograde les poids synaptiques qui sont ajustés à partir d'une règle de correction de l'erreur. Ces ajustements continuent jusqu'à ce que la réponse du réseau s'approche de la réponse désirée au sens de l'ensemble d'apprentissage ou de la fonction.

a. Architecture du réseau

Considérons un Perceptron Multicouches formé d'une couche de L entrées, d'une couche de S neurones cachés et d'une couche de M neurones de sortie. Le réseau est entièrement connecté, c.à.d. chaque neurone d'une couche est relié à l'ensemble des neurones de la couche suivante.

Entrées : $X_n; n = 0, 1, \dots, L; X_0 = 1$

Sorties : $y_k : k = 1, \dots, M$.

Sorties internes : $Z_j : j = 1, \dots, S; Z_0 = 1$

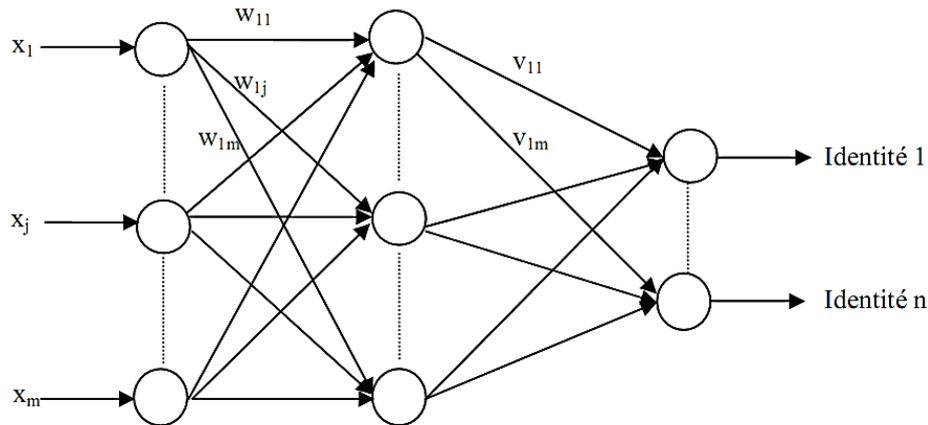


Figure 4.8 : Architecture d'un réseau de neurones multicouches.

b. Equations de fonctionnement :

Connexions entrées- neurones cachés : $u_j = \sum_{n=0}^L w_{jn} x_n ; j = 1, \dots, S$

Fonctions d'activation : $Z_j = \Phi(u_j)$

Connexion neurones cachés-sorties : $v_k = \sum_{j=0}^S w_{kj} Z_j ; k = 1, \dots, M$

Fonction d'activation : $y_k = \Phi(v_k)$

c. Stratégie d'apprentissage

L'erreur commise par le réseau, définie comme la différence entre la sortie attendue et la sortie du réseau, va permettre d'adapter les poids de la structure afin de minimiser cette erreur. Plusieurs algorithmes existent afin de réaliser cet apprentissage. On peut citer par exemple la rétro propagation du gradient.

L'erreur au carré entre les sorties désirées et les sorties calculées par le réseau est :

$$E = \frac{1}{2} \sum_{k=1}^M (d_k - y_k)^2$$

Pour la classification des signaux EEG, le nombre d'entrées de la première couche de réseau dépend du nombre de paramètres extraits pour chaque signal. Plus le nombre de paramètres augmente, plus la complexité de calcul augmente. Pour ce qui sont des sorties de réseau, leur nombre dépend de nombre de classes à déterminer.

Dans la classification des signaux EEG avec les réseaux de neurones, chaque signal est représenté par un vecteur colonne qui contient les différents paramètres caractéristiques, ce qui donne une matrice qui sera envoyée à l'entrée de réseau.

5. Performances de classification

Pour évaluer les performances des deux classificateurs proposés, on s'est intéressé à un ensemble de paramètres qui sont les plus répandus lors des recherches effectuées dans le domaine de la classification des signaux biomédicaux, [24],[25].

5.1.Précision : rapport des vrais positifs(TP) et vrais négatifs(TN). Elle mesure le taux de classification correcte des cas normaux et épileptiques, Elle est donnée par la formule suivante :

$$précision = \frac{TP + TN}{TP + FN + FP + TN} \times 100\%$$

5.2.Sensibilité : rapport des vrais positif (TP), elle mesure le taux de classification correcte des cas normaux. Elle est donnée par la formule suivante :

$$Sensibilité = \frac{TP}{TP + FN} \times 100\%$$

5.3.Spécificité : rapport des vrais négatifs (TN), elle mesure le taux de classification correcte des cas épileptiques. Elle est donnée par la formule suivante :

$$Spécificité = \frac{TN}{TN + FP} \times 100\%$$

La sensibilité de test mesure sa capacité à donner un résultat positif lorsqu'une hypothèse (normale ou épileptique) est vérifiée. Elle s'oppose à la spécificité, qui mesure la capacité de test à donner un résultat négatif lorsque cette hypothèse n'est pas vérifiée.

5.4.Taux d'erreur : mesure l'erreur commise lors de la classification des cas normaux et épileptiques. Il est donné par la formule suivante :

$$Taux\ d'erreur = \left(1 - \frac{TP + TN}{TP + FN + FP + TN}\right) \times 100\%$$

- **TP**(true positive) : vrai positif signifie que le cas normal est classé dans la classe des normaux représente le nombre d'individus malades avec un test positif
- **TN** (true negative) : vrai négatif signifie que le cas épileptique est classé dans la classe des épileptiques.
- **FP** (false positive) : faux positif signifie que le cas épileptique est classé dans la classe des normaux.
- **FN** (false negative) : faux négatif signifie que le cas normal est classé dans la classe des épileptiques.

