

# THÈSE

## En vue de l'obtention du Diplôme de Doctorat

*Présenté par : BELHADJ Sabrina*

*Détection automatique des crises d'épilepsie*

*Faculté : Génie Electrique*  
*Département : Electronique*  
*Domaine : Sciences et Technologie*  
*Filière : Signaux Systèmes Intelligent et Robotique*  
*Intitulé de la Formation : Signaux et Systèmes Intelligents*

*Devant le Jury Composé de :*

<i>Membres de Jury</i>	<i>Grade</i>	<i>Qualité</i>	<i>Domiciliation</i>
<i>BOUGHANMI Nabil</i>	<i>Professeur</i>	<i>Président</i>	<i>USTO-MB</i>
<i>AHMED FOITIH Zoubir</i>	<i>Professeur</i>	<i>Encadrant</i>	<i>USTO-MB</i>
<i>TALEB-AHMED Abdelmalik</i>	<i>Professeur</i>	<i>Co-Encadrant</i>	<i>Université de Valen- ciennes</i>
<i>MIMI Malika</i>	<i>Professeur</i>		<i>UABB-Mostaganem</i>
<i>KADDOUR Abdelhafid</i>	<i>Professeur</i>	<i>Examineurs</i>	<i>USTO-MB</i>
<i>HENDEL Fatiha</i>	<i>Professeur</i>		<i>USTO-MB</i>

*Année Universitaire : 2017/2018*

A

*Ma grand-mère, ma source de bénédiction  
Mes parents, que dieu les garde et les protège  
Mes frères et mes sœurs  
Mes gendres et ma belle sœur  
Mes neveux et mes nièces*

*Ô Dieu, Seigneur des hommes, fais partir le mal et guéris; Tu es le Guérisseur, il  
n'y a de guérison que la Tienne, une guérison qui ne laisse aucun mal*

## ***REMERCIEMENTS***

Je tiens à rendre grâce à notre Seigneur, le Tout Puissant et l'Unique digne d'adoration pour tous ses bienfaits.

Je tiens à remercier plus que chaleureusement mon directeur de thèse, Professeur Zoubir AHMED-FOTTIH de m'avoir donnée l'occasion de travailler sur ce sujet captivant. Sa disponibilité, ses conseils et son humanisme m'ont été très utile durant ces années de thèse. Merci infiniment.

Je tiens à exprimer ma reconnaissance et ma gratitude au Professeur Abdelmalik TALEB-AHMED, pour avoir co-dirigé ce travail et pour ces nombreux conseils ainsi que son soutien tout au long de cette thèse.

J'adresse mes sincères remerciements aux membres du jury pour l'acceptation de l'évaluation de mes travaux malgré leur charge.

Je tiens à remercier Monsieur Nabil BOUGHANMI, Professeur à l'Université d'USTO-MB Oran, pour l'honneur qu'il me fait en présidant le jury d'examen de ce travail.

Mes profonds remerciements à Madame Malika MIMI, Professeur à l'Université UABB de Mostaganem, à Monsieur Abdelhafid KADDOUR Professeur à l'Université d'USTO-MB Oran et à Madame Fatiha HENDEL Professeur à l'Université d'USTO-MB Oran, pour l'honneur qu'ils m'ont fait en acceptant de juger mon travail et d'être les rapporteurs de cette thèse.

Je remercie très chaleureusement Monsieur Bachir Ahmed ADNANE, Neurochirurgien au CHU d'Oran, pour son encadrement très précieux dans le domaine médical.

Je remercie sincèrement Monsieur Abdelouaheb ATTIA, Docteur à l'université UBBA de Bordj Bou Arréridj pour ses conseils et toute l'aide qu'il a pu m'apporter durant cette thèse.

Enfin, je ne saurais terminer ces remerciements sans oublier tous mes professeurs, ainsi que tous mes amis et collègues.

## **Résumé**

La classification des crises d'épilepsie avec des méthodes d'apprentissage automatique est devenue la fameuse solution dans le diagnostic et la détection de l'épilepsie. A travers l'utilisation des algorithmes intelligents sur les signaux d'électroencéphalogramme (EEG). Généralement, ces signaux sont non stationnaires et complexes. Ces méthodes ont permis d'identifier des connaissances utiles sur l'épilepsie. Compte tenu de cela, le travail actuel introduit une nouvelle approche pour la détection et la classification automatique des crises épileptiques. Dans cette approche, la méthode de Burg comme modèle autorégressif (AR) basée sur l'autoencodeur clairsemé (SAE) avec la Machine à Vecteur de Support (SVM) comme classificateur a été utilisée. Tout d'abord, l'extraction de caractéristiques est accomplie par la méthode de Burg, ensuite, les caractéristiques données par une telle méthode constituent une entrée pour le SAE. Les résultats de ce dernier sont employés dans l'étape d'entraînement et de classification en utilisant le classificateur SVM. Pour valider la performance de l'approche proposée, la base de données de Bonn a été utilisée. Au stade expérimental, trois types de classification ont été étudiés (non-épileptique à Interictal ou Ictal) et Interictal à Ictal. En outre, deux types d'expériences ont été réalisés. (i) les caractéristiques extraites par la méthode de Burg puis le classificateur SVM sans SAE et (ii) les caractéristiques sélectionnées par la méthode de Burg améliorées par SAE. Les résultats obtenus ont clairement démontré l'efficacité de l'approche proposée.

## **Abstract**

Epileptic seizure classification with machine learning methods has become the famous solution in the diagnosis and detection of epilepsy. Through employing the smart algorithms on electroencephalogram (EEG) signals. Generally, these signals are non-stationary and complex. These methods permitted to identify useful knowledge about epileptic. Given this, the current work introduces a novel approach for automatic epileptic seizure detection and classification. In this approach, Burg method as an autoregressive model (AR) based on sparse autoencoder (SAE) with Support vector Machine (SVM) as a classifier have been used. First, features extractions are accomplish by Burg method. Then, the features given by such method are an input to (SAE). The results of this later that employed in training and classification stage by using SVM classifier. To validate the performance of the proposed framework, the Bonn database has been employed. In the experimental stage, three types of classification have been studied (healthy non-epileptic to Interictal or Ictal) and Interictal to Ictal. Also, two kinds of experiments have been done. (i) the features extracted by Burg method hen SVM classifier without SAE and (ii) the features selected

by Burg method improved by SAE .The obtained results have clearly demonstrated the value of the proposed framework.

### ملخص

أصبح تصنيف نوبات الصرع مع طرق التعلم التلقائي الحل الشهير في تشخيص والكشف عن الصرع. من خلال استخدام الخوارزميات الذكية على إشارات تخطيط كهربية الدماغ (EEG). بشكل عام، هذه الإشارات غير ثابتة ومعقدة. وقد حددت هذه الأساليب معرفة مفيدة عن الصرع. بالنظر إلى ذلك، يقدم العمل الحالي منهجًا جديدًا للكشف التلقائي عن نوبات الصرع وتصنيفها. في هذا النهج، تم استخدام طريقة Burg كنموذج الانحدار (AR) على أساس Sparse Autoencoder (SAE) مع دعم ناقلات الآلات كمصنف (SVM). أولاً، يتم استخراج الميزات من خلال طريقة Burg. ثم، تشكل الخصائص التي تعطي من خلال هذه الطريقة تشكل مدخلا SAE. يتم استخدام نتائج هذا الأخير في مرحلة التدريب والتصنيف باستخدام مصنف SVM. وللتحقق من صحة أداء النهج المقترح، استخدمت قاعدة بيانات بون، ففي المرحلة التجريبية، تمت دراسة ثلاثة أنواع من التصنيف (صحية مع Interctal أو Ictal) و Interctal مع Ictal. بالإضافة إلى ذلك، تم إجراء نوعين من التجارب، (1) الخصائص المستخرجة بواسطة طريقة Burg ثم المصنف SVM بدون SAE و (ii) الخصائص التي تم اختيارها بطريقة Burg تم تحسينها بواسطة SAE. النتائج التي تم الحصول عليها أظهرت بوضوح فعالية النهج المقترح.

---

# TABLE DE MATIERES

---

<b>TABLE DE MATIERES</b> .....	I
<b>LISTE DES FIGURES</b> .....	VI
<b>LISTE DES TABLEAUX</b> .....	X
<b>INTRODUCTION GENERALE</b> .....	1
<b>CHAPITRE I : CONTEXTE MEDICAL</b>	
I.1. INTRODUCTION .....	5
I.2. CERVEAU.....	5
I.2.1. Notre cerveau.....	5
I.2.2. Structure du cerveau .....	5
I.2.3 Les neurones et l'activité électrique .....	7
I.3. L'ÉPILEPSIE .....	9
I.3.1 Que ce que c'est l'épilepsie ?.....	9
I.3.2. Classification des crises et syndrome épileptique .....	9
I.3.2.1. Différents type de crise .....	10
I.3.2.2. Syndrome épileptiques.....	11
I.3.3. Éthologie de la maladie .....	13
I.3.4. Techniques d'investigation .....	14
I.3.4.1. L'exploration électrophysiologique .....	15
I.3.4.2. L'exploration anatomique et fonctionnelle.....	16
I.3.4. Traitement .....	18
I.4. EEG ET L'EXPLORATION CLINIQUE DE L'ÉPILEPSIE.....	19
I.4.1. Rappel historique .....	19
I.4.2. Le placement des électrodes .....	20
I.4.3. Le montage des électrodes .....	21
I.4.4. Déroulement et réalisation d'une expérience EEG .....	21
I.4.5. L'activité rythmique .....	23
I.4.6. L'EEG en épilepsie .....	26
I.9. CONCLUSION .....	28
BIBLIOGRAPHIE .....	29

## CHAPITRE II : ETAT DE L'ART SUR LA DETECTION AUTOMATIQUE DES CRISES D'EPILEPSIE

II.1. INTRODUCTION .....	32
II.2. SYSTEMES DE DIAGNOSTIC ASSISTES PAR ORDINATEUR .....	32
II.2.1. Prétraitement du signal EEG .....	33
II.2.2. Extraction des caractéristiques .....	33
II.2.2.1. Les méthodes paramétriques.....	34
II.2.2.2. Les méthodes non paramétriques.....	34
II.2.2.3. Les méthodes temps-fréquence.....	35
II.2.2.4. Les méthodes de vecteur propre.....	35
II.2.3. La classification des signaux EEG.....	36
II.3. LES BASES DE DONNEES UTILISEES.....	44
II.3.1. Base de données EEG Freiburg de prédiction des crises .....	44
II.3.2. La base de données EPILEPSIAE.....	44
II.3.3. La base de données Andrzejak.....	45
II.3.4. La base de données CHB-MIT.....	45
II.4. MESURES DE PERFORMANCE .....	46
II.5. CONCLUSION.....	48
BIBLIOGRAPHIE.....	49

## CHAPITRE III : CONTRIBUTION ET METHODOLOGIE

III.1. INTRODUCTION .....	64
III.2. EXTRACTION DES CARACTERISTIQUES .....	64
III.2.1. La modélisation autorégressive du signal EEG .....	65
III.2.1.1. Estimation des paramètres par la méthode de Burg .....	66
III.2.1.2. Critère de sélection de l'ordre optimal du modèle .....	68
III.1. AMELIORATION DES VECTEURS DE CARACTERISTIQUES PAR L'AUTOENCODEUR CLAIRSEME .....	69
III.3.1. Les réseaux de neurones.....	69
III.3.1.1. Formulation de réseau neuronal.....	70
III.3.1.2. Algorithme de rétropropagation.....	73
III.3.1.3. Vérification de gradient et optimisation avancée.....	76
III.3.2. Autoencodeur et parcimonie .....	78
III.4. CLASSIFICATION DES SIGNAUX EEG EN UTILISANT MACHINES A VECTEURS DE SUPPORT (SVM) .....	82
III.4.1. SVM principe de fonctionnement général .....	82
III.4.1.1. Notions de base .....	82

---

III.4.1.2. Maximisation de la marge .....	84
III.4.2. Linéarité et non-linéarité .....	85
III.4.3. Cas non-linéaire .....	85
III.5. CONCLUSION .....	86
BIBLIOGRAPHIE .....	87
 <b>CHAPITRE IV : VALIDATION DE L'APPROCHE ET PRESENTATION DES RESULTATS</b>	
IV.1. INTRODUCTION .....	91
IV.2. METHODE PROPOSEE .....	91
IV.3. RESULTATS EXPERIMENTALES DE LA CLASSIFICATION ET ANALYSE .....	92
IV.3.1. BASE DE DONNEES .....	92
IV.3.2. EXPERIENCES ET RESULTATS .....	93
IV.4. CONCLUSION .....	111
BIBLIOGRAPHIE.....	112
<b>CONCLUSION GENERALE .....</b>	<b>113</b>

---

# TABLE DES FIGURES

---

<b>Figure I.1.</b>	Les deux hémisphères cérébraux .....	6
<b>Figure I.2.</b>	Représentation des quatre lobes de l'hémisphère.....	6
<b>Figure I.3.</b>	Schéma d'un neurone et ses principales composantes .....	8
<b>Figure I.4.</b>	Fonction des neurones .....	8
<b>Figure I.5.</b>	Schéma comparatif des différentes techniques d'exploration.....	15
<b>Figure I.6.</b>	Le premier EEG enregistré par Hans Berger (Publié en 1929).....	20
<b>Figure I.7.</b>	Système 10-20, placement des électrodes .....	21
<b>Figure I.8.</b>	Classification des rythmes en fonction de la fréquence .....	23
<b>Figure I.9.</b>	(a) une pointe, (b) une polypointe-onde lente .....	27
<b>Figure I.10.</b>	Décharge de pointes .....	27
<b>Figure I.11.</b>	Crise d'épilepsie du lobe temporal : apparition d'une oscillation à environ 7 Hz .....	28
<b>Figure I.12.</b>	Crise généralisée de type absence : décharge de pointes-ondes à 3 Hz .....	28
<b>Figure II.1.</b>	Schéma du système de diagnostic EE assisté par ordinateur.....	33
<b>Figure III.1.</b>	Le réseau neuronal .....	69
<b>Figure III.2.</b>	Réseau de neurones avec une seule sortie .....	70
<b>Figure III.3.</b>	Réseau de neurones a deux unités de sortie .....	73
<b>Figure III.4.</b>	Structure d'un autoencodeur .....	79
<b>Figure III.5.</b>	Tracé $KL(\rho \parallel \hat{\rho}_j)$ pour une plage de valeurs de $\hat{\rho}_j$ .....	81
<b>Figure III.6.</b>	Un hyperplan qui sépare les deux ensembles de points .....	82
<b>Figure III.7.</b>	Un hyperplan avec quatre vecteurs de support .....	83
<b>Figure III.8.</b>	Un hyperplan optimal.....	84
<b>Figure III.9.</b>	Un hyperplan avec faible marge (a) et un meilleur hyperplan séparateur (b).....	84
<b>Figure III.10.</b>	Le cas linéairement séparable (a) et le cas non linéairement	

	séparable (b).....	85
<b>Figure III.11.</b>	L'espace de re-description .....	86
<b>Figure IV.1.</b>	Diagramme du système proposé .....	91
<b>Figure IV.2.</b>	Exemples d'époques EEG appartenant aux sous-ensembles : A, B, C, D et E...	92
<b>Figure IV.3.</b>	Un exemple illustre la variation AIC (P).....	94
<b>Figure IV.4.</b>	Diagramme de l'autoencodeur avec P=20.....	96
<b>Figure IV.5.</b>	Diagramme de l'autoencodeur avec P=13.....	97
<b>Figure IV.6.</b>	Diagramme de l'autoencodeur avec P=10.....	97
<b>Figure IV.7.</b>	Meilleure performance d'entraînement des coefficients de données (AE) avec P=20.....	98
<b>Figure IV.8.</b>	Meilleure performance d'entraînement des coefficients de données (AC) avec P=20.....	98
<b>Figure IV.9.</b>	Meilleure performance d'entraînement des coefficients de données (AD) avec P=20.....	99
<b>Figure IV.10.</b>	Meilleure performance d'entraînement des coefficients de données (BE) avec P=20.....	99
<b>Figure IV.11.</b>	Meilleure performance d'entraînement des coefficients de données (BC) avec P=20.....	100
<b>Figure IV.12.</b>	Meilleure performance d'entraînement des coefficients de données (BD) avec P=20.....	100
<b>Figure IV.13.</b>	Meilleure performance d'entraînement des coefficients de données (CE) avec P=20.....	101
<b>Figure IV.14.</b>	Meilleure performance d'entraînement des coefficients de données (AE) avec P=13.....	101
<b>Figure IV.15.</b>	Meilleure performance d'entraînement des coefficients de données (AC) avec P=13.....	102
<b>Figure IV.16.</b>	Meilleure performance d'entraînement des coefficients de données (AD) avec P=13.....	102
<b>Figure IV.17.</b>	Meilleure performance d'entraînement des coefficients de données (BE) avec P=13.....	103
<b>Figure IV.18.</b>	Meilleure performance d'entraînement des coefficients de données (BC) avec P=13.....	103
<b>Figure IV.19.</b>	Meilleure performance d'entraînement des coefficients de données (BD) avec P=13.....	104
<b>Figure IV.20.</b>	Meilleure performance d'entraînement des coefficients de données (CE) avec	

	P=13.....	104
<b>Figure IV.21.</b>	Meilleure performance d'entraînement des coefficients de données (AE) avec P=10.....	105
<b>Figure IV.22.</b>	Meilleure performance d'entraînement des coefficients de données (AC) avec P=10.....	105
<b>Figure IV.23.</b>	Meilleure performance d'entraînement des coefficients de données (AD) avec P=10.....	106
<b>Figure IV.24.</b>	Meilleure performance d'entraînement des coefficients de données (BE) avec P=10.....	106
<b>Figure IV.25.</b>	Meilleure performance d'entraînement des coefficients de données (BC) avec P=10.....	107
<b>Figure IV.26.</b>	Meilleure performance d'entraînement des coefficients de données (AD) avec P=10.....	107
<b>Figure IV.27.</b>	Meilleure performance d'entraînement des coefficients de données (CE) avec P=10.....	108

---

# LISTE DES TABLEAUX

---

<b>Table I.1</b>	Les principales fonctions des lobes.....	7
<b>Table I.2</b>	Classification des crises épileptiques proposées par la Ligue internationale contre l'épilepsie.....	10
<b>Table I.3</b>	Classification de Syndrome selon ILAE.....	11
<b>Table I.4</b>	Les étiologies des crises d'épilepsie.....	14
<b>Table I.5</b>	l'activité rythmique de cerveau.....	24
<b>Table II.1</b>	Diverses méthodes de détection et de classification d'épilepsie avec ses paramètres de performance. ....	38
<b>Table II.2</b>	Tableau de contingence utilisé pour évaluer les performances d'un algorithme de détection par rapport au résultat de l'expérience.....	46
<b>Table IV.1</b>	Résumé du jeu de données de Bonn.....	93
<b>Table IV.2</b>	Résultats de la classification en utilisant (Burg et SVM) .....	94
<b>Table IV.3</b>	La moyenne des mesures de performance de la première expérience (Burg et SVM).....	95
<b>Table IV.4</b>	Résultats de la classification en utilisant (Burg - SAE et SVM).....	95
<b>Table IV.5</b>	La moyenne des mesures de performance de la deuxième expérience (Burg-SAE et SVM).....	96
<b>Table IV.6</b>	Mesures de performance pour étudier l'effet de la longueur du signal EEG sur les performances de la classification.....	109
<b>Table IV.7</b>	Comparaison entre les précisions de la méthode proposée et d'autres méthodes à partir des littératures utilisant différents ensembles de données épileptiques.....	110

---

# **INTRODUCTION GÉNÉRALE**

---

L'épilepsie est l'une des maladies neurologiques les plus répandues et les plus dévastatrices dans le monde. Le signe distinctif de l'épilepsie, est les crises récurrentes appelées «crises d'épilepsie». Dans l'épilepsie, le comportement normal de l'activité neuronale devient perturbé, provoquant d'étranges sensations, émotions et changement de comportements, ou parfois des convulsions, des spasmes musculaires et une perte de conscience. Il peut y avoir une sorte de «tempête» électrique brève découlant de neurones qui sont intrinsèquement instables à cause d'un défaut génétique (comme dans les divers types d'épilepsie héréditaire), ou de neurones rendus instables par des anomalies métaboliques, tels que l'hypoglycémie ou l'alcool. Alternativement, la décharge anormale peut provenir d'une zone localisée du cerveau (c'est le cas chez les patients souffrant d'épilepsie causée par une blessure à la tête ou une tumeur au cerveau). Pendant une crise, les neurones peuvent tirer jusqu'à 500 fois par seconde, beaucoup plus rapidement que la normale (1-100  $\mu\text{V}$ ). Chez certaines personnes, cela arrive seulement de temps en temps; pour d'autres, cela peut arriver jusqu'à des centaines de fois par jour.

Depuis longtemps, cette pathologie a été considérée comme une maladie démoniaque empêchant ainsi toute progression scientifique. Les préjugés négatifs qui entourent la maladie sont des obstacles à la bonne prise en charge des malades, leur épanouissement et leur intégration sociale. Par la suite, c'est au début du dix-huitième siècle que Tissot avait abordé cette maladie sous une approche scientifique dans un traité d'épilepsie en 1770. Puis, vers la fin du 18<sup>ème</sup> siècle, l'avancée technologique dans le domaine médical a contribué à la compréhension de cette maladie de manière objective. Dans cette ère moderne, l'invention qui a le plus marqué la compréhension et l'interprétation de l'épilepsie est celle de Hans Berger en 1924. En effet, ce dernier a mis en place un appareil dénommé électroencéphalographe (EEG) qui permet de recueillir l'activité électrique du cerveau en surface avec un appui des outils de la physique moderne.

L'électroencéphalogramme (EEG) est un enregistrement multicanal de l'activité électrique générée par un certain nombre de neurones dans le cerveau en utilisant plusieurs électrodes placées dans différents endroits du cerveau. Dans la pratique clinique, l'EEG a été un outil fondamental en particulier dans le diagnostic de l'épilepsie. L'analyse est réalisée par l'épileptologiste observant l'EEG en continu. Néanmoins, l'examen visuel prend du temps et

peut s'avérer inefficace. La détection automatique dans le signal EEG est un outil de base qui facilite le diagnostic de l'épilepsie et améliore la gestion des enregistrements EEG. Depuis les années 1970, une attention considérable a été accordée à la détection automatique des crises.

L'extraction des caractéristiques qui décrit le comportement des signaux EEG est une phase importante pour la détection des crises. Pour obtenir les meilleures performances du classificateur, l'étape d'extraction des caractéristiques doit diminuer le signal d'origine à une dimension inférieure qui contient le maximum d'informations comprises dans le signal d'origine. Étant donné que la performance de la classification sera insatisfaisante si les caractéristiques ne sont pas bien sélectionnées, il est fortement recommandé de trouver les principales caractéristiques qui représentent l'ensemble des données.

D'après la littérature, plusieurs types d'extraction de caractéristiques des données EEG épileptiques ont été proposés. Les méthodes d'extraction de caractéristiques peuvent être classées en quatre groupes: méthodes paramétriques, méthodes non paramétriques, méthodes temps-fréquence et méthodes du vecteur propre. D'autres détecteurs ont utilisé une combinaison de plus d'une technique.

Une fois que l'étape d'extraction des caractéristiques a été effectuée et en supposant que les caractéristiques extraites sont appropriées pour distinguer entre les états d'EEG (épileptique ou non épileptique), l'information est utilisée pour décider à quelle classe ces caractéristiques appartiennent. Une étape de prise de décision et une classification des données dans l'espace des caractéristiques sont donc nécessaires.

L'objectif de la classification est de décrire une limite entre les classes et de les étiqueter en fonction de leurs caractéristiques mesurées. Le classificateur peut être aussi simple que de fixer un seuil pour les caractéristiques ou plus sophistiqué, tels que les algorithmes d'apprentissage automatique. Dans un espace de caractéristiques multidimensionnel, cette limite est convertie en un hyperplan de séparation. Le but est de trouver l'hyperplan qui a la distance maximale de toutes les classes.

Plusieurs techniques de classification et de clustering ont été développées. Parmi elles, les règles d'association, ANNs, LDA, la modélisation de Markov cachée (HMM), k-means clustering, la logique floue, et les SVM ont été appliquées à la détection de la crise épileptique.

Bien que les méthodes existantes atteignent une excellente précision dans certains cas, elles ont été jugées insuffisantes pour apprendre et classifier les signaux EEG qui sont

complexes et non stationnaires. De plus, les choix de méthode d'extraction de caractéristiques jouent un rôle important dans les performances de classification.

### **Contribution de la thèse**

L'objectif de la thèse est d'introduire un nouveau cadre pour la détection automatique et la classification des crises d'épilepsie en utilisant une méthode paramétrique appelée modèle autorégressif (AR) avec un autoencodeur clairsemé (Sparse Autoencoder (SAE)) basé sur l'apprentissage en profondeur. Cependant, le modèle AR a été utilisé dans l'extraction de caractéristiques des signaux EEG. Cela permet de sélectionner des coefficients qui peuvent être utilisés directement par les algorithmes de classificateurs. En outre, la modélisation AR est un outil très utile pour les signaux qui ont une résolution haute fréquence et les spectres plus lisses. Dans cette méthode, l'algorithme de Burg a été utilisé pour estimer les coefficients du modèle du signal EEG d'entrée. Ces coefficients obtenus ont été améliorés par un autoencodeur clairsemé. Ensuite, le résultat de SAE a été utilisé comme entrée dans le classificateur SVM.

### **Organisation de la thèse**

Le plan de cette thèse est le suivant :

Le **chapitre 1**, vise à fournir au lecteur un bref aperçu des notions anatomiques et physiologiques. En outre, il décrit l'épilepsie, ensuite brièvement les techniques d'imagerie cérébrale les plus courantes qui ont été développées jusqu'à présent dans la littérature pour le diagnostic de l'épilepsie. Enfin, il introduit les concepts fondamentaux de l'électroencéphalogramme.

Le **chapitre 2**, explore l'état de l'art des techniques de détection de crise d'épilepsie présentées dans la littérature. Au début, il met en lumière les systèmes de diagnostic assistés par ordinateur, il discute également les étapes du système de détection pour fournir au lecteur non familiers des informations de fond. Ensuite, il décrit une comparaison des performances des algorithmes de détection de crises populaires développés au cours de la dernière décennie. En outre, ce chapitre investigate les bases de données existantes dans la littérature. Enfin, les critères d'évaluations d'efficacité des algorithmes de détection automatique seront le dernier objectif du chapitre.

**Le chapitre 3**, décrit la contribution de ce travail qui consiste à proposer un nouveau cadre basé sur l'utilisation d'une technique paramétrique appelée modèle autorégressif (AR) pour l'extraction des caractéristiques, notre contribution concerne à l'amélioration des coefficients obtenus de l'algorithme de Burg en introduisant un autoencodeur clairsemé (Sparse Autoencoder (SAE)). Cette contribution est exposée en détail, enfin, le classificateur Machines à Vecteurs de Support (SVM) sera présenté brièvement.

**Le chapitre 4**, présente en premier lieu la base de données utilisée dans ce travail, ensuite, les résultats obtenus de différentes expérimentations qui seront abordés et discutés et enfin, nos résultats expérimentaux en termes de précision de classification ont été comparés aux méthodes existantes utilisant la même base de donnée.

A la fin, dans une conclusion générale, nous repositionnons l'ensemble de nos développements en regard de l'objectif initial de l'étude : "La détection automatique des crises d'épilepsie, en utilisant un autoencodeur clairsemé pour améliorer les caractéristiques du signal EEG issus de l'algorithme de Burg". Nous résumons à ce stade les principaux résultats de notre étude. Nous abordons enfin une discussion sur les perspectives de travail qui découlent de cette thèse.

CHAPITRE

I

**CONTEXTE MÉDICAL**

## **I.1. INTRODUCTION**

Ce chapitre présente les notions anatomiques et physiologiques de base liées à cette thèse, ces notions sont nécessaires à la compréhension de la démarche scientifique. L'épilepsie sera décrite aussi bien sur le plan neurophysiologique et médicale ainsi que les différentes modalités pouvant intervenir au cours d'un diagnostic et enfin une présentation de la technique utilisée dans notre recherche qui est l'EEG.

## **I.2. LE CERVEAU**

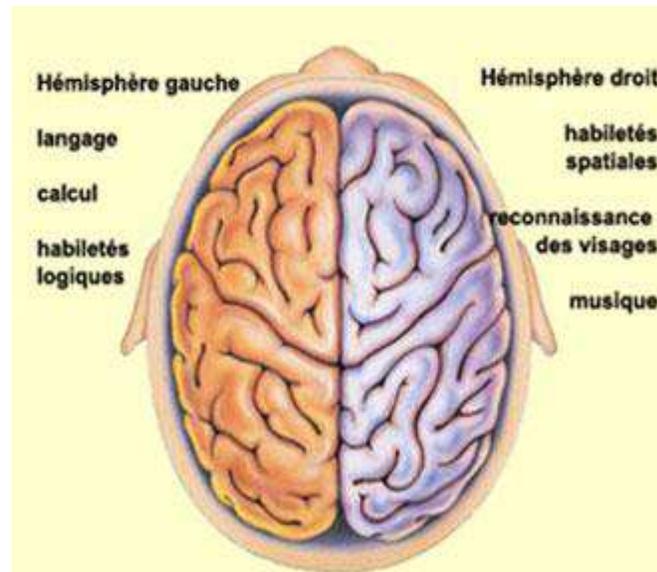
### **I.2.1. Notre cerveau**

Le cerveau humain a la même structure générale que le cerveau des autres mammifères. Il fait partie du système nerveux central. Il agit comme un centre de commande de la planification, le langage, de la pensée, de la perception, de la mémoire, le mouvement volontaire et de la parole [Fournier, 2011; Seron et al., 1998].

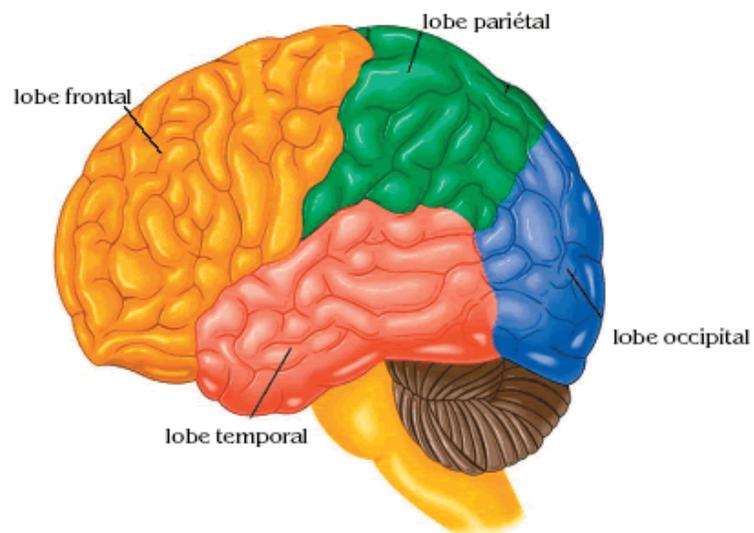
Le cerveau est protégé par la barrière hémato-encéphalique et les os épais du crâne et il baigne dans le liquide céphalorachidien, il ne représente que 2% du poids total du corps mais consomme 20% de son énergie.

### **I.2.2. Structure du cerveau**

Physiologiquement, le cerveau est divisé en deux hémisphères cérébraux qui forment les parties les plus volumineuses du cerveau ; un hémisphère droit et un hémisphère gauche. (Figure I.1) l'hémisphère droit possède une perception du monde plus spatiale, globale et intuitive. Il permet la reconnaissance des formes et des visages, et c'est lui qui nous fait comprendre et apprécier l'art, la musique, ou la beauté de la nature. Alors que L'hémisphère gauche qui participe au fonctionnement de la partie droite du corps humain. Il contrôle la parole, l'écriture, le calcul...etc. Chaque hémisphère est lui-même partagé en quatre zones appelées lobes, dans lesquels ces différentes fonctions sont gérées: Le lobe frontal, le lobe pariétal, le lobe temporal et le lobe occipital (voir (Figure I.2)). Ces lobes ont des fonctions principales qui sont présentées dans le tableau (Table I.1) [Vanghuchten, 1906]:



**Figure I.1.** Les deux hémisphères cérébraux (lapsychologie.weebly.com)



**Figure I.2.** Représentation des quatre lobes de l'hémisphère (frcneurodon.org)

**Table I.1.** Les principales fonctions des lobes.

<b>Lobe</b>	<b>Fonction</b>
<b>Lobe frontal</b>	<b>Contrôle</b> : la parole et langage, raisonnement, mémoire, prise de décision, personnalité, jugement, mouvements. <b>Remarque</b> : Le lobe frontal droit gère les mouvements du côté gauche du corps, et inversement, le lobe frontal gauche gère les mouvements du côté droit.
<b>Lobe pariétal</b>	<b>Contrôle</b> : La lecture, repérage dans l'espace, sensibilité. <b>Remarque</b> : Le lobe pariétal droit gère la sensibilité du côté gauche du corps et réciproquement
<b>Lobe occipital</b>	<b>Contrôle</b> : la vision.
<b>Lobe temporal</b>	<b>Contrôle</b> : le langage la mémoire et les émotions.

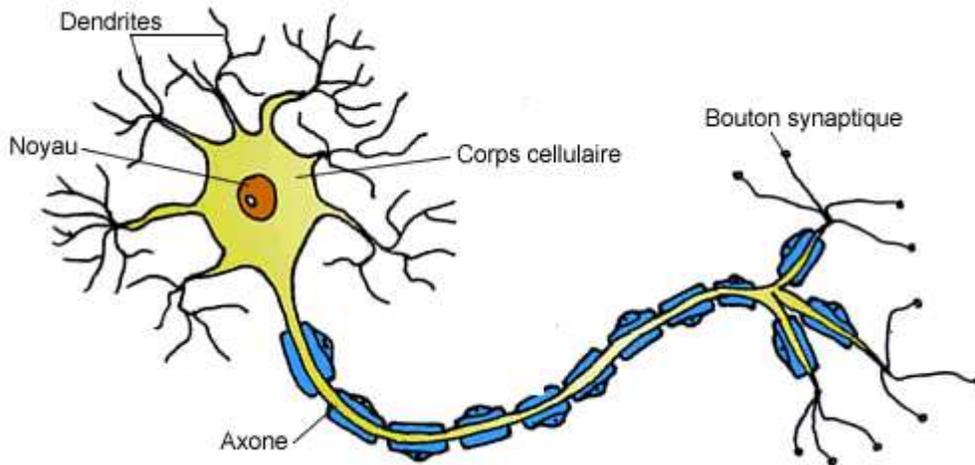
### I.2.3. Les neurones et l'activité électrique

Le cerveau humain compte environ 100 milliards de neurones qui se divisent en 100 à voir 1000 types de neurones. Chacun est capable d'établir jusqu'à 10.000 connexions et possède un poids aux environs de 1300 à 1400 grammes. Ils représentent l'unité du traitement du cerveau. Ces derniers sont caractérisés par une structure particulière et ont leurs activités chimiques.

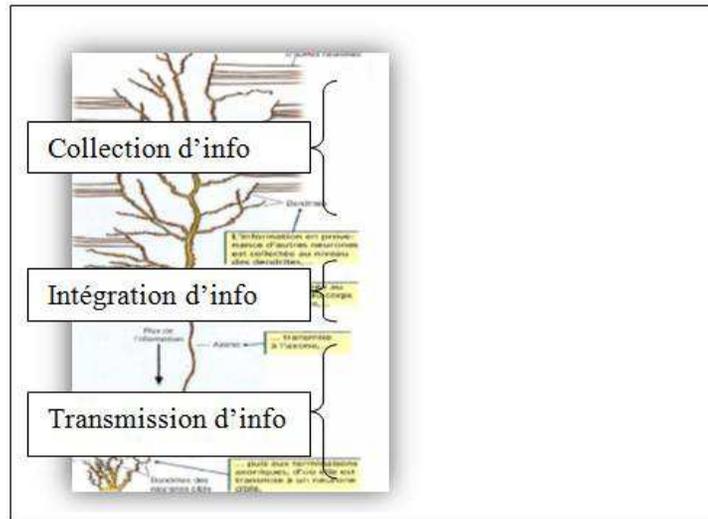
Le neurone est composé de trois organes : Les dendrites qui sont des expansions qui entourent le corps cellulaire, le soma qui est le corps du neurone et l'axone qui est aussi une expansion du corps cellulaire, mais il est plus long que les dendrites (Figure I.3). En effet son rôle principal est de recevoir, traiter et transmettre l'information (Figure I.4).

