

Université Abou Bekr Belkaid
Tlemcen Algérie



جامعة أبي بكر بلقايد

تلمسان الجزائر

République Algérienne Démocratique et Populaire
Ministère de L'Enseignement Supérieur et de la Recherche Scientifique
Université d'Abou bakr Belkaïd – Tlemcen
Faculté des Sciences
Département d'Informatique



MEMOIRE DE PROJET DE FIN D'ETUDES

En vue de l'obtention du diplôme de master en informatique
Spécialité : Modèle intelligent et de décision (M.I.D)

Thème :

**Séries Temporelles Multivariées (EEG) :
Prédiction des crises d'épilepsie**

Réalisé par :

- BENOSMAN Farah
- BOUDAOUZ Sarah

Soutenu publiquement le 27 Juin 2024 devant le jury :

- | | |
|--------------------------|-----------|
| • Mr BENMOUNA Youcef | Président |
| • Mr MEZIANE Abdelfettah | Examineur |
| • Mr BENZAOUZ Mourtada | Encadrant |

Année Universitaire : 2023 / 2024




Remerciements

Tout d'abord, nous tenons à exprimer nos profonds remerciements à Mr. **BENAZZOUZ Mourtada** pour son encadrement tout au long de la réalisation de ce mémoire . Nous le remercions pour son soutien, sa confiance, ses enseignements, sa passion pour la recherche, ainsi que toutes les opportunités qu'il nous a offertes pour mener à bien ce projet.

Nous adressons nos plus sincères remerciements aux membres du jury Mr. **BENMOUNA Youcef** et Mr **MEZIANE Abdelfettah** pour avoir pris le temps d'évaluer notre travail. Votre expertise et vos commentaires constructifs sont inestimables et nous aident à progresser dans notre parcours académique et professionnel.

Nos vifs remerciements vont à l'ensemble de nos enseignants du Département d'informatique, pour leurs conseils, leurs compétences et leur expertise.

Enfin, nous remercions chaleureusement tous ceux qui ont contribué de près ou de loin à la réalisation de ce travail.



Dédicaces

À ma famille et à mes amis,

votre soutien inconditionnels illuminent ma vie chaque jour. Merci d'être toujours présents,
vous êtes ma plus grande force et ma source de bonheur.

BENOSMAN Farah



Dédicaces

Je dédie ce travail à

Ma mère pour son amour inestimable, sa confiance, son soutien, ses sacrifices et toutes les valeurs qu'elle m'a inculqué. Pour les efforts qu'elle a déployés pour me voir arriver ici, et pour les prières qui ont été exaucées, elle est la raison pour laquelle j'ai pu accomplir tout cela.

A mon père qui m'a encouragée, tous les mots ne pourront exprimer mon amour et mon respect. Que Dieu vous récompense de tout le meilleur, la santé et d'une longue vie. Papa et maman je vous aime.

A ma sœur Imene, qu'elle a toujours été plus qu'une sœur pour moi, une véritable amie et une source constante de soutien et d'inspiration, sa force intérieure m'ont souvent donné le courage de surmonter les moments difficiles, je suis fière d'avoir une sœur comme elle.

A mon frère Ayoub pour sa présence rassurante et pour toutes les fois où il a su trouver les mots justes pour me motiver et me redonner confiance, j'ai de la chance de d'avoir un frère merveilleux.

A mon binôme Farah, pour la collaboration, le soutien, l'attitude, la confiance, la patience et l'amitié tout au long de notre parcours.

À mon beau-frère Kheireddine, pour son aide et ses conseils avisés, son soutien et ses encouragements.

À mon petit neveu Racim, pour la joie et la motivation supplémentaires qu'il m'apporte chaque jour, son sourire est une source constante d'inspiration et de bonheur.

A mes tantes, oncles et cousines pour leur soutien.

Boudaoud Sarah

TABLE DE MATIERE

LISTE DES FIGURES	viii
LISTE DES TABLES	ix
LISTE DES ABREVIATIONS	x
INTRODUCTION GENERALE	xi
1 CHAPITRE 1	
 INFORMATIONS MÉDICALES	2
1.1 INTRODUCTION	3
1.2 Épilepsie	3
1.2.1 Définition	3
1.2.2 Crise d'épilepsie	3
1.2.3 La classification des troubles	3
1.2.4 Types de crises	4
1.2.4.1 focale	5
1.2.4.2 Généralisé	5
1.2.5 Diagnostique	7
1.2.6 Impacts sur la qualité de vie	7
1.3 EEG	8
1.3.1 Les systèmes de montage d'EEG	9
1.3.1.1 Le système 10-20	9
1.3.1.2 Le système 10-10	10
1.3.2 Les types de montage d'EEG	11
1.3.3 Type d'onde de signaux	14
1.3.4 États de crise en EEG :	15
1.3.5 Modèles EEG dans les crises focales et généralisées	16
1.4 CONCLUSION	20