Table 4.2 : Table de diagnostic (confusion)

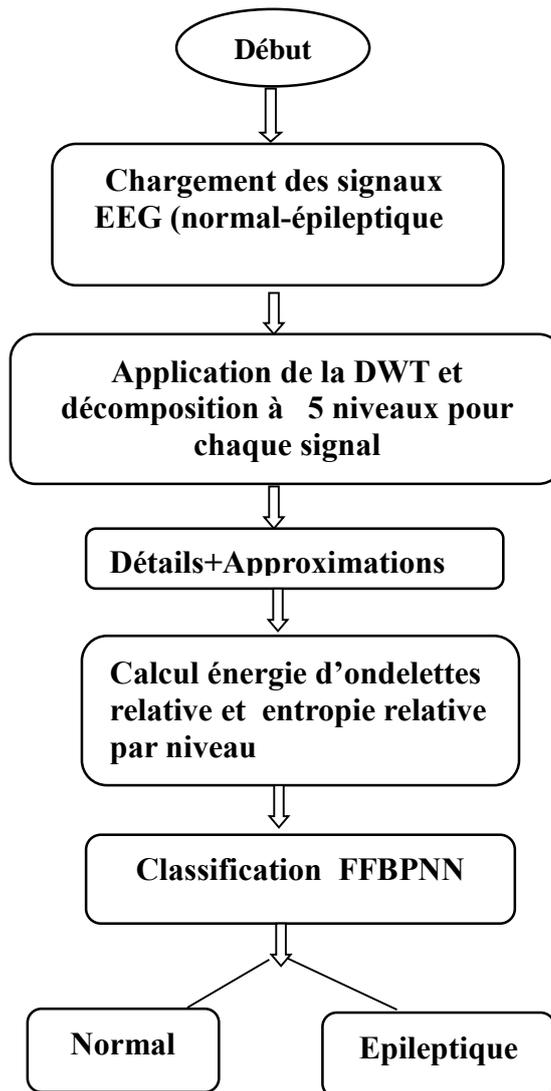
		Classe réelle	
		Classe +	Classe -
Classe prédite	Classe +	TP (vrai positifs)	FP (faux positifs)
	Classe -	FN (faux négatifs)	TN (vrais négatifs)

Les paramètres ci-dessus permettent d'évaluer la capacité de classification des deux classificateurs proposés.

6. Résultats et discussions

Dans cette partie on va mettre en évidence et en pratique toutes les notions citées précédemment afin de réaliser un classificateur automatique qui représente une aide au diagnostic de la pathologie épileptique, on trouve dans cette partie les résultats obtenus par la classification appliquée sur des données réelles, ainsi l'évaluation et la vérification de la fiabilité de système de classification conçu. Pour cela, on évalue les résultats de chaque étape de développement de ce système automatique de la classification.

Le processus de réalisation : est représenté par l'organigramme suivant



Pour cela nous avons exploité la plateforme Matlab (R2013a) avec ces différentes fonctions incluant d'autres fonctions disponibles dans laWaveletToolbox, BioinformaticsToolbox.

6.1. Phase de prétraitement (application de la DWT aux signaux EEG) :

Tout d'abord on décrit la base de données utilisée puis on passe aux résultats de décomposition ; On a utilisé la base de données mise à la disposition du public [26], comprenant 5 ensembles (dénotés A, B, C, D, E), chacun d'eux contient 100 signaux d'une durée de 23,6s. Les ensembles A et B ont été pris à partir d'enregistrements EEG de surface de cinq volontaires sains avec les yeux ouverts et fermés, respectivement.

L'ensemble E correspond aux signaux présentant des crises épileptiques. Les ensembles A et B ont été enregistrés par voie extra crânienne, tandis que les ensembles C (la commissure hippocampique de l'hémisphère opposé du cerveau), D (la zone épileptogène) et E ont été enregistrés par voie endocrânienne. Tous les signaux EEG ont été enregistrés avec le système d'amplification à 128 canaux, en utilisant une moyenne de référence commune. Les données ont été numérisées à 173.61 échantillons par seconde en utilisant une résolution de 12 bits. La bande passante est de 0,53 à 40 Hz (12 dB / oct). La figure (6.1) représente les signaux EEG obtenus à partir des Set A, B, C, D et E.

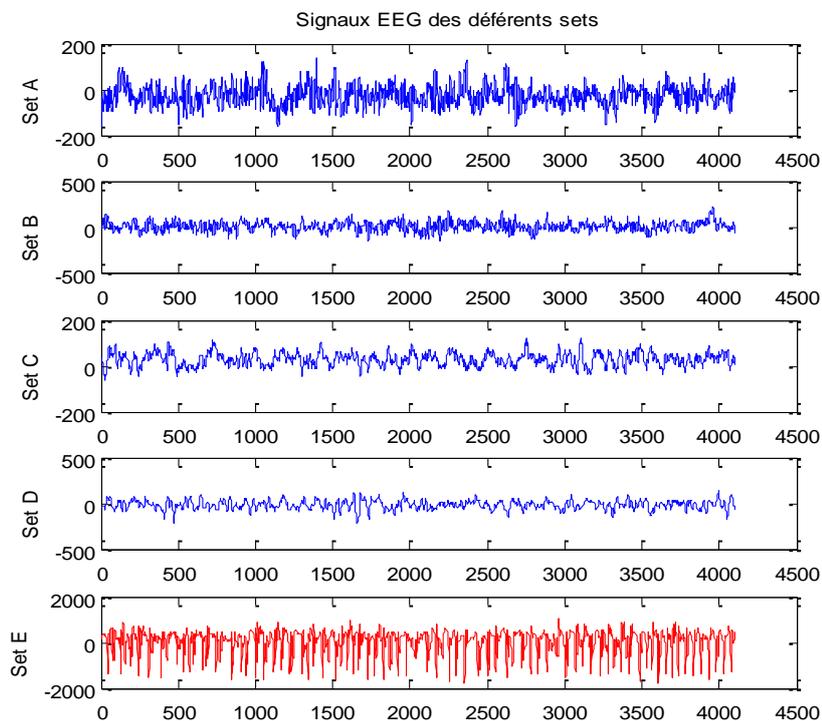


Figure 6.1 : Représentation temporelle des signaux EEG.