Ce processus est réalisé au niveau des synapses qui représentent l'unité structurale et fonctionnelle. Ce fonctionnement est d'une nature biochimique et électrique qui est caractérisé par le transport d'ion de sodium entre le milieu intra et extracellulaire, crée une impulsion électrique appelée soit potentiel d'action soit des potentiels post-synaptiques. Ce potentiel se

transmet de la dendrite vers le soma. Lorsque le potentiel interne dépasse un seuil d'activation, on parle alors de décharge électrique [Changeux, 1983].



**Figure I.3.** Schéma d'un neurone et ses principales composantes (tpehandisportbergson.sitew.fr)



**Figure I.4.** Fonction des neurones (F.wendling, 2008)

Selon les lois de Maxwell, l'ensemble des courants qui circulent dans les tissus nerveux cérébraux produit une distribution de potentiel dans les volumes conducteurs voisins. Cette

distribution de potentiel peut être mesurée sur le scalp grâce aux différentes techniques de diagnostic cérébral [Froger et al., 2006].

### **I.3. L'ÉPILEPSIE**

#### **I.3.1. Que ce que c'est l'épilepsie ?**

Depuis 2005, l'épilepsie est définie par la ligue internationale contre l'épilepsie (ILAE) comme une affection neurologique qui se caractérise par des crises récurrentes se manifestant par de brefs épisodes de tremblements involontaires liées à une décharge anormale, excessive et hypersynchrone d'une population plus ou moins étendue de neurones du cortex cérébral [Fisher et al., 2005]. Elles peuvent toucher une partie ou l'ensemble du corps.

La maladie d'épilepsie est définie par la répétition de crises chez le même sujet. Une crise épileptique unique ou la répétition dans le cadre d'une affection cérébrale aiguë ne constitue donc pas une maladie épileptique, il s'agit de crises accidentelles accompagnant un dysfonctionnement transitoire et réversible du système nerveux central [Fisher et al. 2014].

#### **I.3.2. Classification des crises et syndrome épileptique**

La classification des épilepsies et des syndromes épileptiques faite par la LICE dépend de deux critères : selon le caractère de la crise «généralisé» (les crises intéressent d'emblée les deux hémisphères cérébraux touche 30 à 40% des épileptiques), ou «partiel» (les crises n'intéressent qu'une population limitée de neurones touche 60 à 70% des épileptiques), et selon leur étiologie (idiopathiques, symptomatiques ou cryptogéniques) [Engel, 2006; Berg et Scheffer, 2011].

Les épilepsies idiopathiques sont des épilepsies sans lésion cérébrale et ayant des causes génétiques complexes et qui touchent principalement les enfants [Angeles, 1981], au contraire des épilepsies idiopathiques, les épilepsies symptomatiques et cryptogéniques sont dues à des lésions cérébrales identifiables pour la première et non identifiable pour la deuxième [DRAVET, 2005].

### I.3.2.1. Différents type de crise

La classification internationale des crises épileptiques distingue trois groupes principaux, cette classification est résumée dans le tableau 2 (Table I.2) [Engel et Jerome, 2006 ; Gevrey, 2007] :

**Table I.2.** Classification des crises épileptiques proposées par la Ligue internationale contre l'épilepsie

#### **Crises partielles (crises focales)**

##### **1. Crises partielles simples (sans rupture de conscience)**

- a. Avec signes moteurs
- b. Avec signes somato-sensitifs ou sensoriels
- c. Avec signes végétatifs
- d. Avec signes psychiques
- e. Formes mixtes

##### **2. Crises partielles complexes (avec altération de la conscience)**

- a. A début partiel simple, suivi de troubles de la conscience et/ou d'automatisme
- b. Avec troubles de la conscience dès le début de la crise, accompagnée ou non d'automatismes

##### **3. Crises partielles secondairement généralisées**

- a. Crises partielles simple secondairement généralisées
- b. Crises partielles complexes secondairement généralisées (représente ~60% des crises)

crises partielles simples évoluant vers une crise partielle complexe puis vers une généralisation secondaire

##### **4. Crises d'emblée généralisées**

- a. Crises toniques
- b. Crises tonico-cloniques (=grand mal) (représentent ~30% des crises)
- c. Crises atoniques

##### **5. Crises non classées**

**Les crises partielles (focales)**

Les crises partielles ne se manifestent que dans une partie du cerveau. Environ 60% des épileptiques souffrent de crises partielles. Ces crises portent souvent le nom de leur foyer épileptogène dans le cerveau. En cas de crise partielle simple, le patient ne perd pas connaissance et peut ressentir des sensations inhabituelles ou désagréables diverses et variées. Le patient peut également entendre, sentir par l'odorat ou le goût, voir ou ressentir des choses qui ne sont pas réelles.

**Les crises partielles complexes (focales)**

Les crises partielles complexes ne durent le plus souvent que quelques secondes. Elles provoquent une perte de connaissance ou une altération de la conscience. On peut également assister à des états proches du traumatisme et à des comportements étranges répétés comme des clignements des yeux, des convulsions, des mouvements de la bouche ou voir le patient courir en rond.

**Crises généralisées**

Les crises généralisées sont la conséquence d'une altération de l'activité des neurones dans de nombreuses parties du cerveau. Ces crises peuvent provoquer une perte de connaissance, des chutes ou des convulsions musculaires massives. Les crises commencent parfois comme des crises partielles et se propagent ensuite à tout le cerveau.

**I.3.2.2. Syndrome épileptiques**

Un certain nombre de syndromes épileptiques ont été individualisés, caractérisés par le contexte clinique, les symptômes épileptiques, et les résultats de l'électro-encéphalogramme, le tableau 3 (Table I.3) résume la classification de syndrome épileptique selon ILAE.

**Table I.3.** Classification de Syndrome selon ILAE

<p><b>1. Epilepsie et syndromes épileptiques focaux</b></p> <p>a. Idiopathique (Liés à l'âge) :</p> <ul style="list-style-type: none"><li>• Epilepsie bénigne de l'enfance avec pointe centro-temporales</li><li>• Epilepsie de l'enfance à paroxysme occipitaux</li><li>• Epilepsie primaire de la lecture</li></ul> <p>b. Symptomatiques :</p> <ul style="list-style-type: none"><li>• Epilepsie partielle continue de l'enfance (syndrome de Kojewnikow)</li><li>• Epilepsie partielle reflexe</li><li>• Epilepsie lobaire</li></ul> <p>c. Cryptogéniques</p> <ul style="list-style-type: none"><li>• Epilepsie dont l'origine reste inconnue</li></ul> <p><b>2. Epilepsie et syndromes épileptiques généralisés</b></p> <p>a. Idiopathiques (Liés à l'âge, et dans chronologique)</p> <ul style="list-style-type: none"><li>• Convulsions néonatales familiales bénignes</li><li>• Convulsions néonatales familiales bénignes</li><li>• Epilepsie myoclonique bénigne de l'enfance</li><li>• Epilepsie-absence de l'enfance</li><li>• Epilepsie-absence de l'adolescence</li><li>• Epilepsie myoclonique juvénile</li><li>• Epilepsie à crise grand mal du réveil</li><li>• Epilepsie à crise précipitées par certaines modalités spécifiques</li><li>• Autre épilepsie idiopathiques généralisées non définies précédemment</li></ul> <p>b. Cryptogéniques ou symptomatiques (liés à l'âge, et dans l'ordre chronologique)</p> <ul style="list-style-type: none"><li>• Syndrome de West (spasmes infantiles)</li><li>• Syndrome de Lennox-Gastaut</li><li>• Epilepsie avec crise myoclonico-astatique</li></ul>
--

- Epilepsie avec absence myocloniques
- Epilepsie avec absences myocloniques
- c. Symptomatiques
  - Sans étiologie spécifique
    - ✓ Encéphalopathie myoclonique précoce
    - ✓ Encéphalopathie infantiles précoce avec suppression-bursts
  - Syndromes spécifiques
    - ✓ Les crises peuvent compliquer un grand nombre de maladies ou syndromes que l'on classe ici
- 3. Epilepsie ou syndromes dont le caractère localisé ou généralisé n'est pas déterminé**
  - a. Avec association de crise généralisées et partielle
    - Crise néonatale
    - Epilepsie myoclonique sévère
    - Epilepsie avec pointes-ondes continues pendant le sommeil lent
    - Epilepsie avec aphasie acquise (syndrome de Landau-Kleffner)
  - b. Sans caractères généralisés ou focaux certains
- 4. Syndromes spéciaux**
  - a. Crises occasionnelles, liées à une situation épileptogène transitoire
    - ✓ Convulsion fébriles
    - ✓ Crises uniquement précipitées par un facteur toxique ou métabolique
  - b. Crises et états de mal isolés

### **I.3.3. Éthologie de la maladie**

Les causes de l'épilepsie sont souvent difficiles à déterminer car elles sont multiples et variées. Selon la classification d'ILAE, on distingue l'épilepsie idiopathique ou (génétique), et symptomatique ou (structurel/métabolique), il existe aussi l'épilepsie cryptogénique qui regroupe

toute celle d'origine inconnue, le tableau 4 (Table I.4) représente les différentes étiologies [Cisse, 2014].

**Table I.4.** Les étiologies des crises d'épilepsie

<p><b>1. Epilepsies idiopathiques</b></p> <ul style="list-style-type: none"><li>a. Par hérédité mendélienne</li><li>b. Par hérédité multifactorielle</li></ul> <p><b>2. Epilepsies symptomatiques</b></p> <ul style="list-style-type: none"><li>a. Malformations</li><li>b. Tumeurs</li><li>c. Hémorragie</li><li>d. Traumatismes</li><li>e. Infections (méningo-encéphalites)</li><li>f. Maladies dégénératives</li><li>g. Troubles électrolytiques / métaboliques</li><li>h. Intoxications</li><li>i. ALCOOL : en particulier lors du sevrage</li></ul> <p><b>3. Epilepsies cryptogéniques</b></p> <p>Elles regroupent toutes celles dont l'origine est inconnue</p>
--

### **I.3.4. Techniques d'investigation**

Pour le diagnostic de l'épilepsie différents examens sont demandés, on trouve l'exploration électrophysiologique (l'électroencéphalogramme (EEG)) qui est l'outil le plus utilisé, la magnétoencéphalographie et l'exploration anatomique et fonctionnelle qui est dominée par l'Imagerie par Résonance Magnétique (IRM) et par l'Imagerie par Résonance Magnétique fonctionnelle (IRMf) qui sont généralement utilisées pour un bilan chirurgical [Caparos, 2006]. Les différentes techniques d'imagerie médicale sont différenciées l'une à l'autre selon trois critères : (i) leur résolution spatiale. (ii) leur résolution temporelle et (iii) degré d'invasivité (Figure I.5).

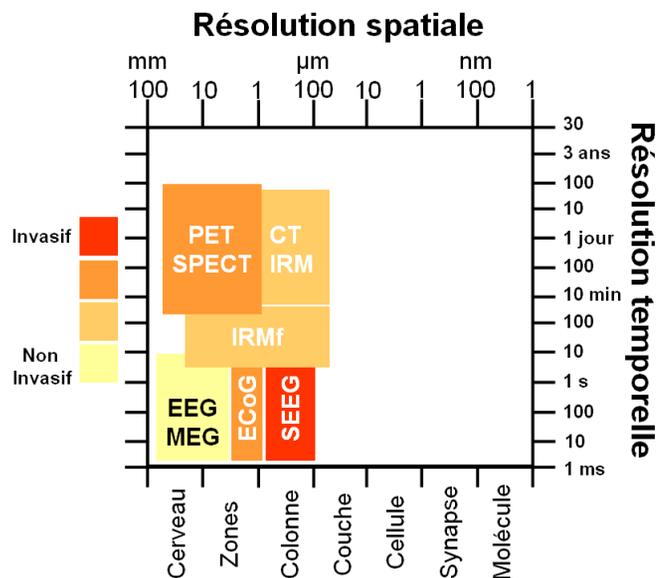


Figure I.5. : Schéma comparatif des différentes techniques d’exploration (Caparos, 2006)

### I.3.4.1. L’exploration électrophysiologique

#### I.3.4.1.a. L’électroencéphalogramme

L’E.E.G joue un rôle crucial dans le diagnostic de l’épilepsie. Cet examen est incontournable pour le diagnostic et la classification des épilepsies car il fournit des informations en temps réel et avec une excellente résolution temporelle de l’ordre de la milliseconde par rapport aux autres techniques d’enregistrement. La justesse de cette orientation syndromique initiale peut être déterminante pour le choix d’une thérapeutique adaptée. L’E.E.G permet aussi de surveiller l’épilepsie lorsqu’il existe une modification de la symptomatologie ou de la fréquence des crises lorsqu’un arrêt du traitement est envisagé [Holmes, 2008; Halgren et al., 1995].

### **I.3.4.1.b. La magnétoencéphalographie**

La magnétoencéphalographie (MEG) est une technique de mesure des champs magnétiques induits par l'activité électrique des neurones du cerveau [Agirre-Arrizubieta et al.,2009].

Notamment offre aux scientifiques de mesurer l'activité du cerveau en temps réel. Les champs magnétiques mesurés à la surface du scalp sont très faibles de l'ordre de 10 femto-Teslas (1fT=10-15 Tesla), comparé avec le champ magnétique terrestre qui est de 10milliards de fois plus grand. Pour la mesure de champ magnétique, la MEG utilise un appareillage basé sur des magnétomètres à SQUID (Superconducting Quantum Interference Devices) placé dans une pièce isolée magnétiquement par du mu-métal qui sont refroidis à l'hélium [Seron et al. 1998].

### **I.3.4.2. L'exploration anatomique et fonctionnelle**

Les explorations anatomique et fonctionnelle permettent de détecter les structures cérébrales endommagées et donc de localiser la lésion responsable qui génère les crises, elles jouent aussi un rôle dans la compréhension des mécanismes physiopathologiques de l'Epilepsie.

#### **I.3.4.2.a. Tomodensitométrie ou scanner cérébral**

Le scanner est un examen radiologique également appelé tomodensitométrie ou TDM son rôle est la visualisation des vaisseaux sanguins et les différentes structures cérébrales. L'utilisation du scanner en épileptologie a diminué depuis l'apparition et l'évolution des techniques d'imagerie par résonance magnétique, car la sensibilité du TDM pour détecter des lésions associées à l'épilepsie est assez faible, environ 15 à 35 %, et est liée à la nature d'épilepsie, de l'âge de début de la maladie et de la présence de signes neurologiques associés. Généralement, il est indiqué en cas de première crise associée à des signes neurologiques focaux [Adam et al., 2000].

#### **I.3.4.2.b. Imagerie par résonance magnétique**

L'IRM est une technique d'imagerie médicale très dominante. Cette technique est utilisée pour faire un diagnostic précis sur le plan anatomique structurel, permettant d'avoir une vue 2D avec éventuellement un effet de 3D d'une partie du corps, notamment du cerveau. Cette technique est basée sur les principes de la résonance magnétique nucléaire (RMN). Cette modalité a été une révolution importante en imagerie médicale considérant son excellente résolution spatiale (de

l'ordre du millimètre) et une résolution temporelle moyenne (l'ordre de la seconde). Dans le cas d'un dépistage de l'épilepsie, l'IRM reste le seul examen anatomique à réaliser et il est aussi la modalité la plus utilisée pour la recherche et le suivi de l'évolution d'une lésion cérébrale à l'origine de l'épilepsie car sa sensibilité pour la détection d'une anomalie en épilepsie peut atteindre les 90 % [Adam et al. 2000].

#### **I.3.4.2.c. Imagerie fonctionnelle**

Les techniques d'imagerie fonctionnelle permettent de localiser le foyer épileptogène et aide à la compréhension des mécanismes physiopathologiques de l'épilepsie, elles sont utilisées dans le cas d'épilepsies partielles et réfractaires afin de proposer une intervention chirurgicale.

Ces techniques se divisent en deux catégories, celles qui sont pratiquées dans les services de médecine nucléaire, ce type est basé sur l'injection d'un isotope (La Tomographie par Emission de Position (TEP), la Tomographie d'Emission Monophotonique (TEMP), la Spectroscopie RMN) et l'IRM fonctionnelle qui est pratiquée dans les services de radiologie [Bouilleret et Dupont, 2003].

##### **a) Imagerie par résonance magnétique fonctionnelle (IRMf)**

L'IRM fonctionnelle est une technique qui permet de détecter l'activité fonctionnelle de cerveau également quand l'être humain effectue certaines tâches bien définies, son objectif est de localiser ces régions afin de ne pas les endommager lors de la chirurgie. Cette technique est prometteuse en évolution permettrait de détecter les aires fonctionnelles du cerveau au cours du temps et de manière non invasive. Elle possède une résolution spatiale de 3 à 4 mm et une résolution temporelle de l'ordre d'une seconde [Attia et al ,2016].

##### **b) La Tomographie par Emission de Position (TEP)**

La tomographie par émission de positons (TEP) permet d'obtenir des images du flux sanguin, du métabolisme et des systèmes de neurotransmission. Cette technique est souvent utilisée pour localiser le foyer de l'épilepsie partielle pharmaco-résistante [Lomena, 2008].

**c) La Tomographie d'Emission Monophotonique (TEMP)**

La Tomographie d'Emission Monophotonique consiste à injecter un traceur radioactif que l'on va pouvoir ensuite suivre au travers d'une succession d'images prises à différents instants [Amann, 2006].

**d) La Spectroscopie RMN**

La spectroscopie RMN est une technique non invasive qui nous fournit des informations métaboliques et biochimie du cerveau. Elle très efficace dans la caractérisation métabolomique des tissus épileptogènes [Cérébrale, 1998].

**I.3.5. Traitement**

Le but du traitement est de supprimer les crises ou réduire leur fréquence. Il est basé sur le type du syndrome, son intensité et son origine.

**Traitement médicamenteux**

Autour de 80% des épileptiques peuvent être traitées par des médicaments. Il existe de nombreux médicaments (antiépileptiques) pour traiter l'épilepsie, le médicament et sa posologie sont prescrits par le neurologue. La monothérapie est généralement recommandée. Pour les cas les plus complexes, l'association de deux médicaments peut offrir une meilleure efficacité thérapeutique [Roger et al., 2010] .

**Traitement par stimulation électrique**

Ce traitement est recommandé aux patients dont le traitement médicamenteux offre des résultats insuffisants. Il s'agit d'implanter un stimulateur électrique sous la clavicule gauche, et relié à des électrodes fixées sur le nerf. Cette intervention est réalisée sous anesthésie générale par un neurochirurgien [Roux et al., 2008].

**Traitement chirurgical**

Les 20% des personnes atteintes d'épilepsie résistent aux médicaments (on parle d'épilepsie pharmaco-résistant). Pour certains d'entre eux (5 à 10%) la chirurgie est possible. Lors de

l'intervention, le neurochirurgien essaye de réséquer le foyer épileptique, il existe deux types de chirurgie [Devaux et al. 2008] :

**La chirurgie curative:** elle est recommandée dans le cas d'épilepsie focale, son but est de supprimer les crises par l'ablation du foyer épileptique qui doit être bien identifié et se trouve dans une zone sans risque (pour ne pas endommager une zone fonctionnelle).

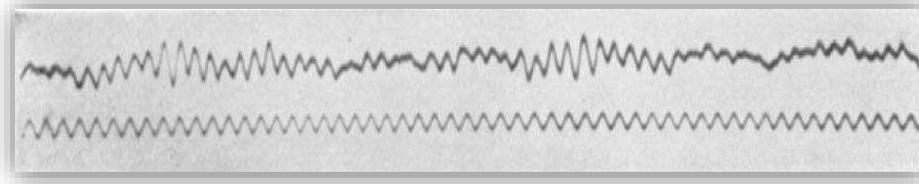
**La chirurgie palliative :** l'objectif de cette dernière est de réduire la fréquence ou la sévérité des crises en limitant la propagation des décharges épileptiques.

## I.4. EEG ET L'EXPLORATION CLINIQUE DE L'ÉPILEPSIE

### I.4.1. Rappel historique

L'électrophysiologie a été émergée en 1786 notamment le chercheur Galvani observe un mouvement chez une grenouille après contact avec deux plaques métalliques par l'expérience accidentelle. De plus il a découvert que le muscle était capable de générer un courant électrique en l'absence de tout métal [Goodwin et Hall, 1939]. A peu près un siècle pas de découverte dans le domaine.

En effet jusqu'à 1875 le biologiste RICHARD CATON, détecta chez les mammifères (le singe et le lapin) la présence de courants électriques via l'utilisation des électrodes placées sur leurs crânes attestés par des oscillations galvanométriques (activité électrique fluctuante à la surface du cortex cérébral) [Caton, 1875]. Après Hans Berger appliqua cette technique à l'homme dont il enregistra le premier signal EEG en 1929 sous forme de variation du potentiel (voir Figure I.6.). Il publia sa découverte de deux types d'activités électriques cérébrales quasi sinusoïdales qu'il dénomma "rythme alpha" et "rythme bêta" [Jasper et Andrews, 1936]. Ces travaux furent repris et complétés par Edger Douglas Adrian (obtient le prix NOBEL) ou il sera très facile de visualiser ces activités électriques sur papier. Les bases de l'examen sont toujours appliquées et la méthode est répandue dans la pratique médicale courante, en particulier dans la pratique épileptologique [Adrian et Mattheis, 1934].



**Figure I.6.** Le premier EEG enregistré par Hans Berger (Publié en 1929)

Cependant, l'enregistrement des premières crises d'épilepsie fut réalisé en 1938 par Gibbs [Gibbs F. A. et Gibbs E. L., 1946]. Ce n'est qu'après la seconde guerre mondiale, à la fin des années 1940, que les premières méthodes intrusives par électrodes profondes furent réalisées. Il fallut encore attendre les années 1950 pour que l'EEG soit couramment utilisé dans la pratique médicale, notamment dans le diagnostic de l'épilepsie.

#### **I.4.2. Le placement des électrodes**

L'emplacement est standardisé par une nomenclature internationale appelée «système 10/20» (Figure I.7). Chaque électrode porte un nom précis. Les chiffres pairs indiquent le côté droit, les impairs le côté gauche. Le nombre d'électrodes varie de 8 à 21, ce nombre peut être plus important selon les indications [Jasper,1958].

Le système 10/20 répond à des règles strictes:

- La ligne de départ de ce système est celle qui réunit le nasion et l'inion en passant par le vertex.
- Cette ligne est divisée en 6 parties: 10% de la longueur est portée au-dessus du nasion pour former le plan frontal et 10% au-dessus de l'inion pour le plan occipital, le reste est divisé en 4 parties égales représentant chacune 20% de la longueur totale.
- La symétrie doit être parfaite.

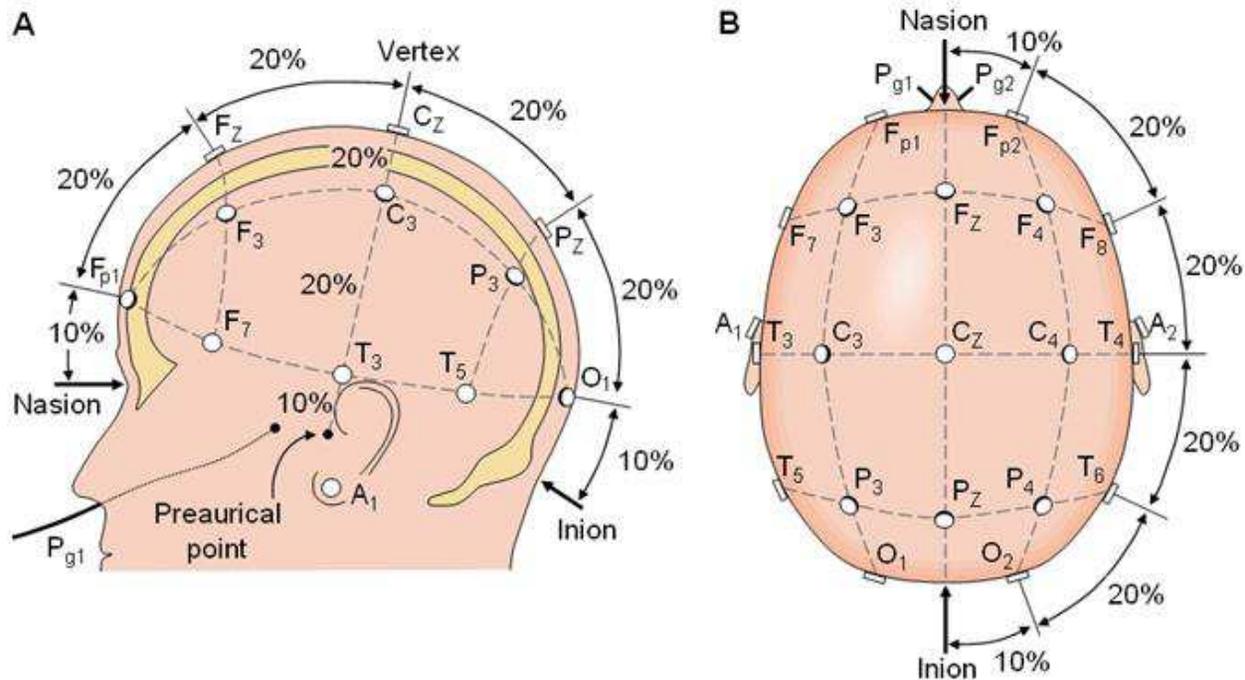


Figure I.7. Système 10-20, placement des électrodes (Sharbrough, 1991)

### I.4.3. Le montage des électrodes

Un montage vise à couvrir de façon parfaitement symétrique la surface du scalp, plusieurs montages sont effectués

- Le montage référentiel : c'est la différence de potentiel entre une électrode active et l'électrode la plus neutre possible. Chaque électrode du scalp est évaluée par rapport à cette électrode neutre.
- Le montage bipolaire antéropostérieur (ou longitudinal) explore d'avant en arrière et de droite à gauche.
- Le montage transverse explore de droite à gauche et d'avant en arrière.

### I.4.4. Déroulement et réalisation d'une expérience EEG

L'EEG est obtenu au moyen d'un ensemble d'électrodes placées sur la surface du scalp. L'information mesurée correspond à des différences de potentiel électrique entre deux électrodes. Le contact de ces électrodes avec la peau est fait en utilisant une pâte conductrice et elles sont

maintenues en place par un casque élastique. L'amplitude des signaux captés est faible, donc ils doivent être amplifiés, avec élimination des signaux indésirables grâce à des amplificateurs différentiels. Les signaux EEG sont alternatifs, plus ou moins sinusoïdaux, entrant dans la bande des fréquences basses: de 0,5 à 60 Hz.

L'étape d'enregistrement du signal peut prendre quelques minutes (~10mn) également peut se faire généralement dans les conditions suivantes (i) le sujet en état de repos et (ii) le sujet avec les yeux fermés (iii) le sujet avec yeux ouverts suivis de deux épreuves de stimulation.

Épreuve d'hyperpnée et épreuve de la stimulation lumineuse intermittente (SLI). Dont la première peut se faire respirer le sujet d'une durée de 3 à 5 minutes fortement avec une vitesse accélérée de respiration. Cette respiration ample, répétée de façon continue afin de provoquer une sensation de malaise avec parfois des nausées. Cette technique est utilisée car elle peut augmenter les anomalies EEG dans plusieurs types d'épilepsies et elle peut provoquer une crise épileptique partielle complexe. Alors que la deuxième épreuve (SLI) qui consiste à soumettre le sujet à des flashs lumineux avec une fréquence de rotation entre 1 et 30 tours par seconde. De plus elle permet d'identifier la photosensibilité, laquelle est la cause de certaines formes d'épilepsie. Cependant l'épreuve peut être réalisée parfois avec yeux fermés [Vion-Dury et Blanquet, 2011].

Il existe plusieurs techniques d'enregistrement d'EEG. Ces techniques sont émergées grâce à l'évolution technologique qui a un fort impact dans le domaine de l'électroencéphalographie également on peut mentionner les types suivants :

- EEG numérique : Une fois les signaux EEG sont amplifiés et filtrés. Elles sont converties en un signal numérique qui permet une visualisation sur un écran sous forme d'un tracé de variations dans le temps, ainsi la possibilité d'enregistrement de ces signaux par l'utilisation de support informatique. D'autres avantages comme un traitement à posteriori des signaux, un stockage et archivage des données, une transmission à distance en temps réel par télécommunications.
- Polysomnographie : c'est un examen médical effectué au cours du sommeil, qui consiste à enregistrer des variables physiologiques comme le rythme respiratoire, rythme cardiaque

afin de déterminer certains troubles liés au sommeil. L'enregistrement du signal EEG dans ce cas s'effectue sur une longue durée qui permet le bon suivi du sujet.

- Holter EEG : L'enregistrement du signal EEG sur appareillage portable permettant des enregistrements même à domicile surtout pour les handicapés.
- EEG vidéo : Le couplage de l'EEG avec des systèmes de surveillance comme l'enregistrement vidéo ce qui permet de mieux interpréter les événements du tracé.

#### I.4.5. L'activité rythmique

Le mot rythme désigne l'activité ou des ondes dont la période et la morphologie sont à peu près constantes. Les rythmes sont obtenus à partir de l'enregistrement d'un EEG, ils permettent de définir des bandes de fréquences. Cependant il est possible d'identifier et de différencier des activités électriques cérébrales rythmiques classées selon leur bande de fréquence (Figure I.8) qui, peut être décrite selon deux types de régularités:

- Des rythmes (dits de base) qui caractérisent l'état cérébral sur des périodes temporelles variables allant de quelques secondes à quelques minutes voire une heure.
- Une cyclicité approximativement circadienne d'évènements comportementaux et électriques, regroupés sous le nom générique d'état de vigilance [Delay et al., 1966].

Delta	Theta	Alpha	Beta	Gamma
0	4	8	12	24-32

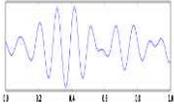
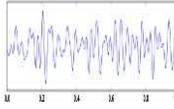
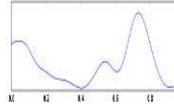
*Fréquence (Hz)*

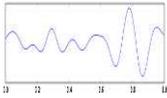
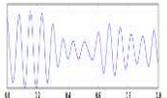
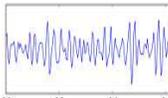
**Figure I.8.** Classification des rythmes en fonction de la fréquence (Montaine Bernard, 2002)

Comme on a vu, le cerveau est défini aussi par son activité rythmique, en effet au niveau du cortex cérébral on distingue plusieurs types d'activités en les résumant dans le tableau 5 (Table I.5).

Table I.5. L'activité rythmique de cerveau

	Alpha	Béta	Delta
Fréquence (Hz)	8 à 12	13 à 25	Inférieur à 4
Amplitude ( $\mu\text{V}$ )	20 à 50	5 à 10	>30
localisation	dominant sur les régions postérieures bilatérale et symétrique, mais extension fréquente aux aires pariétales et même frontales	Régions frontales, indiquent une activation globale du cortex.	Région frontal
Aspect	Ondes sinusoïdales régulières formant le plus souvent des fuseaux synchrones à droite et à gauche. génééré par interaction entre les populations neuronales corticales et certains noyaux thalamiques	Ondes sinusoïdales très peu amples, irrégulière, difficile à visualiser.	On distingue classiquement les ondes des monomorphes lents et réguliers, et les ondes polymorphes plus irrégulières plus lentes et moins amples
réactivité	C'est le rythme dit 'de repos' ;il survient quand le sujet est allongé, les yeux fermés à l'abri de toute stimulation	Rythme de l'adulte au repos et éveillé, il peut être bloqué lors de l'exécution volontaire d'un	

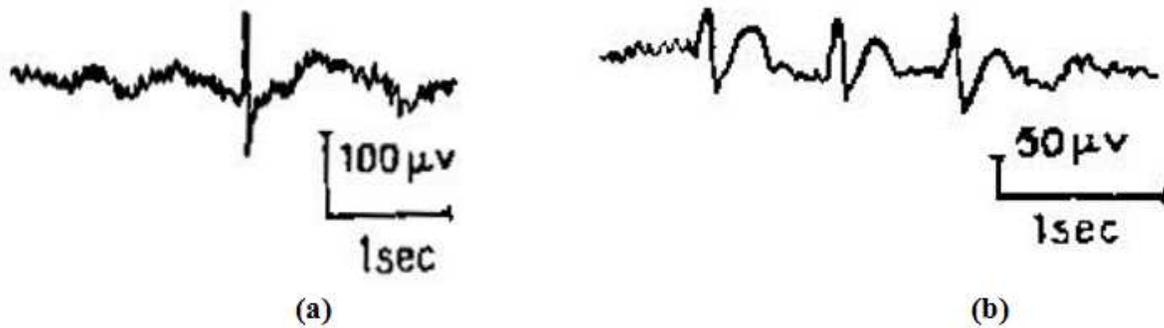
	sensorielle sans toutefois s'endormir. ce rythme est labile(bloqué par l'ouverture des yeux)	mouvement.	
	Dés l'âge de 7-8 ans.	Apparaît vers l'âge de 15 ans.	
Représentation			
	Théta	Mu	Gamma
Fréquence (Hz)	4 à 7	8 à 12	>30
Amplitude (µv)	50	Souvent supérieure au rythme alpha	
localisation	Régions temporales	Rolandique (regions centrales)	Régions frontales, indiquent une activation globale du cortex.
Aspect	Ondes sinusoïdales assez amples, il survient en général par bouffées fusiformes brèves et bilatérales.	survient en bouffée aspect en "arceaux" considérées comme étant caractéristiques du rythme alpha moteur.	

réactivité	Normalement présent mais peut abondant, il est masqué par le rythme alpha.	Apparaît quand le sujet éprouve besoin de bouger mais respect les consignes d'immobilité de l'examen, et il se bloque pendant le mouvement  Rythme normal.	
Représentation			

#### I.4.6. L'EEG en épilepsie

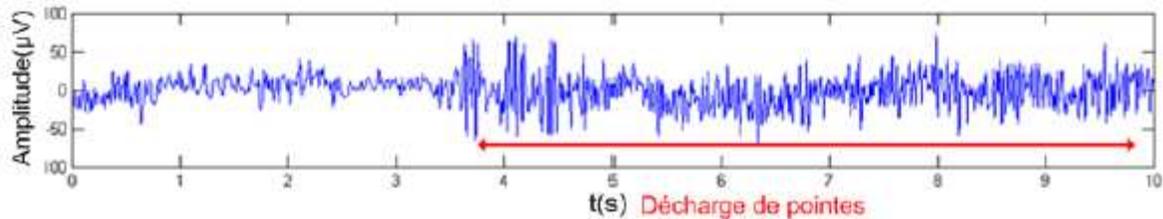
Aujourd'hui l'EEG est un examen paraclinique primordial à la prise en charge d'un patient épileptique. Les anomalies observées en EEG sont différentes selon que le patient est enregistré en période interictal (entre deux crises) ou ictal (au cours d'une crise) [Chartrian, 1974 ;Hocepiéd et al.,2012].

- **En période interictal** : Dans ce type d'enregistrement les patterns les plus fréquentes sont :
  - ✓ **Pointe** : décharge en forme de pointe de durée entre 20 et 70 ms (Figure 1.9(a)).
  - ✓ **Pointe-onde** : pointe suivie d'une onde.
  - ✓ **Polypointe-onde** : 2 ou plusieurs pointes associées avec une ou plusieurs ondes (Figure I.9(b)).
  - ✓ Surcharge lente en thêta ou delta.
  - ✓ Ralentissement du rythme.



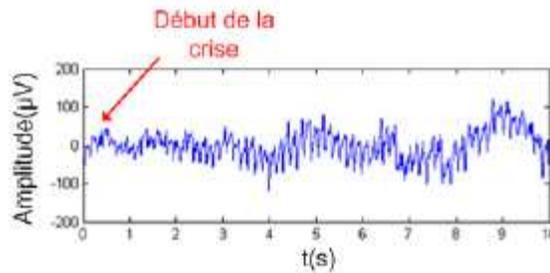
**Figure I.9.** Une pointe(a), une polypointe-onde lente (b) (D'après Husson 1957)

- **En période ictal :** Dans ce cas il existe plusieurs types d'anomalies selon la nature de la crise, on trouve :
  - ✓ Une décharge de pointes (Figure I.10), polypointes, pointes ondes ou encore polypointes ondes.