2	CHAPITRE 2:	
	Modèles De Deep Learning Pour Les Séries Temporelles	21
2.1	INTRODUCTION	22
2.2	Les séries temporelles	22
2.2.1	Historique	22
2.2.2	Définition	22
2.2.3	Série temporelle univariée et multivariée	26
2.2.4	Détection d'anomalies	27
2.2.5	Les modèles uni-variés	28
2.3	Deep Learning:	29
2.3.1	Définition	29
2.3.2	Histoire des réseaux de neurones et du deep learning en traitement de signaux et des images	29
2.3.3	Les types des réseaux de neurones :	30
2.3.3.1	Convolutional Neural Network (CNN) :	30
2.3.3.2	Réseau de Neurones Récurrent (Récurrent Neural Network (RNN))	34
2.3.3.3	Long Short-Term Memory (LSTM):	35
2.3.3.4	La différence entre LSTM , CNN et RNN	39
2.4	Les Algorithmes d'optimisation de la descente de gradient	40
2.5	CONCLUSION	40
3	CHAPITRE 3:	
	CONTRIBUTION ET IMPLÉMENTASSIONS	41
3.1	INTRODUCTION	42
3.2	Outils et Bibliothèques Utilisés	42
3.2.1	Environnements de travail	42
3.2.2	Bibliothèques et dépendances	43
3.3	Datasets	44
3.3.1	Présentation des datasets disponibles	44
3.3.2	Datasets utilisées	45
3.3.3	Pré-traitement	48
3.3.3.1	Méthode 1 : Pré-traitement pour la Base de Données 1 CHB-MIT «prédiction »	49
3.3.3.2	Méthode 2 : Pré-traitement pour la Base de Données 2 TUSZ « classification »	50
3.4	Transformation bipolaire	51
3.5	Équilibrage des données	52

TABLE DE MATIERE

3.6	Extraction des caractéristiques	54
3.7	Transformée de Fourier	55
3.8	État de l'art	57
3.9	Modèle réaliser	59
3.10	Résultats	61
3.11	CONCLUSION	64
	CONCLUSION GENERALE	65
	BIBLIOGRAPHY	66
	Résumé	74
	Abstract	74
		74

LISTE DES FIGURES

1.1	Classification de l'épilepsie et des troubles épileptiques [4]	4
1.2	Localisation des crises	5
1.3	Classification des crise d'épilepsie [57]	6
1.4	Placement des électrodes pour l'enregistrement des signaux EEG[15]	8
1.5	Transmission synaptique pendant une crise[16]	9
1.6	Montage 10/20[17]	10
1.7	Montage 10/10[18]	11
1.8	Cartes de montage des pics spectraux : bipolaire homologue (Bco), bipolaire longitudinal (Lbp), bipolaire croisé (Bcr), référence biauriculaire (Bar) et référence Cz (Czr)[20]	14
1.9	Ondes cérébrale[22]	15
1.10	Etats de crise	16
1.11	Exemple d'EEG (patiente de 32 ans, épilepsie myoclonique)	17
1.12	Crise frontale gauche[25]	18
1.13	EEG typique montrant un fond normal et une décharge polyspike-wave bilatérale, symétrique et synchrone de 4 Hz.	19
1.14	Pointes-ondes généralisées.	20
2.1	Evolution des prix du Dow Jones de 1928 à 2004, données mensuelles	23
2.2	Evolution de la puissance éolienne au large de la Bretagne (m/s) de 1979 à 2001, données quotidiennes.	24
2.3	Tendances hebdomadaires des cas de grippe en France de 1984 (semaine) à 2002 (semaine 50) soit une valeur de 945.	24
2.4	Exemple de série temporelle	25
2.5	Exemples synthétiques (a)[31]	26
2.6	Exemples synthétiques (b)[31]	27
2.7	Quelques évènements clé du développement historique des réseaux de neurones[36]	29
2.8	Réseau De Neurones Avec De Nombreuse Couches Convolutives	30
2.9	Exemple Explicative Sur L'opération De Convolution	31
2.10	(A) Pooling maximal, (B) Pooling moyen	32

2.11	Couche fully-connected	32
2.12	Un exemple d'architecture CNN pour la classification d'images	33
2.13	Architecture De RNN[43]	34
2.14	L'architecture de LSTM [48]	35
2.15	Un résumé des types d'architectures de réseaux de neurones[50]	38
3.1	Répartition des fichiers d'entraînement et de test	49
3.2	Segmentation des données [52]	50
3.3	Répartition des fichiers d'entraînement et de test et de validation	51
3.4	La fenêtre glissante [52]	52
3.5	Répartition des différentes classes dans le dataset TUSZ	53
3.6	Repartition par patient	53
3.7	Résumer de méthodes d'extraction de caractéristiques	55
3.8	Représentation du signale dans le domaine temporelle	56
3.9	Représentation du signale dans le domaine fréquentielle	57
3.10	Un modèle CNN	58
3.11	Un modèle hybride ResNet-LSTM [52]	59
3.12	Schéma typique d'un système automatique de prédiction des crises d'épilepsie .	60
3.13	Modèle proposé CNN_LSTM	61
3.14	Diagramme détaillé de l'architecture proposé	61
3.15	Progression de la perte et de la précision (F1 Score) au cours des itérations d'entraînement	63
3.16	Progression des différentes métriques de validation au cours des itérations d'entraînement	64