La sélection des ondelettes appropriées et le nombre de niveaux de décomposition est important dans l'analyse des signaux EEG :

- **Le choix d'ondelette analysante :**

Dans le cadre d'analyse des signaux EEG plusieurs recherches ont été effectuées concernant le choix de l'ondelette analysante ; on trouve souvent dans la littérature que les ondelettes de COIFLET et de Daubechies sont les plus utilisées.

Dans ce travail on applique la Daubechies d'ordre 4 'db4' qui a été utilisée par [27], [28], [29], [30] car elle donne des bons résultats.

- **Le nombre des niveaux de décomposition :**

Le nombre de niveau de décomposition est choisi en fonction des composantes de fréquences dominantes du signal. Dans notre étude comme les signaux EEG n'ont pas de composantes de fréquence utiles au-dessus de 80 HZ on s'arrête au niveau 5. Par conséquent, le signal sera décomposé en cinq (05) coefficients d'approximation A1 jusqu'à A5 et Cinq (05) coefficients de détail D1 jusqu'à D5.

Dans cette phase tous les signaux représentant les EEG normaux et épileptiques sont décomposée en plusieurs sous-bandes à l'aide de la DWT, les plages de fréquences de ces sous bandes sont représentées dans le tableau 6.1.

Tableau 6.1 : Gamme de fréquence

Niveau de décomposition	Fréquences(Hz)
D1	43.4 – 86.8
D2	21.7 – 43.4
D3	10.8 – 21.7
D4	5.4 – 10.8
D5	2.7 – 5.4
A5	0 – 2.7

Le prétraitement est fait par une décomposition avec décimation, où on note qu'à chaque niveau de décomposition l'échelle augmente et la dimension diminue. Sachant que le filtrage passe bas demi-bande enlève la moitié des fréquences sans aucune perte d'information, et le sous-échantillonnage après filtrage n'affecte pas la résolution [31]. Les résultats de la décomposition des signaux EEG normaux et épileptiques obtenus sont représentés par la figure (1.6).

La figure 6.2 illustrent un EEG normal et épileptique typique et ses coefficients d'ondelettes. En remarque, Le nombre de coefficients d'ondelettes sont réduites de moitié après chaque niveau de décomposition ce qui réduit le temps de calcul sensiblement.

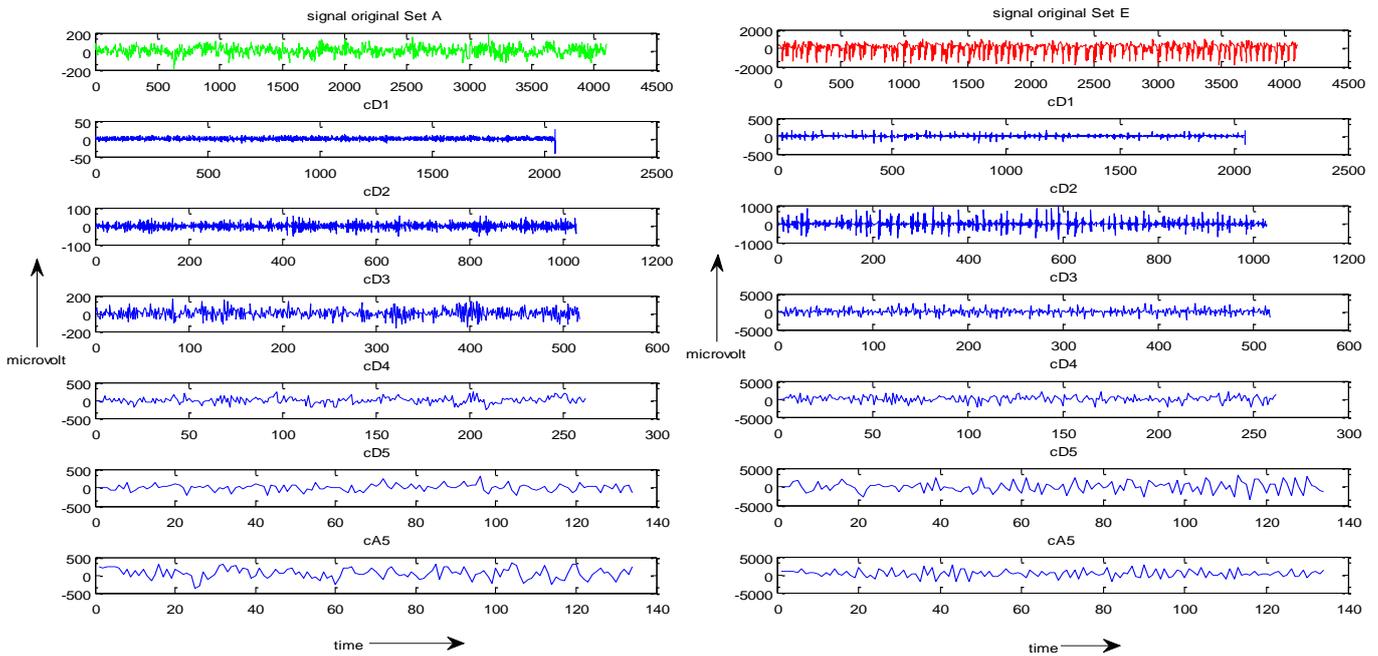


Figure 6.2 : Coefficients d'ondelettes typiques d'EEG normal (à gauche) et épileptique (à droite).