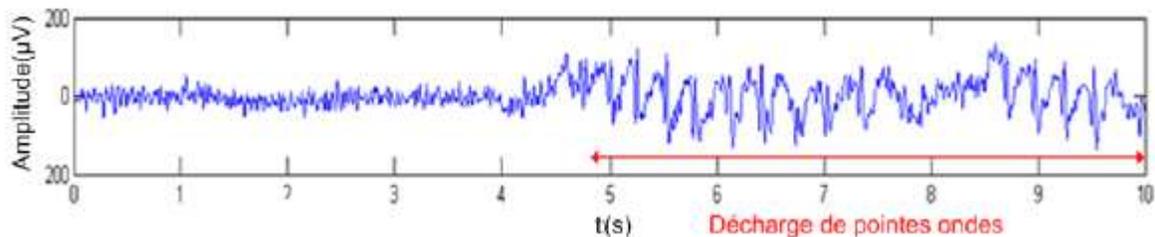
**Figure I.10.** Décharge de pointes (Hocepied et al., 2012)

- ✓ Une oscillation basse fréquence (thêta focale) à environ 5 Hz.
- ✓ Une oscillation à plus haute fréquence à environ 10 Hz (Figure 1.11).



**Figure I.11.** Crise d'épilepsie du lobe temporal : apparition d'une oscillation à environ 7 Hz  
(Hocepied et al. 2012)

- ✓ Crise généralisée de type absence se caractérise par la survenue de pointes ondes à 3 Hz (Figure I.12).



**Figure I.12.** Crise généralisée de type absence : décharge de pointes-ondes à 3 Hz  
(Hocepied et al. 2012)

- ✓ Une crise généralisée tonique-clonique se caractérise par une oscillation à 10 Hz

## I.9. CONCLUSION

L'épilepsie est une affection neurologique chronique définie par la répétition, en général spontanée, à moyen et à long terme, de crises épileptiques. Il existe plusieurs types de crise d'épilepsie. Les causes de l'épilepsie sont variées et résultent de la conjonction de facteurs génétiques et de facteurs acquis.

Le diagnostic de l'épilepsie est primordial, l'électroencéphalogramme (EEG) est le seul examen qui peut apporter des arguments pour le diagnostic positif.

---

# **BIBLIOGRAPHIE**

---

- [Adam et al, 2000] ADAM, C., ARZIMANOGLU, M., ANS BAULAC, A., *et al.* Epilepsies: de la clinique aux examens complémentaires (Tome 1). *Expressions santé éditions*, 2000.
- [Adrian et Matthews, 1934] ADRIAN, Edgar Douglas et MATTHEWS, Brian HC. The Berger rhythm: potential changes from the occipital lobes in man. *Brain*, 1934, vol. 57, no 4, p. 355-385.
- [Agirre-Arrizubieta et al,2009] AGIRRE-ARRIZUBIETA, Z., HUISKAMP, G. J. M., FERRIER, C. H., *et al.* Interictal magnetoencephalography and the irritative zone in the electrocorticogram. *Brain*, 2009, vol. 132, no 11, p. 3060-3071.
- [Amann ,2006] AMANN, Jean-Paul. *Épilepsie, connaissance du cerveau et société*. Presses Université Laval, 2006.
- [Angeles ,1981] ANGELES, D. K. Proposal for revised clinical and electroencephalographic classification of epileptic seizures. *Epilepsia*, 1981, vol. 22, no 4, p. 489-501.
- [Attia et al ,2016] ATTIA, Abdelouahab, FRAHTA, Nabila, MOUSSAOUI, Abdelouahab, *et al.* An Efficient fMRI Data Clustering Method using PHA Algorithm and Dynamic Time Warping. *International Journal of Computer Science and Information Security*, 2016, vol. 14, no 5, p. 222
- [Berg et Scheffer ,2011] BERG, Anne T. et SCHEFFER, Ingrid E. New concepts in classification of the epilepsies: entering the 21st century. *Epilepsia*, 2011, vol. 52, no 6, p. 1058-1062.
- [Bouilleret et Dupont,2003] BOUILLERET, V. et DUPONT, S. Imagerie fonctionnelle dans l'épilepsie. *EMC Neurologie*, 2003, p. 17-045.
- [Caparos,2006] CAPAROS, Matthieu. *Analyse automatique des crises d'épilepsie du lobe temporal à partir des EEG de surface*. 2006. Thèse de doctorat. Institut National Polytechnique de Lorraine-INPL.
- [Caton,1875] CATON, Richard. Electrical Currents of the Brain. *The Journal of Nervous and Mental Disease*, 1875, vol. 2, no 4, p. 610.
- [Cérébrale et al,1998] CÉRÉBRALE, SPECTROSCOPIE RMN ET PATHOLOGIE, LE BAS, J. F., ESTEVE, F., *et al.* SPECTROSCOPIE RMN ET PATHOLOGIE CÉRÉBRALE Enseignement J. Neuroradiol., 1998, 25, 55-69© Masson, Paris, 1998. *J. Neuroradiol*, 1998, vol. 25, p. 55-69.
- [Changeux,1983] CHANGEUX, J. P. L'Homme neuronal. Fayard, Paris; English edition: Neuronal man. *Pantheon New York*, 1983.
- [Chatrian, 1974] CHATRIAN, G. E. A glossary of terms most commonly used

- by clinical electroencephalographers. *Electroenceph. clin. Neurophysiol.*, 1974, vol. 37, p. 538-548.
- CISSE, Mr Lassana. FACULTE DE MEDECINE ET D'ODONTO-STOMATOLOGIE (FMOS). 2014.
- [Delay et al, 1966] DELAY, Jean, VERDEAUX, Georges, DELAY, Jean Paul Louis, *et al.* *Electroencéphalographie clinique*. Masson, 1966.
- [Devaux et al, 2008] DEVAUX, B., CHASSOUX, F., LANDRE, E., *et al.* Résections en région fonctionnelle: étude d'une série de 89 cas Surgical resections in functional areas: Report of 89 cases. 2008.
- [Dravet,2005] DRAVET, Charlotte. *Comprendre l'épilepsie: notions élémentaires sur l'épilepsie et les épilepsies*. John Libbey Eurotext, 2005.
- [Engel, 2006] ENGEL, Jerome. Report of the ILAE classification core group. *Epilepsia*, 2006, vol. 47, no 9, p. 1558-1568.
- [Engel, 2006] ENGEL JR, Jerome. ILAE classification of epilepsy syndromes. *Epilepsy research*, 2006, vol. 70, p. 5-10.
- [Fisher et al,2005] FISHER, Robert S., BOAS, Walter van Emde, BLUME, Warren, *et al.* Epileptic seizures and epilepsy: definitions proposed by the International League Against Epilepsy (ILAE) and the International Bureau for Epilepsy (IBE). *Epilepsia*, 2005, vol. 46, no 4, p. 470-472.
- [Fisher et al,2014] FISHER, Robert S., ACEVEDO, Carlos, ARZIMANOGLU, Alexis, *et al.* Définition clinique pratique de l'épilepsie. *Epilepsia*, 2014, vol. 55, no 4, p. 475-482.
- [Fournier et al,2011] FOURNIER, Gérald. *Évolution et civilisation: de l'anthropologie de Charles Darwin à l'économie évolutionniste étendue*. Gérald Fournier, 2011.
- [Froger et Oppenheim, 2011] FROGER, Jérôme, PÉLISSIER, Jacques, et OPPENHEIM, C. Imagerie cérébrale fonctionnelle et rééducation. *Journal de Radiologie*, 2006, vol. 87, no 6, p. 718.
- [Gevrey,2007] GEVREY, Roland. *Prise en charge de l'enfant épileptique en odontologie*. 2007. Thèse de doctorat.
- [Gibbs et Gibbs ,1946] GIBBS, F. A. et GIBBS, E. L. The electroencephalographic pattern of encephalitis. *Archives of neurology and psychiatry*, 1946, vol. 55, p. 166-166.
- [Goodwin et Hall,1939] et GOODWIN, J. E. et HALL, G. E. The human electroencephalogram and its clinical significance. *Canadian Medical Association Journal*, 1939, vol. 41, no 2, p. 146.

- [Halgren et al, 1995] HALGREN, Eric, BOUJON, Christophe, CHAUVEL, Patrick, *et al.* Etapes neurophysiologiques dans la perception: EEG et MEG. In : *Perception et agnosies*. De Boeck Supérieur, 1995. p. 135-179.
- [Hocepiéd et Nonclercq, 2012] et HOCEPIED, Gatién, GRENEZ, Francis, et NONCLERCQ, Antoine. Détection précoce de crises d'épilepsie à l'aide d'une modélisation du comportement oscillatoire neuronal. 2012.
- [Holmes, 2008] HOLMES, Mark D. Dense array EEG: methodology and new hypothesis on epilepsy syndromes. *Epilepsia*, 2008, vol. 49, no 3, p. 3-14.
- [Jasper et Andrews, 2008] JASPER, Herbert Henri et ANDREWS, Howard Lucius. Human brain rhythms: I. Recording techniques and preliminary results. *The Journal of General Psychology*, 1936, vol. 14, no 1, p. 98-126.
- [Jasper, 1958] JASPER, Herbert. Report of the committee on methods of clinical examination in electroencephalography. *Electroencephalogr Clin Neurophysiol*, 1958, vol. 10, p. 370-375.
- [Lomeña, 2008] LOMEÑA, F. La tomographie par émission de positons (TEP) hors oncologie: l'exploration du cerveau. *Médecine Nucléaire*, 2008, vol. 32, no 10, p. 502-510.
- [Roux, 2008] ROUX, F.-X., TURAK, B., et LANDRÉ, E. Stimulation chronique du nerf vague dans le traitement de l'épilepsie pharmaco-résistante. *Neurochirurgie*, 2008, vol. 54, no 3, p. 332-339.
- [Roger et al, 2010] ROGER, Joseph, BUREAU, Michelle, DRAVET, C. H., *et al.* *Les syndromes épileptiques de l'enfant et de l'adolescent*. John Libbey Eurotext, 2010.
- [Seron et Jeannerod, 1998] SERON, Xavier, BARON, Jean-Claude, et JEANNEROD, Marc. *Neuropsychologie humaine*. Editions Mardaga, 1998.
- [VanGehuchten, 1906] VAN GEHUCHTEN, Arthur. *Anatomie du système nerveux de l'homme*. Librairie Universitaire, A. Uystpruyst-Dieudonné, 1906.
- [Vion-Dury, 2011] VION-DURY, Jean et BLANQUET, France. *Pratique de l'EEG: bases neurophysiologiques, principes d'interprétation et de prescription*. Elsevier Masson, 2011.

CHAPITRE

II

**ÉTAT DE L'ART SUR LA  
DÉTECTION AUTOMATIQUE  
DES CRISES D'ÉPILEPSIE**

## II.1. INTRODUCTION

L'électroencéphalogramme (EEG) est l'outil d'imagerie cérébrale le plus utile qui aide les neurologues dans l'investigation et le diagnostic des troubles neurologiques, ainsi que dans la classification de l'activité épileptique. Cependant, l'inspection visuelle prend beaucoup de temps et elle peut être inefficace, particulièrement dans le cas d'enregistrements EEG- long terme. D'où naît la nécessité d'utiliser une méthode de détection automatique des crises. Dans ce chapitre, nous donnons une brève description des systèmes de diagnostic assistés par ordinateur, nous discutons également les étapes de développement du système de détection et nous donnons aussi un bref aperçu avec une comparaison des performances des algorithmes de détection de crises populaires développés au cours de la dernière décennie. Ensuite, nous investiguons les bases de données existantes dans la littérature et en dernier nous fournissons les critères d'évaluations d'efficacité des algorithmes de détection automatique.

## II.2. SYSTEMES DE DIAGNOSTIC ASSISTES PAR ORDINATEUR

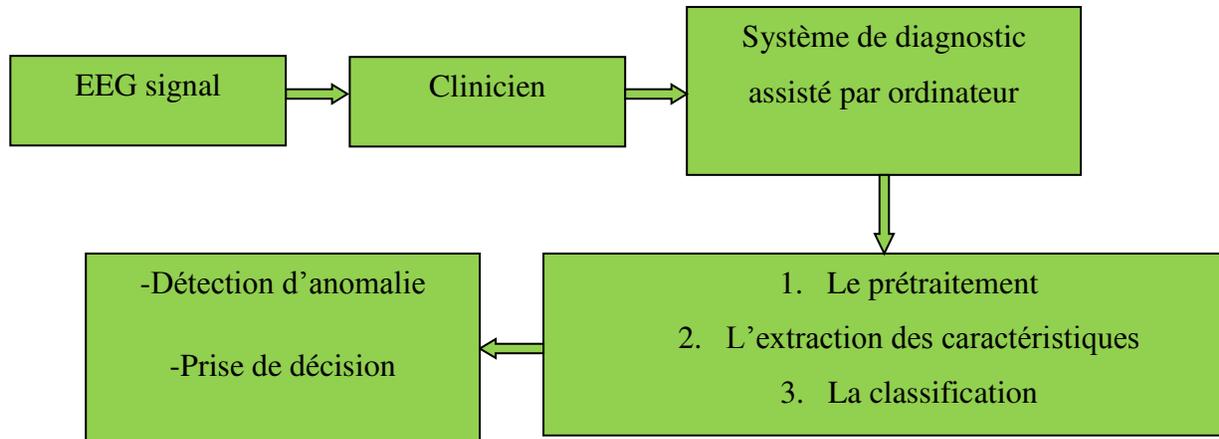
Les signaux d'EEG sont complexes et leur analyse en masse obtenue auprès d'un grand nombre de patients rend l'évaluation chronophage [Kumaretal., 2010; Yalcinet al., 2015]. Ainsi, récemment, le système de diagnostic assisté par ordinateur (CAO) est utilisé pour la détection automatique des crises d'épilepsie à partir de données de signaux EEG. Ce système permet de gérer des échantillons plus longs de signaux de manière très précise et donc un diagnostic plus rapide et beaucoup plus efficace [Alkan, 2005]. Le système de CAO comprend trois étapes principales : le prétraitement, l'extraction des caractéristiques et la classification [Arimura et al., 2009], comme indiqué dans la Figure. II.1.

Dans le prétraitement, les données EEG acquises sont traitées pour éliminer les bruits, ce qui réduit la complexité et le temps de calcul des algorithmes de CAO.

L'étape d'extraction des caractéristiques du système de CAO est l'une des parties les plus importantes où les biomarqueurs de l'identification de la maladie sont extraits des données de source d'origine.

Dans le processus de classification, le vecteur de caractéristiques extrait est utilisé dans le modèle de classificateur en tant qu'entrée pour affecter le candidat à l'une des catégories possibles (par exemple épileptique ou non-épileptique) en fonction de la sortie d'un classificateur.

Actuellement, de nombreux chercheurs procèdent au développement des systèmes de CAO pour la détection et la classification des crises d'épilepsie [Siuly et Zhang 2016].



**Figure. II.1.** Schéma du système de diagnostic EEG assisté par ordinateur

### II.2.1. Prétraitement du signal EEG

Généralement, dans le traitement du signal biomédical, il est important d'éliminer le bruit et les artefacts présents dans les signaux d'origine, surtout dans les enregistrements du signal de l'EEG qui ont une large gamme d'artefacts, et qui peuvent survenir lors de l'acquisition du signal [Sörnmo et Laguna, 2005]. L'étape de prétraitement tente de supprimer ces artefacts sans perdre les informations pertinentes. L'étape de prétraitement d'EEG implique l'élimination de ces artefacts indésirables. Certaines techniques de prétraitement sont réalisées pour déterminer la bande de fréquence souhaitée, des techniques de filtrage (par exemple : filtre passe-bande), débruitage bayésien [Tong et Thakor, 2009] et l'analyse indépendante des composants (ICA) sont utilisées à titre indicatif pour l'élimination des artefacts.

### II.2.2. Extraction des caractéristiques

Pour une classification efficace, une méthode précise d'extraction des caractéristiques est très importante pour extraire les caractéristiques qui décrivent le comportement des signaux originaux. En fait, si les caractéristiques extraites des EEG ne sont pas pertinentes et ne décrivent pas précisément les signaux EEG utilisés, un algorithme de classification utilisant de telles

caractéristiques aura du mal à identifier les classes des caractéristiques [Belhadj et al. , 2016]. Par conséquent, les taux de classification corrects seront très faibles.

D'après la littérature, plusieurs types d'extraction de caractéristiques des données EEG épileptiques ont été proposées [Orosco et al., 2013]. Les méthodes d'extraction de caractéristiques peuvent être classées en quatre groupes: méthodes paramétriques, méthodes non paramétriques, méthodes temps-fréquence et méthodes du vecteur propre.

### **II.2.2.1. Les méthodes paramétriques**

Les méthodes paramétriques reposent sur l'idée que le processus est issu d'un modèle dont on cherche ses paramètres. Une fois les paramètres sont trouvés, il suffit d'introduire ces paramètres dans les expressions mathématiques de la densité spectrale. Les méthodes paramétriques populaires sont le modèle autorégressif (AR), le modèle à moyenne mobile (MA), modèle autorégressif à moyenne mobile (ARMA) [Ubeyli, 2009a] et l'exposant de Liapounov [Guler et al., 2005, Murugavel et al., 2011].

La méthode AR est appropriée pour représenter des spectres avec des pics étroits. Le modèle MA fournit une bonne approximation pour les spectres qui sont caractérisés par des pics larges et des zéros nets (pics et des valeurs nulles). De tels spectres sont rencontrés moins fréquemment dans les applications que les spectres à bande étroite, de sorte qu'il y a un intérêt quelque peu limité à utiliser le modèle MA pour l'estimation spectrale.

Les spectres avec des pics aigus et des zéros profonds peuvent être modélisés par le modèle ARMA. Les estimateurs ARMA sont simples d'un point de vue informatique et souvent assez fiables, mais leur précision peut parfois être médiocre [Kay et Marple, 1981, Stoica et Moses, 1997].

### **II.2.2.2. Les méthodes non paramétriques**

Les méthodes non paramétriques reposent entièrement sur les définitions de la densité spectrale de puissance (PSD) pour fournir des estimations spectrales. Deux méthodes non paramétriques communes, le périodogramme et le corrélogramme [Ubeyli, 2009a], fournissent une résolution raisonnablement élevée pour des longueurs de données suffisamment longues, mais sont de mauvais estimateurs spectraux car leur variance est élevée et ne diminue pas avec

l'augmentation de la longueur des données. La forte variance des méthodes du périodogramme et du corrélogramme motive le développement de méthodes modifiées dont la variance est plus faible au prix d'une résolution réduite [Ubeyli, 2009a].

### II.2.2.3. Les méthodes temps-fréquence

Les mappages entre les espaces de fréquence et de temps sont généralement utilisés dans le cadre de l'analyse et le traitement de signal. Les méthodes qui sont habituellement utilisées dans le domaine temps-fréquence sont la transformée de Fourier rapide (FFT)[Welch,1967], transformée en ondelettes (WT) [Adeli and Dadmehr, 2003; Subasi et al. , 2005b; Ubeyli, 2009b et Murugavel et al., 2011], Transformée en ondelettes accordable-Q[Lotte,2008], transformée de Fourier de courte durée (STFT)[Ubeyli,2009a], l'entropie des ondelettes [Ubeyli,2009], la fonction de l'énergie des ondelettes [Zhou et al,2013], seuil d'ondelettes multi-domaine [Gotman,1990], transformée en paquets d'ondelettes harmoniques [Minasyan,2010], la transformation de Stockwell [Aarabi et al,2006], la décomposition en mode empirique d'ensemble [Claassen et al,2004], Décomposition du mode empirique multivarié [Meier et al, 2008], graphique de visibilité [Ghosh-Dastidar et al,2008 ;Güler et Übeyli,2005], Fonctions noyau de Cohen [Kearsley-Fleet et al,2013] et autres méthodes basées sur l'entropie (Chan et al,2008).

Étant donné que les méthodes de Fourier peuvent ne pas convenir aux signaux non stationnaires ou aux signaux ayant des composantes de courte durée, d'autres approches ont été proposées. Parmi les premiers travaux dans ce domaine figure le développement par Gabor de la transformée de Fourier de courte durée (STFT). La transformée en ondelettes (WT) fournit une représentation du signal dans un réseau de blocks ayant une bonne localisation fréquentielle et temporelle. Les ondelettes, sous formes discrètes et continues, et en plus jusqu'à une approximation multi-résolution sont présentées par Akay ,Ubeyli et Guler [Akay, 1998; Ubeyli et Guler, 2004].

### II.2.2.4. Les méthodes de vecteur propre

Les méthodes de vecteur propre sont utilisées pour estimer les fréquences et les puissances des signaux à partir de mesures corrompues par le bruit. Ces méthodes sont basées sur une décomposition propre de la matrice de corrélation du signal altéré par le bruit. Même lorsque le rapport signal / bruit (SNR) est faible, les méthodes du vecteur propre produisent des spectres de

fréquence de haute résolution. Les méthodes du vecteur propre, telles que Pisarenko [Proakis et Manolakis, 1996], la classification à signaux multiples (MUSIC) [Stoica et Moses, 1997] et la norme minimale, sont les mieux adaptées aux signaux qui peuvent être supposés être composés de plusieurs sinusoides spécifiques enfouies dans le bruit [Ubeyli et Guler 2003].

### II.2.3. La classification des signaux EEG

Une fois que les étapes précédemment décrites auparavant du système de détection ont été effectuées et en supposant que les caractéristiques extraites sont appropriées pour distinguer entre les états d'EEG (épileptique ou non épileptique), l'information sera utilisée pour décider à quelle classe ces caractéristiques appartiennent. Une étape de prise de décision et une classification des données dans l'espace des caractéristiques sont donc nécessaires.

Cette étape est un processus global qui encapsule une stratégie pour déterminer quelles caractéristiques sélectionner, comment les combiner pour optimiser les performances du système.

L'objectif de la classification est de décrire une limite entre les classes et de les étiqueter en fonction de leurs caractéristiques mesurées. Le classificateur peut être aussi simple que de fixer un seuil pour les caractéristiques ou plus sophistiqué, tel que les algorithmes d'apprentissage automatique. Dans un espace de caractéristiques multidimensionnel, cette limite est convertie en un hyperplan de séparation. Le but est de trouver l'hyperplan qui a la distance maximale de toutes les classes.

Plusieurs techniques de classification et de clustering ont été développées. Parmi elles, les règles d'association, ANNs, LDA, la modélisation de Markov cachée (HMM), k-means clustering, la logique floue, et les SVM ont été appliquées à la détection de la crise épileptique. Les fondements mathématiques de ces techniques ont été développés et sont bien expliqués dans la littérature. Par conséquent, seules de brèves descriptions et applications de détection de crises sont données ci-dessous:

Les règles d'association permettent d'inspecter l'ensemble de fonctions et d'établir des relations simples entre les entités. Les seuils sont souvent utilisés pour prendre des décisions. Gotman a proposé l'algorithme Monitor, qui utilise le seuillage des caractéristiques temps (amplitude, durée et coefficient de variation de l'amplitude) pour détecter les crises [Gotman, 1982 ; Gotman, 1990].

Schad et al. proposent un seuil de pentes locales dans les signaux EEG pour effectuer les détections de crises [Schad et al.,2008]. Niederhauser et al. ont utilisé un seuil pour les caractéristiques de fréquence temporelle [Niederhauser et al., 2003]. Gardner et al l'ont également fait mais avec une énergie de courte durée [Gardner et al., 2007]. Mitra et al. ont établi un ensemble de règles (différents seuils) pour le rejet des artefacts, suivi de règles d'évaluation de la qualité globale des crises [Mitra et al. ,2009]. D'autres chercheurs ont également utilisé des règles d'association pour la détection des crises [Orosco et al. , 2011; Zandi et al., 2010; Marsh et al.,2010].

Lorsque la corrélation entre les caractéristiques est similaire, des méthodes de classification automatique sont nécessaires, les techniques telles que LDA [Orosco et al. , 2011], logique floue [Güler et Übeyli, 2005; Kannathal et al. 2005 ; Subasi, 2006], machine à vecteurs de support (SVM) [Hunyadi et al. ,2017], PCA modulaire global avec SVM [Jaiswal et Banka, 2017], machine de vecteurs de support des moindres carrés (LS-SVM)[Hanbay, 2009] et réseau de neurones artificiels (ANN) [Kocadagli, et Langari, , 2017; Talathi, 2017]. ANN avec relations floues [Chen et al,2017] réseau neuronal perceptron multicouche (MLPNN) [Guler et Ubeyli, 2007], réseau neuronal récurrent (RNN) [Talathi,2017], machine à vecteur de pertinence (RVM), réseau neuronal probabiliste (PNN), mélange d'experts (ME), mélange modifié d'experts (MME), kNN [Truong et al., 2017; Birjandtalab et al.,2017] , algorithme génétique [Zhang et al.,2017], machine d'apprentissage extrême non-linéaire [Wang et al.,2017], analyse d'enveloppe basée sur les ondelettes (EA) avec ensemble de réseaux neuraux [Mursalin et al.,2017] , classificateur forestier aléatoire [Puspita et al.,2017; Acharya et al.,2012], classificateur bayésien [Tibdewal et al,2017], modèle d'entropie floue [Truong et al.,2017], k-means clustering sont aussi utilisés pour la détection de l'épilepsie [Gardner et al.,2006].

Au cours des dernières décennies, l'utilisation d'ANN (Artificial Neural Network) a été augmentée en raison de son niveau de précision de la classification. Particulièrement ANN qui fournit une nouveauté dans la recherche de la relation entre l'entrée et la sortie par la signification de l'entraînement approprié du paramètre variable en trouvant ses poids et ses biais [Subasi, 2005].

Comme ANN, la méthode la plus couramment utilisée dans le processus d'apprentissage automatique pour réaliser la classification des caractéristiques multidimensionnelles est la technique SVM (Support Vector Machine) [Cortes et Vapnik, 1995].

Lorsque les caractéristiques sont si grandes, elles seront classées dans des groupes en fonction de leurs hyperplans de séparation. Pour transformer la caractéristique désirée en classe linéairement séparable, les méthodes du noyau ont été proposées [Lima et Coelho ,2011]. Pour la détection multicanal de la crise générée par le signal EEG, Asha et al. [Asha, 2013] ont utilisé les classificateurs ANN et SVM.

Diverses méthodes de détection et de classification de l'épilepsie sont résumées dans le tableau 1 (Table II.1) avec ses paramètres de performance.

**Table II.1.** Diverses méthodes de détection et de classification d'épilepsie avec ses paramètres de performance.

<b>Auteurs</b>	<b>Année</b>	<b>La méthode utilisée</b>	<b>Paramètre d'évaluation utilisée</b>
Priori et al.	1973	Algorithme de traitement de signal +transformé de Fourier	Fonction cérébrale, variations de temps et de fréquence / Non spécifié
Babb et al.	1974	Surveillance d'EEG télémétrique	Non spécifié
Viglione et al.	1975	La reconnaissance de formes	Fréquence principale et Indication de niveau de seuil / non spécifié
Gotman et al.	1976	Reconnaissance de l'activité épileptique inter-ictal	Combinaison de l'amplitude et de la durée des demi-ondes / Non spécifié
Da Silva et al.	1977	Modèle de filtre autorégressif + filtrage inverse	Non stationnarité transitoire (profils paroxystiques) / Non spécifié
Birkemeier et al.	1978	Prédiction linéaire et Technique de performance de la seconde différenciation	Comparaison entre deux méthodes/Non spécifié
Ktonas et al.	1979	Teste de variable Chi-square	Amplitude et durée / Non spécifié
Gotman et al.	1979	Reconnaissance automatique de l'épilepsie inter-ictal	ACCentre 67% et 100%
Gotman	1982	Décomposition de l'EEG en ondes élémentaires + détection des	Amplitude, durée et rythmicité / Non spécifié

		sursauts paroxystiques de l'activité rythmique	
Abrams et al.	1989	La thérapie par électrochocs	ACC/Non spécifié
Olsen et al.	1994	Détection automatique à base de microprocesseur	ACC/Non spécifié
Weng and Khorasani	1996	Perceptron multicouche + fonction d'erreur stabilisée	Réduction de l'époque de l'apprentissage de 60 à 70%.
D'attellis et al.	1997	Analyses d'ondelettes	Localisation temporelle et caractérisation des événements épileptiques / Non spécifié
James et al.	1999	Réseau de neurones artificiels + carte d'entités auto-organisatrices + logique floue	SENS=55,3% SELE= 82%
Jerger et al.	2001	analyse de modèle de pointe inter-ictal	Analyse comparative
Liu et al.	2002	Réseau de neurones artificiels + transformée en ondelettes + filtrage adaptatif intégré	ACC = 90.0% FDR = 6.1%
Maryann et al.	2003	Fonctions du domaine temporel, caractéristiques du domaine fréquentiel + ANFIS	SENS=62.5% SPEC=90.47% ACC =92.22%
Iasemidis	2003	Modèle de dynamique non linéaire	Analyse comparative
Chan et al.	2004	Module maximal de la transformée en ondelettes	ACC/Non spécifié
Runarsson et al.	2005	Domaine temporel, histogramme et caractéristiques d'amplitude + SVM	SENS= 90%
Subasi et al.	2005	Modèle autorégressif + estimation du maximum de vraisemblance +	SPEC=96.2% SENS=90.3%

		ANN	ACC= 92.3%
Subasi et al.	2005	Domaine temps-fréquence, caractéristiques basées sur les ondelettes +ANN	ACC=95%
Firpi et al.	2007	Algorithme programmé génétiquement + classificateur K-plus proche voisin	Taux de faux négatif =4.35%
Polat et al.	2007	FFT +classificateur d'arbre de décision +k-fold processus de validation croisée (CV)	A 5 fold CV ACC = 98.68%, de 10 fold CV ACC = 98.72%
Tafreshi et al.	2008	Détection EMD, Caractéristiques de l'ondelette+ Réseau de neurones	ACC= 95%
Ghosh-Dastidar et al.	2008	PCA+ cosinus amélioré RBFNN	ACC= 99.3%
Patnaik et al.	2008	Extraction de caractéristiques basée sur les ondelettes +Réseau de neurones de propagation pour la classification	SPEC=99.19% SENS= 91.29% ACC=91.14%
Meier et al.	2008	Détection automatique en ligne et en temps réel	ACC= 96%
Tzallas et al.	2009	Analyse temps-fréquence+ ANN	ACC= 99.28%
Ocak et al.	2009	DWT + ApEn	ACC = 96%
Chandaka et al.	2009	Cross-corrélation+ SVM	ACC=95.96%
Übeyli	2009	Vecteurs propres dans le domaine de fréquence+MLPNN/RNN	ACCRNN=98.15% ACCMLPNN=92.9%
Gayatri et al.	2010	Réseau neuronal d'Elman	ACC/ Non spécifié
Guo et al	2010	Longueur des caractéristiques +ANN	ACC=99.66%
Subasi et al.	2010	PCA, ICA, LDA + SVM	ACCPCA=98.75%

			ACCICA =99.50% ACCLDA = 100%
Panda et al.	2010	Domaine d'ondelettes, énergie, écart-type d'entropie + SVM	ACC = 91.2%
Zandi et al.	2010	Analyse d'ondelettes + analyse de fenêtres mobiles	SENS=90,5% Délai de détection médian= 7sec
Nasehi et Pourghassem	2011	Algorithme de détection d'apparition de crise +Classificateur IPSONN + DFT + DWT	Spécificité (faux taux de détection)= 3 faux / 24 heures SENS=98% Latence = 55% avec 3
Orosco et al.	2011	EMD / FMI Énergie, les seuils d'analyse de fréquence / temps d'EMD / IMF+ LDA	SEN=41,4% SPE=79.3% SEN=69.4% SPE=69.2%
Orhan et al.	2011	Ondelette+ clustering k-means / PD / ANN	ACC=96.67%
Oweis and Abdulhay	2011	MEMD/ EMD+ t-test/ clustering Euclidian	ACCEMD=94% ACCMEMD=80%
Nicolaou et al.	2012	Entropie de permutation (PE) et SVM	ACC=93.55%
Arslanet al.	2012	ANN + PSO	Taux de réussitemoyen98%
Dalton et al.	2012	Domaine temporel, Signature des crises+SVM	SENS= 91 %, SPEC=84%
Vivek et al.	2013	Filtre pré-traitement non-linéaire multi-étages + réseau neuronal LAMSTAR	ACC= 97.2%
Asha et al.	2013	SVM+ANN	ACC= 75%
Aguirree-Echeverry et al.	2013	Classificateurs optimisé d'uneseule classe	SENS=96.67%, SPEC=100%
Boubchir et al.	2013	Caractéristiques basées sur le	ACC=99.33%

		descripteur LBP+SVM	
Das et al.	2013	DWT + réseau de neurones artificiels feed-forward	SENS=99.19% SPEC=91.14%
Saadat and Hossein	2013	Algorithme de détection d'apparition de crise+Classificateur IPSONN + DFT + DWT	SENS=84% SPEC=98%
Yoo et al.	2013	Domaine temporel, Energies de sous-bandes+SVM	ACC=84.4%
Meenakshi et al.	2014	Transformée de Fourier Rapid	$\alpha, \beta, \gamma, \delta$ et $\theta$ activité/ non spécifié
Boubchir et al.	2014	Signal T-f, caractéristiques liées à l'image t-f+SVM	AAC=97.5%
Shoib et al.	2014	Caractéristiques de l'ondelette+SVM	SENS=91%
Meenakshi et al.	2014	ANN + SVM + K-means Classificateur +Naïve Bayes Classificateur + fonction de base radiale	SENS = 100%, ACC = 100%
Boubchir et al.	2015	Caractéristiques basées sur des descripteurs de texture d'image+SVM	ACC=98%
Dalia et al.	2015	Plate-forme Android intégrée + système GPS	Performance en temps réel / non spécifié
Dogali et al.	2015	ANN (cascade et Elman) + FFBPNN	ACC= 98.3%
Nesibe et al.	2015	PSO + back propagation algorithme	SENS = = 100%, ACC=99.67%
Lin, et al.	2016	SSAE networks - softmax classificateur	ACC=100%
Sharmila et al.	2016	DWT + naïve Bayes + K-plus	ACC= 100%

		proche voisin	
Akshata et al.	2016	DWT + ANN classificateur+ Analyse multi-résolution	ACC= 96%
Orellana and Fabio	2016	Classificateur de forêt aléatoire + détecteur d'enveloppe	Taux de faux positifs= 0,77 h-1 SENS=99,29% et SPEC=97,12%
Karthika et al.	2016	DWT + ANN classificateur + Analyse Multi-Résolution	ACC=96%
Belhadj et al.	2016	Clustering Fast-PHA basé sur EMD	ACC=98.84%
Swami et al.	2016	DTCWT, énergie, écart-type, entropie, etc. + régression générale, réseau de neurones	ACC=99.15 SENS= 98.32 SPEC=99.55
Mingyang Li et al.	2017	DT-CWT-basée sur les caractéristiques non linéaires + SVM	ACC=98.87
ShivnarayanPatidar et TrilochanPanigrahi	2017	TQWT et Kropsov entropie +LS- SVM	ACC=97.75 SENS= 97.00 SPE=99.55
Manish Sharma et al.	2017	ATFFWT et FD caractéristiques+LS-SVM	ACC =100
TIWARI et al.	2017	LBP + SVM	ACC =100
ALICKOVIC et al.	2018	MSPCA + EMD+DWT +SVM+ANN+KNN	ACC=100 SENS=100 SPE=100
Kostas M. Tsiouris	2018	Analyse spectrale, variations de la distribution d'énergie EEG sur les rythmes delta, thêta et alpha, détection de crises simple basée sur des règles.	SENS= 88%

### II.3. LES BASES DE DONNEES UTILISEES

Certaines bases de données accessibles au public contenant des données sur les crises ont été utilisées comme référence pour diverses études. Les plus connus sont la base de données EEG de Freiburg [Freiburg EEG database, 2008] contenant des enregistrements EEG invasifs de 21 patients souffrant d'épilepsie focale réfractaire, la base de données EPILEPSIAE [The European Epilepsy Database, 2007] qui contient des enregistrements lors d'une surveillance épileptique pré-chirurgicale invasive au Centre Epilepsie du CHU de Freiburg, la base de données Bonn EEG [Andrzejak et al., 2001] et la base de donnée CHB-MIT [Goldberger et al., 2000].

#### II.3.1. Base de données EEG Freiburg de prédiction des crises

La base de données de prédiction EEG (FSPEEG) de Fribourg contient des enregistrements EEG invasifs de 21 patients (13 hommes, 8 femmes, âge =  $29,9 \pm 11,9$  ans) souffrant d'épilepsie focale réfractaire. Chez 9 patients, la source de l'épilepsie est localisée dans le lobe temporal; 6 souffrent d'épilepsie focale frontale; et 1 a l'épilepsie pariétale. Les 5 autres patients ont deux sources d'épilepsie.