LISTE DES TABLES

2.1	La différence entre LSTM , CNN et RNN	39
3.1	Caractéristiques des Datasets	44
3.2	Application des Datasets	45
3.3	Description de la référence de l'électrode et nombre d'événements par type de crise dans TUSZ [59]	48



LISTE DES ABREVIATIONS

Adem Adaptive Moment Estimation

CNN Convolutional Neural Network (Réseau de neurones à convolution)

DL Deep Learning

EEG ElectroEncéphaloGramme

IA Intelligence Artificielle

IRM Imagerie par Résonance Magnétique

LSTM Long Short-Term Memory (Longue Mémoire à Court Terme)

ML Machine Learning

ReLu Rectified Linear Unit (Unité Linéaire Rectifiée)

RNN Recurrent Neural Network (Réseau de neurones récurrent)

ST Série Temporelle

STM Série Temporelle Multivariée

SVM Support Vector Machine

STFT Short-Time Fourier Transform

TF Transformers de Fourier



INTRODUCTION GENERALE

Contexte

L'épilepsie, le deuxième trouble neurologique le plus courant après l'accident vasculaire cérébral . Elle affecte environ 50 millions de personnes dans le monde, selon l'Organisation mondiale de la santé (OMS). Ces crises peuvent entraîner des conséquences graves, notamment des blessures physiques, une diminution de la qualité de vie, et des stigmates sociaux. La capacité de prédire ces crises permettrait non seulement de réduire ces risques, mais aussi d'améliorer significativement la gestion de la maladie pour les patients.

L'électroencéphalogramme (EEG) est un outils essentiels dans le diagnostic et la gestion de l'épilepsie. En enregistrant l'activité électrique du cerveau, l'EEG fournit des informations précieuses sur les patterns neuronaux associés aux crises. Cependant, ces données sont souvent complexes et multidimensionnelles, nécessitant des méthodes d'analyse avancées pour en extraire des informations pertinentes.

Problématique

La prédiction de séries temporelles multivariées a des applications dans une grande variété de domaines, considérée comme une tâche très difficile, en particulier ont des corrélations et présentent des modèles temporels complexes, tels que les données EEG qui permettent de modéliser les relations dynamiques entre plusieurs variables enregistrées au fil du temps, capturant ainsi les interactions complexes entre différentes régions du cerveau. L'intégration des techniques d'apprentissage automatique avec l'analyse des séries temporelles offre des perspectives prometteuses pour améliorer la précision des prédictions de crises.

Cependant, la prédiction précise des crises d'épilepsie reste un défi majeur en neurologie. Malgré la richesse des données EEG, l'extraction de motifs prédictifs fiables est entravée par la nature hautement non linéaire et dynamique des signaux cérébraux. Les méthodes traditionnelles d'analyse des données EEG montrent des limites en termes de précision et de robustesse. De plus, la complexité des interactions entre différentes régions cérébrales, capturées par les séries temporelles multivariées, exige des modèles capables de gérer cette complexité.

Contribution

Ce projet de fin d'étude se propose d'apporter une contribution significative à la prédiction des crises d'épilepsie en utilisant des techniques avancées d'analyse de séries temporelles multivariées. Nous nous concentrerons sur le développement et l'évaluation de modèles prédictifs basés sur l'apprentissage automatique et l'intelligence artificielle. Plus précisément, nous explorerons l'utilisation des réseaux de neurones récurrents (RNN), des réseaux neuronaux convolutifs (CNN) et d'autres architectures de deep learning pour modéliser les dépendances temporelles et spatiales dans les données EEG.

Plan du mémoire

1. Dans le chapitre 1 nous présentons des informations médicales .
2. Le chapitre 2 traite les fondamentaux des modèles de deep learning .
3. Dans le chapitre 3 nous illustrons par nos implémentations .
4. A la fin nous terminons par une conclusion générale.

1

CHAPITRE 1
INFORMATIONS MÉDICALES

1.1 INTRODUCTION

Il y a actuellement plus de 51 millions de personnes souffrant d'épilepsie dans le monde et chaque année, plus de 4,9 millions de personnes développent une nouvelle épilepsie. Le diagnostic et la gestion de l'épilepsie reposent largement sur l'électroencéphalographie (EEG). Dans ce chapitre nous entamons l'épilepsie, ses types, les effets secondaires, le diagnostic en parlant de l'électroencéphalogramme, ses divers types de montages et son rôle crucial dans la détection de l'épilepsie.