6.2. Phase d'extraction des paramètres caractéristiques

Dans cette étape, on calcule l'énergie (E_1, E_2, \dots, E_6) des coefficients d'ondelettes de détail CD1-CD5 et approximatifs Ca5. Ainsi, l'énergie d'ondelettes relative ($\rho_1, \rho_2, \dots, \rho_6$) pour les différentes bandes de fréquences

Les valeurs obtenues de l'énergie relative sont tabulées dans le tableau (6.2)

Tableau 6.2 : Energie relative d'ondelettes pour les différents niveaux

RWE	Data Sets					Sub-band
	A	B	C	D	E	
ρ_1	0.000508	0.000469	0.000171	0.000149	0.000173	43.4-86.8
ρ_2	0.008810	0.007804	0.001454	0.001378	0.006409	21.7-43.4
ρ_3	0.058392	0.106870	0.012451	0.014129	0.079862	10.85-21.7
ρ_4	0.120826	0.250782	0.064089	0.088033	0.227105	5.43-10.85
ρ_5	0.145397	0.112384	0.197263	0.201341	0.365422	2.70-5.43
ρ_6	0.666068	0.521691	0.724571	0.694969	0.321029	0-2.70

Les résultats suivants montrent que la valeur de l'énergie d'ondelette relative (RWE) ρ_6 de la sous bande (0 - 2,70 Hz) correspondant aux signaux d'épilepsie est inférieure à ρ_6 trouvée dans le cas des signaux EEG intercritiques et normal.

Les valeurs de la RWE (ρ_3, ρ_4, ρ_5) de la sous-bande 2,70 - 21,7 Hz correspondant au set E de la base de données plus élevées que les valeurs trouvées dans le cas de set A, C, et D

Les valeurs de la RWE (ρ_1, ρ_2) de la Sous-bande 21,7 - 86,8 Hz correspondant au EEG épileptiques (set E) sont plus élevées que les valeurs (ρ_3, ρ_4, ρ_5) de set C, set D et inférieures à celle de set B.

Par conséquent, on peut conclure que les signaux épileptiques ont plus de rythmicité que les EEG inter-critiques et normales. Et donc en se basant sur les valeurs de RWE, on peut considérer (x_1, x_2, x_3, x_4) comme vecteurs caractéristiques pour la classification par FFBPNN, telle que :

$$\begin{aligned} x_1 &= \rho_1 + \rho_2 + \rho_3 + \rho_4 + \rho_5 \\ x_2 &= \rho_2 + \rho_3 + \rho_4 + \rho_5 \\ x_3 &= \rho_6 \\ x_4 &= WEN \end{aligned}$$

Les vecteurs caractéristiques x_1, x_2, x_3 et x_4 sont appliqués à l'entrée de classificateurs d'EEG. Les cas pris pour l'étude sont les suivants :

- Cas 1: set A vs Set E
- Cas 2: set B vs Set E
- Cas 3: set C vs Set E
- Cas 4: set D vs Set E
- Case 5: set A, C, D vs Set E , Cas6: setA, B, C, D vs Set E

Les valeurs de ces caractéristiques sont calculées et représentées dans le tableau 6.3

Tableau 6.3 : les valeurs moyennes des paramètres caractéristiques pour les différents sets de la base de données.

Sets	paramètres			
	x_1	x_2	x_3	x_4
A	0.333932451	0.33342492	0.666067549	0.961366222
B	0.478308702	0.477839624	0.5216913	1.103895635
C	0.275428614	0.275257464	0.724571386	0.758538
D	0.305030492	0.304881417	0.69497	0.80801
E	0.678971	0.678798	0.321029	1.148783637

Les valeurs moyennes de x_1, x_2, x_3 et x_4 sont utilisées pour différencier entre les EEG normaux et EEG pathologiques par le classificateur FFBPNN

A partir des résultats représentés dans le tableau suivant, on remarque que les valeurs moyennes de x_1 , x_2 et x_4 pour le set E sont plus élevées que celles trouvées pour les sets A, B, C, D.

La valeur moyenne de x_3 pour le set E est moins élevée par rapport à celles trouvées pour les sets A, B, C, D. Pour cette raison, ces paramètres peuvent être utilisés sous forme de vecteurs de paramètres pour la classification des signaux EEG.

La Figure 6.1(a-b) montre que les valeurs de x_1 qui représentent la distribution énergétique dans la bande de fréquence (2.7-86.8 Hz) pour les signaux EEG épileptiques sont plus élevées par rapport aux valeurs de x_1 trouvées dans le cas des signaux EEG normaux et interictal. Donc cette représentation graphique montre la différence significative entre les EEG normaux (A, B), les EEG critique (C, D) et épileptiques (E).

La figure 6.2 (a-b) montre que les valeurs de x_3 qui représentent la distribution énergétique dans la bande de fréquence (0 – 2.7 Hz) pour les signaux épileptogène sont inférieures aux valeurs de x_3 trouvées dans le cas critique et normal, ce qui montre la différence significative entre les trois différents cas (x_3 -A), (x_3 -B), (x_3 -C), (x_3 -D) par conséquent ces caractéristiques peuvent être considérées comme de très bons paramètres pour la classification des signaux EEG

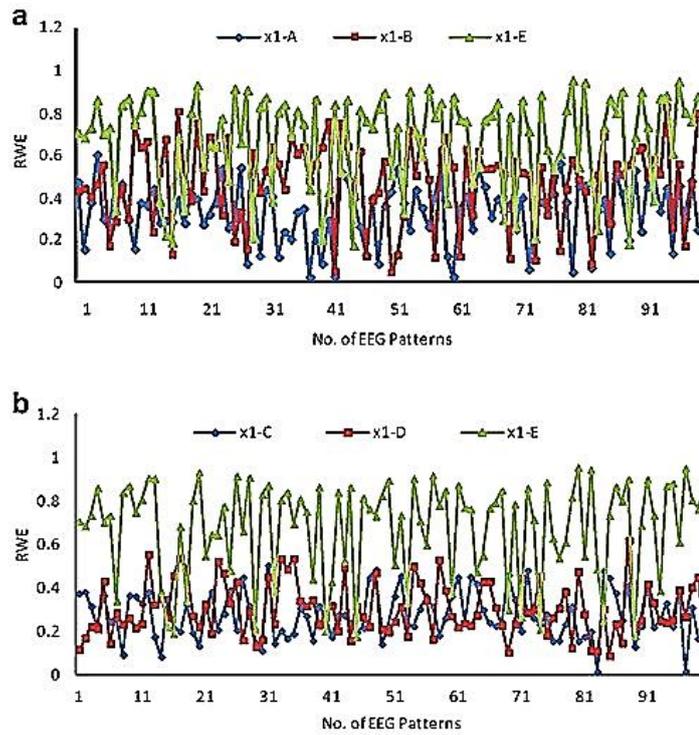


Figure 6.2 :(a)valeurs de x1 pour le set A, B et E. (b)valeurs de x1 pour le set C, D et E.