Les données ont été enregistrées au cours de la surveillance invasive de l'épilepsie pré-chirurgicale au Centre de l'épilepsie de l'hôpital universitaire de Fribourg en Allemagne. Afin d'obtenir un rapport signal / bruit élevé et moins d'artefacts, et d'enregistrer directement à partir des zones focales, des électrodes intracrâniennes de grille, de bande et de profondeur ont été utilisées. Les données EEG ont été acquises en utilisant un système EEG vidéo numérique Neurofile NT avec 128 canaux, un taux d'échantillonnage de 256 Hz et un convertisseur analogique / numérique de 16 bits. Les données disponibles comprennent seulement 6 canaux EEG intracrâniens (3 électrodes focales et 3 électrodes extrafocales). Cette base de données contient les annotations des heures de début et de fin des crises effectuées par des experts [Freiburg EEG database, 2008].

#### II.3.2. La base de données EPILEPSIAE

La possibilité de prédire l'apparition de crises d'épilepsie en surveillant l'activité électroencéphalographie (EEG) est considérée comme l'une des options les plus prometteuses pour établir de nouvelles stratégies thérapeutiques pour la fraction considérable de patients avec

des crises actuellement insuffisamment contrôlées. La base de données "EPILEPSIAE" fait partie d'un projet financé par l'UE visant le développement d'algorithmes de prédiction de crise. L'architecture et le schéma sous-jacent sont ici rapportés pour cette base de données. Il a été conçu pour une organisation, un accès et une recherche efficaces des données de 300 patients atteints d'épilepsie, y compris des enregistrements EEG à long terme de haute qualité, obtenus avec des électrodes intracrâniennes et du cuir chevelu, ainsi que des données cliniques et d'imagerie complémentaires [The European Epilepsy Database, 2007].

### **II.3.3. La base de données Andrzejak**

La base de données Andrzejak contient des données obtenues au département d'épileptologie à Bonn, en Allemagne, en utilisant le système d'électrodes standard 10-20. Les données se composent de cinq ensembles (notés A à E), chacun contenant un seul canal de 100 segments d'une durée de 23,6 s. Ces segments ont été sélectionnés et découpés à partir d'enregistrements EEG multicanaux continus après inspection visuelle des artefacts.

Les ensembles A (yeux ouverts) et B (yeux fermés) recueillis à partir de cinq volontaires en bonne santé. Les ensembles C, D et E proviennent de cinq patients pour un diagnostic pré-chirurgical de l'archive EEG intracrânienne. L'ensemble D a été enregistré dans la zone épileptogène, et l'ensemble C a été enregistré à partir de la formation de l'hippocampe de l'hémisphère opposé du cerveau. Les ensembles C et D ne contiennent que de l'activité pendant les intervalles sans crise, alors que l'ensemble E ne contient qu'une activité de crise. Tous les signaux EEG ont été enregistrés avec le même système d'amplification à 128 canaux, en utilisant une référence commune moyenne (en omettant l'activité pathologique contenant des électrodes (C, D et E) ou des artefacts forts de mouvement oculaire (A et B)). Après une conversion analogique-numérique de 12 bits, les données ont été enregistrées à une fréquence d'échantillonnage de 173,61 Hz. Le réglage du filtre passe-bande était de 0,53 à 40 Hz (12 dB / oct). Cette base de données contient également des annotations faites par des experts pour les limites temporelles des crises [Andrzejak et al.,2001].

### **II.3.4. La base de données CHB-MIT**

Les jeux de données CHB-MIT sont disponibles en ligne sur phisionet.org. Cette base de données, recueillie à l'Hôpital d'enfants à Boston, comprend des enregistrements d'EEG

provenant de sujets pédiatriques souffrant de crises intractables (pharmaco-résistante). Les sujets ont été suivis pendant plusieurs jours après le retrait des médicaments antiépileptiques afin de caractériser leurs crises et d'évaluer leur candidature à une intervention chirurgicale. Les enregistrements d'EEG qui sont divisés entre 24 cas ont été recueillis chez 22 sujets (5 hommes âgés de 3 à 22 ans et 17 femmes âgés de 1,5 à 19 ans). (Un patient a deux séries d'enregistrements EEG.). Le cas 24 a été ajouté à cette collection en décembre 2010 et ne contient aucune donnée sur le patient. Tous les signaux ont été échantillonnés à 256 échantillons par seconde avec une résolution de 16 bits. La plupart des fichiers contiennent 23 signaux EEG (24 ou 26 dans certains cas). Le système international 10-20 des positions et de la nomenclature des électrodes EEG a été utilisé pour ces enregistrements. Les données ont été segmentées en enregistrements d'une heure. Les enregistrements qui ne contiennent pas de crise sont appelés enregistrements sans crise et ceux qui contiennent une ou plusieurs crises sont appelés enregistrements de crises [Goldberger et al., 2000] .

#### II.4. MESURES DE PERFORMANCE

Les mesures de performance dans la détection des crises sont extraites de tableaux de contingence décrivant les fréquences des crises détectées et non détectées par un algorithme proposé contre les crises réelles et fausses (voir Tableau II.2). Les mesures les plus utilisées comprennent la sensibilité, la spécificité, l'exactitude et la précision [Šimundić, 2008; Azar et El-Said, 2014].

**Tableau II.2.** Tableau de contingence utilisé pour évaluer les performances d'un algorithme de détection par rapport au résultat de l'expérience

		<b>Crise</b>	<b>Pas de crise</b>
<b>Résultat de l'expérience</b>	Positive(P)	TP	FP
	Négative(N)	FN	TN

D'où, TP représente les vrais positifs, FP représente les faux positifs, FN représente les faux négatifs et TN représente les vrais négatifs

$$\text{Sensibilité} = \frac{\text{Nombre de crises correctement détectées}}{\text{Nombre total de résultats positifs de l'algorithme}}$$

$$\text{SENS} = \frac{TP}{TP + FN} \quad (\text{II.1})$$

$$\text{Spécificité} = \frac{\text{Nombre d'états normaux correctement détectés}}{\text{Nombre total de résultats négatifs de l'algorithme}}$$

$$\text{SPEC} = \frac{TN}{TN + FP} \quad (\text{II.2})$$

$$\text{Exactitude} = \frac{\text{Nombre de crises correctement détectées} + \text{états normaux}}{\text{Nombre total de cas}}$$

$$\text{ACC} = \frac{TP + TN}{TP + FP + FN + TN} \quad (\text{II.3})$$

$$\text{Précision} = \frac{\text{Nombre de crises correctement détectées}}{\text{Nombre total de crises}}$$

$$\text{PREC} = \frac{TP}{TP + FP} \quad (\text{II.4})$$

En outre, il existe également une valeur prédictive positive (PPV) et une valeur prédictive négative (NPV) définies comme suit :

$$\text{PPV} = \frac{\text{Nombre de crises correctement détectées}}{\text{Nombre total d'incidents détectés}}$$

$$\text{PPV} = \frac{TP}{TP + FP} \quad (\text{II.5})$$

$$NPV = \frac{\text{Nombre d'états normaux correctement détectés}}{\text{Nombre total d'états normaux}}$$

$$NPV = \frac{TN}{FN + TN} \quad (\text{II.6})$$

PPV et NPV traitent la probabilité qu'une crise détectée soit une crise réelle et la probabilité qu'un état EEG normal détecté soit un état EEG réel, respectivement.

Enfin, les tests peuvent être évalués par le rapport de vraisemblance qui est la probabilité d'un segment caractérisé comme ictal classé comme ictal divisé par la probabilité d'un segment caractérisé comme ictal classé comme non-ictal. Ceci indique combien il est probable qu'un segment dont les tests sont positifs est ictal comparé à un test négatif.

$$\text{Rapport de vraisemblance} = \frac{\text{Sensibilité}}{1 - \text{Spécificité}} \quad (\text{II.7})$$

## II.5. CONCLUSION

Ce chapitre fournit une étude sur les diverses techniques utilisées pour la détection de l'épilepsie en utilisant les signaux EEG. Ce chapitre, présente de nombreuses méthodes d'extraction de caractéristiques et diverses techniques de classification. Cependant, il existe certaines limitations associées à ces méthodes, ces limitations sont principalement dues à l'inexactitude dans l'extraction des caractéristiques du signal dans le cas où les données sont larges tel qu'EEG long-terme, car il nécessite un long temps pour le traitement. De telles limitations peuvent être évitées en améliorant les méthodes d'extraction de caractéristiques et les techniques de classification.

---

# **BIBLIOGRAPHIE**

---

- [Aarabiet al, 2006] AARABI, A., WALLOIS, F., et GREBE, R. Automated neonatal seizure detection: a multistage classification system through feature selection based on relevance and redundancy analysis. *Clinical Neurophysiology*, 2006, vol. 117, no 2, p. 328-340.
- [Abramset Swartz, 1989] ABRAMS, Richard et SWARTZ, Conrad M. *Electroconvulsive therapy apparatus and method for automatic monitoring of patient seizures*. U.S. Patent No 4, 873,981, 17 oct. 1989.
- SUBASI, Abdulhamit, KIYMIK, M. Kemal, ALKAN, Ahmet, *et al.* Neural network classification of EEG signals by using AR with MLE preprocessing for epileptic seizure detection. *Mathematical and Computational Applications*, 2005, vol. 10, no 1, p. 57-70.
- [Acharyaet al, 2012] ACHARYA, U. Rajendra, MOLINARI, Filippo, SREE, S. Vinitha, *et al.* Automated diagnosis of epileptic EEG using entropies. *Biomedical Signal Processing and Control*, 2012, vol. 7, no 4, p. 401-408.
- [Adeliet al, 2003] ADELI, Hojjat, ZHOU, Ziqin, et DADMEHR, Nahid. Analysis of EEG records in an epileptic patient using wavelet transform. *Journal of neuroscience methods*, 2003, vol. 123, no 1, p. 69-87.
- [Aguirre-Echeverryet al, 2013] AGUIRRE-ECHEVERRY, C. A., DUQUE-MUNOZ, L., et CASTELLANOS-DOMINGUEZ, G. Epilepsy activity detection based on optimized one-class classifiers. In: *Image, Signal Processing, and Artificial Vision (STSIVA), 2013 XVIII Symposium of. IEEE*, 2013. p. 1-5.
- [Akshataet al, 2016] AKSHATA, P., SRUSHTI, B., et VEENA, D. EEG signal classification into seizure and non-seizure class using discrete wavelet transform and artificial neural network. *Int J Innovative Res Comput Commun Eng*, 2016, vol. 4, p. 14541-14547.
- [Akayet al, 1998] AKAY, Metin. *Time Frequency and Wavelets in Biomedical Signal Processing*. IEEE press series in Biomedical Engineering, 1998.
- [Alickovicet al, 2018] ALICKOVIC, Emina, KEVRIC, Jasmin, et SUBASI, Abdulhamit. Performance evaluation of empirical mode decomposition, discrete wavelet transform, and wavelet packed decomposition for automated epileptic seizure

- detection and prediction. *Biomedical Signal Processing and Control*, 2018, vol. 39, p. 94-102.
- [Alkanet al, 2005] ALKAN, Ahmet, KOKLUKAYA, Etem, et SUBASI, Abdulhamit. Automatic seizure detection in EEG using logistic regression and artificial neural network. *Journal of Neuroscience Methods*, 2005, vol. 148, no 2, p. 167-176.
- [Andrzejaket al, 2001] ANDRZEJAK, Ralph G., LEHNERTZ, Klaus, MORMANN, Florian, *et al.* Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state. *Physical Review E*, 2001, vol. 64, no 6, p. 061907.
- [Arimuraet al, 2009] ARIMURA, Hidetaka, MAGOME, Taiki, YAMASHITA, Yasuo, *et al.* Computer-aided diagnosis systems for brain diseases in magnetic resonance images. *Algorithms*, 2009, vol. 2, no 3, p. 925-952.
- [Arslanet al, 2012] ARSLAN, Sem, TEZEL, Gulay, et ISLK, Hakan. EEG Signals Classification Using a Hybrid Structure of ANN and PSO. *International Journal of Future Computer and Communication*, 2012, vol. 1, no 2, p. 170.
- [Ashaet al, 2013] ASHA, S. A., SUDALAIMANI, C., DEVANAND, P., *et al.* Automated seizure detection from multichannel EEG signals using support vector machine and artificial neural networks. In : *Automation, Computing, Communication, Control and Compressed Sensing (iMac4s), 2013 International Multi-Conference on. IEEE*, 2013. p. 558-563.
- [Azaret El-said, 2014] AZAR, Ahmad Taheret EL-SAID, Shaimaa Ahmed. Performance analysis of support vector machines classifiers in breast cancer mammography recognition. *Neural Computing and Applications*, 2014, vol. 24, no 5, p. 1163-1177.
- [Babbet al, 1974] BABB, Thomas L., MARIANI, Elmo, et CRANDALL, Paul H. An electronic circuit for detection of EEG seizures recorded with implanted electrodes. *Electroencephalography and clinical neurophysiology*, 1974, vol. 37, no 3, p. 305-308
- [Belhadjet al, 2016] BELHADJ, Sabrina, ATTIA, Abdelouahab, ADNANE, Ahmed Bachir, *et al.* Whole brain epileptic seizure detection using unsupervised classification. In : *Modelling, Identification and Control (ICMIC), 2016*

- 8th International Conference on*. IEEE, 2016. p. 977-982.
- [Belhadjet al, 2016] BELHADJ, Sabrina, ATTIA, Abedlouaheb, ADNANE, Bachir Ahmed, *et al.* A novel epileptic seizure detection using fast potential-based hierarchical agglomerative clustering based on emd. *International Journal of Computer Science and Network Security (IJCSNS)*, 2016, vol. 16, no 5, p. 7.
- [Birjandtalabet al, 2017] BIRJANDTALAB, Javad, POUYAN, Maziyar Baran, COGAN, Diana, *et al.* Automated seizure detection using limited-channel EEG and non-linear dimension reduction. *Computers in biology and medicine*, 2017, vol. 82, p. 49-58.
- [Birkemeier et al, 1978] BIRKEMEIER, William P., FONTAINE, A. Burr, CELESIA, Gastone G., *et al.* Pattern recognition techniques for the detection of epileptic transients in EEG. *IEEE Transactions on Biomedical Engineering*, 1978, no 3, p. 213-217
- [Boubchir et Boashash, 2013] BOUBCHIR, Larbi et BOASHASH, Boualem. Wavelet denoising based on the MAP estimation using the BKF prior with application to images and EEG signals. *IEEE Transactions on signal processing*, 2013, vol. 61, no 8, p. 1880-1894.
- [Boubchir et al, 2014] BOUBCHIR, Larbi, AL-MAADEED, Somaya, et BOURIDANE, Ahmed. Haralick. Feature extraction from time-frequency images for epileptic seizure detection and classification of EEG data. In: *Microelectronics (ICM), 2014 26th International Conference on*. IEEE, 2014. p. 32-35.
- [Boubchir et al, 2015] BOUBCHIR, Larbi, AL-MAADEED, Somaya, BOURIDANE, Ahmed, *et al.* Time-frequency image descriptors-based features for EEG epileptic seizure activities detection and classification. In : *Acoustics, Speech and Signal Processing (ICASSP), 2015 IEEE International Conference on*. IEEE, 2015. p. 867-871.
- [Chan et al, 2008] CHAN, Alexander M., SUN, Felice T., BOTO, Erem H., *et al.* Automated seizure onset detection for accurate onset time determination in intracranial EEG. *Clinical Neurophysiology*, 2008, vol. 119, no 12, p. 2687-2696. Chen H, Niu H. 2004.
- [Chandaka et al, 2009] CHANDAKA, Suryannarayana, CHATTERJEE, Amitava, et MUNSHI, Sugata. Cross-correlation aided

- support vector machine classifier for classification of EEG signals. *Expert Systems with Applications*, 2009, vol. 36, no 2, p. 1329-1336.
- [Claassen et al, 2004] CLAASSEN, J., MAYER, S. A., KOWALSKI, R. G., *et al.* Detection of electrographic seizures with continuous EEG monitoring in critically ill patients. *Neurology*, 2004, vol. 62, no 10, p. 1743-1748.
- [Cortes et Vanprik, 1995] CORTES, Corinna et VAPNIK, Vladimir. Support-vector networks. *Machine learning*, 1995, vol. 20, no 3, p. 273-297.
- [Dalton et al, 2012] DALTON, Anthony, PATEL, Shyamal, CHOWDHURY, Atanu Roy, *et al.* Development of a body sensor network to detect motor patterns of epileptic seizures. *IEEE Transactions on Biomedical Engineering*, 2012, vol. 59, no 11, p. 3204-3211.
- [Daset al, 2013] DAS, Pradipta Kumar, MOHAPATRA, Ayeskanta, et PANDA, MohitRanjan. Epilepsy disorder detection from EEG signal. *Int. J. Intell. Comput.Appl. Sci*, 2013, vol. 1, no 1, p. 41-49.
- [D'attellis et al, 1997] D'ATTELLIS, Carlos E., ISAACSON, Susana I., et SIRNE, Ricardo O. Detection of epileptic events in electroencephalograms using wavelet analysis. *Annals of Biomedical Engineering*, 1997, vol. 25, no 2, p. 286-293.
- [Dogali et Bozkurt, 2015] DOGALI, Gamze et BOZKURT, Mehmet Recep. The detection of normal and epileptic EEG signals using ANN methods with Matlab-based GUI. *International Journal of Computer Applications*, 2015, vol. 114, no 12.
- [Firpi et al, 2007] FIRPI, Hiram, GOODMAN, Erik D., et ECHAUZ, Javier. Epileptic seizure detection using genetically programmed artificial features. *IEEE Transactions on Biomedical Engineering*, 2007, vol. 54, no 2, p. 212-224.
- [Freiburg EEG database, 2008] Freiburg EEG database. <https://epilepsy.unifreiburg.de/freiburg-seizure-prediction-project/eeeg-database>.
- [Gardner et al, 2006] GARDNER, Andrew B., KRIEGER, Abba M., VACHTSEVANOS, George, *et al.* One-class novelty detection for seizure analysis from intracranial EEG. *Journal of Machine Learning Research*, 2006, vol. 7, no Jun, p. 1025-1044.

- [Gardner et al, 2007] GARDNER, Andrew B., WORRELL, Greg A., MARSH, Eric, *et al.* Human and automated detection of high-frequency oscillations in clinical intracranial EEG recordings. *Clinical neurophysiology*, 2007, vol. 118, no 5, p. 1134-1143.
- [Gayatri et al, 2010] GAYATRI, M., KUMAR, Arun, JANGHU, Manish, *et al.* Implementation of epileptic EEG using recurrent neural network. *International Journal of Computer Science and Network Security*, 2010, vol. 10, no 3, p. 290-296.
- [Ghosh-Dastidar et al, 2008] GHOSH-DASTIDAR, Samanwoy, ADELI, Hojjat, et DADMEHR, Nahid. Principal component analysis-enhanced cosine radial basis function neural network for robust epilepsy and seizure detection. *IEEE Transactions on Biomedical Engineering*, 2008, vol. 55, no 2, p. 512-518.
- [Goldberger et al, 2000] GOLDBERGER, Ary L., AMARAL, Luis AN, GLASS, Leon, *et al.* Physiobank, physiotoolkit, and physionet. *Circulation*, 2000, vol. 101, no 23, p. e215-e220.
- [Gotman et Gloor, 1976] GOTMAN, J. et GLOOR, P. Automatic recognition and quantification of interictal epileptic activity in the human scalp EEG. *Electroencephalography and clinical neurophysiology*, 1976, vol. 41, no 5, p. 513-529.
- [Gotman et al, 1979] GOTMAN, J., IVES, J. R., et GLOOR, P. Automatic recognition of inter-ictal epileptic activity in prolonged EEG recordings. *Electroencephalography and Clinical Neurophysiology*, 1979, vol. 46, no 5, p. 510-520.
- [Gotman, 1982] GOTMAN, J. Automatic recognition of epileptic seizures in the EEG. *Electroencephalography and clinical Neurophysiology*, 1982, vol. 54, no 5, p. 530-540.
- [Gotman, 1990] GOTMAN, Jean. Automatic seizure detection: improvements and evaluation. *Electroencephalography and clinical Neurophysiology*, 1990, vol. 76, no 4, p. 317-324.
- [Guler et al, 2005] GÜLER, Nihal Fatma, ÜBEYLI, ElifDerya, et GÜLER, Inan. Recurrent neural networks employing Lyapunov exponents for EEG signals classification. *Expert systems with applications*, 2005, vol. 29, no 3, p. 506-514.

- [Guler et Ubeyli, 2005] GÜLER, Inan et ÜBEYLI, Elif Derya. Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients. *Journal of neuroscience methods*, 2005, vol. 148, no 2, p. 113-121.
- [Guler et Ubeyli, 2007] GULER, Inan et UBEYLI, Elif Derya. Multiclass support vector machines for EEG-signals classification. *IEEE Transactions on Information Technology in Biomedicine*, 2007, vol. 11, no 2, p. 117-126.
- [Guo et al, 2010] GUO, Ling, RIVERO, Daniel, DORADO, Julián, *et al.* Automatic epileptic seizure detection in EEGs based on line length feature and artificial neural networks. *Journal of neuroscience methods*, 2010, vol. 191, no 1, p. 101-109.
- [Hanbay, 2009] HANBAY, Davut. An expert system based on least square support vector machines for diagnosis of the valvular heart disease. *Expert Systems with Applications*, 2009, vol. 36, no 3, p. 4232-4238.
- [Huaifu et Hai, 2004] HUAFU, Chen et HAI, Niu. Detection the character wave in epileptic EEG by wavelet. *Journal of Electronic Science and Technology*, 2004, vol. 2, no 1, p. 69-71.
- [Hunyadi et al, 2017] HUNYADI, Borbála, SIEKIERSKA, Aleksandra, SOURBRON, Jo, *et al.* Automated analysis of brain activity for seizure detection in zebrafish models of epilepsy. *Journal of neuroscience methods*, 2017, vol. 287, p. 13-24.
- [Jaiswal et Banka, 2017] JAISWAL, Abeg Kumar et BANKA, Haider. Epileptic seizure detection in EEG signal with GModPCA and support vector machine. *Bio-medical materials and engineering*, 2017, vol. 28, no 2, p. 141-157.
- [James et al, 1999] JAMES, Christopher J., JONES, Richard D., BONES, Philip J., *et al.* Detection of epileptiform discharges in the EEG by a hybrid system comprising mimetic, self-organized artificial neural network, and fuzzy logic stages. *Clinical Neurophysiology*, 1999, vol. 110, no 12, p. 2049-2063.
- [Jerger et al, 2001] JERGER, Kristin K., NETOFF, Theoden I., FRANCIS, Joseph T., *et al.* Early seizure detection. *Journal of Clinical Neurophysiology*, 2001, vol. 18, no 3, p. 259-268.

- [Kannathal et al, 2005] KANNATHAL, N., CHOO, Min Lim, ACHARYA, U. Rajendra, *et al.* Entropies for detection of epilepsy in EEG. *Computer methods and programs in biomedicine*, 2005, vol. 80, no 3, p. 187-194.
- [Karthika et Vijayanand, 2016] KARTHIKA, A. P. et VIJAYANAND, R. S. Detection and classification of epileptic seizure using RBF neural network. *Int J Emerging Technol ComputSci Electronics (IJETCSE)*, 2016, vol. 22, p. 56-60.
- [Kay et Marple, 1981] KAY, Steven M. et MARPLE, Stanley L. Spectrum analysis—a modern perspective. *Proceedings of the IEEE*, 1981, vol. 69, no 11, p. 1380-1419.
- [Kearsley-Fleet et al, 2013] KEARSLEY-FLEET, L., O'NEILL, D. G., VOLK, H. A., *et al.* Prevalence and risk factors for canine epilepsy of unknown origin in the UK. *Vet Rec*, 2013, vol. 172, no 13, p. 338.
- [Ktonas et al, 1979] KTONAS, P. Y., OSORIO, P. L., et EVERETT, R. L. Automated detection of EEG artifacts during sleep: preprocessing for all-night spectral analysis. *Clinical Neurophysiology*, 1979, vol. 46, no 4, p. 382-388.
- [Kocadagli et Langari, 2010] KOCADAGLI, Ozan et LANGARI, Reza. Classification of EEG signals for epileptic seizures using hybrid artificial neural networks based wavelet transforms and fuzzy relations. *Expert Systems with Applications*, 2017, vol. 88, p. 419-434.
- [Kumar et al, 2010] KUMAR, S. Pravin, SRIRAAM, N., BENAKOP, P. G., *et al.* Entropies based detection of epileptic seizures with artificial neural network classifiers. *Expert Systems with Applications*, 2010, vol. 37, no 4, p. 3284-3291.
- [Lasemidis,2003] IASEMIDIS, Leon D. Epileptic seizure prediction and control. *IEEE Transactions on Biomedical Engineering*, 2003, vol. 50, no 5, p. 549-558.
- [Li et al, 2017] LI, Mingyang, CHEN, Wanzhong, et ZHANG, Tao. Classification of epilepsy EEG signals using DWT-based envelope analysis and neural network ensemble. *Biomedical Signal Processing and Control*, 2017, vol. 31, p. 357-365.
- [Li et al, 2017] LI, Mingyang, CHEN, Wanzhong, et ZHANG, Tao. Automatic epileptic EEG detection using DT-CWT-based non-linear features. *Biomedical Signal Processing and Control*, 2017, vol. 34, p. 114-125.

- [Lima et Coelho, 2011] LIMA, Clodoaldo AM et COELHO, André LV. Kernel machines for epilepsy diagnosis via EEG signal classification: A comparative study. *Artificial Intelligence in Medicine*, 2011, vol. 53, no 2, p. 83-95.
- [Liu et al, 2002] LIU, He Sheng, ZHANG, Tong, et YANG, Fu Sheng. A multistage, multimethod approach for automatic detection and classification of epileptiform EEG. *IEEE Transactions on biomedical engineering*, 2002, vol. 49, no 12, p. 1557-1566.
- [Lin et al, 2016] LIN, Qin, YE, Shu-qun, HUANG, Xiu-mei, *et al.* Classification of epileptic EEG signals with stacked sparse autoencoder based on deep learning. In : *International Conference on Intelligent Computing*. Springer, Cham, 2016. p. 802-810.
- [Da Silva et al, 1997] DA SILVA, FH Lopes, VAN HULTEN, K., LOMMEN, J. G., *et al.* Automatic detection and localization of epileptic foci. *Electroencephalography and Clinical Neurophysiology*, 1977, vol. 43, no 1, p. 1-13.
- [Lotte, 2008] LOTTE, F., Study of electroencephalographic signal processing and classification techniques towards the use of brain computer interfaces in virtual reality applications. *Doctoral dissertation, INSA de Rennes*, 2008.
- [Marsh et al, 2010] MARSH, Eric D., PELTZER, Bradley, BROWN III, Merritt W., *et al.* Interictal EEG spikes identify the region of electrographic seizure onset in some, but not all, pediatric epilepsy patients. *Epilepsia*, 2010, vol. 51, no 4, p. 592-601.
- [Maryann et al, 2003] MARYANN, D’ALESSANDRO, ESTELLER, Rosana, VACHTSEVANOS, George, *et al.* Epileptic seizure prediction using hybrid feature selection over multiple intracranial EEG electrode contacts: a report of four patients. *IEEE Transactions on Biomedical Engineering*, 2003, vol. 50, no 5, p. 603-615.
- [Meenakshi et Singh, 2014] MEENAKSHI, Dr RK et SINGH, A. K. Frequency analysis of healthy & epileptic seizure in EEG using fast Fourier transform. *International Journal of Engineering Research and General Science*, 2014, vol. 2, no 4, p. 683-691.
- [Meier et al, 2008] MEIER, Ralph, DITTRICH, Heike, SCHULZE-BONHAGE, Andreas, *et al.* Detecting epileptic seizures in long-term human EEG: a new approach to automatic

- online and real-time detection and classification of polymorphic seizure patterns. *Journal of Clinical Neurophysiology*, 2008, vol. 25, no 3, p. 119-131.
- [Minasyan et al, 2010] MINASYAN, Georgiy R., CHATTEN, John B., CHATTEN, Martha Jane, *et al.* Patient-specific early seizure detection from scalp EEG. *Journal of clinical neurophysiology: official publication of the American Electroencephalographic Society*, 2010, vol. 27, no 3, p. 163.
- [Mitra et al, 2009] MITRA, Joyeeta, GLOVER, John R., KTONAS, Periklis Y., *et al.* A multi-stage system for the automated detection of epileptic seizures in neonatal EEG. *Journal of clinical neurophysiology: official publication of the American Electroencephalographic Society*, 2009, vol. 26, no 4, p. 218.
- [Moses et al, 1997] MOSES, P. Stoica R. et STOICA, Peter. Introduction to Spectral Analysis. 1997.
- [Mursalin et al, 2017] MURSALIN, Md, ZHANG, Yuan, CHEN, Yuehui, *et al.* Automated epileptic seizure detection using improved correlation-based feature selection with random forest classifier. *Neuro computing*, 2017, vol. 241, p. 204-214.
- [Murugavel et al, 2011] MURUGAVEL, AS Muthanantha, RAMAKRISHNAN, S., BALASAMY, K., *et al.* Lyapunov features based EEG signal classification by multi-class SVM. In : *Information and Communication Technologies (WICT), 2011 World Congress on.* IEEE, 2011. p. 197-201.
- [Nashat et al, 2015] NASHAT, Dalia, KHALIFA, G. Z., MOHAMED, M. G., *et al.* Android Application for Epilepsy Detection and Monitoring. *International Journal*, 2015, vol. 5, no 9.
- [Nasehi et Pourghassem, 2011] NASEHI, Saadat et POURGHASSEM, Hossein. Real-time seizure detection based on EEG and ECG fused features using Gabor functions. In : *Intelligent Computation and Bio-Medical Instrumentation (ICBMI), 2011 International Conference on.* IEEE, 2011. p. 204-207.
- [Nasehi et Pourghassem, 2013] NASEHI, Saadat et POURGHASSEM, Hossein. Patient-specific epileptic seizure onset detection algorithm based on spectral features and IPSONN classifier. In: *Communication Systems and Network*

- Technologies (CSNT), 2013 International Conference on.* IEEE, 2013. p. 186-190.
- [Nicolaou et Georgiou, 2012] NICOLAOU, Nicoletta et GEORGIU, Julius. Detection of epileptic electroencephalogram based on permutation entropy and support vector machines. *Expert Systems with Applications*, 2012, vol. 39, no 1, p. 202-209.
- [Niederhauser et al, 2003] NIEDERHAUSER, Joël J., ESTELLER, Rosana, ECHAUZ, Javier, *et al.* Detection of seizure precursors from depth-EEG using a sign periodogram transform. *IEEE Transactions on Biomedical Engineering*, 2003, vol. 50, no 4, p. 449-458.
- [Ocak, 2009] OCAK, Hasan. Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy. *Expert Systems with Applications*, 2009, vol. 36, no 2, p. 2027-2036.
- [Orellana et Cerqueira, 2016] ORELLANA, Marco Pinto et CERQUEIRA, Fabio. Personalized epilepsy seizure detection using random forest classification over one-dimension transformed EEG data. *bioRxiv*, 2016, p. 070300.
- [Olsen et al, 1994] OLSEN, Dale E., LESSER, Ronald P., HARRIS, John C., *et al.* *Automatic detection of seizures using electroencephalographic signals.* U.S. Patent No 5,311,876, 17 mai 1994.
- [Orhan et al, 2011] ORHAN, Umut, HEKIM, Mahmut, et OZER, Mahmut. EEG signals classification using the K-means clustering and a multilayer perceptron neural network model. *Expert Systems with Applications*, 2011, vol. 38, no 10, p. 13475-13481.
- [Orosco et al, 2011] OROSCO, Lorena, CORREA, Agustina Garcés, et LEBER, Eric Laciari. Epileptic seizures detection based on empirical mode decomposition of EEG signals. In : *Management of Epilepsy-Research, Results and Treatment.* InTech, 2011.
- [Orosco et al, 2013] OROSCO, Lorena, CORREA, Agustina Garcés, et LACIARI, Eric. a survey of performance and techniques for automatic epilepsy detection. *Journal of Medical and Biological Engineering*, 2013, vol. 33, no 6, p. 526-537.
- [Oweis et Abdulhay, 2011] OWEIS, Rami J. et ABDULHAY, Enas W. Seizure classification in EEG signals utilizing Hilbert-Huang transform. *Biomedical engineering online*, 2011, vol. 10,

- no 1, p. 38.
- [Panda et al, 2010] PANDA, R., KHOBRAGADE, P. S., JAMBHULE, P. D., *et al.* Classification of EEG signal using wavelet transform and support vector machine for epileptic seizure detection. In : *Systems in Medicine and Biology (ICSMB), 2010 International Conference on.* IEEE, 2010. p. 405-408.
- [Patnaik et Manyam, 2008] Patnaik, Lalit M. et MANYAM, Ohil K. Epileptic EEG detection using neural networks and post-classification. *Computer methods and programs in biomedicine*, 2008, vol. 91, no 2, p. 100-109.
- [Polat et Güneş, 2007] POLAT, Kemal et GÜNEŞ, Salih. Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform. *Applied Mathematics and Computation*, 2007, vol. 187, no 2, p. 1017-1026.
- [Prior et al, 1973] PRIOR, P. F., VIRDEN, R. S. M., et MAYNARD, D. E. An EEG device for monitoring seizure discharges. *Epilepsia*, 1973, vol. 14, no 4, p. 367-372.
- [Proakis et Manolakis, 1996] Proakis, J. G., &Manolakis, D. G. (1996) *Digital Signal Processing Principles, Algorithms, and Applications*, New Jersey: Prentice Hall.
- [Puspita et al,2017] PUSPITA, JuniWijayanti, GUNADHARMA, Suryani, INDRATNO, Supto Wahyu, *et al.* Bayesian approach to identify spike and sharp waves in EEG data of epilepsy patients. *Biomedical Signal Processing and Control*, 2017, vol. 35, p. 63-69.
- [Runarsson et Sigurdsson, 2005] RUNARSSON, Thomas Philip et SIGURDSSON, Sven. On-line detection of patient specific neonatal seizures using support vector machines and half-wave attribute histograms. In: *Computational Intelligence for Modelling, Control and Automation, 2005 and International Conference on Intelligent Agents, Web Technologies and Internet Commerce, International Conference on.* IEEE, 2005. p. 673-677.
- [Viglione et al, 1975] VIGLIONE, Sam S., ORDON, Vladimir A., MARTIN, William B., *et al.* *Epileptic seizure warning system.* U.S. Patent No 3,863,625, 4 févr. 1975.
- [Sharma et al, 2017] SHARMA, Manish, PACHORI, Ram Bilas, et ACHARYA, U. Rajendra. A new approach to characterize epileptic seizures using analytic time-frequency flexible wavelet transform and fractal

- dimension. *Pattern Recognition Letters*, 2017, vol. 94, p. 172-179.
- [Schad et al, 2008] SCHAD, Ariane, SCHINDLER, Kaspar, SCHELTER, Björn, *et al.* Application of a multivariate seizure detection and prediction method to non-invasive and intracranial long-term EEG recordings. *Clinical neurophysiology*, 2008, vol. 119, no 1, p. 197-211.
- [Sharmila et Geethanjali, 2016] SHARMILA, A. et GEETHANJALI, P. Detection of Epileptic Seizure from Electroencephalogram Signals Based on Feature Ranking and Best Feature Subset Using Mutual Information Estimation. *Journal of Medical Imaging and Health Informatics*, 2016, vol. 6, no 8, p. 1850-1864.
- [Patidar et Panigrahi, 2017] PATIDAR, Shivnarayan et PANIGRAHI, Trilochan. Detection of epileptic seizure using Kraskov entropy applied on tunable-Q wavelet transform of EEG signals. *Biomedical Signal Processing and Control*, 2017, vol. 34, p. 74-80.
- [Shoaib et al, 2014] SHOAIIB, Mohammed, LEE, Kyong Ho, JHA, Niraj K., *et al.* A 0.6–107  $\mu$ W energy-scalable processor for directly analyzing compressively-sensed EEG. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 2014, vol. 61, no 4, p. 1105-1118.
- [Simundic, 2008] ŠIMUNDIĆ, Ana-Maria. Measures of diagnostic accuracy: basic definitions. *Medical and biological sciences*, 2008, vol. 22, no 4, p. 61-65.
- [Siuly et Zhang, 2016] SIULY, Siulyet ZHANG, Yanchun. Medical big data: neurological diseases diagnosis through medical data analysis. *Data Science and Engineering*, 2016, vol. 1, no 2, p. 54-64.
- [Sörnmo et Laguna, 2005] SÖRNMO, Leif et LAGUNA, Pablo. *Bioelectrical signal processing in cardiac and neurological applications*. Academic Press, 2005.
- [Subasi et al, 2005] SUBASI, Abdulhamit, ALKAN, Ahmet, KOKLUKAYA, Etem, *et al.* Wavelet neural network classification of EEG signals by using AR model with MLE preprocessing. *Neural Networks*, 2005, vol. 18, no 7, p. 985-997
- [Subasi et al, 2005] SUBASI, Abdulhamit, KIYMIK, M. Kemal, ALKAN, Ahmet, *et al.* Neural network classification of EEG signals by using AR with MLE preprocessing for

- epileptic seizure detection. *Mathematical and Computational Applications*, 2005, vol. 10, no 1, p. 57-70.
- [Subasi, 2005] SUBASI, Abdulhamit. Epileptic seizure detection using dynamic wavelet network. *Expert Systems with Applications*, 2005, vol. 29, no 2, p. 343-355.
- [Subasi, 2006] SUBASI, Abdulhamit. Automatic detection of epileptic seizure using dynamic fuzzy neural networks. *Expert Systems with Applications*, 2006, vol. 31, no 2, p. 320-328.
- [Subasi et GURSOY, 2010] SUBASI, Abdulhamit et GURSOY, M. Ismail. EEG signal classification using PCA, ICA, LDA and support vector machines. *Expert Systems with Applications*, 2010, vol. 37, no 12, p. 8659-8666.
- [Tafreshi et al, 2016] SWAMI, Piyush, GANDHI, Tapan K., PANIGRAHI, Bijaya K., *et al.* A novel robust diagnostic model to detect seizures in electroencephalography. *Expert Systems with Applications*, 2016, vol. 56, p. 116-130.
- [Tafreshi et al, 2008] TAFRESHI, Azadeh Kamali, NASRABADI, Ali M., et OMIDVARNIA, Amir H. Epileptic seizure detection using empirical mode decomposition. In: *Signal Processing and Information Technology, 2008. ISSPIT 2008. IEEE International Symposium on*. IEEE, 2008. p. 238-242
- [Talathi, 2017] TALATHI, Sachin S. Deep Recurrent Neural Networks for seizure detection and early seizure detection systems. *arXiv preprint arXiv:1706.03283*, 2017
- [The EuropeanEpilepsyDatabase,2007] The European Epilepsy Database. <http://epilepsy-database.eu>
- [Tong et al, 2017] TIBDEWAL, Manish N., DEY, Himanshu R., MAHADEVAPPA, Manjunatha, *et al.* Multiple entropies performance measure for detection and localization of multi-channel epileptic EEG. *Biomedical Signal Processing and Control*, 2017, vol. 38, p. 158-167.
- [Tiwari et al, 2017] TIWARI, Ashwani Kumar, PACHORI, Ram Bilas, KANHANGAD, Vivek, *et al.* Automated diagnosis of epilepsy using key-point-based local binary pattern of EEG signals. *IEEE journal of biomedical and health informatics*, 2017, vol. 21, no 4, p. 888-896.