1.2 Épilepsie

1.2.1 Définition

L'épilepsie est une maladie cérébrale chronique non transmissible, qui se caractérise par des crises récurrentes non provoquées se manifestant par de brefs épisodes de tremblements involontaires touchant une partie du corps ou l'ensemble du corps. [1][2]

1.2.2 Crise d'épilepsie

Une crise épileptique est la présence transitoire de signes et symptômes dus à une activité neuronale excessive ou synchrone anormale dans le cerveau[1], provoquée par une décharge électrique cérébrale incontrôlée[1][3].

1.2.3 La classification des troubles

La classification des troubles est un moyen de parvenir à une compréhension commune de la terminologie utilisée pour identifier les troubles épileptiques dans le domaine clinique ou de la recherche, deux classifications internationales ont été élaborées : l'une pour les crises épileptiques et l'autre pour l'épilepsie et les syndromes épileptiques[2].

La première catégorie distingue les crises partielles et généralisées, avec des sous-catégories basées sur l'état de conscience.

La deuxième catégorie classe l'épilepsie en troubles localisés ou généralisés, en fonction des types de crises et des facteurs étiologiques[2][4].

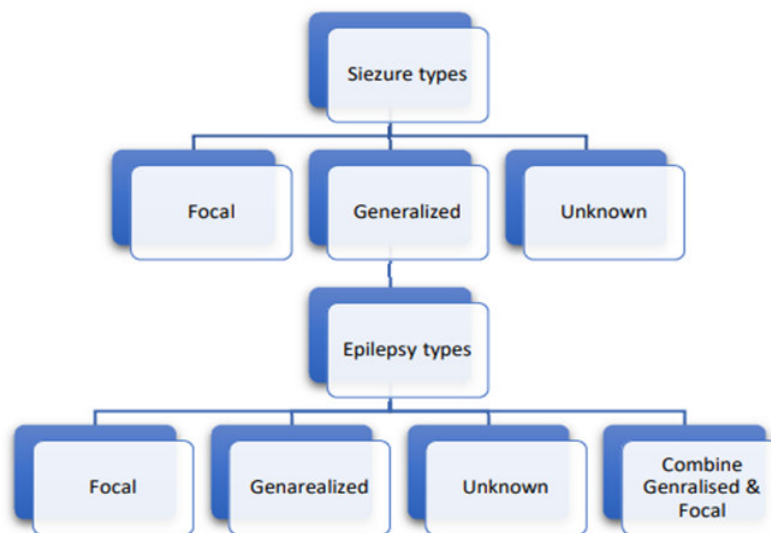


Figure 1.1: Classification de l'épilepsie et des troubles épileptiques [4]

1.2.4 Types de crises

Les crises épileptiques présentent des caractéristiques variées influencées par l'endroit où la perturbation débute au niveau du cerveau et de sa propagation (figure 1.2). Des signes temporaires sont observés, telle qu'une désorientation ou une perte de conscience, ainsi que des problèmes de mouvement et de sensations, de l'humeur ou d'autres processus cognitifs.

On distingue deux grandes catégories de crises qui renferment différents types de crises: les crises généralisées et focales[2].