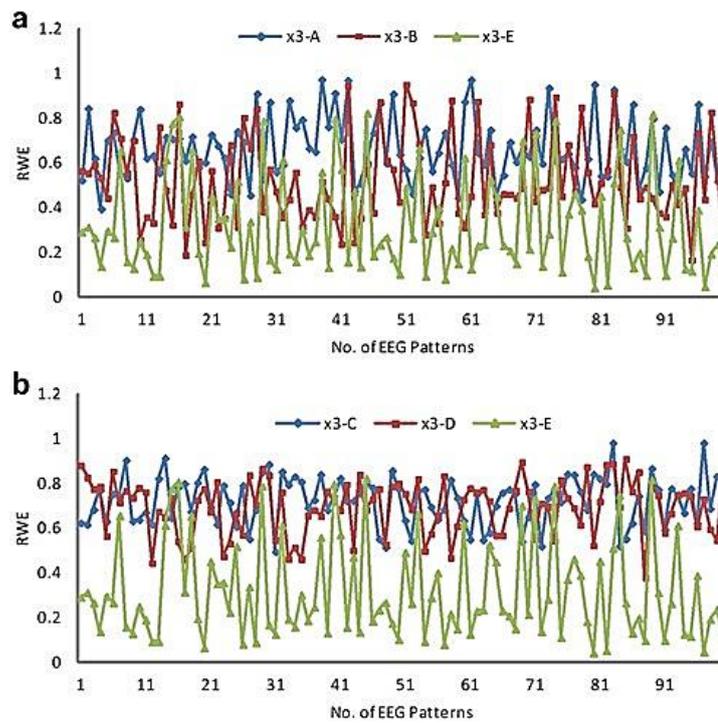


Figure 6.3 : (a) valeurs de x3 pour le set A, B et E. (b) valeurs de x3 pour le set C, D et E.

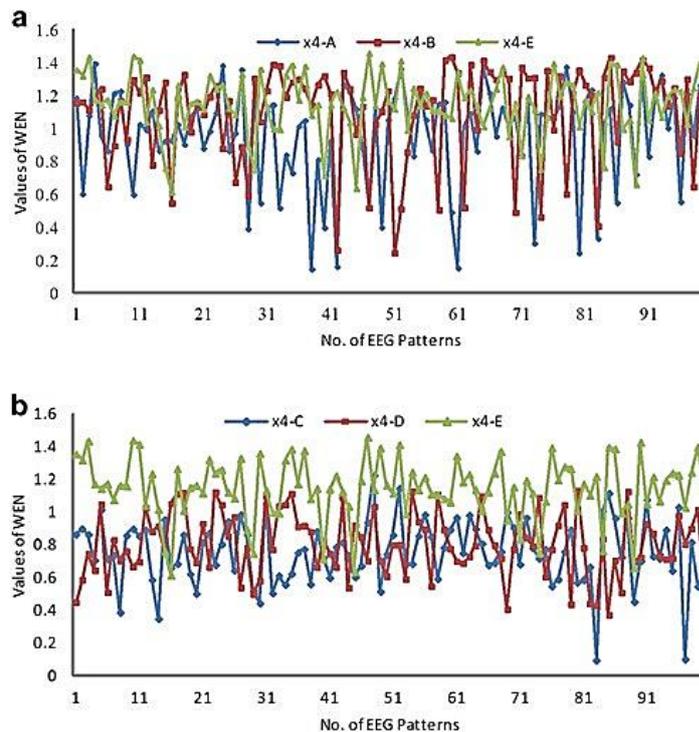


Figure 6.4 :(a)valeurs de x4 pour le set A, B et E. (b) valeurs de x4 pour le set C, D et E.

Les valeurs de la caractéristique (x4) de sets A, B, C et D comparée à celle correspondant à celles de E sont tracées dans la figure 6.4(a-b). Ces courbes montrent que la plupart des valeurs x4 de set E sont plus élevées que les valeurs x4 de sets A, B, C et D. Ceci amène à conclure que l'ensemble de données E est plus ordonné si on le compare par rapport aux autres ensembles de données A, B, C et D.

On note un chevauchement important entre les vecteurs caractéristiques des différents ensembles de données A, B, C, D et E cela prouve que les vecteurs caractéristiques ne sont pas linéairement indépendants.

6.3.Phase de la classification (par les réseaux neurones)

Le réseau de neurones utilisé est le feedforward à rétro-propagation (FFBPNN)

Le principal problème lié à son utilisation est le choix des fonctions d'activation des couches cachées et la fonction linéaire a utilisée pour la couche de sortie en plus de la définition du nombre de neurones cachés.

Dans certaines applications de classification, on utilise :

- la fonction tangente hyperbolique pour la couche cachée
- la fonction linéaire pour la couche de sortie.

De bons résultats ont été obtenus avec ou sans utilisation de la durée.

Pour spécifier la structure du réseau, il est nécessaire de choisir

- le nombre de couches
- le nombre de neurones sur chaque couche.
- Le nombre d'entrées du réseau
- De même que le nombre de neurones sur la couche de sortie est fixé par les spécifications du problème que l'on veut résoudre avec ce réseau.