- [Tong et Thakor, 2009] TONG, Shanbaoet THAKOR, Nitish Vyomesh. *Quantitative EEG analysis methods and clinical applications*. Artech House, 2009.
- [Tsiouris et al, 2018] TSIOURIS, Kostas M., MARKOULA, Sofia, KONITSIOTIS, Spiros, *et al.* A robust unsupervised epileptic seizure detection methodology to accelerate large EEG database evaluation. *Biomedical Signal Processing and Control*, 2018, vol. 40, p. 275-285.
- [Truong et al, 2017] TRUONG, Nhan Duy, KUHLMANN, Levin, BONYADI, Mohammad Reza, *et al.* Supervised learning in automatic channel selection for epileptic seizure detection. *Expert Systems with Applications*, 2017, vol. 86, p. 199-207.
- [Tzallas et al, 2009] TZALLAS, Alexandros T., TSIPOURAS, Markos G., et FOTIADIS, Dimitrios I. Epileptic seizure detection in EEGs using time–frequency analysis. *IEEE transactions on information technology in biomedicine*, 2009, vol. 13, no 5, p. 703-710.
- [Übeyli et Güler, 2003] ÜBEYLI, Elif Derya et GÜLER, İnan. Comparison of eigenvector methods with classical and model-based methods in analysis of internal carotid arterial Doppler signals. *Computers in biology and medicine*, 2003, vol. 33, no 6, p. 473-493.
- [Übeyli, 2009] ÜBEYLI, Elif Derya. Decision support systems for time-varying biomedical signals: EEG signals classification. *Expert Systems with Applications*, 2009, vol. 36, no 2, p. 2275-2284.
- [Übeyli, 2009] ÜBEYLI, Elif Derya. Statistics over features: EEG signals analysis. *Computers in Biology and Medicine*, 2009, vol. 39, no 8, p. 733-741.
- [Übeyli, 2009] ÜBEYLI, Elif Derya. Combined neural network model employing wavelet coefficients for EEG signals classification. *Digital Signal Processing*, 2009, vol. 19, no 2, p. 297-308.
- [Übeyli,2009] ÜBEYLI, Elif Derya. Analysis of EEG signals by implementing eigenvector methods/recurrent neural networks. *Digital Signal Processing*, 2009, vol. 19, no 1, p. 134-143.
- [Vivek et al, 2013] VIVEK, N. P. et DANIAL, G. A .Network-Based Detection of Epilepsy. *A Journal of Progress in Neurosurgery, Neurology, and Neurosciences [serial online]*, 2013, vol. 26, no 1.

- [Wang et al, 2017] WANG, Yuanfa, LI, Zunchao, FENG, Lichen, *et al.* Automatic Detection of Epilepsy and Seizure Using Multiclass Sparse Extreme Learning Machine Classification. *Computational and mathematical methods in medicine*, 2017, vol. 2017.
- [Welch , 1967] WELCH, Peter. The use of fast Fourier transform for the estimation of power spectra: a method based on time averaging over short, modified periodograms. *IEEE Transactions on audio and electroacoustics*, 1967, vol. 15, no 2, p. 70-73.
- [Weng et Khoasani, 1996] WENG, W. d et KHORASANI, Khashayar. An adaptive structure neural networks with application to EEG automatic seizure detection. *Neural Networks*, 1996, vol. 9, no 7, p. 1223-1240.
- [Yalcin et al, 2015] YALCIN, Nesibe, TEZEL, Gülay, et KARAKUZU, Cihan. Epilepsy diagnosis using artificial neural network learned by PSO. *Turkish Journal of Electrical Engineering & Computer Sciences*, 2015, vol. 23, no 2, p. 421-432
- [Yoo et al,2013] YOO, Jerald, YAN, Long, EL-DAMAK, Dina, *et al.* An 8-channel scalable EEG acquisition SoC with patient-specific seizure classification and recording processor. *IEEE journal of solid-state circuits*, 2013, vol. 48, no 1, p. 214-228.
- [Zandi et al, 2010] ZANDI, Ali Shahidi, JAVIDAN, Manouchehr, DUMONT, Guy A., *et al.* Automated real-time epileptic seizure detection in scalp EEG recordings using an algorithm based on wavelet packet transform. *IEEE Transactions on Biomedical Engineering*, 2010, vol. 57, no 7, p. 1639-1651.
- [Zhang et al, 2017] ZHANG, Zhongnan, WEN, Tingxi, HUANG, Wei, *et al.* Automatic epileptic seizure detection in EEGs using MF-DFA, SVM based on cloud computing. *Journal of X-ray Science and Technology*, 2017, vol. 25, no 2, p. 261-272.
- [Zhou et al,2013] ZHOU, Weidong, LIU, Yinxia, YUAN, Qi, *et al.* Epileptic seizure detection using lacunarity and Bayesian linear discriminant analysis in intracranial EEG. *IEEE Transactions on Biomedical Engineering*, 2013, vol. 60, no 12, p. 3375-3381.

CHAPITRE

III

**CONTRIBUTION ET  
MÉTHODOLOGIE**

### III.1. INTRODUCTION

Bien que les méthodes citées dans le chapitre précédent atteignent une excellente précision dans certains cas, elles ont été jugées insuffisantes pour apprendre et classifier les signaux EEG qui sont complexes et non stationnaires. De plus, le choix de méthode d'extraction de caractéristiques joue un rôle très important dans les performances de classification. Pour traiter ce problème, cette thèse introduit un nouveau cadre pour la détection automatique et la classification des crises d'épilepsie en utilisant une méthode paramétrique appelée modèle autorégressif (AR) avec un autoencodeur clairsemé (Spars Autoencoder(SAE)). Cependant, le modèle AR a été utilisé pour l'extraction de caractéristiques des signaux EEG. Cela permet de sélectionner des coefficients qui peuvent être utilisés directement par les algorithmes de classificateurs. En outre, la modélisation AR est un outil très utile pour les signaux qui ont une résolution haute fréquence et les spectres plus lisses. Dans cette méthode, l'algorithme de Burg a été utilisé pour estimer les coefficients du modèle du signal EEG d'entrée. Ces coefficients obtenus ont été améliorés par un autoencodeur clairsemé. Ensuite, le résultat de SAE a été utilisé comme entrée dans le classificateur SVM. La méthode proposée sera décrit dans ce chapitre.

### III.2. EXTRACTION DES CARACTERISTIQUES

Il existe quatre types de techniques d'extraction de caractéristiques : méthodes paramétriques, méthodes non paramétriques, méthodes temps-fréquence et méthodes du vecteur propre. Dans ce travail, nous utilisons une méthode paramétrique. La méthode paramétrique nous donne les paramètres des signaux EEG qui peuvent être utilisés pour la classification des crises d'épilepsie. L'une des méthodes paramétriques les plus importantes est la modélisation autorégressive (AR). L'algorithme d'erreur quadratique, l'algorithme de Berg et l'algorithme de Yule-Walker sont des méthodes paramétriques les plus utilisées. L'algorithme de burg a déjà prouvé son efficacité pour la modélisation autorégressive car les paramètres extraits avec l'algorithme d'erreur quadratique et l'algorithme de Yule-Walker sont de mauvaise qualité lorsque la taille des échantillons de données augmente. Ainsi, pour ces raisons, nous utilisons la méthode de Berg. L'algorithme de Berg nous fournit les caractéristiques précises même si la longueur de l'échantillon de données est élevée.

Ceci sera décrit dans les sections suivantes en supposant que le signal d'entrée EEG  $X(n)$ ,  $n$  varié  $n = 1, 2, 3, \dots, N$  où  $N$  est la longueur du signal EEG.

### III.2.1. La modélisation autorégressive du signal EEG

Le modèle AR est l'une des méthodes paramétriques importantes appliquées dans de nombreuses études pour modéliser les signaux EEG.

Dans le modèle autorégressif (AR), chaque échantillon  $x(n)$  du signal aléatoire à modéliser est décrit par une combinaison linéaire de  $p$  échantillons précédents plus un terme erreur  $e(n)$  [Steven et al., 1988 ; Kay et Marple, 1981 ; Makhoul, 1981]:

$$X(n) = - \sum_{k=1}^p a_k x(n-k) + e(n) \quad (\text{III.1})$$

Le modèle AR peut être interprété comme un système linéaire excité par le signal  $e(n)$  et dont la réponse est  $x(n)$ .

$e(n)$  est un bruit blanc gaussien centré de variance  $\sigma_e^2$ .

La densité spectrale  $\hat{G}_{AR}(f)$  est donnée par [Baldeweck et al., 1995]:

$$\hat{G}_{AR}(f) = \frac{\sigma_e^2}{|1 + \sum_{n=1}^p a_n e^{-j2\pi f n}|^2} \quad (\text{III.2})$$

L'estimation de la densité spectrale d'un processus AR consiste à calculer les coefficients  $a_k (k=1, \dots, p)$  et la variance  $\sigma_e^2$ .

La mise en œuvre du modèle AR est réalisée par la résolution des équations de Yule-Walker [Steven et al., 1988]. Ces équations sont données par :

$$R_{xx}(k) = \begin{cases} - \sum_{i=1}^p a_i R_{xx}(k-i) & k > 0 \\ \sum_{i=1}^p |a_i R_{xx}(-i) + \sigma_e^2| & k = 0 \end{cases} \quad (\text{III.3})$$

La détermination des paramètres AR du système d'équations (III.3) est obtenue par le choix et la résolution du système de  $p$  équations pour ( $k=0$ ). Pour déterminer  $\sigma_e^2$ , on utilise le cas où ( $k=0$ ).

L'algorithme récursif de Levinson permet de déterminer les paramètres AR et  $\sigma_e^2$  en mettant en relation les coefficients AR et les valeurs des coefficients d'autocorrélation

estimées à partir des données. Cette procédure s'effectuant en deux temps n'est pas la meilleure méthode. En se basant sur la récursivité de Levinson, Burg a développé une approche permettant de calculer les paramètres AR directement à partir des données [Kay et Marple, 1981 ; Burg, 1967].

### III.2.1.1. Estimation des paramètres par la méthode de Burg

L'algorithme de Burg est une innovation de celui de Yule-Walker. Il s'agit d'estimer les coefficients du modèle par un algorithme récursif qui consiste à trouver les fonctions d'autocorrélations décrites par des coefficients de réflexion. Les étapes successives de l'algorithme correspondent à des modèles autorégressifs d'ordre croissant. Ainsi, à chaque étape, les paramètres autorégressifs seront donnés par les coefficients de réflexion ainsi que les paramètres autorégressifs de l'étape précédente.

Cependant, les paramètres AR sont basés sur les coefficients de réflexion défini par [Stoica et al., 2005; Rangayyan, 2015] :

$$\begin{cases} a_{pk} = a_{p-1,k} + a_{pp}a_{p-1,p-k}^* & k = 1, \dots, p \\ \sigma_e^2 = (1 - |a_{pp}|^2) \sigma_{p-1}^2 \end{cases} \quad (\text{III.4})$$

Où  $a_{pk}$  est le  $k$  ième coefficient dans la  $p$  ième itération,  $p$  étant l'ordre optimal.

Burg a estimé les paramètres AR d'un processus stationnaire au sens large en minimisant la somme de l'erreur quadratique progressive et de l'erreur quadratique rétrograde résumées dans un seul critère :

$$E_p = \sum_{n=p}^{N-1} |e_p^p(n)|^2 + \sum_{n=p}^{N-1} |e_p^r(n)|^2 \quad (\text{III.5})$$

Où  $e_p^p(n)$  est l'erreur de prédiction progressive d'ordre  $p$  (les  $p$  valeurs précédentes) définie par :

$$e_p^p(n) = x(n) - \hat{x}(n) = \sum_{k=0}^p a_{pk} x(n-k), \quad p \leq n \leq N-1 \quad (\text{III.6})$$

$N$  est le nombre d'échantillons, et  $e_p^r(n)$  est l'erreur de prédiction rétrogradée d'ordre  $p$  (les  $p$  valeurs futures) définie par :

$$e_p^r(n) = x(n-p) - \hat{x}(n-p) = \sum_{k=0}^p a_{pk}^* x(n+k-p), \quad p \leq n \leq N-1 \quad (\text{III.7})$$

La substitution de (III.4) dans (III.6) et (III.7) résulte en les expressions itératives suivantes [Giordano et Hsu, 1985]:

$$\begin{cases} e_p^p(n) = e_{p-1}^p(n-1) + a_{pp}^* e_{p-1}^r(n) \\ e_p^r(n) = e_{p-1}^r(n) + a_{pp} e_{p-1}^p(n-1) \end{cases} \quad (\text{III.8})$$

En substituant l'équation (III.8) dans (III.5) et en utilisant le critère de minimisation de l'erreur quadratique moyenne  $\frac{\partial E_P}{\partial a_{pp}} = 0$ , il vient :

$$a_{kk} = \hat{K}_k = \frac{-2 \sum_{i=k}^{N-1} e_{k-1}^p(i-1) e_{k-1}^r(i)}{\sum_{i=k}^{N-1} (|e_{k-1}^p(i-1)|^2 + |e_{k-1}^r(i)|^2)} \quad k = 1, 2, \dots, p \quad (\text{III.9})$$

La procédure de l'estimation de la densité spectrale par la technique itérative de Burg est résumée ci-dessous.

➤ Initialisation :

- Calcul de l'erreur quadratique moyenne initiale :

$$R_{xx}(0) = \sigma_e^2$$

- Calcul des erreurs de prédiction à l'ordre 0 :

$$e_0^p(n) = x(n) \quad n = 1, \dots, N-1$$

$$e_0^r(n) = x(n) \quad n = 1, \dots, N-1$$

➤ Calcul des coefficients de réflexion :

Equation (III.9)

➤ Calcul de la récursivité de Levinson :

$$\begin{cases} a_{kj} = a_{k-1,j} + a_{kk} a_{k-1,k-j}^* \\ \sigma_k^2 = (1 - |a_{kk}|^2) \sigma_{k-1}^2 \end{cases} \quad j = 1, \dots, k-1$$

- La mise à jour des erreurs de la prédiction :

$$e_k^p(n) = e_{k-1}^p(n-1) + a_{pp}e_{k-1}^r(n) \quad n = k, k+1, \dots, N-2$$

$$e_k^r(n) = e_{k-1}^r(n) + a_{kk}e_{k-1}^p(n-1) \quad n = k+1, \dots, N-1$$

- Calcul de la densité spectrale :

Equation (III.2)

Où les coefficients AR  $a_k, k = 0, \dots, p$  sont remplacés par  $a_{pk}, k = 0, \dots, p$  et  $\sigma_e^2$  est remplacé par  $\sigma_k^2, k = p$ .

### III.2.1.2. Critère de sélection de l'ordre optimal du modèle

La sélection de l'ordre du modèle est une étape très importante pour l'analyse fréquentielle dans un processus autorégressif. Il s'agit de déterminer le nombre des observations passées nécessaire pour prédire les observations du processus de la série temporelle.

Par conséquent, de nombreux chercheurs se sont concentrés sur la recherche d'une méthode objective pour déterminer l'ordre des signaux du modèle autorégressif. Plusieurs critères de sélection d'ordre ont été proposés, tel que le critère d'information Akaike (AIC) [Krusienski et McFarland, 2006] qui est largement utilisé pour sélectionner le meilleur ordre de modèle P [Kamel et al., 2007 ; Vedavathi et al., 2014]. Cependant, l'ordre du modèle P permet d'obtenir des coefficients de modèle AR adéquats. En supposant que le signal d'entrée a une taille N, l'AIC pour un processus AR sélectionné par:

$$AIC(p) = \ln(\sigma^2) + \frac{2p}{N} \quad (III.10)$$

Où  $\sigma^2$  est la variance du bruit blanc.

Il s'agit principalement de choisir l'ordre qui minimise le critère (III.10).

### III.3. AMELIORATION DES VECTEURS DE CARACTERISTIQUES PAR L'AUTOENCODEUR CLAIRSEME

L'objectif principal de cette thèse est l'utilisation de l'autoencodeur afin d'améliorer les caractéristiques extraites des signaux EEG en utilisant la méthode de Burg. Fondamentalement, un autoencodeur est une méthode d'apprentissage non supervisée qui est formée pour reconstruire son entrée à sa sortie [Hinton and Zemel, 1994; Vincent et al, 2008].

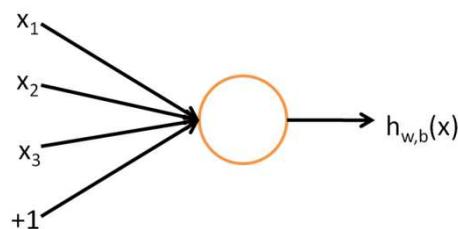
Nous allons tout d'abord décrire les réseaux neuronaux non bouclés (appelés aussi réseaux à couches ou réseaux unidirectionnels) (en anglais : feedforward) et l'algorithme de rétropropagation pour l'apprentissage supervisé.

Ensuite, nous montrons comment cela est utilisé pour développer un autoencodeur, qui est un algorithme d'apprentissage non supervisé.

#### III.3.1. Les réseaux de neurones

Considérons un problème d'apprentissage supervisé où nous avons accès à des exemples d'apprentissage étiquetés  $(x(i), y(i))$ . Les réseaux de neurones permettent de définir une forme complexe, non-linéaire, d'hypothèses  $h_{W,b}(x)$ , avec des paramètres  $W, b$  que nous pouvons adapter à nos données.

Pour décrire les réseaux neuronaux, nous commencerons par décrire le réseau neuronal le plus simple possible, qui comprend un seul «neurone». Nous utiliserons le diagramme suivant pour désigner un seul neurone [ABDI, 1994]:



**Figure III.1.** Le réseau neuronal

Ce "neurone" est une unité de calcul qui prend comme entrée  $x_1, x_2, x_3$  (et un terme d'interception  $a + 1$ ), et une sortie  $h_{W,b}(x) = f(W^T x) = f(\sum_{i=1}^3 W_i x_i + b)$ ,  $f: \mathbb{R} \rightarrow \mathbb{R}$

Où elle est appelée fonction d'activation,  $f(z)$  est la fonction sigmoïde définie par:

$$f(z) = \frac{1}{1 + \exp(-z)} \quad (\text{III.11})$$

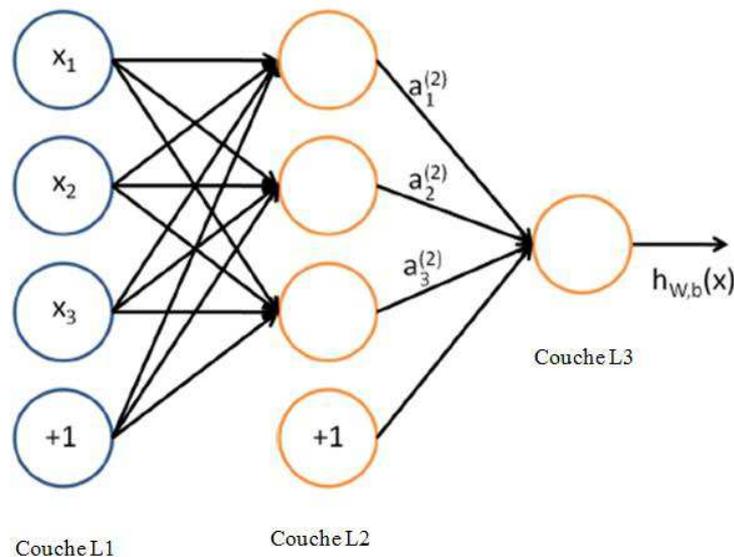
Alors la dérivée est donnée par :

$$f'(z) = f(z)(1 - f(z)) \quad (\text{III.12})$$

Ainsi, notre neurone unique correspond exactement au mappage entrées-sorties défini par la régression logistique.

### III.3.1.1. Formulation de réseau neuronal

Un réseau de neurones est mis en place en reliant plusieurs "neurones" simples, de sorte que la sortie d'un neurone peut être l'entrée d'un autre [DAVALO et NAÏM, 1990 ; DEMUTH et al., 2014]. Par exemple, voici un petit réseau de neurones (Figure III.2):



**Figure III.2.** Réseau de neurones avec une seule sortie

Les cercles en bleu désignent les entrées du réseau. Les cercles étiquetés "+1" sont appelés unités de polarisation et correspondent au terme d'interception. La couche à gauche du réseau s'appelle la couche d'entrée, et la couche à droite la couche de sortie (qui, dans cet exemple, n'a qu'un nœud). La couche intermédiaire des nœuds s'appelle la couche cachée, car ses valeurs ne sont pas observées dans l'ensemble d'apprentissage. Cet exemple de réseau de

neurones à 3 unités d'entrée (sans compter l'unité de polarisation), 3 unités cachées, et 1 unité de sortie.

Nous laisserons  $n_l$  indiquer le nombre de couches dans notre réseau (dans l'exemple précédent  $n_l = 3$ ). Nous étiquetons la couche  $l$  comme  $L_l$ , donc la couche  $L_l$  est la couche d'entrée, et la couche  $L_{n_l}$  la couche de sortie.

Notre réseau de neurones a des paramètres  $(W, b) = (W_{(1)}, b_{(1)}, W_{(2)}, b_{(2)})$ , où nous notons  $W_{ij}^{(l)}$  pour désigner le paramètre (ou poids) associé à la connexion entre l'unité  $j$  dans la couche  $l$ , et l'unité  $i$  dans la couche  $l + 1$ . De plus,  $b_i^{(l)}$  est la polarisation associée à l'unité  $i$  dans la couche  $l + 1$ . Ainsi, dans notre exemple, nous avons  $W^{(1)} \in \mathbb{R}^{3 \times 3}$  et  $W^{(2)} \in \mathbb{R}^{1 \times 3}$

Notons que les unités de polarisation ne possèdent pas d'entrées ou de connexions, puisqu'elles fournissent toujours la valeur +1. Nous indiquons également  $s_l$  le nombre de nœuds dans la couche  $l$  (sans compter l'unité de polarisation).

Nous allons écrire  $a_i^{(l)}$  pour désigner l'activation (signifiant la valeur de sortie) de l'unité  $i$  dans la couche  $l$ . Pour  $l = 1$ , on utilise aussi  $a_i^{(1)} = x_i$  pour désigner la  $i$ -ième entrée.

Étant donné un réglage fixe des paramètres  $W$  et  $b$ , notre réseau de neurones définit une hypothèse  $h_{w,b}(x)$  qui produit un nombre réel. Plus précisément, le calcul que représente ce réseau neuronal est donné par :

$$a_1^{(2)} = f(W_{11}^{(1)} x_1 + W_{12}^{(1)} x_2 + W_{13}^{(1)} x_3 + b_1^{(1)}) \quad (\text{III.13})$$

$$a_2^{(2)} = f(W_{21}^{(1)} x_1 + W_{22}^{(1)} x_2 + W_{23}^{(1)} x_3 + b_2^{(1)}) \quad (\text{III.14})$$

$$a_3^{(2)} = f(W_{31}^{(1)} x_1 + W_{32}^{(1)} x_2 + W_{33}^{(1)} x_3 + b_3^{(1)}) \quad (\text{III.15})$$

$$h_{w,b}(x) = a_1^{(3)} = f(W_{11}^{(2)} a_1^{(2)} + W_{12}^{(2)} a_2^{(2)} + W_{13}^{(2)} a_3^{(2)} + b_1^{(2)}) \quad (\text{III.16})$$

Dans la suite, nous indiquons aussi  $z_i^{(l)}$  la somme totale pondérée des entrées de l'unité  $i$  dans la couche  $l$ , y compris le terme de biais (e.g.,  $z_i^{(2)} = \sum_{j=1}^n W_{ij}^{(1)} x_j + b_i^{(2)}$ ), alors que  $a_i^{(l)} = f(z_i^{(l)})$ .

Notons que cela se prête facilement à une notation plus compacte. Plus précisément, si nous étendons la fonction d'activation  $f(\cdot)$  pour l'appliquer aux vecteurs de manière élémentaire (i.e.,  $f([z_1, z_2, z_3]) = [f(z_1), f(z_2), f(z_3)]$ ), alors nous pouvons écrire les équations (III.13-III.16) de manière plus compacte comme :

$$z^{(2)} = W^{(1)}x + b^{(1)} \quad (\text{III.17})$$

$$a^{(2)} = f(z^{(2)}) \quad (\text{III.18})$$

$$z^{(3)} = W^{(2)}a^{(2)} + b^{(2)} \quad (\text{III.19})$$

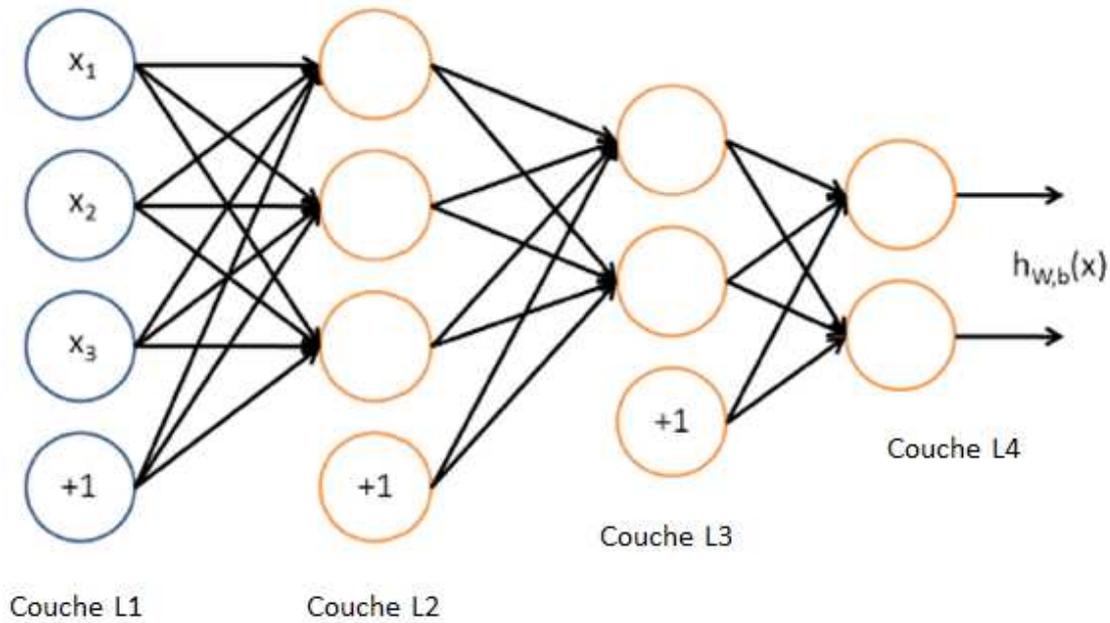
$$h_{W,b}(x) = a^{(3)} = f(z^{(3)}) \quad (\text{III.20})$$

Plus généralement,  $a^{(1)} = x$  est aussi utilisée pour désigner les valeurs de la couche d'entrée, puis donné les activations de la couche  $a^{(l)}$ , nous pouvons calculer les activations  $a^{(l+1)}$  de la couche  $l+1$  comme suite :

$$z^{(l+1)} = W^{(l)}a^{(l)} + b^{(l)} \quad (\text{III.21})$$

$$a^{(l+1)} = f(z^{(l+1)}) \quad (\text{III.22})$$

Les réseaux de neurones peuvent également avoir plusieurs unités de sortie. Par exemple, voici un réseau avec deux couches cachées  $L_2$  et  $L_3$  et deux unités de sortie dans la couche  $L_4$  (Figure III.3) :



**Figure III.3.** Réseau de neurones à deux unités de sortie

Pour former ce réseau, nous aurions besoin d'exemples d'apprentissage  $(x^{(i)}, y^{(i)})$  où  $y^{(i)} \in \mathbb{R}^2$ .

Ce type de réseau est utile s'il existe plusieurs sorties que nous souhaitons prédire. (Par exemple, dans une application de détection de crise d'épilepsie, le vecteur  $x$  peut donner les caractéristiques d'entrée d'un patient, et les différentes sorties  $y_i$  peuvent indiquer la présence ou l'absence de crise.)

### III.3.1.2. Algorithme de rétropropagation

Supposons que nous ayons un ensemble d'entraînement fixe  $\{(x^{(1)}, y^{(1)}), \dots, (x^{(m)}, y^{(m)})\}$  de  $m$  exemples d'entraînement. Nous pouvons former notre réseau neuronal en utilisant la descente en gradient par lot.

En détail, pour un seul exemple d'apprentissage  $(x, y)$ , nous définissons la fonction de coût par rapport à cet exemple par [KROGH et HERTZ, 1992 ; LECUN et al, 1998] :

$$J(W, b; x, y) = \frac{1}{2} \|h_{W,b}(x) - y\|^2 \quad (\text{III.23})$$

C'est une fonction de coût d'erreur quadratique. Étant donné un ensemble d'entraînement d'exemples  $m$ , nous définissons ensuite la fonction de coût globale par :

$$\begin{aligned}
 J(W, b) &= \left[ \frac{1}{m} \sum_{i=1}^m J(W, b; x^{(i)}, y^{(i)}) \right] + \frac{\lambda}{2} \sum_{l=1}^{n_l-1} \sum_{i=1}^{s_l} \sum_{j=1}^{s_{l+1}} (W_{ji}^{(l)})^2 \\
 &= \left[ \frac{1}{m} \sum_{i=1}^m \left( \frac{1}{2} \|h_{W,b}(x^{(i)}) - y^{(i)}\|^2 \right) \right] + \frac{\lambda}{2} \sum_{l=1}^{n_l-1} \sum_{i=1}^{s_l} \sum_{j=1}^{s_{l+1}} (W_{ji}^{(l)})^2
 \end{aligned} \tag{III.24}$$

Le premier terme de la définition de  $J(W, b)$  est un terme d'erreur moyenne de la somme des carrés. Le second terme est un terme de régularisation (également appelé terme de désintégration du poids) qui tend à diminuer l'amplitude des poids et à prévenir le surajustement. Le paramètre de désintégration du poids  $\lambda$  contrôle l'importance relative des deux termes. Notons également que la notation légèrement surchargée:  $J(W, b; x, y)$  est le coût d'erreur quadratique par rapport à un seul exemple;  $J(W, b)$  est la fonction de coût globale, qui inclut le terme de désintégration de poids.

Cette fonction de coût ci-dessus est souvent utilisée à la fois pour la classification et pour les problèmes de régression. Pour la classification, on donne  $y = 0$  ou  $1$  représentant les deux classes étiquettes (on rappelle que la fonction d'activation sigmoïde fournit des valeurs dans  $[0, 1]$ , pour les problèmes de régression, nous étalons d'abord nos sorties pour nous assurer qu'elles se situent dans la plage  $[0, 1]$ ).

Notre objectif est de minimiser  $J(W, b)$  en fonction de  $W$  et  $b$ . Pour apprendre notre réseau de neurones, nous allons initialiser chaque paramètre  $W_{ij}^{(l)}$  et chaque  $b_i^{(l)}$  à une petite valeur aléatoire proche de zéro, puis appliquons un algorithme d'optimisation tel que la descente du gradient par lots. Puisque  $J(W, b)$  est une fonction non-convexe, la descente du gradient est sensible aux optima locaux; cependant, dans la pratique, la descente en gradient fonctionne généralement assez bien. Enfin, notons qu'il est important d'initialiser les paramètres de manière aléatoire, plutôt que sur tous les 0. Si tous les paramètres démarrent à des valeurs identiques, alors toutes les unités de couches cachées finiront par apprendre la même fonction d'entrée (plus formellement,  $W_{ij}^{(l)}$  sera le même pour toutes les valeurs de  $i$ , de sorte que  $a_1^{(2)} = a_2^{(2)} = a_3^{(2)} = \dots$  pour toute entrée  $x$ ). L'initialisation aléatoire sert à la rupture de la symétrie.

Une itération de descente du gradient met à jour les paramètres  $W, b$  comme suit :

$$W_{ij}^{(l)} := W_{ij}^{(l)} - \alpha \frac{\partial}{\partial W_{ij}^{(l)}} J(W, b) \quad (\text{III.25})$$

$$b_i^{(l)} := b_i^{(l)} - \alpha \frac{\partial}{\partial b_i^{(l)}} J(W, b) \quad (\text{III.26})$$

Où  $\alpha$  est le taux d'apprentissage. L'étape clé consiste à calculer les dérivées partielles ci-dessus. Nous allons maintenant décrire l'algorithme de rétropropagation, qui fournit un moyen efficace pour calculer ces dérivées partielles.

Nous décrirons d'abord comment la rétropropagation peut être utilisée pour calculer  $\alpha \frac{\partial}{\partial W_{ij}^{(l)}} J(W, b; x, y)$  et  $\alpha \frac{\partial}{\partial b_i^{(l)}} J(W, b; x, y)$ , les dérivées partielles de la fonction de coût  $J(W, b; x, y)$  définies par rapport à un seul exemple  $(x, y)$ . Une fois que nous pouvons les calculer, alors en faisant référence à l'équation (III.24), nous voyons que la dérivée de la fonction de coût global  $J(W, b)$  peut être calculée comme suit :

$$\frac{\partial}{\partial W_{ij}^{(l)}} J(W, b) = \left[ \frac{1}{m} \sum_{i=1}^m \frac{\partial}{\partial W_{ij}^{(l)}} J(W, b; x^{(i)}, y^{(i)}) \right] + \lambda W_{ij}^{(l)} \quad (\text{III.27})$$

$$\frac{\partial}{\partial b_i^{(l)}} J(W, b) = \frac{1}{m} \sum_{i=1}^m \frac{\partial}{\partial b_i^{(l)}} J(W, b; x^{(i)}, y^{(i)}) \quad (\text{III.28})$$

Les deux lignes ci-dessus diffèrent légèrement parce que la désintégration de poids est appliquée à  $W$  mais pas à  $b$ .