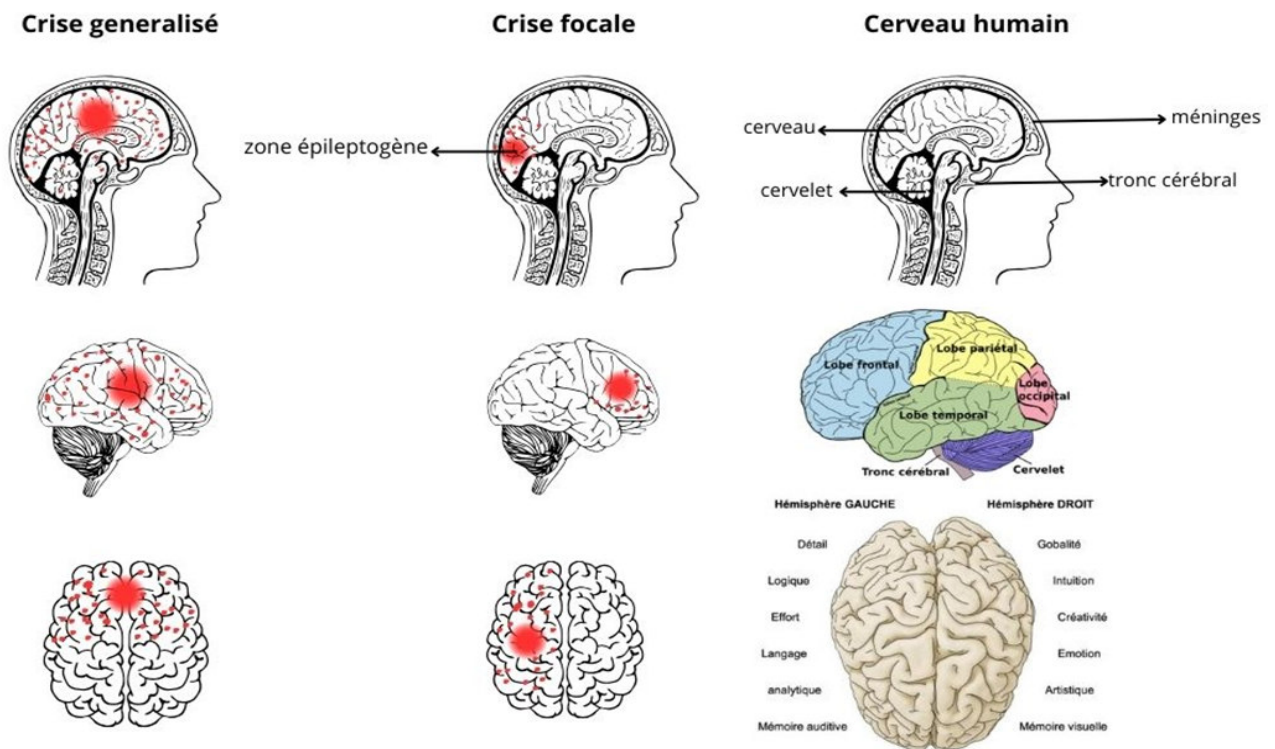


Figure 1.2: Localisation des crises

1.2.4.1 Focale

Les crises d'épilepsie d'origine focale débutent dans une petite région du cerveau, une zone du cortex est activée initialement considérées comme un signal. Ces crises sont souvent légères ou étranges et généralement courtes.

La conscience d'une personne pendant une crise peut être classée en deux catégories

1) Conscience focale « partielle simple » : La personne est totalement consciente de son environnement mais incapable de parler ou de répondre.[58]

2) Conscience focale altérée « crise partielle complexe » : La connaissance et la compréhension sont altérées, et la personne peut sembler perplexe, floue ou confuse. [58]

1.2.4.2 Généralisé

Les crises d'épilepsies généralisées idiopathiques (IGE) sont l'une des formes les plus courantes d'épilepsie. Ce sont des crises qui impliquent les deux hémisphères du cerveau dès leur apparition,

elles présentent diverses manifestations clinique . Les principaux types de crises généralisées incluent :

- **Crise d'absence** : caractérisée par de courtes périodes de perte de conscience de 10 à 20 secondes, souvent décrites comme des « absences » ou des épisodes de « rêverie » accompagnées de mouvements automatiques, elles sont fréquentes chez les enfants[8].

- **Crise généralisée tonique-clonique** « grand mal » : caractérisée par des contractions musculaires violentes et des mouvements involontaires qui affectent tout le corps, La crise évolue en trois phases **Phase tonique**, **Phase clonique** et **résolutive** .

- **Crise généralisée myoclonique** : Secousses brusques et rapides des muscles, qui peuvent affecter un groupe musculaire spécifique ou se généraliser, caractérisée par des mouvements involontaires rapides et répétés.