Pour notre application, on a pris les paramètres suivants :

- La fonction d'activation utilisée pour la couche cachée est la fonction tangente hyperbolique

$$f(n) = \frac{e^n - e^{-n}}{e^n + e^{-n}}$$

- La fonction d'activation utilisée pour la couche de sortie : la fonction linéaire

$$f(n) = n$$

Le FFBPNN utilisée dans ce travail est la suivante : 4 neurones dans la couche d'entrée, 6 neurones dans la couche cachée, et deux neurones dans la couche de sortie. Les performances de la méthode proposée sont calculées à l'aide de trois paramètres statistiques qui sont ensuite présentés dans le tableau (6.4) pour les différents cas (1-6) étudiés.

Tableau 6.3 : les performances de classification par le réseau FFBPNN

<i>FFBPNN</i>	<i>SEN (%)</i>	<i>SPE (%)</i>	<i>CA (%)</i>
<i>Cas1(A-E)</i>	94.5	95.20	95.00
<i>Cas2(B-E)</i>	73.6	90.4	82.00
<i>Cas3(C-E)</i>	94.73	100	97.50
<i>Cas4(D-E)</i>	94.73	100	97.50
<i>Cas5(ACD-E)</i>	78.94	100	95.00
<i>Cas6(ABCD-E)</i>	63.15	100	93.00

La comparaison de la précision de la classification obtenue par la méthode proposée par rapport à d'autres procédés [30, 31, 32, 33,34 et 34-35] présentée dans le tableau (annexeA) appliquées en même temps à la même base de données, idem aux mêmes cas qui sont les plus performants

- Pour le cas 1, la précision de la classification obtenu (96,25% de) est meilleure que les résultats rapportés par différents références [30, 31, 34, 36] et pour la même base données.

Sachant que les résultats cités dans ces différentes articles ont été obtenus en utilisant différentes méthodes comme celle de Subasi [34], dans lesquelles la transformée en ondelettes discrètes et le modèle « mixture expert » sont utilisés pour évaluer la précision de la classification.

- Pour le cas 2, 3 et4, la précision de classification obtenue est 82,00%, 97,5%, et 97,5% respectivement, on peut les considérer comme étant de bons résultats en se référant aux résultats trouvés par Nicolaou [31] qui a signalé les mêmes cas avec une précision de (82,8%, 88,0% et 79,94%) respectivement par la méthode « employing permutation entropy with SVM ».

- Pour le 5eme cas, la précision de la classification obtenue à l'aide de la méthode proposée est de 95,00%. Ce cas est également présenté dans le travail de Lingo [37], la fonction de la longueur de ligne reflète la forme d'onde, changements de dimensionnalité et est une mesure sensible de variation de l'amplitude du signal et de la fréquence. Jargon aussi a rapporté une exactitude de 97,75% en utilisant les caractéristiques de longueur de ligne basée sur la transformée en ondelettes a décomposition multi-résolution et les réseaux de neurones RNA pour classer l'EEG.

- Pour le cas 6, le résultat de la classification obtenu est 93,0% ; il est inférieur à la précision démontrée dans le travail de Tzallas[38], dans lequel les auteurs ont employé l'énergie caractéristique de distribution extraite du plan temps fréquence à un RNA pour la classification EEG avec une précision qui vaux 97,73%. Et idem il est inférieur aux précisions de classification (99,73%) obtenu par Jargon [37], qui a utilisé les caractéristiques de longueur de ligne comme entrée pour la SVM.

Conclusion

L'évolution que connaissent l'acquisition, le prétraitement et la classification de signaux d'enregistrements EEG, signaux non-stationnaires, a rendu leur exploitation complexe ; ce qui redirige les recherches vers différentes techniques afin d'en extraire les informations utiles.

Plusieurs méthodes d'analyse, de prétraitement et de classification existent dans la littérature. Elles visent à extraire et à utiliser uniquement la structure intrinsèque de ces données qui contient juste l'information utile pour les traitements postérieurs, en vue d'une classification automatique pour une aide au diagnostic dans le domaine biomédical. Il s'agira, dans le cas présent, d'un prétraitement par transformation en ondelettes discrètes et en paquets d'ondelette. On propose des solutions à ces problèmes en déterminant les caractéristiques statistiques extraites à partir des coefficients de la transformée d'ondelette.

Les aspects théoriques et fondamentaux des ondelettes ont été abordés. Ces ondelettes constituent le principal outil mathématique qu'on utilise pour le prétraitement des signaux EEG par la DWT. Il était donc de première importance de bien comprendre ces fonctions et d'étudier leurs propriétés. Le choix de la transformée en ondelette est dicté par les caractéristiques du signal non-stationnaire d'enregistrement EEG.

Le classificateur FFPBNN constituant une méthode de classification supervisée particulièrement bien adaptée pour le traitement de nos données ont été exploitées afin de classer les enregistrements des signaux EEG en cas normaux et en cas épileptiques.

Finalement, les performances de mesures ont été discutées en se basant sur l'exactitude, la sensibilité et la spécificité.

Il est à noter que les algorithmes qu'on a développé pour la classification de l'épilepsie sont exploitables par n'importe quelle application de diagnostic des signaux biomédicaux. Il suffit de changer la banque de données d'apprentissage.

Ce travail s'inscrit dans le cadre d'un domaine de recherche en pleine expansion : la neuroscience. Du point de vue pédagogique, ce projet m'a permis de découvrir le domaine du traitement et de la classification des signaux électroencéphalographies. Le développement des

différents logiciels alloués à cette application, était une occasion pour maîtriser le logiciel MATLAB 2013a.

Les résultats obtenus avec l'algorithme suivi sont très prometteurs. On envisage en perspective des possibilités d'optimisation et d'implémentation matérielle sur une carte DSP et/ou FPGA.