L'intuition derrière l'algorithme de rétropropagation est la suivante [PLAUT, 1986] : Étant donné un exemple d'apprentissage  $(x, y)$ , nous allons d'abord exécuter une "passe avant (forward pass)" pour calculer toutes les activations dans le réseau, y compris la valeur de sortie de l'hypothèse  $h_{W,b}(x)$ . Ensuite, pour chaque nœud  $i$  de la couche  $l$ , nous allons calculer un "terme d'erreur"  $\delta_i^{(l)}$  qui mesure combien ce nœud était "responsable" de toute erreur dans

notre sortie. Pour un nœud de sortie, on peut mesurer directement la différence entre l'activation du réseau et la vraie valeur cible, et l'utiliser pour définir  $\delta_i^{(n_l)}$  (Où couche  $n_l$  est la couche de sortie).

En détail, voici l'algorithme de rétropropagation [LECUN et al, 1998] :

1. Effectuer une passe feedforward, en calculant les activations pour les couches  $L_2, L_3$ , etc. jusqu'à la couche de sortie  $L_{n_l}$ .
2. Pour chaque unité de sortie  $i$  dans la couche  $n_l$  (couche de sortie), réglez

$$\delta_i^{(n_l)} = \frac{\partial}{\partial z_i^{(n_l)}} \frac{1}{2} \|y - h_{W,b}(x)\|^2 = -(y_i - a_i^{(n_l)}) \cdot f'(z_i^{(n_l)}) \quad (\text{III.29})$$

3. Pour  $l = n_l - 1, n_l - 2, n_l - 3, \dots, 2$   
Pour chaque nœud  $i$  de la couche  $l$ , réglez

$$\delta_i^{(n_l)} = \left( \sum_{j=1}^{s_{l+1}} W_{ji}^{(l)} \delta_j^{(l+1)} \right) f'(z_i^{(n_l)}) \quad (\text{III.30})$$

4. Calculer les dérivées partielles désirées, qui sont données comme :

$$\frac{\partial}{\partial W_{ij}^{(l)}} J(W, b; x, y) = a_j^{(l)} \delta_i^{(l+1)} \quad (\text{III.31})$$

$$\frac{\partial}{\partial b_i^{(l)}} J(W, b; x, y) = \delta_i^{(l+1)} \quad (\text{III.32})$$

### III.3.1.3. Vérification de gradient et optimisation avancée

La rétropropagation est un algorithme notoirement difficile à déboguer et à corriger, en particulier depuis de nombreuses implémentations subtilement boguées de celle-ci - par exemple, celle qui a une erreur par défaut dans les index et qui n'enseigne donc que certaines couches de poids, ou une implémentation qui omet le terme de biais réussissant à apprendre quelque chose qui peut sembler étonnamment raisonnable (tout en formant moins bien qu'une

implémentation correcte). Ainsi, même avec une implémentation bugée, il peut ne pas être évident que quelque chose ne va pas. Dans cette section, nous décrivons une méthode pour vérifier numériquement les dérivées calculées par le code pour s'assurer que l'implémentation est correcte.

La réalisation de la procédure de vérification dérivée décrite ici augmentera de manière significative la confiance dans l'exactitude du code [OMATU et al, 1996].

Supposons que nous voulions minimiser  $J(\theta)$  en fonction de  $\theta$ . Pour cet exemple,  $J: \mathbb{R} \rightarrow \mathbb{R}$ , de sorte que  $\theta \in \mathbb{R}$ . Dans ce cas à 1 dimension, une itération de la descente du gradient est donnée par :

$$\theta := \theta - \alpha \frac{d}{d\theta} J(\theta) \quad (\text{III.33})$$

Supposons aussi que nous avons implémenté une fonction  $g(\theta)$  censée de calculer  $\frac{d}{d\theta} J(\theta)$ , de sorte que nous implémentons la descente du gradient en utilisant la mise à jour  $\theta := \theta - \alpha g(\theta)$ . Comment pouvons-nous vérifier si notre implémentation de  $g$  est correcte?

Rappelons la définition mathématique de la dérivée comme :

$$\frac{d}{d\theta} J(\theta) = \lim_{\epsilon \rightarrow 0} \frac{J(\theta + \epsilon) - J(\theta - \epsilon)}{2\epsilon} \quad (\text{III.34})$$

Ainsi, à n'importe quelle valeur spécifique de  $\theta$ , nous pouvons approximer numériquement la dérivée comme suit:

$$\frac{J(\theta + \text{EPSILON}) - J(\theta - \text{EPSILON})}{2 \times \text{EPSILON}}$$

En pratique, nous mettons EPSILON à une petite constante, disons autour  $10^{-4}$ . (Il y a une large gamme de valeurs d'EPSILON qui devrait bien fonctionner, mais nous ne définissons pas EPSILON pour être extrêmement petit, disons  $10^{-20}$ , car cela conduirait à des erreurs d'arrondi numérique.)

Ainsi, étant donné une fonction  $g(\theta)$  qui est censée calculer  $\frac{d}{d\theta} J(\theta)$ , nous pouvons vérifier numériquement son exactitude en vérifiant que :

$$g(\theta) \approx \frac{J(\theta + \text{EPSILON}) - J(\theta - \text{EPSILON})}{2 \times \text{EPSILON}} \quad (\text{III.35})$$

Le degré auquel ces deux valeurs devraient se rapprocher dépendra des détails de  $J$ . Mais en supposant que  $\text{EPSILON} = 10^{-4}$ , nous trouverons généralement que les côtés gauche et droit de ce qui précède conviendront à au moins 4 chiffres significatifs (et souvent beaucoup plus).

Maintenant, considérons le cas où  $\theta \in \mathbb{R}^n$  est un vecteur plutôt qu'un seul nombre réel (de sorte que nous avons  $n$  paramètres que nous voulons apprendre), et  $\theta \in \mathbb{R}^n \rightarrow \mathbb{R}$ . Dans notre exemple de réseau neuronal, nous avons utilisé " $J(W, b)$ ", mais on peut imaginer mettre les paramètres  $W, b$  dans un vecteur long  $\theta$ . Nous généralisons maintenant notre procédure de vérification dérivée au cas où  $\theta$  peut être un vecteur.

Supposons que nous ayons une fonction  $g_i(\theta)$  qui prétend calculer  $\frac{\partial}{\partial \theta} J(\theta)$ , nous aimerions vérifier si  $g_i$  produit des valeurs dérivées correctes.  $\text{EPSILON} \times \vec{e}_i$ , où :

$$\vec{e}_i = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 1 \\ \vdots \\ 0 \end{bmatrix}$$

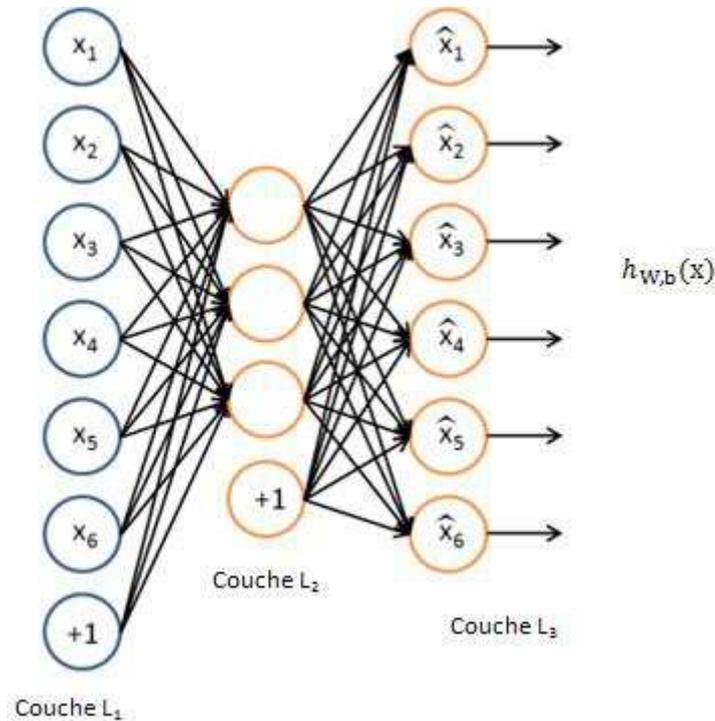
Soit  $\theta^{i+} = \theta + \text{EPSILON} \times \vec{e}_i$  est le  $i$ -ième vecteur de base (un vecteur de la même dimension que  $\theta$ , avec un "1" dans la  $i$ -ième position et "0" partout ailleurs). Donc,  $\theta^{i+}$  est le même que  $\theta$ , Sauf que son  $i$ -ième élément a été incrémenté par  $\text{EPSILON}$ . De même, soit  $\theta^{i-} = \theta - \text{EPSILON} \times \vec{e}_i$  est le vecteur correspondant avec le  $i$ ème élément diminué par  $\text{EPSILON}$ . Nous pouvons maintenant vérifier numériquement l'exactitude de  $g_i(\theta)$  par vérifier, pour chaque  $i$ , que:

$$g_i(\theta) \approx \frac{J(\theta^{i+}) - J(\theta^{i-})}{2 \times \text{EPSILON}} \quad (\text{III.36})$$

### III.3.2. Autoencodeur et parcimonie

Jusqu'à présent, nous avons décrit l'application des réseaux de neurones à l'apprentissage supervisé, dans lequel nous avons étiqueté des exemples d'apprentissage. Supposons

maintenant que nous avons seulement des exemples d'apprentissage non étiquetés  $\{x^{(1)}, x^{(2)}, x^{(3)}, \dots\}$ , où  $x^{(i)} \in \mathbb{R}^n$ . Un réseau neuronal autoencodeur est un algorithme d'apprentissage non supervisé qui applique une rétropropagation [NG, 2011 ; DENG et al, 2013 ; LEUNG et HAYKIN, 2014, JIANG et al, 2015], en définissant les valeurs cibles égales aux entrées. C'est-à-dire, il utilise  $y^{(i)} = x^{(i)}$ . Voici un autoencodeur :



**Figure III.4.** Structure d'un autoencodeur

L'autoencodeur essaie d'apprendre une fonction  $h_{W,b}(x) \approx x$ . En d'autres termes, il essaie d'apprendre une approximation de la fonction d'identité, de manière à produire  $\hat{x}$  qui est similaire à  $x$ . La fonction d'identité semble être une fonction particulièrement triviale à essayer d'apprendre; mais en plaçant des contraintes sur le réseau, comme en limitant le nombre d'unités cachées, nous pouvons découvrir une structure intéressante à propos des données. Mais même lorsque le nombre d'unités cachées est important (peut-être même supérieur au nombre de pixels d'entrée), on peut encore découvrir une structure intéressante, en imposant d'autres contraintes sur le réseau. En particulier, si nous imposons une contrainte de parcimonie sur les unités cachées, l'autoencodeur découvrira toujours une structure intéressante dans les données, même si le nombre d'unités cachées est important.

Informellement, nous considérerons un neurone comme étant "actif" si sa valeur de sortie est proche de 1, ou comme "inactif" si sa valeur de sortie est proche de 0. Nous aimerions contraindre que les neurones sont inactifs la plupart du temps.

Rappelons que  $a_j^{(2)}$  désigne l'activation de l'unité cachée  $j$  dans l'autoencodeur. Cependant, cette notation ne rend pas explicite quelle était l'entrée  $x$  qui a conduit à cette activation. Ainsi, nous écrivons  $a_j^{(2)}(x)$  pour indiquer l'activation de cette unité cachée lorsque le réseau reçoit une entrée spécifique  $x$ . En outre, soit :

$$\hat{\rho}_j = \frac{1}{m} \sum_{i=1}^m [a_j^{(2)}(x^{(i)})] \quad (\text{III.37})$$

Est l'activation moyenne de l'unité cachée  $j$  (moyennée sur l'ensemble d'apprentissage). Nous aimerions (approximativement) appliquer la contrainte

$$\hat{\rho}_j = \rho$$

Où  $\rho$  est un paramètre de parcimonie, typiquement une petite valeur proche de zéro (disons  $\rho = 0,05$ ). En d'autres termes, nous aimerions que l'activation moyenne de chaque neurone caché  $j$  soit proche de 0,05 (disons). Pour satisfaire cette contrainte, les activations de l'unité cachée doivent être proches de 0. Pour y parvenir, nous ajouterons un terme de pénalité supplémentaire à notre optimisation objectif qui pénalise  $\hat{\rho}_j$  déviant significativement de  $\rho$ . De nombreux choix du terme de pénalité donneront des résultats raisonnables. Nous choisirons ce qui suit :

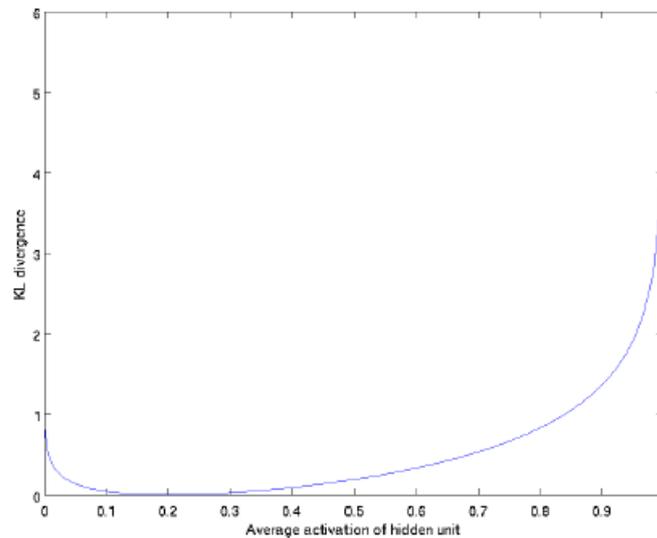
$$\sum_{j=1}^{s_2} \rho \log \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_j} \quad (\text{III.38})$$

Ici,  $s_2$  est le nombre de neurones dans la couche cachée, et l'indice  $j$  somme sur les unités cachées dans notre réseau. Ce terme de pénalité est basé sur le concept de divergence Kullback-Leibler (KL) [Lee et Ng, 2008 ; Nair et Hinton, 2009], et peut aussi être écrit:

$$\sum_{j=1}^{s_2} KL(\rho \parallel \hat{\rho}_j) \quad (\text{III.39})$$

Où  $KL(\rho \parallel \hat{\rho}_j) = \rho \log \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \log \frac{1-\rho}{1-\hat{\rho}_j}$  est la divergence de Kullback-Leibler entre une variable aléatoire de Bernoulli avec une moyenne  $\rho$  et une variable aléatoire de Bernoulli avec la moyenne  $\hat{\rho}_j$ . KL-divergence est une fonction standard pour mesurer la différence entre deux distributions différentes.

Cette fonction de pénalité a la propriété que  $KL(\rho \parallel \hat{\rho}_j) = 0$  si  $\hat{\rho}_j = \rho$ , Et sinon elle augmente de façon monotone car  $\hat{\rho}_j$  diverge de  $\rho$ . Par exemple, dans la figure ci-dessous, nous avons défini  $\rho = 0,2$ , et tracé  $KL(\rho \parallel \hat{\rho}_j)$  pour une plage de valeurs de  $\hat{\rho}_j$ :



**Figure 3.5.** Tracé  $KL(\rho \parallel \hat{\rho}_j)$  pour une plage de valeurs de  $\hat{\rho}_j$

On voit que la divergence KL atteint son minimum de 0 à  $\hat{\rho}_j = \rho$ , et elle se rapproche vers l'infini quand  $\hat{\rho}_j$  tend vers 0 ou 1. Ainsi, en minimisant ce terme de pénalité, on obtient que  $\hat{\rho}_j$  soit proche de  $\rho$ . Notre fonction de coût global est maintenant :

$$J_{sparse}(W, b) = J(W, b) + \beta \sum_{j=1}^{s_2} KL(\rho \parallel \hat{\rho}_j) \quad (\text{III.40})$$

Où  $J(W, b)$  est tel que défini précédemment, et  $\beta$  contrôle le poids du terme de pénalité de parcimonie. Le terme  $\hat{\rho}_j$  (implicitement) dépend de  $W, b$  aussi, parce que c'est l'activation moyenne de l'unité cachée  $j$ , et l'activation d'une unité cachée dépend des paramètres  $W, b$ .

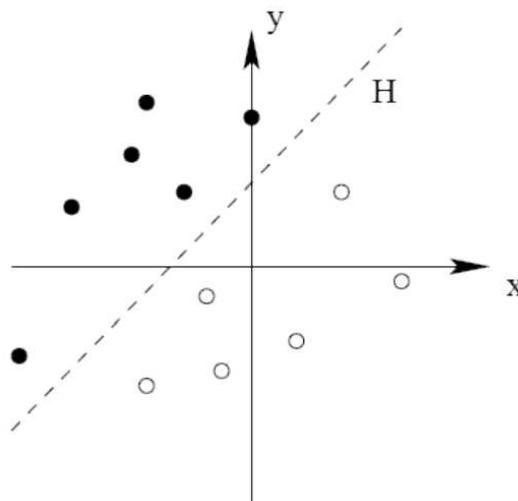
### III.4. CLASSIFICATION DES SIGNAUX EEG EN UTILISANT MACHINES A VECTEURS DE SUPPORT (SVM)

Plusieurs algorithmes de classification ont été appliqués avec succès à la détection des crises d'épilepsies. Machines à vecteurs de support (SVM) est l'algorithme le plus couramment utilisé. Les séparateurs à vaste marge ont été développés dans les années 1990 à partir des considérations théoriques de Vladimir Vapnik sur le développement d'une théorie statistique de l'apprentissage [VAPNIK, 2013]. Il a été proposé pour aborder le problème de l'apprentissage des hyperplans de marge maximum afin de décomposer les données en classes dont le but est de maximiser les performances de la classification. Les SVM sont connus par leur capacité à traiter un grand nombre de prédicteurs et par leur bonne précision [SUBASI et GURSOY, 2010].

#### III.4.1. SVM principe de fonctionnement général

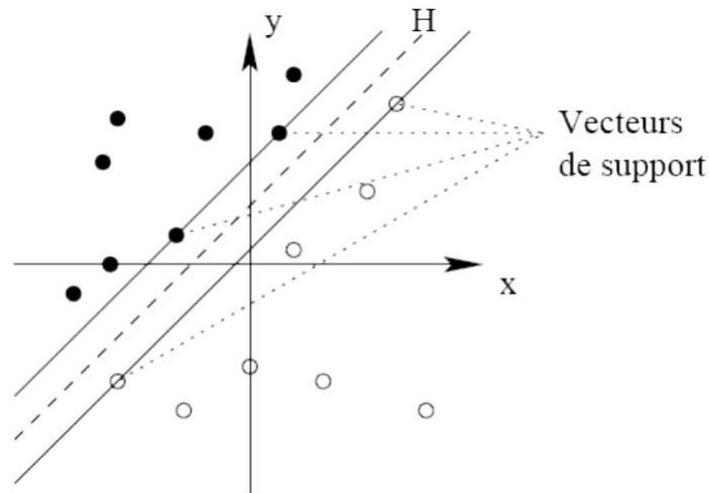
##### III.4.1.1. Notions de base

Pour deux classes d'exemples donnés, le but de SVM est de trouver un classificateur qui va séparer les données et maximiser la distance entre ces deux classes. Avec SVM, ce classificateur est un classificateur linéaire appelé hyperplan. Dans la figure 3.6, on détermine un hyperplan qui sépare les deux ensembles de points [JOACHIMS, 1998].



**Figure III.6.** Un hyperplan qui sépare les deux ensembles de points

Les points les plus proches, qui seuls sont utilisés pour la détermination de l'hyperplan, sont appelés vecteurs de support (voir Figure III.7).



**Figure III.7.** Un hyperplan avec quatre vecteurs de support

Il est évident qu'il existe plusieurs hyperplans valides mais la propriété remarquable des SVM est que cet hyperplan doit être optimal. Nous allons donc en plus chercher parmi les hyperplans valides, celui qui passe « au milieu » des points des deux classes d'exemples. Intuitivement, cela revient à chercher l'hyperplan le « plus sûr ». En effet, supposons qu'un exemple n'ait pas été décrit parfaitement, une petite variation ne modifiera pas sa classification si sa distance à l'hyperplan est grande. Formellement, cela revient à chercher un hyperplan dont la distance minimale aux exemples d'apprentissage est maximale.

On appelle cette distance « marge » entre l'hyperplan et les exemples. L'hyperplan séparateur optimal est celui qui maximise la marge. Comme on cherche à maximiser cette marge, on parlera de séparateurs à vaste marge (voir figure III.8).

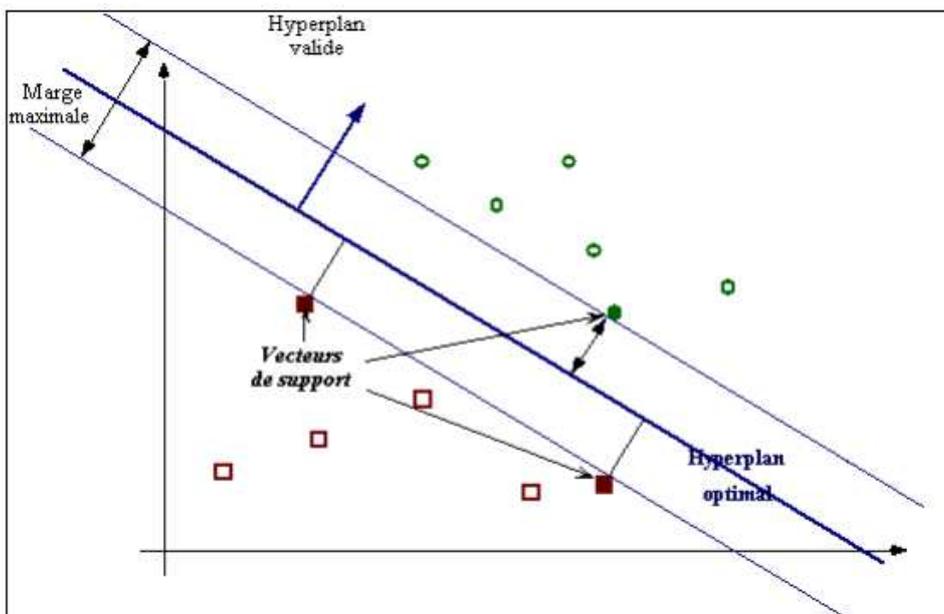


Figure III.8. Un hyperplan optimal

III.4.1.2. Maximisation de la marge

Le fait d'avoir une marge plus large procure plus de sécurité lorsque l'on classe un nouvel exemple. De plus, si l'on trouve le classificateur qui se comporte le mieux vis-à-vis des données d'apprentissage, il est clair qu'il sera aussi celui qui permettra au mieux de classer les nouveaux exemples [HASAN, 2006]. Dans la figure 3.9, la partie droite nous montre qu'avec un hyperplan optimal, un nouvel exemple reste bien classé alors qu'il tombe dans la marge. On constate sur la partie gauche qu'avec une plus petite marge, l'exemple se voit mal classé.

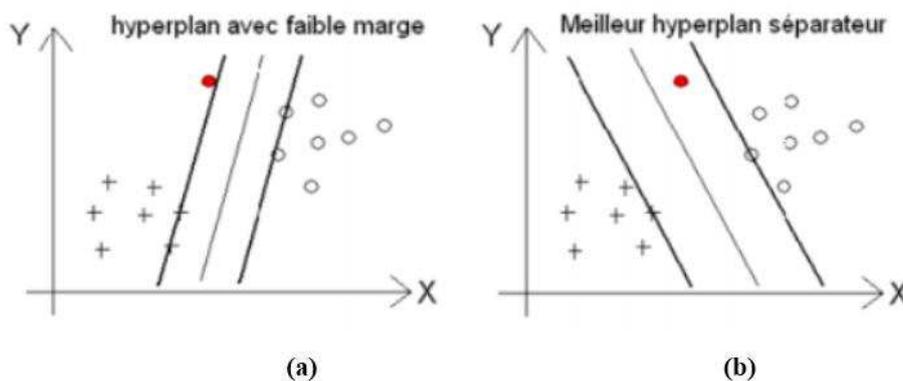
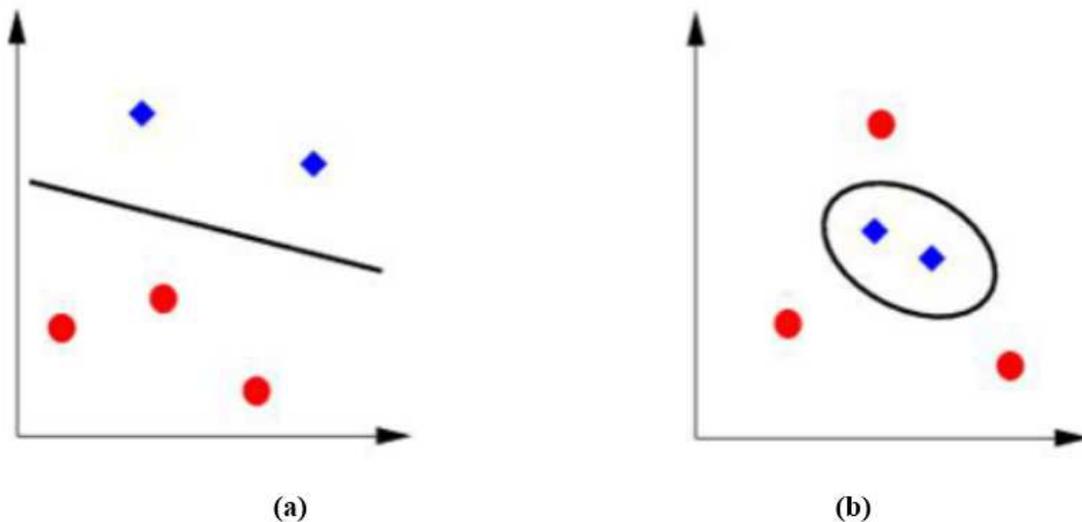


Figure III.9. Un hyperplan avec faible marge (a) et un meilleur hyperplan séparateur (b)

### III.4.2. Linéarité et non-linéarité

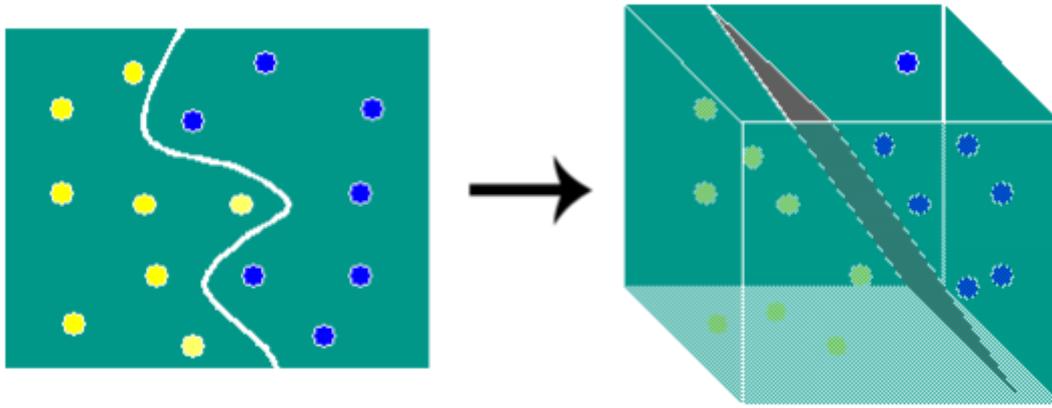
Parmi les modèles des SVM, on constate les cas linéairement séparable et les cas non-linéairement séparable. Les premiers sont les plus simples de SVM car ils permettent de trouver facilement le classificateur linéaire. Dans la plupart des problèmes réels il n'y a pas de séparation linéaire possible entre les données, le classificateur de marge maximale ne peut pas être utilisé car il fonctionne seulement si les classes de données d'apprentissage sont linéairement séparables.



**Figure III.10.** Le cas linéairement séparable (a) et le cas non linéairement séparable (b)

### III.4.3. Cas non-linéaire

Pour surmonter les inconvénients des cas non linéairement séparable, l'idée des SVM est de changer l'espace des données. La transformation non linéaire des données peut permettre une séparation linéaire des exemples dans un nouvel espace. On va donc avoir un changement de dimension. Cette nouvelle dimension est appelé « espace de re-description ». En effet, plus la dimension de l'espace de re-description est grande, plus la probabilité de pouvoir trouver un hyperplan séparateur entre les exemples est élevée. Ceci est illustré par la figure III.11 :



**Figure III.11.** L'espace de re-description

On a donc une transformation d'un problème de séparation non linéaire dans l'espace de représentation en un problème de séparation linéaire dans un espace de re-description de plus grande dimension. Cette transformation non linéaire est réalisée via une fonction noyau. En pratique, quelques familles de fonctions noyau paramétrables sont connues et il revient à l'utilisateur de SVM d'effectuer des tests pour déterminer celle qui convient le mieux pour son application. On peut citer les exemples de noyaux suivants : polynomiale, gaussien, sigmoïde et la racine [LOOSLI, 2005].

### III.5. CONCLUSION

Dans ce chapitre on a présenté les techniques utilisées dans cette thèse pour la détection des crises d'épilepsie. Les caractéristiques des signaux EEG ont été extraites par la méthode de Burg, ensuite ces coefficients ont été améliorés en utilisant un autoencodeur clairsemé et en fin classifiés par un classificateur supervisé qui est SVM.

---

# **BIBLIOGRAPHIE**

---

- [Abdi, 1994] ABDI, Hervé. *Les réseaux de neurones*. Grenoble : Presses universitaires de Grenoble, 1994.
- [Baldeweck et al, 1995] BALDEWECK, T., LAUGIER, P., HERMENT, A., *et al.* Application of autoregressive spectral analysis for ultrasound attenuation estimation: interest in highly attenuating medium. *IEEE transactions on ultrasonics, ferroelectrics, and frequency control*, 1995, vol. 42, no 1, p. 99-110.
- [Burg, 1967] BURG, John Parker. Maximum entropy spectral analysis. In : *37<sup>th</sup> Annual International Meeting, Soc. of Explor. Geophys., Oklahoma City, Okla., Oct. 31, 1967*. 1967.
- [Cricenti et Egan, 1991] CRICENTI, A. L. et EGAN, G. K. *Comparative Performance of the Burg Algorithm Implemented in Parallel FORTRAN and the Applicative Language SISAL*. Technical report 31-026 version 1.0, 1991.
- [De Hoon et al, 1991] DE HOON, M. J. L., VAN DER HAGEN, T. H. J. J., SCHOONEWELLE, H., *et al.* Why Yule-Walker should not be used for autoregressive modelling. *Annals of nuclear energy*, 1996, vol. 23, no 15, p. 1219-1228.
- [Deng et al, 2013] DENG, Jun, ZHANG, Zixing, MARCHI, Erik, *et al.* Sparse autoencoder-based feature transfer learning for speech emotion recognition. In : *Affective Computing and Intelligent Interaction (ACII), 2013 Humaine Association Conference on*. IEEE, 2013. p. 511-516.
- [Demuth et al, 2014] DEMUTH, Howard B., BEALE, Mark H., DE JESS, Orlando, *et al.* *Neural network design*. Martin Hagan, 2014.
- [Hasan et Boris, 2006] HASAN, Mohamadally et BORIS, Fomani. Svm: Machines à vecteurs de support ou séparateurs à vastes marges. *Rapport technique, Versailles St Quentin, France. Cité*, 2006, p. 64
- [HINTON et Zemel, 1994] HINTON, Geoffrey E. et ZEMEL, Richard S. Autoencoders, minimum description length and Helmholtz free energy. In: *Advances in neural*

*information processing systems*. 1994, p. 3-10.

- [Giordano et Hsu, 1985] GIORDANO, Arthur A. et HSU, Frank M. *Least square estimation with applications to digital signal processing*. John Wiley & Sons, Inc., 1985.
- [Jiang et al, 2015] JIANG, Nan, RONG, Wenge, PENG, Baolin, *et al*. An empirical analysis of different sparse penalties for autoencoder in unsupervised feature learning. In: *Neural Networks (IJCNN), 2015 International Joint Conference on*. IEEE, 2015. p. 1-8.
- [Joachims , 1998] JOACHIMS, T. Making Large-Scale Support Vector Machine Learning Practical. *Advances in Kernel Methods-Support Vector Learning*, 1998.
- [Kamel et al , 2007] KAMEL, Nidal, SAMRAJ, Andrews, et MOUSAVI, Arash. Whitening of background brain activity via parametric modeling. *Discrete Dynamics in Nature and Society*, 2007, vol. 2007.
- [Kay et Marple, 1981] KAY, Steven M. et MARPLE, Stanley L. Spectrum analysis—a modern perspective. *Proceedings of the IEEE*, 1981, vol. 69, no 11, p. 1380-1419.
- [Krogh et Hertz, 1992] KROGH, Anders et HERTZ, John A. A simple weight decay can improve generalization. In: *Advances in neural information processing systems*. 1992. p. 950-957.
- [Krusienski et al, 2006] KRUSIENSKI, Dean J., MCFARLAND, Dennis J., et WOLPAW, Jonathan R. An evaluation of autoregressive spectral estimation model order for brain-computer interface applications. In : *Engineering in Medicine and Biology Society, 2006. EMBS'06.28th Annual International Conference of the IEEE*. IEEE, 2006. p. 1323-1326.
- [Lecun et al, 1998] LECUN, Yann, BOTTOU, Léon, ORR, Genevieve B., *et al*. Efficient backprop. In: *Neural networks: Tricks of the trade*. Springer, Berlin, Heidelberg, 1998. p. 9-50.
- [Lee et al, 2008] LEE, Honglak, EKANADHAM, Chaitanya, et NG, Andrew Y. Sparse deep belief net model for visual area

V2. In: *Advances in neural information processing systems*. 2008. p. 873-880.

- [Leung et Haykin, 1991] LEUNG, Henry et HAYKIN, Simon. The complex backpropagation algorithm. *IEEE Transactions on Signal Processing*, 1991, vol. 39, no 9, p. 2101-2104.
- [Loosli et al, 2005] LOOSLI, Gaëlle, CANU, Stéphane, VISHWANATHAN, S. V. N., *et al.* Boîte à outils SVM simple et rapide. *Revue d'intelligence artificielle*, 2005, vol. 19, no 4-5, p. 741-767.
- [Makhoul, 1981] Makhoul J. Linear prediction: a tutorial review. *Proc. IEEE*, 1981, vol. 63, no 4, p. 561-580.
- [Nair et Hinton, 2009] NAIR, Vinod et HINTON, Geoffrey E. 3D object recognition with deep belief nets. In: *Advances in neural information processing systems*. 2009. p. 1339-1347.
- [Ng, 2011] NG, A. Sparse Autoencoder, vol. 72 of. *CS294A Lecture Notes*, 2011.
- [Omatu et al, 1996] OMATU, Sigeru, KHALID, Marzuki, et YUSOF, Rubiyah. Neuro-control applications. In: *Neuro-Control and its Applications*. Springer London, 1996. p. 171-243.
- [Plaut et al, 1986] PLAUT, David C., *et al.* Experiments on Learning by Back Propagation. 1986.
- [Davallo et Naïm, 1990] DAVALLO, Eric et NAÏM, Patrick. *Des réseaux de neurones*. Eyrolles, 1990.
- [Rangayyan, 2015] RANGAYYAN, Rangaraj M. *Biomedical signal analysis*. John Wiley & Sons, 2015.
- [Shiman et al, 2012] SHIMAN, F., SAFAVI, S. H., VANEGHI, F. M., *et al.* EEG feature extraction using parametric and non-parametric models. In: *Biomedical and Health Informatics (BHI), 2012 IEEE-EMBS International Conference on*. IEEE, 2012. p. 66-70.
- [Stoica et al, 2015] STOICA, Petre, MOSES, Randolph L., *et al.* *Spectral analysis of signals*. Upper Saddle River, NJ: Pearson

Prentice Hall, 2005.