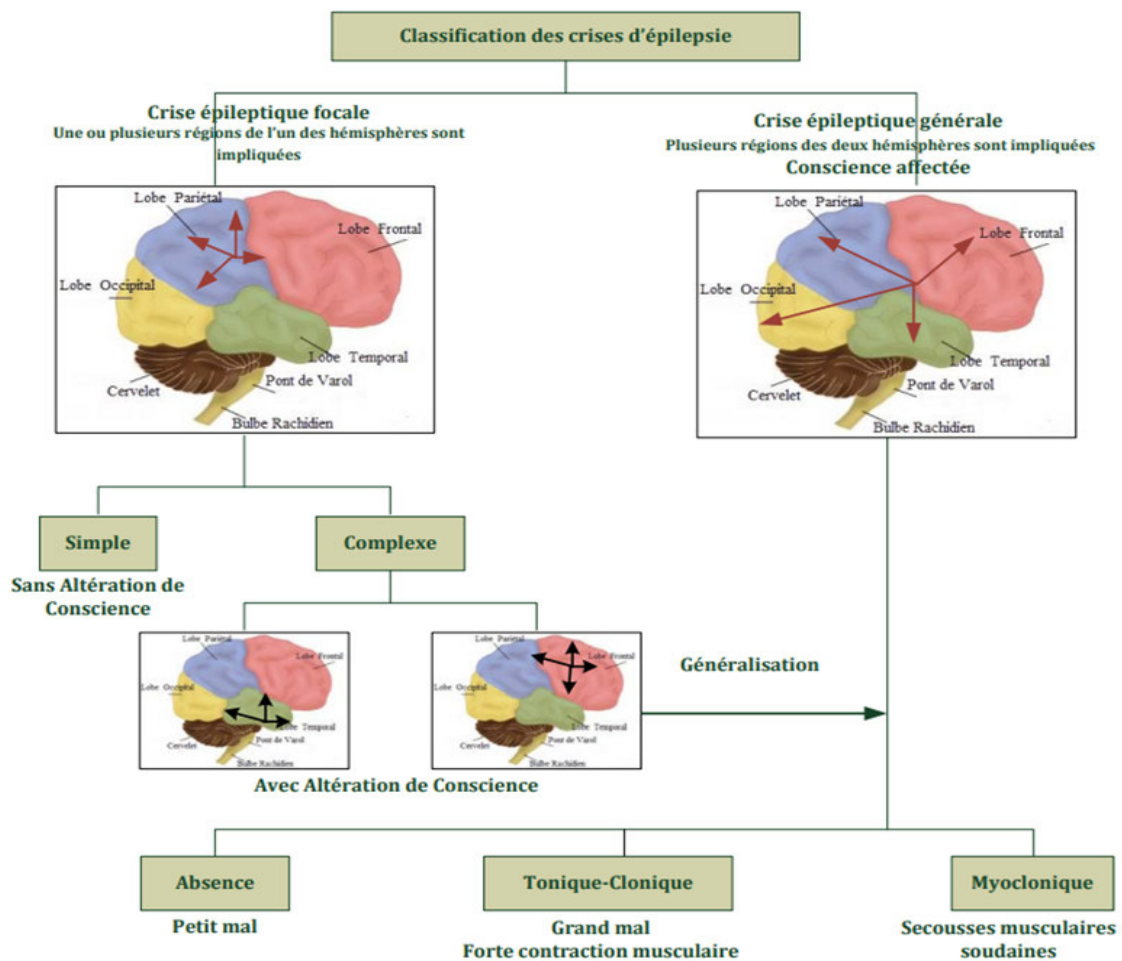


Figure 1.3: Classification des crise d'épilepsie [57]

1.2.5 Diagnostique

Le diagnostic de l'épilepsie repose sur une approche intégrée combinant des évaluations cliniques et des examens complémentaires. L'interrogatoire détaillé du patient et des témoins permet de recueillir des descriptions de crises.

Parmi les outils du diagnostics, l'électroencéphalogramme (EEG) qui occupe une place centrale pour une prise en charge efficace de l'épilepsie. L'EEG, réalisé entre les crises ou pendant une crise, fournit des informations cruciales pour confirmer le diagnostic et orienter le traitement[9].

Complément, l'imagerie par résonance magnétique (IRM) cérébrale et les bilans biologiques aident à identifier les causes sous-jacentes des crises[10].

1.2.6 Impacts sur la qualité de vie

Outre la gravité de la maladie, qui se mesure par la fréquence des crises, d'autres facteurs sont fortement associés à une mauvaise qualité de vie des patients souffrants d'épilepsie comme la tolérance aux médicaments antiépileptiques et la présence de dépression, de stigmatisation et d'inquiétude face à de nouvelles crises[11].

•**Dépendance médicamenteuse:** Le traitement pharmaceutique est crucial pour maîtriser les crises, cependant il peut causer des effets indésirables qui influence sur la qualité de vie.

•**Fréquence des crises:** La présence régulière de crises peut perturber la vie quotidienne, ce qui peut entraîner des contraintes dans les activités et la mobilité.

•**Inquiétude concernant les nouvelles crises:** La crainte des crises à venir peut provoquer de l'anxiété et une détérioration de la qualité de vie[12].

Les signes d'événements indésirables, de dépression, de peur ou de stigmatisation liés aux médicaments doivent être activement étudiés afin de garantir que les patients reçoivent un traitement personnalisé et amélioré[12].

1.3 EEG

L'électroencéphalographie est le terme donné à la technique d'enregistrement de l'activité électrique résultant des flux de courant ionique générés par les neurones du cerveau (Figure 1.5), Les électrodes placées sur le cuir chevelu enregistrent les potentiels de tension résultant du flux de courant dans et autour des neurones (Figure 1.4), l'EEG permet de mesurer directement et en temps réel l'activité neuronale du cerveau ce qui est possible de caractériser l'intégrité de voies neurophysiologiques spécifiques, les états de conscience/sommeil, ainsi que la dynamique temporelle précise du cerveau[13]. Ce qui peut être bénéfique pour diverses applications cliniques : Diagnostic des troubles neuropsychiatriques, AVC, Traumatisme cérébral (TCC), Troubles d'apprentissage et d'attention. La maladie d'Alzheimer et l'identification de l'épilepsie ainsi que la localisation des foyers épileptiques[14].