Annexe A

Researchers	Year	Methods	Problem	CA(%)
NigamandGraupe	2004	Non-linearpreprocessingfilter-diagnosticneuralnetwork	A-E	97.20
Srinivasanetal.	2005	Timeandfrequency-domainfeatures-recurrentneuralnetwork	A-E	99.60
Kannathaetal.	2005	Entropyasures-adaptiveneuro-fuzzyinferencesystem	A-E	92.22
PolatandGünes,	2007	FastFouriertransform-decisiontree	A-E	98.72
Subasi	2007	Discretewavelettransform-mixtureofexpertmodel	A-E	95.00
Tzallasetal.	2007	Time–frequencyanalysis-Artificialneuralnetwork	A-E	100
			ABCD-E	97.73
Guoetal.	2009	Discretewavelettransform-relativewaveletenergy-MLPNN	A-E	95.20
Subasietal.	2010	DWT-PCA,ICA,LDAandSVM	A-E	98.75(PCA)
				99.50(ICA) 100(LDA)
LingGuoetal.	2010	Multiwavelettransform-approximateentropyfeature-MLPNN	A-E	99.85
			ABCD-E	98.27
LingGuoetal.	2010	linelengthfeature-ANN	A-E	99.60
			ACD-E	97.75
			ABCD-E	97.77
ElifDeryaUbeyli	2010	LS-SVMmodel-basedmethodscoefficients	A-E	99.56
Umutorhanetal.	2011	EEGclassification-K-meansclustering-MLPNN	A-E	100
			ABCD-E	99.60
LingGuoetal.	2011	GP-basedfeatureextraction-KNNclassifier	A-E	99.20
ZaferIsçanetal.	2011	ClassificationofEEGsignalwithcombinedtimeandfrequencyfeatures	A-E	100
DengWangetal.	2011	Waveletpacketentropy-hierarchicalEEGclassification	A-E	99.44
Nicolaouetal.	2012	PermutationEntropy-SVM	A-E	93.55
			B-E	82.88
			C-E	88.00
			D-E	79.94

Annexe B : Les programmes informatiques de notre système de classification

Pour ce qui est des programmes, on a créé des fonctions pour chaque bloc de notre système englobant différentes tâches. Les deux programmes sont affichés ci-dessous :

```
% Systeme de classification des signaux EEG en utilisant les etapes suivantes:  
%DWT_LDA_RNN
```

```
wname='db4';%l'ondelette mere  
level=5;% niveau de decomposition de la DWT  
loadX.mat; % les signaux EEG (set A + set E + set B+ set C + set D)  
loadgroup;% vecteur Class pour les signaux Normaux et les signaux Anormaux
```

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%  
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
```

```
% ----- 1- Transformee en ondelette: DWT ----- %  
[DEC cd5,cd4,cd3,cd2,cd1 ] = multDWT_decomposition(X,level,wname );
```

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%  
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
```

```
% ----- 2- Extraction des parametrescaracteristiques ----- %  
[MAX,MIN,RANGE,STD]=multDWT_max_min_range_std(ca5,cd5,cd4,cd3,cd2,cd1);  
[ENT,~,ENG_AD]= multDWT_entropie_energie(DEC,ca5,cd5,cd4,cd3,cd2,cd1);
```

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%  
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
```

```
% ----- 3- analyse des donnees : LDA ----- %  
[data1_MAX,data1_MIN,data1_RANGE,data1_STD,data1_ENT,data1_ENG_AD,data1_test]=multDWT_feature_ACP( MAX,MIN,RANGE,STD,ENT,ENG_AD);  
FEATURE = {data1_MAX data1_MIN data1_RANGE data1_STD data1_ENT data1_ENG_AD};
```

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%  
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
```

```
% ----- 4- CLASSIFICATION : RNN -----%  
[ClassFEATURE,ClassMAX,ClassMIN,ClassRANGE,ClassSTD,ClassENT,ClassENG_AD]=multDWT_classificationRNN(data1_test,data1_MAX,data1_MIN,data1_RANGE,data1_STD,data1_ENT,data1_ENG_AD,test,train,group);
```

```
%----les performances de la classifications RNN-----%  
[CorrectRate,Sensitivity,Specificity]=multDWT_performance(ClassFEATURE,ClassMAX,ClassMIN,ClassRANGE,ClassSTD,ClassENT,ClassENG_AD,group,test);
```

Bibliographie :

- [1] ROMO V'AZQUEZ, 2010, Contribution à la détection et à l'analyse des signaux EEG épileptiques : débruitage et séparation de sources.
- [2] BERGER, H. (1929). Überdaselektrenkephalogramm des menschen. European Archives of Psychiatry and Clinical Neuroscience, 87(1):527–570.
- [3] SANEI, S. et CHAMBERS, J. (2007). EEG signal processing. Wiley-Interscience.
- [5] Montaine BERNARD, (2002), Méthodologie d'analyse des synchronisations neuronales dans les signaux EEG à l'aide de graphes d'informations temps-fréquence, UNIVERSITÉ DE POITIERS.
- [6] R. MILLER :Corticohippocampal interplay and the representation of contexts in the brain. Springer Verlag, 1991.
- [7] K. SASAKI, T. TSUJIMOTO, S. NISHIKAWA, N. NISHITANI et T. ISHIHARA:
Frontal mental theta wave recorded simultaneously with magnetoencephalography and electroencephalograph. Neurosci Res, 26(1):79–81, Sep 1996.
- [8] D.J. McFarland, C. W. Anderson, K.-R. Muller, A. Schlogl, and D.J. Krusienski. Bci meeting 2005-workshop on bci signal processing: feature extraction and translation. IEEE transactions on Neural Systems and Rehabilitation Engineering, 14(2):135 – 138, 2006.
- [9] BOTTOU, L. et CHIH-JEN, L. (2007). Support vector Machine Solvers, in Large Scale Kernel Machines. MIT Press.
- [10] Subasi Alkan, Koklukaya. Automatic seizure detection in eeg using logistic regression and artificial neural network. Journal of Neuroscience Methods, vol. 148, no. 2, pp. 167-76, 2005.
- [11] Ubeyli Guler. Adaptive neuro-fuzzy inference system for classification. Journal of Neuroscience Methods, vol. 148, no. 2, pp. 113-121, 2005.
- [12] Bishop, C. M. (2006). Pattern Recognition and Machine Learning, volume 4
- [13] Sahin Ogulata Erol Aslan, Bozdemir. A radial basis function neural network model for classification of epilepsy using eeg signals. The Journal of Medical Systems, vol.32, no. 5, 2008.
- [14] Homan Dashei Wunsch Petrosian, Prokhorov. Recurrent neural network based prediction of epileptic seizures in intra and extracranial eeg. *Neurocomputing*, vol.30, no. 1-4, pp. 201-218, 2000.
- [15] Mourad Adnane ; Zhongwei Jiang ; Zhonghong Yan. Sleep–wake stages classification and sleep efficiency estimation using single-lead electrocardiogram. Expert Systems with Applications, vol. 39, pp. 1401-1413, 2012.
- [16] Nilsson, N. J. (2004). Introduction to Machine Learning, volume 56. The MIT Press. de Information science and statistics. Springer.
- [17] A. CHERIF, « Réseaux de neurones, SVM et approches locales pour la prévision des séries temporelles », UNIVERSITÉ FRANÇOIS RABELAIS DE TOURS, 2013.