- [Steven et al, 1988] STEVEN, M. Kay, *et al.* Modern spectral estimation: theory and application. *Signal Processing Series*, 1988.
- [Subasi et Gursoy, 2010] SUBASI, Abdulhamitet and GURSOY, M. Ismail. EEG signal classification using PCA, ICA, LDA and support vector machines. *Expert Systems with Applications*, 2010, vol. 37, no 12, p. 8659-8666.
- [Vapnik, 2013] VAPNIK, Vladimir. *The nature of statistical learning theory*. Springer science & business media, 2013.
- [Vedavathi et al, 2014] VEDAVATHI, K., RAO, K. Srinivasa, et DEVI, K. Nirupama. Unsupervised learning algorithm for time series using bivariate AR (1) model. *Expert Systems with Applications*, 2014, vol. 41, no 7, p. 3402-3408.
- [Vincent et al, 2014] VINCENT, Pascal, LAROCHELLE, Hugo, BENGIO, Yoshua, *et al.* Extracting and composing robust features with denoising autoencoders. In: *Proceedings of the 25th international conference on Machine learning*. ACM, 2008. p. 1096-1103.

CHAPITRE

IV

**VALIDATION DE L'APPROCHE  
ET PRÉSENTATION DES  
RÉSULTATS**

## IV.1. INTRODUCTION

Afin de valider l'étude théorique citée au chapitre 3, nous présentons dans ce qui suit les résultats de simulations des différents cas de la base de données utilisée, ensuite une étude comparative entre les résultats obtenus en utilisant l'approche proposée comparée à celles présentées dans la littérature.

## IV.2. METHODE PROPOSEE

La méthode proposée pour la classification des crises épileptiques s'effectue en quatre étapes. La première consiste à extraire les caractéristiques en utilisant (AR-Burg). Après cela, un autoencodeur clairsemé a été appliqué sur les vecteurs de caractéristiques. Ensuite, la méthode SVM a été utilisée pour la classification. La dernière étape est l'évaluation des performances du classificateur. La Figure IV.1 illustre clairement le schéma de la méthode introduite.

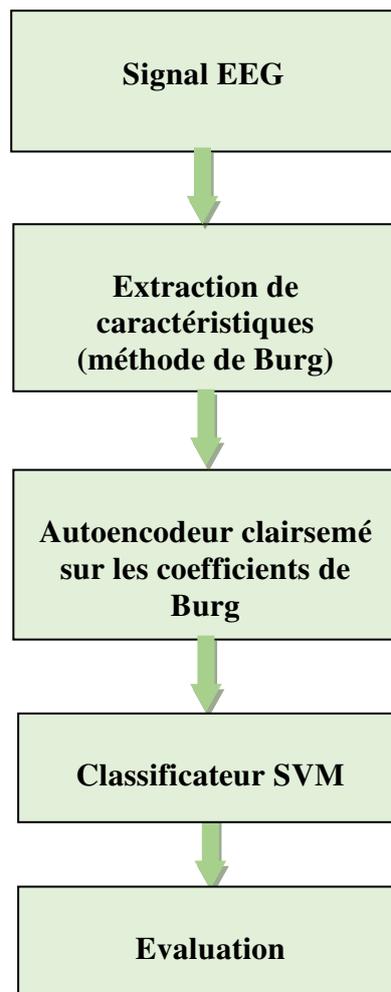


Figure IV.1. Diagramme du système proposé

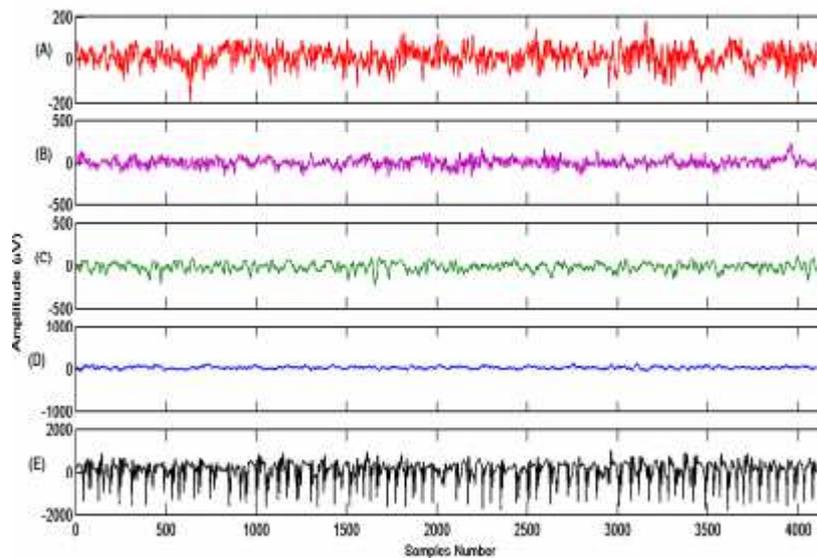
### IV.3. RÉSULTATS EXPÉRIMENTALES DE LA CLASSIFICATION ET ANALYSE

Dans cette partie nous allons présenter la base de données utilisée dans notre étude, ainsi que les résultats obtenus lors des expériences effectuées.

#### IV.3.1. Base de données

La base de données de Bonn [Andrzejak et al., 2001] a été couramment utilisée dans les études sur l'épilepsie et la détection des crises épileptiques. Compte tenu de cela, nous l'avons utilisé dans nos travaux. La base de données de Bonn a été collectée par Ralph Andrzejak et al.

Le jeu de données contient cinq ensembles (A, B, C, D, E) où chacun d'eux a 100 époques par classe et 4097 échantillons par époque avec une durée égale à 23,6 secondes, la Figure IV.2 présente un exemple pour chaque ensemble et le tableau 1 (Table IV.1) résume l'ensemble de données.



**Figure IV.2.** Exemples d'époques EEG appartenant aux sous-ensembles : A, B, C, D et E.

Table IV.1. Résumé du jeu de données de Bonn.

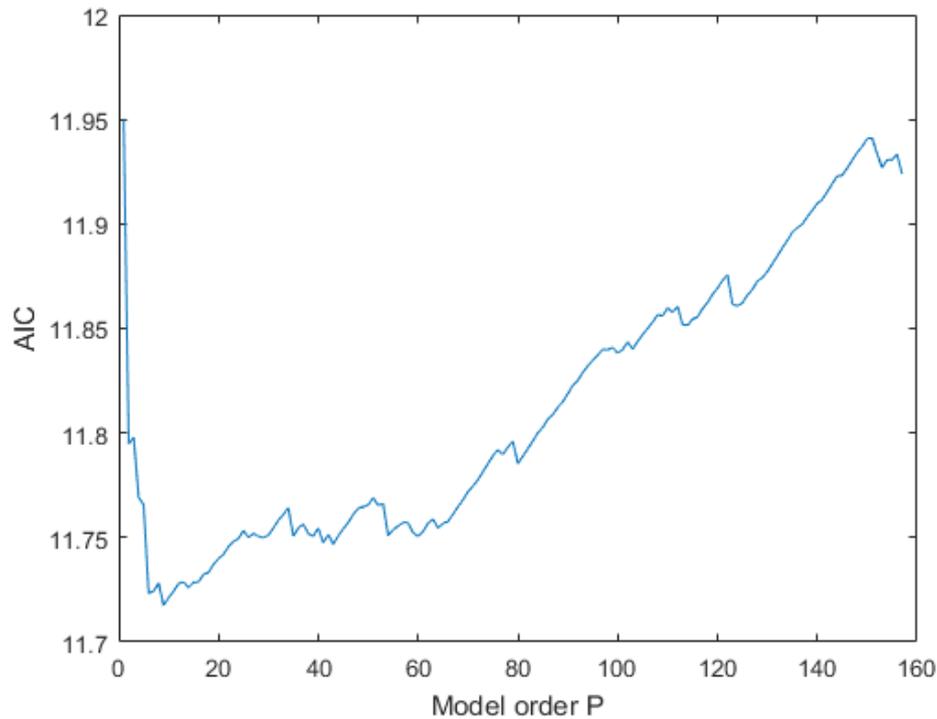
Étiquette de jeu de données	La description
A	Sujet normal, les yeux ouverts
B	Sujet normal, yeux fermés
C	Sans épilepsie, électrodes de profondeur, formations hippocampiques
D	Sans épilepsie, électrodes de profondeur, formations épileptogènes
E	Activité épileptique, électrodes de profondeur, formations épiques

### IV.3.2. Expériences et résultats

Dans cette étude, deux types d'expériences ont été réalisées. Dans la première, les données EEG ont été prétraitées. Ensuite, les caractéristiques ont été extraites en utilisant la méthode de Burg. Puis, l'utilisation du classificateur SVM.

Dans la seconde expérience, le SAE a été appliqué sur le coefficient AR donné par la méthode de Burg afin de les améliorer. Après cela, le classificateur SVM a été appliqué.

Dans ces expériences, Les ensembles de données ont été divisés en trois classes: (i) sain (non épileptique) :Z, O; (ii) Interictal :N, F; et (iii) Ictal :S. Les notations : A, B, C, D, E ont été utilisées, respectivement, pour les classes Z, O, N, F, S pour faire des comparaisons avec d'autres travaux. Toujours dans les expériences menées, le meilleur ordre de modèle P a été sélectionné en utilisant la métrique AIC pour le modèle de Burg (voir Figure IV.3), nous avons pris P=13. Enfin, la classification a été étudiée comme suit: (i) non-épileptique (Normal) à Interictal (ensembles A, B) en bonne santé (ensembles C, D). (ii) Sain non épileptique (normal) à Ictal (ensembles A, B) à (ensemble E). (iii) Interictal To Ictal (définit C, D) à (set E).



**Figure IV.3.** Un exemple illustre la variation AIC (P)

Le tableau 2 (Table IV.2) illustre en détails les résultats de la première expérience concernant la première partie de l'expérience. Le tableau 3 (Table IV.3) présente La moyenne des mesures de la performance de classification. On peut évidemment voir dans le tableau 2 que les exactitudes de la classification les plus élevées sont des ensembles (A et E) et (B et E) de l'ordre de 98,00% pour chacun d'eux. De plus, les exactitudes de classification pour la paire restante de Sets sont entre 94.00% et 96.00%. Ensuite, nous obtenons une précision de classification moyenne de 98,0%, 100,00% et 96,00% pour la sensibilité et la spécificité respectivement pour les non-épileptiques sains (Normal) à Interictal.

**Table IV.2.** Résultats de la classification en utilisant (Burg et SVM)

Non-épileptique (A)			Non-épileptique (B)			Interictal (C,D)	
A Interictal (C,D)		A Ictal (E)	A Interictal (C,D)		A Ictal (E)	A Ictal (set E)	
AC	AD	AE	BC	BD	BE	CE	DE

ACC	0.9600	0.9500	<b>0.9800</b>	0.9400	0.9600	<b>0.9800</b>	0.9500	0.9500
SEN	0.9400	0.9800	<b>1.0000</b>	0.9000	0.9600	<b>1.0000</b>	0.9400	0.9400
SPE	0.9800	0.9200	0.9600	0.9800	0.9600	0.9600	0.9600	0.9600

**Table IV.3.** La moyenne des mesures de performance de la première expérience (Burg et SVM)

	Non-épileptique (A) à Interictal (C, D)	Non-épileptique (B) à Interictal (C, D)	Interictal (C, D) à Ictal (E)
ACC	95.25%	<b>98.00%</b>	95.00%
SEN	94.50%	<b>100.00%</b>	94.00%
SPE	96.00%	96.00%	96.00%

Dans la deuxième expérience, les coefficients obtenus en utilisant l'algorithme de burg sont améliorés par SAE afin d'obtenir une meilleure représentation des coefficients qui ont été utilisés par le classificateur SVM.

Le tableau 4 (Table IV.4) décrit en détail les résultats de cette expérience. Le tableau 5 (Table IV.5) présente la moyenne des performances de la classification. Il en ressort clairement du tableau 4 que les précisions de la classification les plus élevées sont des ensembles (A et E) et (B et E) de l'ordre de 100,00%, pour chacun d'eux. Et les exactitudes de classification pour les paires restantes sont entre 93.00% et 96.00%. Ensuite, une exactitude de classification moyenne de 100,00%, 100,00% et 100,00% est atteinte pour la sensibilité et la spécificité respectivement pour les non-épileptiques à Interictal.

**Table IV.4.** Résultats de la classification en utilisant (Burg - SAE et SVM)

	Non-épileptique (A)			Non-épileptique (B)			A Interictal (C,D) à Ictal (E)	
	A Interictal (C,D)		A Ictal (E)	A Interictal (C,D)		A Ictal (E)		
	AC	AD	AE	BC	BD	BE	CE	DE
ACC	0.9600	0.9300	<b>1.0000</b>	0.9500	0.9400	<b>1.0000</b>	0.9600	0.9600
SEN	1.0000	0.9100	<b>1.0000</b>	0.9000	0.9200	<b>1.0000</b>	0.9400	0.9400
SPE	0.9200	0.9500	<b>1.0000</b>	1.0000	0.9600	<b>1.0000</b>	0.9800	0.9800

**Table IV.5.** La moyenne des mesures de performance de la deuxième expérience (Burg-SAE et SVM)

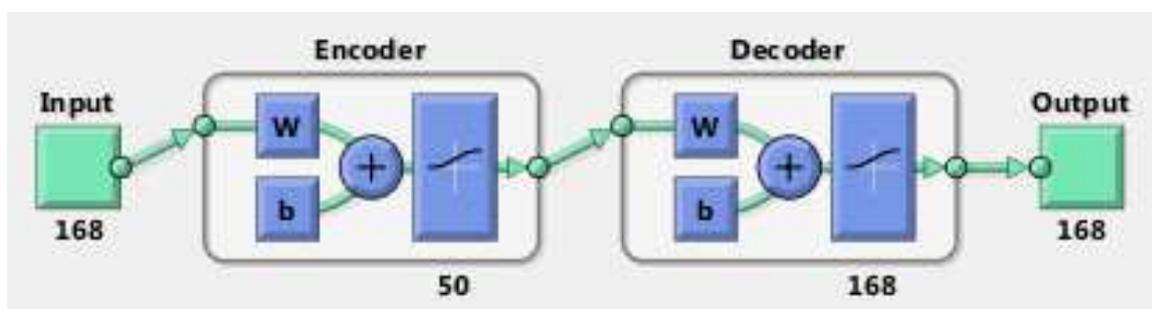
	Non-épileptique (A) à Interictal (C, D)	Non-épileptique (B) à Interictal (C, D)	Interictal (C, D) à Ictal (E)
ACC	94,50%	<b>100%</b>	96.00%
SEN	93.25%	<b>100%</b>	94.00%
SPE	95.75%	<b>100%</b>	98.00%

Cette étude est primordiale car elle nous montre l'importance du choix de l'ordre  $P$  qui peut avoir une influence sur les performances d'entraînement des coefficients, et qui peu par la suite fournir une performance de classification efficiente.

Pour ce faire, nous avons effectué un ensemble d'expériences en varions la valeur de  $P$ . Les résultats de nos expériences sont présentées ci-dessous, qui indique que les paramètres de l'autoencodeur s'influence par le changement de l'ordre  $P$ .

Plus important encore, on peut observer que la meilleure performance d'entraînement est obtenue avec la valeur de  $P$  qui minimise le critère de l'AIC, et plus nous éloignant de cette valeur plus les performances d'entraînement devient inadéquate.

Dans cette partie, nous allons voir l'effet de l'ordre  $P$  sur les paramètres de l'autoencodeur. Pour cela nous allons tester trois valeurs de  $P$  :  $P=10$ ,  $P=13$  et  $P=20$ .



**Figure IV.4.** Diagramme de l'autoencodeur avec  $P=20$

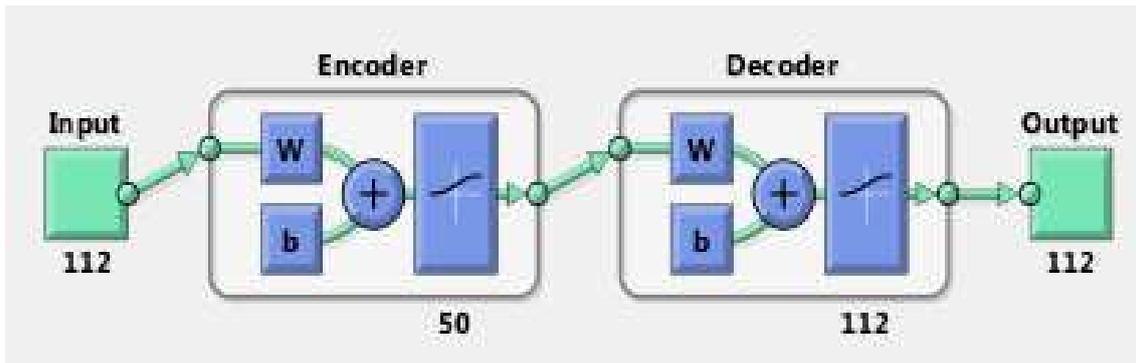


Figure IV.5. Diagramme de l'autoencodeur avec  $P=13$

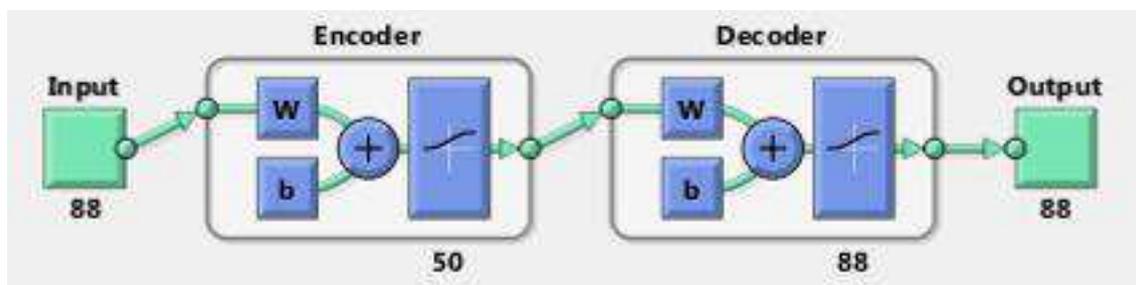


Figure IV.6. Diagramme de l'autoencodeur avec  $P=10$

Selon les diagrammes, on remarque bien que les paramètres de SAE changent si la valeur du  $P$  change, elles augmentent si  $P$  augmente et elles diminuent si  $P$  diminue, ce qui peut avoir un effet sur les performances des coefficients améliorés.

Nous allons maintenant étudier l'effet de l'ordre  $P$  sur les performances Obtenues de chaque paire en utilisant SAE. Nous allons considérer les mêmes valeurs précédentes de  $P$ .

Les figures suivantes illustrent la meilleure performance d'entraînement des coefficients quand on augmente la valeur  $P$  à de l'ordre de  $P=20$ .

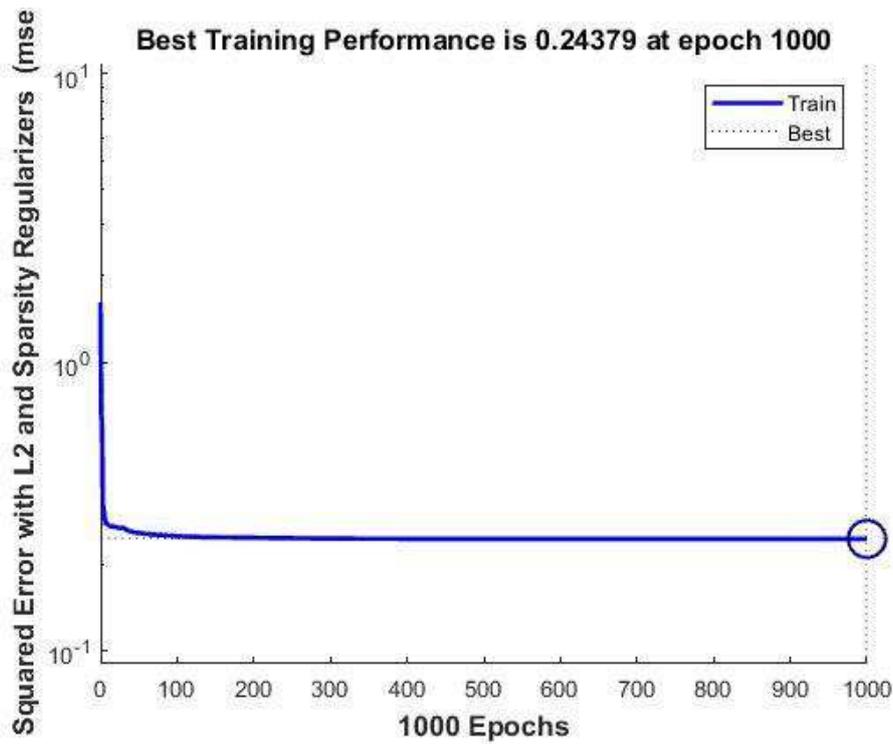


Figure IV.7. Meilleure performance d'entraînement des coefficients de données (AE) avec  $P=20$

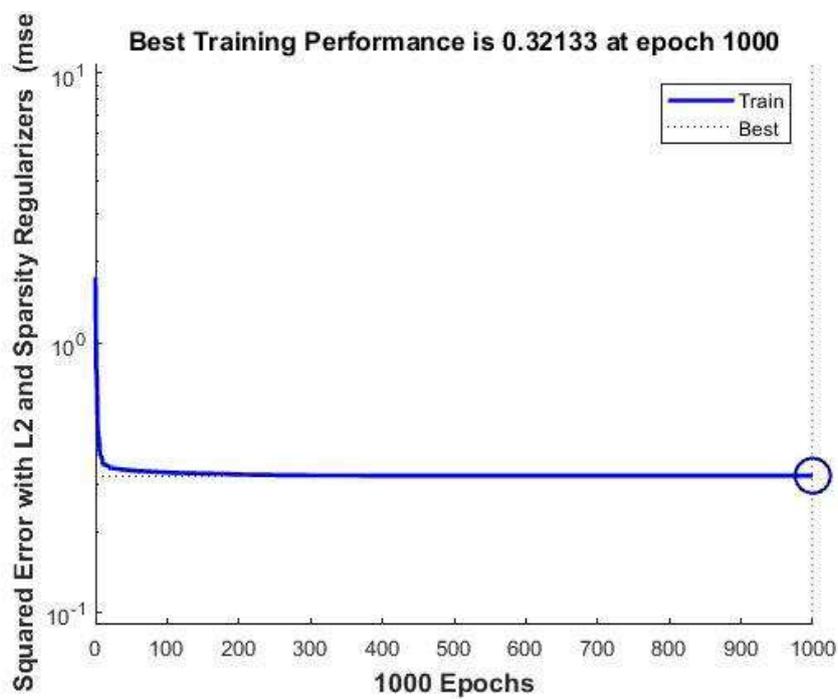


Figure IV.8. Meilleure performance d'entraînement des coefficients de données (AC) avec  $P=20$

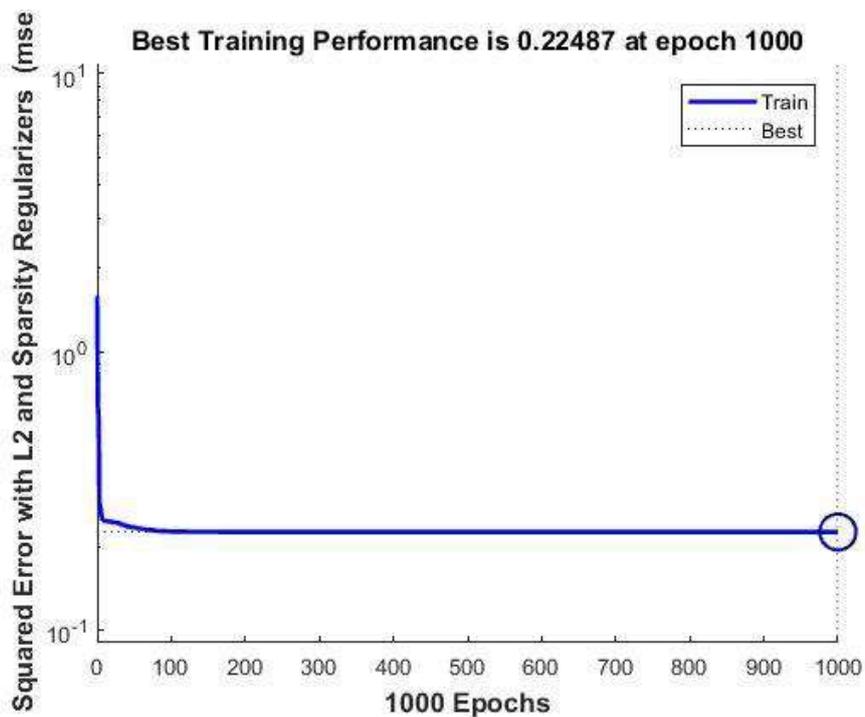


Figure IV.9. Meilleure performance d'entraînement des coefficients de données (AD) avec  $P=20$

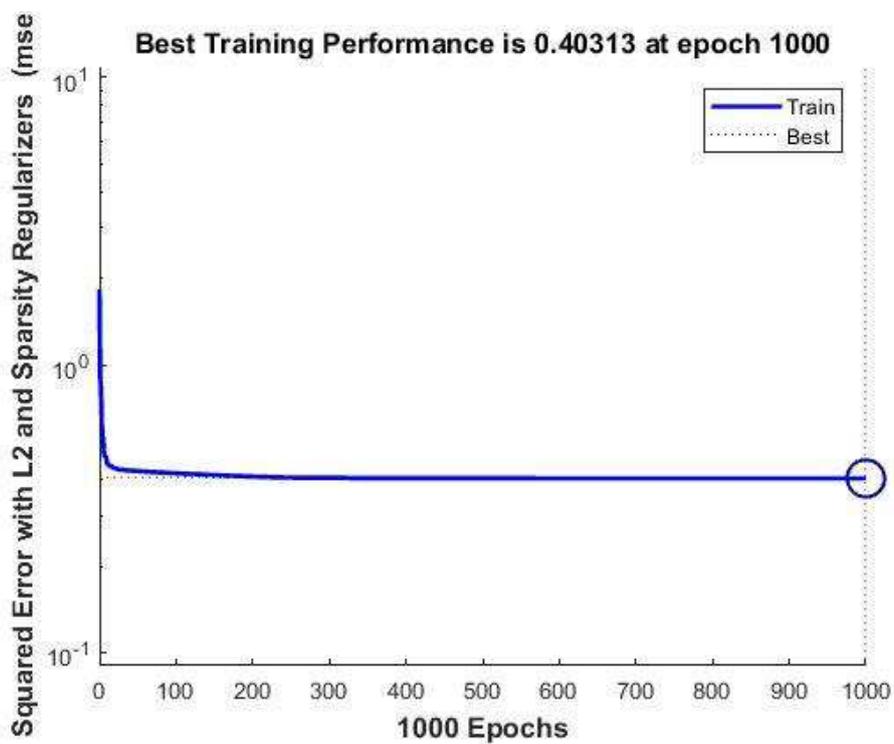


Figure IV.10. Meilleure performance d'entraînement des coefficients de données (BE) avec  $P=20$

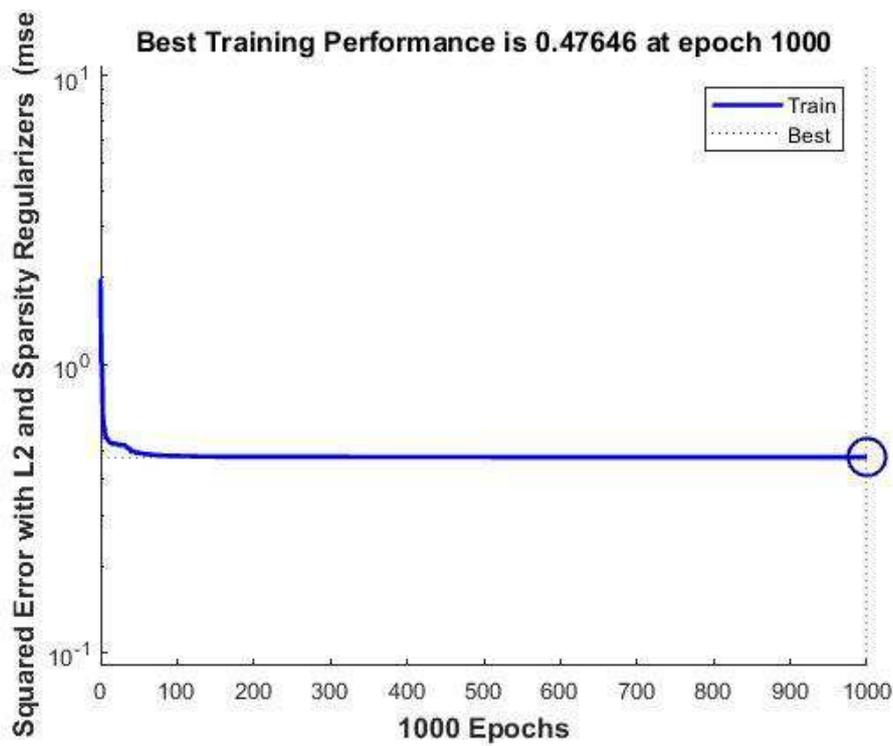


Figure IV.11. Meilleure performance d'entraînement des coefficients de données (BC) avec  $P=20$

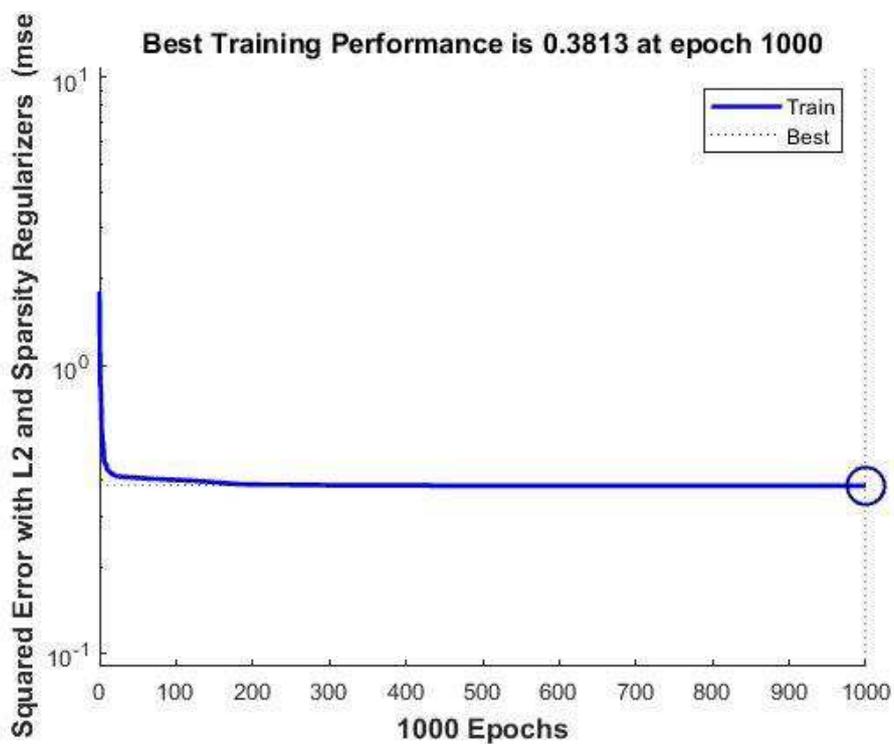
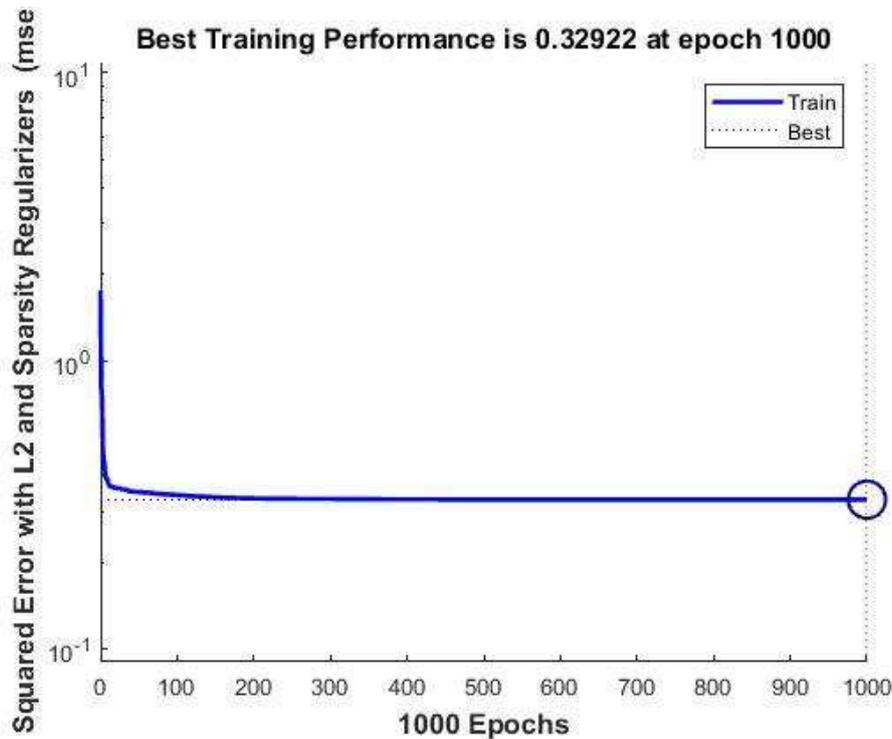
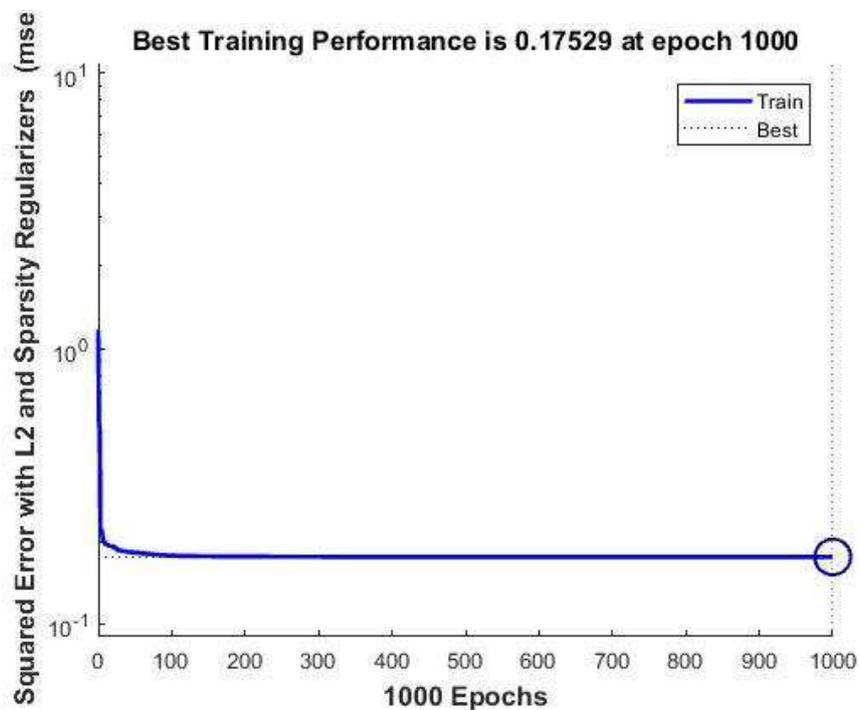


Figure IV.12. Meilleure performance d'entraînement des coefficients de données (BD) avec  $P=20$



**Figure IV.13.** Meilleure performance d'entraînement des coefficients de données (CE) avec  $P=20$

Les figures suivantes présentent la meilleure performance d'entraînement des coefficients avec la valeur de  $P$  trouvé par l'AIC,  $P=13$ .