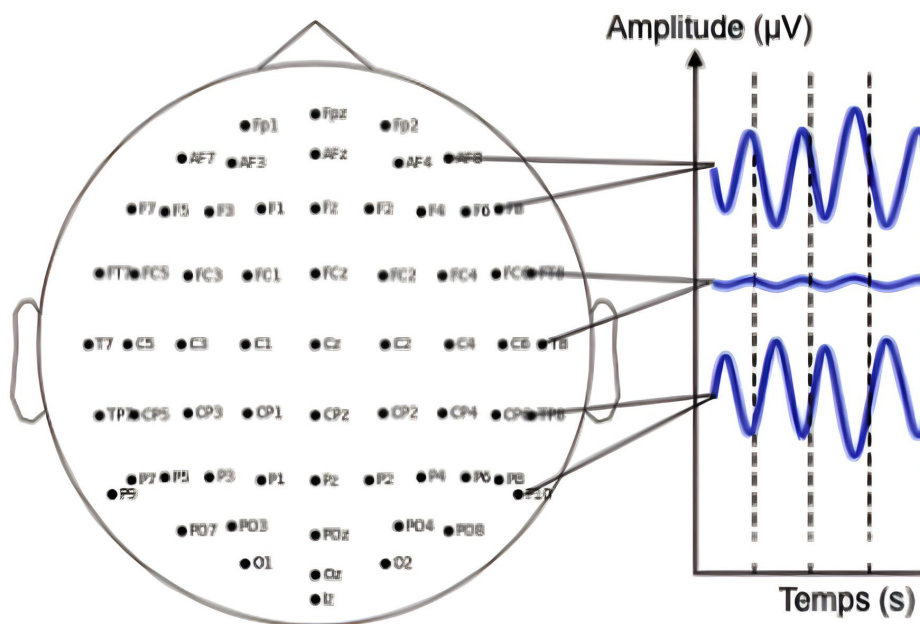


Figure 1.4: Placement des électrodes pour l'enregistrement des signaux EEG[15]




Figure 1.5: Transmission synaptique pendant une crise[16]

1.3.1 Les systèmes de montage d'EEG

Le placement des électrodes EEG sur le scalp est crucial pour garantir la reproductibilité des expériences et faciliter la comparaison avec les enregistrements de différents individus. Pour résoudre ce problème, un comité a été formé en 1947 pour établir une norme qui unifie les procédures de mesure EEG. Ce comité a développé le système EEG 10-20, qui précise le positionnement et l'étiquetage des canaux EEG et recommande un minimum de 21 électrodes pour l'examen du cerveau adulte. Ce standard a été étendu en 1998 par la suite en créant le standard 10-10

1.3.1.1 Le système 10-20

Dans ce système chaque électrode porte un nom spécifique composé de lettres et de chiffres. Une électrode paire indique que l'électrode est située sur le côté droit de la tête, et une électrode impaire indique que l'électrode est située sur le côté gauche. Les lettres indiquent l'emplacement des électrodes par rapport à la logique suivante : A indique le lobe de l'oreille (auricule), C le central, P le pariétal, F le frontal, Fp le frontal polaire, O l'occipital, T le temporel et les lettres z représentent l'axe central[17].

L'usage de ce système garantit un positionnement spatial identique en fonction des repères anatomiques spécifiques de chaque patient. Le système met à l'échelle la position des électrodes par rapport à des repères osseux fixes tels que le nasion (la jonction entre l'arête du nez et le front) et l'os occipital (un point défini sur l'os occipital), puis place les électrodes à 10% ou le long de cette ligne, intervalle de 20%[17].