- [18] N. Martaj, M. Mokhtari, MATLAB R2009, SIMULINK et STATEFLOW pour Ingénieurs, Chercheurs et Etudiants, DOI 10.1007/978-3-642-11764-0_17, Springer-Verlag Berlin Heidelberg 2010.
- [19]. G. Dreyfus, J.-M. Martinez, M. Samuelides M. B. Gordon, F. Badran, S. Thiria «Apprentissage statistique» Eyrolles 2004.
- [20] Y. Kumar, M. L. Dewal, R. S. Anand, “ Relative wavelet Energy and wavelet Entropy Based epileptic Brain signals classification”, the society of medical & biological engineering and springer, vol 2, pp147-157, 2012.
- [21] Allahabad, “classification of EEG Signals under Different Mental Tasks Using Wavelet Transform and neural Network with One step Secant Algorithm” International Journal of Scientific Engineering and technology, vol2, pp :256-259
- [22] Rumelhart, D. E., Hinton, G. E. et Williams, R. J. (1986). Learning internal representations by error propagation. *Parallel distributed processing : explorations in the microstructure of cognition*, 1:318–362.
- [23]. Antoine Cornuéjols - Laurent Miclet Avec la participation d'Yves Kodratoff ; «Apprentissage artificiel Concepts et algorithms » ; Eyrolles 2003.
- [24] A. Subasi, M. I. Gursoy, “EEG signal classification using PCA, ICA, LDA and support vector machines”, *Expert Systems with Applications*, vol. 37, pp.8659-8666, 2010.
- [25] L. Guo*, D. Rivero, A. Pazos, “Epileptic seizure detection using multiwavelet transform based approximate entropy and artificial neural networks”, *Journal of Neuroscience Methods*, vol.193 ,pp.156–163, 2010.
- [26] Sahin Ogulata Erol Aslan, Bozdemir. A radial basis function neural network model for classification of epilepsy using eeg signals. *The Journal of Medical Systems*, vol.32, no. 5, 2008.
- [27] A. Subasi, M. I. Gursoy, “EEG Signal classification using PCA, ICA, LDA and support vector machines”, *Expert Systems with Applications*, vol:37, pp:8659-8666, 2010.
- [28] T. Gandi, B. K. Panigrahi, S. Anand, “A comparative study of wavelet families for EEG signal classification”, *Neurocomputing*, vol:74, pp:3051-3057, 2011.
- [29] I. Omerhodzic, S. Avdakovic, A. Nuhanovic, K. Dizdarevic, “Energy Distribution of EEG Signals: EEG Signal Wavelet-Neural Network classifier”.
- [30] M. K. Arjmandi, M. Pooyan, “An optimum algorithm in pathological voice quality assessment using wavelet-packet-based features, linear discriminant analysis and support vector machine”, *Biomedical Signal processing and control*, vol:7, pp:3-19, 2012.
- [30] Guo L, Rivero D, Seoane J, Pazos A. Classification of EEG signals using relative wavelet energy and artificial neural networks. *Proc first ACM/SIGEVO Summit Genet Evol Comput (GEC)*. 2009; 177-84.
- [31] Nicolaou, N, Georgiou J. Detection of epileptic electroencephalogram based on permutation entropy and support vector machine. *Expert Syst Appl*. 2012; 39:202-9.
- [32] Iscan Z, Dokur Z, Demiralap T. Classification of electroencephalogram signals with combined time and frequency features. *Expert Syst Appl*. 2011; 38:10499-505.
- [33] Nigam V, Graupe D. A neural-network-based detection of epilepsy. *Neurosci Res*. 2004; 26(1):55-60.
- [34] Subasi A. EEG signal classification using wavelet feature extraction and a mixture of expert model. *Expert Syst Appl*. 2007; 32(4):1084-93.

- [35] Wang D, Miao D, Xie C. Best basis-based wavelet packet entropy feature extraction and hierarchical EEG classification for epileptic detection. *Expert Syst Appl.* 2011; 38: 14314-20.
- [36] Kannathal N, Choo ML, Acharya UR, Sadasivan PK. Entropies for detection of epilepsy in EEG. *Comput Meth Prog Bio.* 2005; 80:187-94
- [37] Guo L, Rivero D, Dorado J, Rabunal, JR, Pazos A. Automatic epileptic seizure detection in EEG based on line length feature and artificial neural network. *J Neurosci Meth.* 2010; 191:101-9.
- [38] Tzallas AT, Tsipouras MG, Fotiadis DI. Automatic seizure detection based on time-frequency analysis and artificial neural networks. *ComputIntellNeurosci.* 2007; doi:10.1155/2007/80510.