**Figure IV.14.** Meilleure performance d'entraînement des coefficients de données (AE) avec  $P=13$

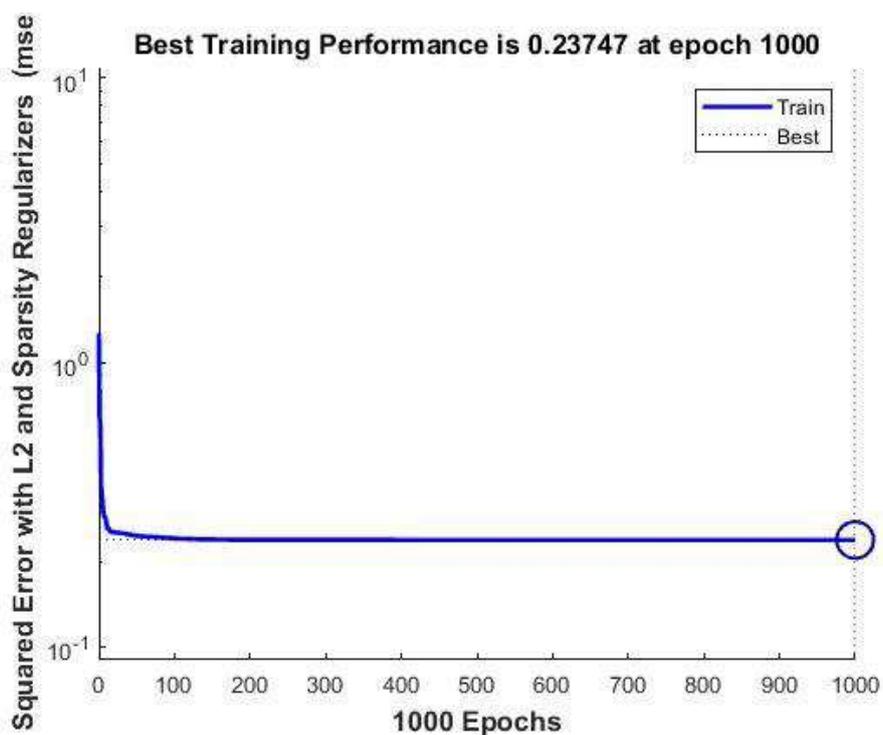


Figure IV.15. Meilleure performance d'entraînement des coefficients de données (AC) avec  $P=13$

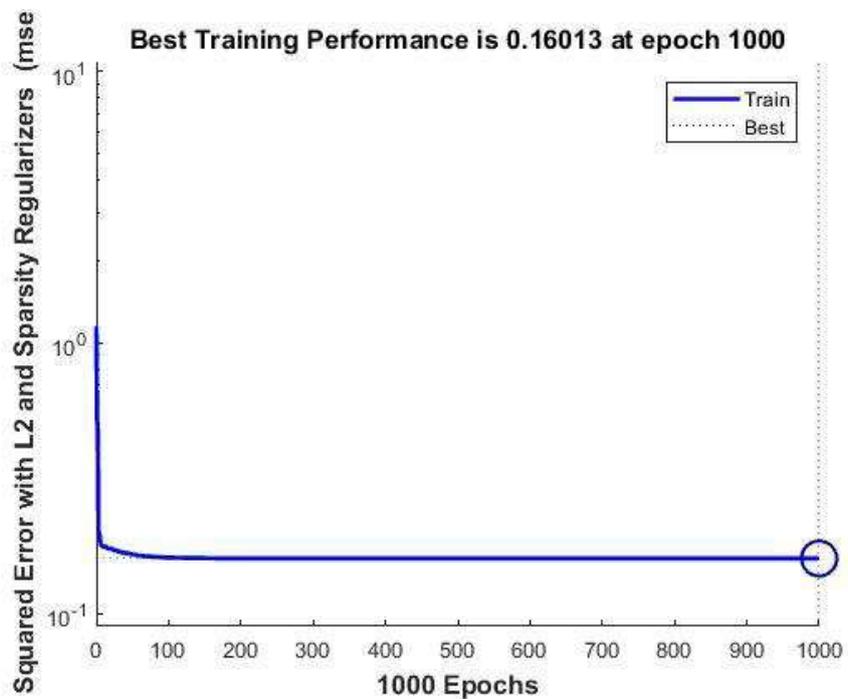


Figure IV.16. Meilleure performance d'entraînement des coefficients de données (AD) avec  $P=13$

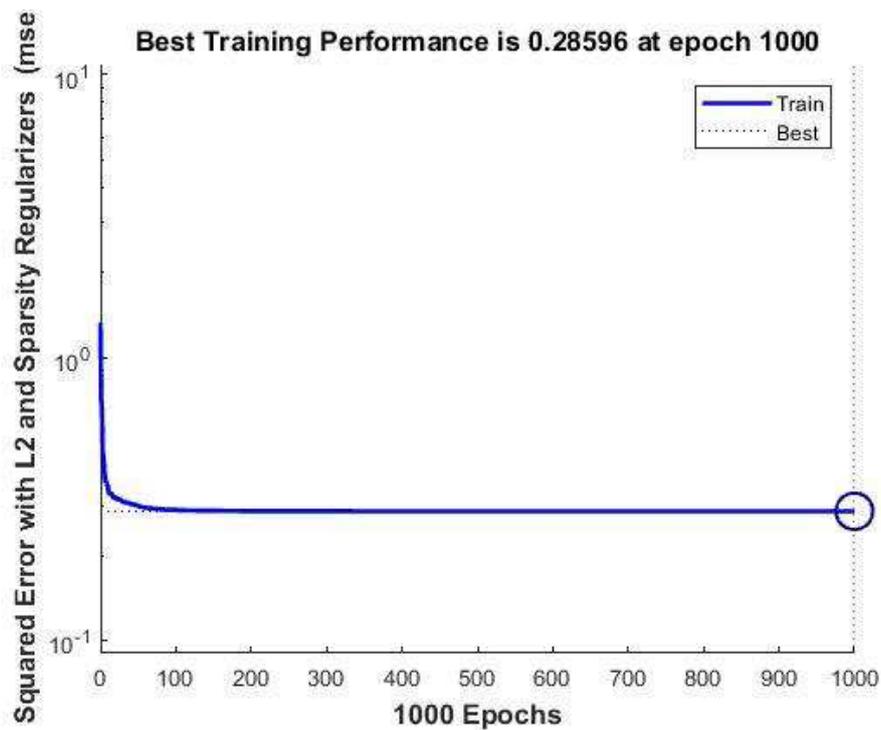


Figure IV.17. Meilleure performance d'entraînement des coefficients de données (BE)  
avec  $P=13$

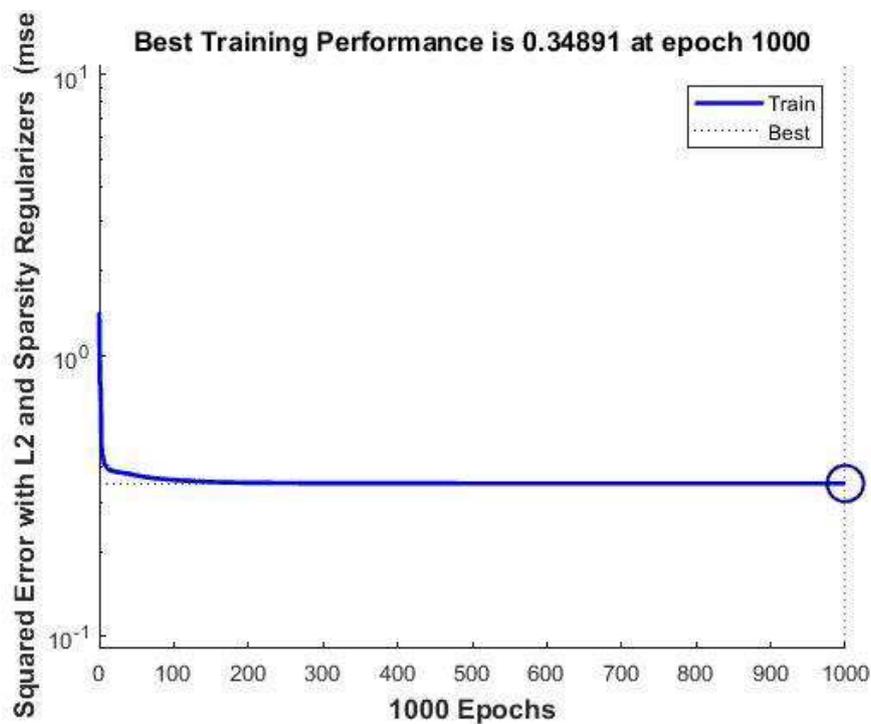


Figure IV.18. Meilleure performance d'entraînement des coefficients de données (BC)  
avec  $P=13$

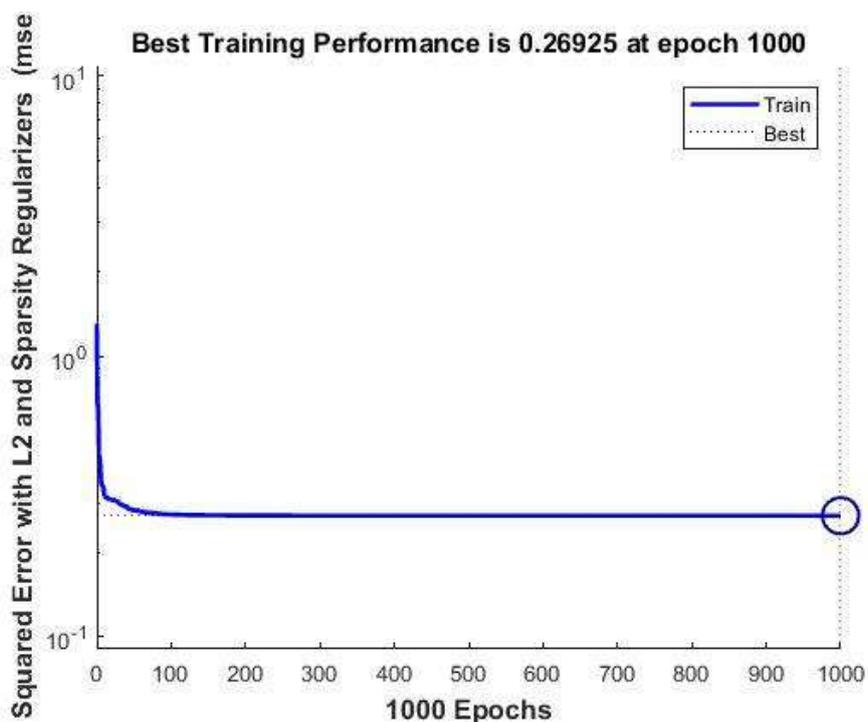


Figure IV.19. Meilleure performance d'entraînement des coefficients de données (BD) avec  $P=13$

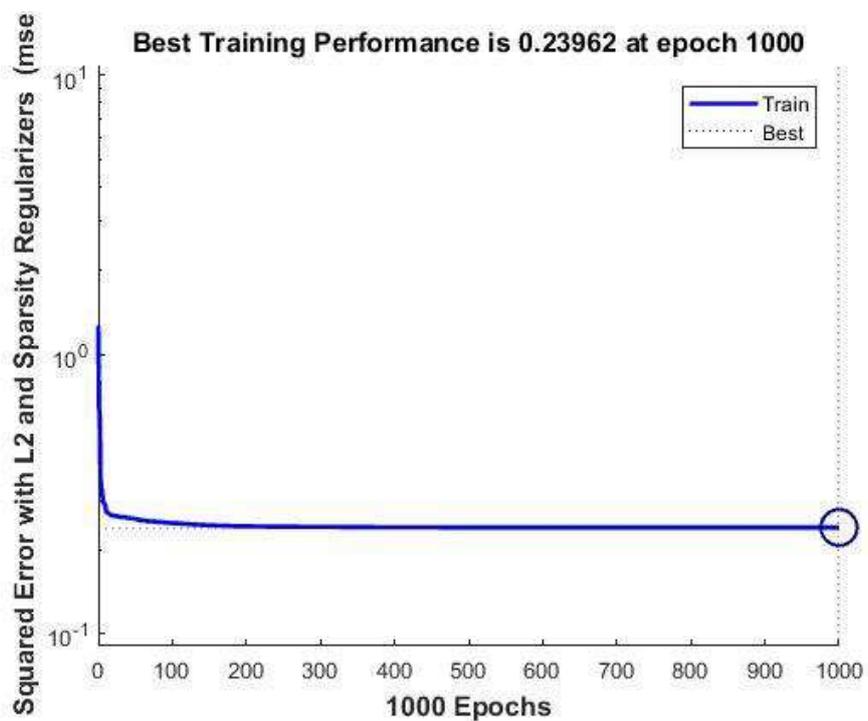


Figure IV.20. Meilleure performance d'entraînement des coefficients de données (CE) avec  $P=13$

Les figures suivantes illustrent meilleure performance d'entraînement des coefficients quand on diminue la valeur de l'ordre P (P=10).

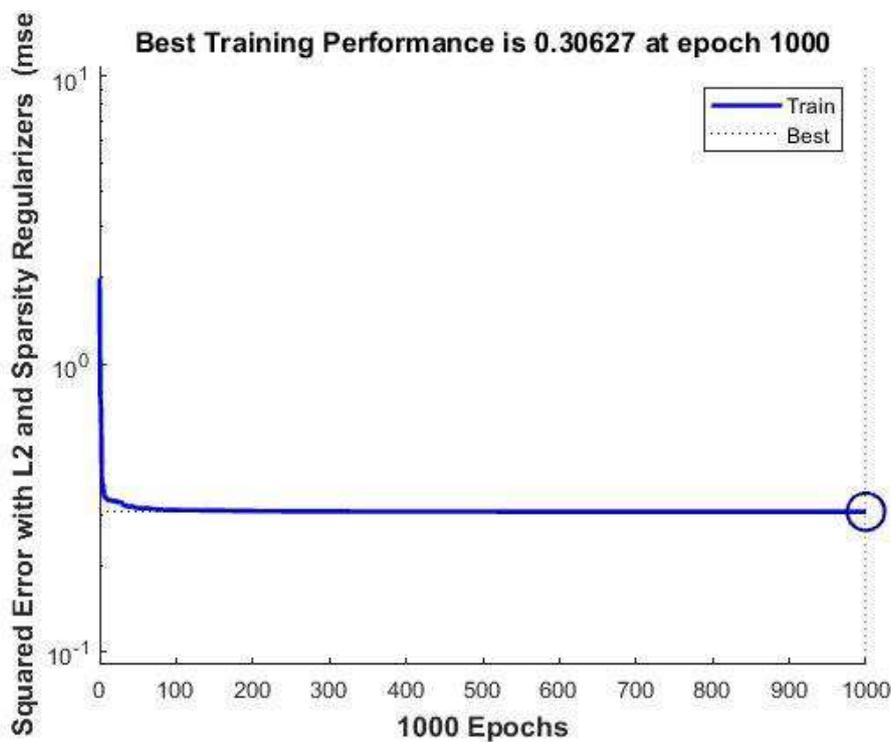


Figure IV.21. Meilleure performance d'entraînement des coefficients de données (AE) avec P=10

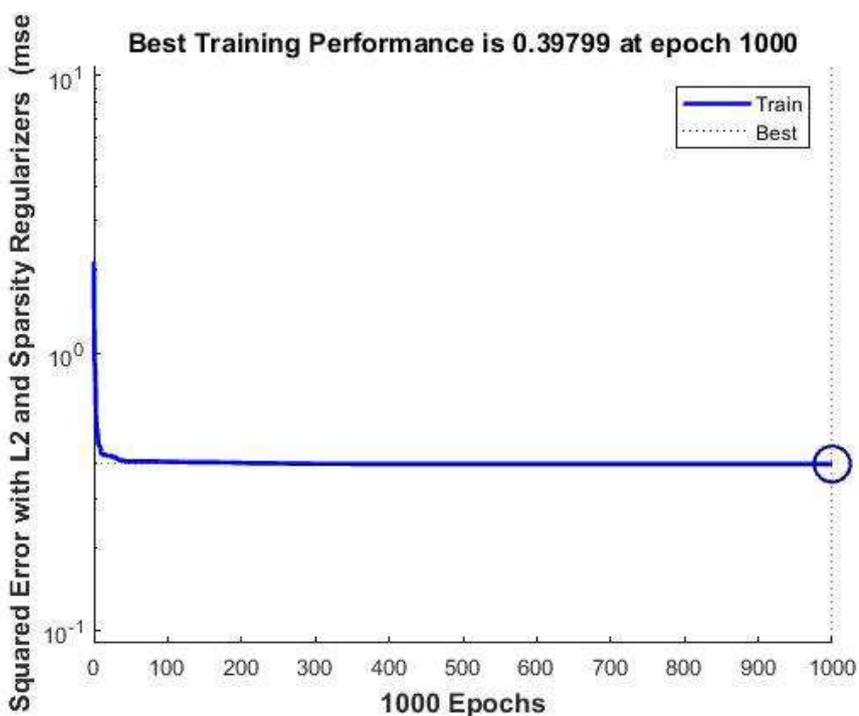


Figure IV.22. Meilleure performance d'entraînement des coefficients de données (AC) avec P=10

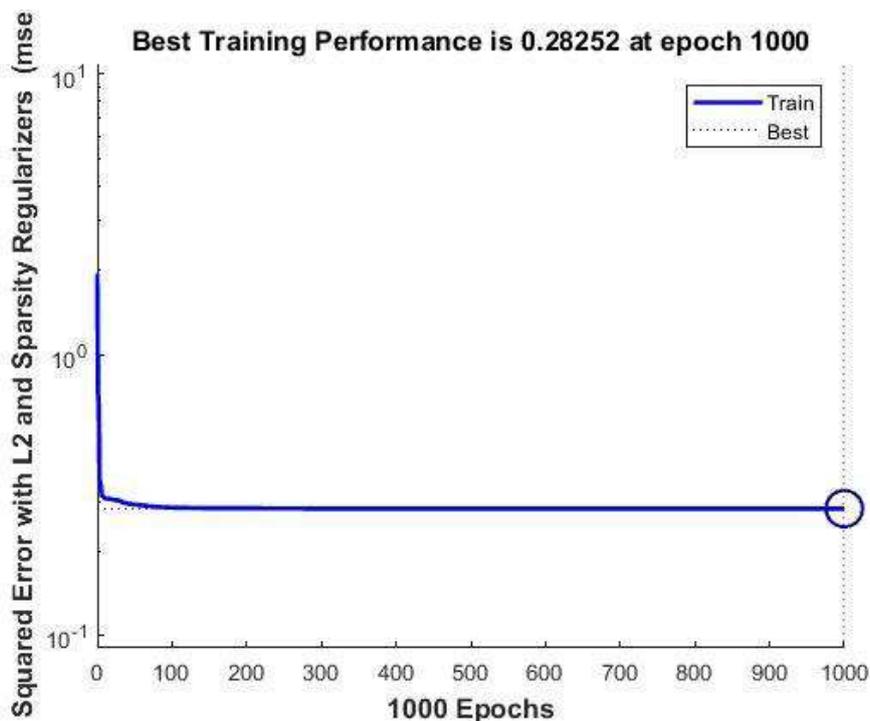


Figure IV.23. Meilleure performance d'entraînement des coefficients de données (AD) avec  $P=10$

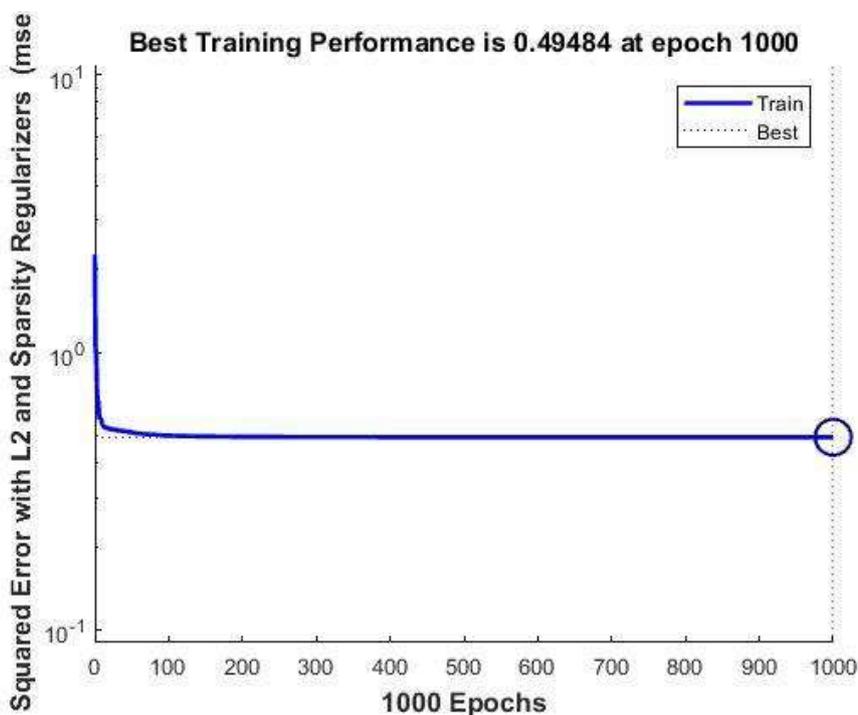


Figure IV.24. Meilleure performance d'entraînement des coefficients de données (BE) avec  $P=10$

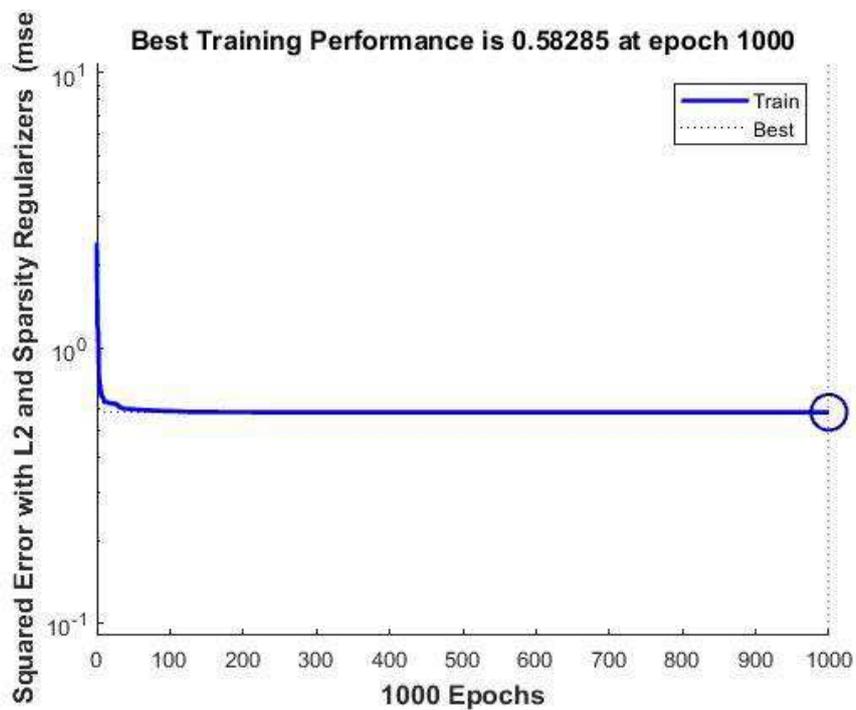


Figure IV.25. Meilleure performance d'entraînement des coefficients de données (BC) avec  $P=10$

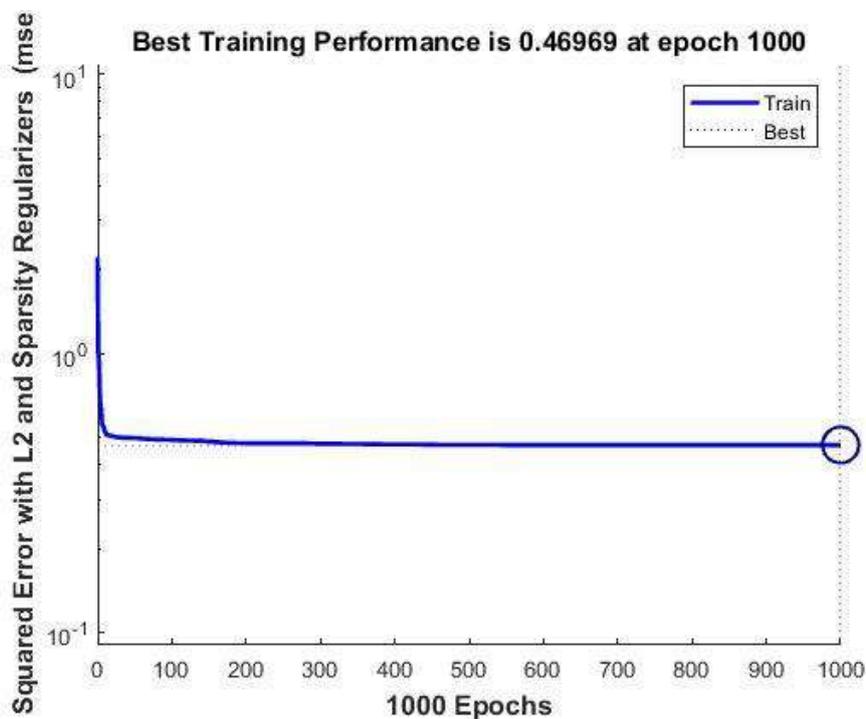
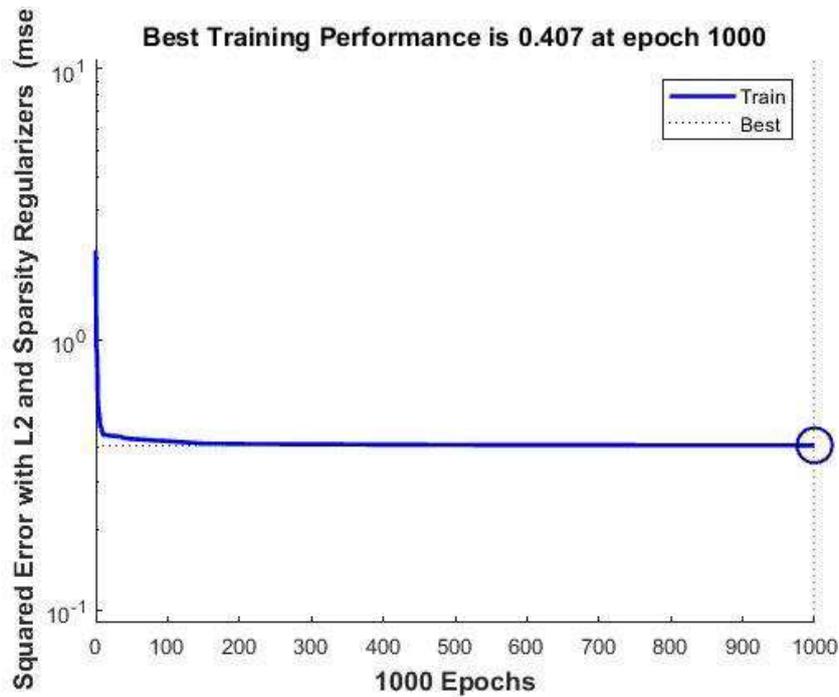


Figure IV.26. Meilleure performance d'entraînement des coefficients de données (BD) avec  $P=10$



**Figure IV.27.** Meilleure performance d'entraînement des coefficients de données (CE) avec  $P=10$

D'après les graphes présentés ci-dessus, il est clair que la valeur de  $P$  a un effet sur la performance d'entraînement des coefficients obtenus.

Temps que nous éloignant de l'ordre optimal, nous obtenons moins de précision par exemple dans le cas de la paire de donnée (AE) nous voyons que la performance d'entraînement égale à 0.24379, **0.17529** et 0.30627 pour  $P$  égale à 20, **13** et 10 respectivement.

Dans cette section, nous présentons les résultats de nos expériences qui ont été réalisées pour étudier l'effet de la longueur (ou de la durée) du signal EEG enregistré sur la performance de la classification.

Cette étude est importante car elle nous aide à identifier la longueur minimale du signal EEG qui peut fournir une performance satisfaisante pour les problèmes de classification considérés dans cette étude. Pour ce faire, nous avons effectué un ensemble d'expériences en réduisant successivement la longueur du segment EEG ( $N$ ). Les résultats de nos expériences sont résumés dans le tableau 6 (Table IV.6), qui indique que notre approche atteint une classification presque parfaite même avec une longueur de segment de 1000 échantillons pour

la classification des signaux EEG. Plus important encore, on peut observer qu'une réduction significative de la longueur du segment ne provoque qu'une détérioration marginale des performances de classification.

**Table IV.6.** Mesures de performance pour étudier l'effet de la longueur du signal EEG sur les performances de la classification

Longueur du segment ( <i>N</i> )	Tache de classification	ACC	SEN	SPE
4000	AE	0.9900	1.0000	0.9800
	BE	0.9700	1.0000	0.9400
	CE	0.9900	0.9800	0.9800
3000	AE	<b>0.9900</b>	<b>1.0000</b>	<b>0.9800</b>
	BE	<b>0.9900</b>	<b>1.0000</b>	<b>0.9800</b>
	CE	<b>0.9900</b>	<b>1.0000</b>	<b>0.9800</b>
250	AE	0.9800	0.9800	0.9800
	BE	0.9800	0.9800	0.9800
	CE	0.9600	1.0000	0.9200
50	AE	0.9500	0.9600	0.9400
	BE	0.8800	0.8200	0.9400
	CE	0.9500	0.9600	0.9400

La méthode proposée a été comparée aux études précédentes rapportées dans la littérature (voir le tableau 7). A partir de ce tableau, les résultats de classification obtenus par la première expérience de la méthode proposée (modèle Burg AR et classificateur SVM) ont donné une bonne performance de précision (98,00%, 100%, 96,00%), sensibilité, spécificité, respectivement (A et E). En outre, dans la deuxième expérience (Burg avec SAE et SVM), ils

présentent une excellente performance de (100,00%, 100,00%, 100,00%) précision, sensibilité, spécificité, respectivement dans les ensembles (A et E). On peut conclure que la méthode introduite est meilleure que les méthodes précédentes.

**Tableau IV.7.** Comparaison entre les précisions de la méthode proposée et d'autres méthodes à partir des littératures utilisant différents ensembles de données épileptiques.

Auteurs	Données	Méthodes	ACC
Cette étude	A et E	Burg +SVM	98.00%
		Burg+SAE +SVM	100%
	A et D	Burg +SVM	95.00%
		Burg+SAE +SVM	93.00%
	(C , D) et (E)	Burg +SVM	95.00%
		Burg+SAE +SVM	96.00%
[Guo et al, 2010]	A and E	longueur de ligne de caractéristiques +ANN	99.66%
[Subasi et Gursoy, 2010]	A et E	SVM+PCA	98.75%
SVM+ICA		99.50%	
SVM+LDA		100%	
[Lin et al, 2016]	A et E	SSAE networks - softmax classificateur	100%
	B et E		100%
	C et E		100%
	D et E		100%
	A et D		93.33%
[Chandaka et al, 2009]	A et E	Cross-correlation assisté par SVM	95.96%

[Nicolaou et Georgiou, 2012]	A et E	Permutation Entropie (PE) et SVM	93.55%
	A et D		88.83%

#### IV.4. CONCLUSION

Dans ce chapitre, nous avons validé une nouvelle application basée sur le modèle AR et l'autoencodeur clairsemé employé comme une nouvelle méthode d'extraction de caractéristiques pour mieux identifier et classifier les crises d'épilepsie à partir des signaux EEG.

Les modèles AR sont des outils efficaces utilisés pour classer les données épileptiques transmises par les signaux EEG. En outre, l'amélioration des coefficients AR par SAE est une technique puissante et efficace qui nous a permis d'obtenir une meilleure exactitude de classification de l'ordre de 100,00%.

De plus, les résultats des expériences montrent la capacité de la méthode proposée même avec une longueur de segment de 1000 échantillons pour la classification des signaux EEG.

Cependant, la méthode introduite atteint une bonne moyenne d'exactitude des classifications entre 94,50% et 100% selon l'utilisation de quelques données. Par rapport aux études précédentes rapportées dans la littérature, cette méthode est capable de fournir plus de connaissances et peut mieux faire la distinction entre les signaux d'EEG normaux et la crise d'épilepsie.

---

# **BIBLIOGRAPHIE**

---

- [Andrzejak et al.,2001] ANDRZEJAK, Ralph G., LEHNERTZ, Klaus, MORMANN, Florian, *et al.* Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state. *Physical Review E*, 2001, vol. 64, no 6, p. 061907.
- [Chandaka et al, 2009] CHANDAKA, Suryannarayana, CHATTERJEE, Amitava, et MUNSHI, Sugata. Cross-correlation aided support vector machine classifier for classification of EEG signals. *Expert Systems with Applications*, 2009, vol. 36, no 2, p. 1329-1336.
- [Guo et al, 2010] GUO, Ling, RIVERO, Daniel, DORADO, Julián, *et al.* Automatic epileptic seizure detection in EEGs based on line length feature and artificial neural networks. *Journal of neuroscience methods*, 2010, vol. 191, no 1, p. 101-109.
- [Karimoi et Karimoi, 2014] KARIMOI, Reza Yaghoobi et KARIMOI, Azra Yaghoobi. Classification of EEG signals using hyperbolic tangent-tangent plot. *International Journal of Intelligent Systems and Applications*, 2014, vol. 6, no 8, p. 39.
- [Li et al, 2016] LI, Peng, KARMAKAR, Chandan, YAN, Chang, et al. Classification of 5-s epileptic eeg recordings using distribution entropy and sample entropy. *Frontiers in physiology*, 2016, vol. 7, p. 136.
- [Lin et al, 2016] LIN, Qin, YE, Shu-qun, HUANG, Xiu-mei, *et al.* Classification of epileptic EEG signals with stacked sparse autoencoder based on deep learning. In: *International Conference on Intelligent Computing*. Springer, Cham, 2016. p. 802-810.
- [Nicolaou et Georgiou, 2012] NICOLAOU, Nicoletta et GEORGIU, Julius. Detection of epileptic electroencephalogram based on permutation entropy and support vector machines. *Expert System swith Applications*, 2012, vol. 39, no 1, p. 202-209.
- [Subasi et GURSOY, 2010] SUBASI, Abdulhamit et GURSOY, M. Ismail. EEG signal classification using PCA, ICA, LDA and support vector machines. *Expert Systems with Applications*, 2010, vol. 37, no 12, p. 8659-8666.

---

# CONCLUSION GÉNÉRALE

---

Le travail présenté dans cette thèse avait pour objectif d'apporter une contribution aux travaux déjà menés dans le cadre de la classification et la détection des crises d'épilepsie à l'aide des méthodes d'apprentissage automatique, il s'agit de développer une méthode automatique et intelligente pour résoudre les problèmes des caractéristiques extraites du signal EEG afin d'être utilisées pour la classification et la détection des crises d'épilepsie.

Au cours du premier chapitre, nous avons présenté les principales notions de neurophysiologie et d'électroencéphalographie dans le cas de l'épilepsie.

Après avoir présenté un bref aperçu sur le système d'aide au diagnostic assisté par ordinateur (CAO), dans le chapitre 2, les étapes du CAO ont été décrites. Ensuite, une revue des travaux réalisés sur la détection automatique des crises d'épilepsie utilisant l'EEG a été présentée. Enfin les bases de données utilisées et les outils d'évaluation sont introduits, ceci permet alors de commenter et de comparer les algorithmes de détection précoce présents dans la littérature.

Pour améliorer la robustesse de l'étape la plus importante dans un système de détection automatique de crise d'épilepsie qui est l'extraction de caractéristiques d'un signal EEG, nous avons présenté dans le chapitre 3, une approche intelligente pour l'extraction de caractéristiques, en utilisant un modèle autorégressif de Burg suivi par un autoencodeur clairsemé (SAE). Nous avons appliqué la technique SAE pour l'amélioration des coefficients obtenus à partir du Burg, puis nous avons utilisé, par ailleurs, les coefficients améliorés comme entrée pour le classificateur SVM afin de les classifier.

Le chapitre 4 a été consacré à la mise en œuvre de l'approche proposée, la présentation, la discussion et l'interprétation des résultats obtenus. La méthodologie était d'étudier trois problèmes de classification à savoir, (i) non-épileptique à Interictal, (ii) non-épileptique à Ictal et (iii) Interictal à Ictal.

À partir des résultats obtenus, il est clairement démontré que l'amélioration des coefficients AR par SAE est une technique puissante et efficace qui nous a permis d'obtenir une meilleure exactitude de classification de l'ordre de 100,00% pour le cas de non-épileptique à Interictal.

On peut conclure que le choix de l'ordre P a une grande importance car il a une influence remarquable sur les paramètres de l'autoencodeur.

Il peut être noté qu'une réduction significative de la longueur du segment a très peu d'influence sur la performance de la méthode proposée et ne provoque qu'une détérioration marginale des performances de classification.

Afin d'éprouver un peu plus notre système, nous envisageons d'utiliser les algorithmes d'optimisation pour le choix de l'ordre du model P. Au niveau de l'étape de classification, nous envisageons la combinaison du SVM avec d'autres classificateurs.

Sur le plan clinique, nous envisageons d'appliquer l'approche proposés sur une base de donnée collectée au niveau local (CHU'Oran).

Enfin, dans le futur proche, la recherche peut être accentuée sur l'utilisation de l'approche présentée pour développer un algorithme robuste et efficace pour la localisation du foyer epileptogene en combinaison l'EEG et l'IRMf.