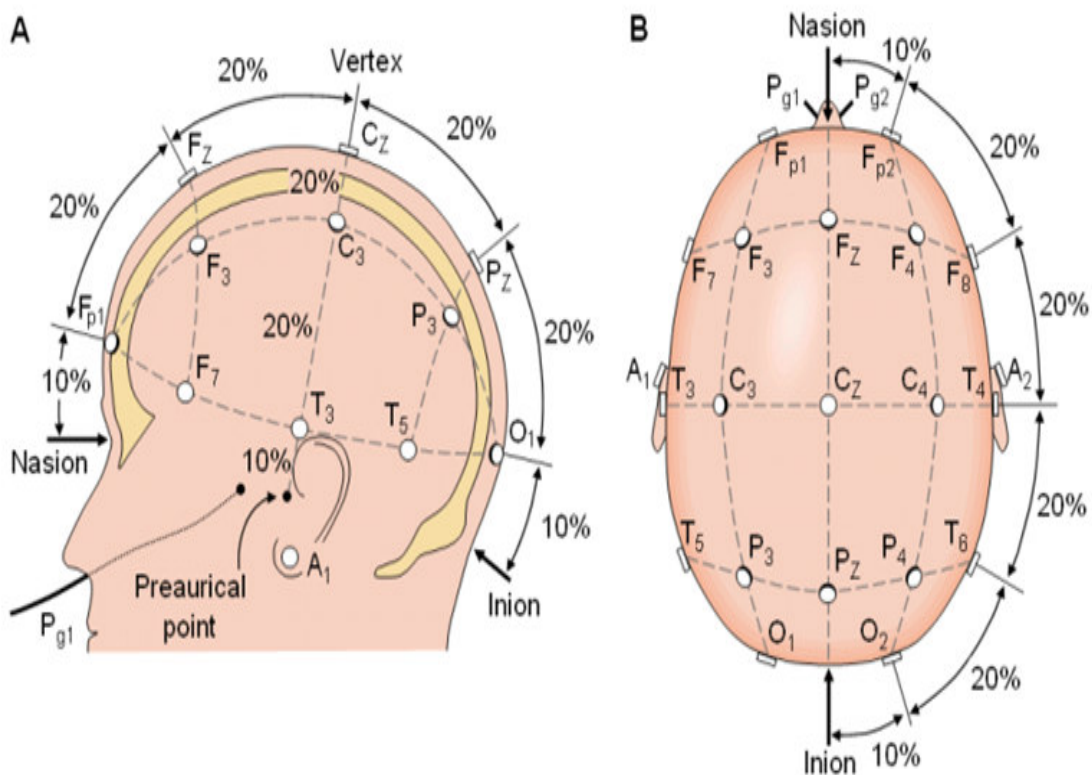


Figure 1.6: Montage 10/20[17]

1.3.1.2 Le système 10-10

Appelé aussi le système 10% est une extension du système 10-20 basé sur 64 électrodes, où la rangée coronale AF se situe à mi-chemin entre les rangées Fp et F ; FC entre F et C ; CP entre C et P ; PO, à mi-chemin entre P et O. Les rangées latérales 1 et 5 se situent respectivement à mi-chemin entre Z et 3, et entre 3 et 7 (Figure 1.7). Cela peut être étendu latéralement jusqu'aux rangées 9, 11, etc. sur le visage ou le cou selon les besoins. Dans ces colonnes

supplémentaires, les lignes 3 et 4 sont alignées avec les lignes 3 et 4 des 10 à 20 sites du système traditionnel. D'autres localisations sont proportionnellement plus médiales ou latérales. Les sites traditionnels T3 à T6 restent les noms préférables sur ces sites ; mais les noms T7, T8, P7 et P8 seraient acceptables, noms alternatifs pour ces mêmes sites dans des circonstances particulières. C7, C8, FC7, FC8, CP7 et CP8 peuvent également remplacer respectivement T3, T4, FT7, FT8, TP7 et TP8, dans des circonstances particulières[18].




Figure 1.7: Montage 10/10[18]

1.3.2 Les types de montage d'EEG

Les configurations de l'EEG sont harmonisées pour faciliter l'échange entre les laboratoires. On distingue plusieurs montages :

- **Montage en référence commune, "Common Reference Montage" (CRM)**

Dans ce montage, l'électrode "d'intérêt" est placée sur le scalp, sur une région du cerveau selon la norme 10–20 en général. L'électrode de référence se situe à l'extérieur du cerveau, sur le scalp. Les exemples de positionnement choisis pour l'électrode de référence dans la littérature sont les lobes des oreilles, la peau sur les mastoïdes (derrière les oreilles), le nez, le menton, certaines électrodes céphaliques (Cz, FPz) et la base du cou. Dans la phase du post-traitement, à partir du montage en référence commune (CRM), plusieurs autres montages

peuvent être obtenus et chacun d'entre eux présente des avantages et inconvénients[19].

•**Montage bipolaire, Bipolar Montage (BM)**

Dans ce type de montage, on représente les signaux par la différence de potentiel entre deux électrodes de mesure. En pratique, on obtient le montage BM à partir du montage CRM et faire la différence entre les voies. De ce fait, le potentiel de l'électrode de référence, présent dans le CRM, disparaît dans le BM, et l'activité mesurée par le montage bipolaire désigne une activité électrique différentielle locale sous-jacente[19].

Contrairement au montage en référence commune, il est à noter que pour les "n" électrodes dans la chaîne bipolaire, il y a forcément au plus "n-1" paires de signaux linéairement indépendantes. On voit bien que dans les montages bipolaires, le maximum d'une décharge cérébrale ne peut pas être affiché de manière simple en trouvant les ondes ayant la plus grande amplitude[19].

Au lieu d'utiliser l'amplitude des ondes dans le montage bipolaire, le maximum est obtenu en trouvant l'inversion de phase (le point le long d'une chaîne d'électrodes bipolaires où la direction de la pente d'onde change de bas en haut ou de haut en bas). Les montages bipolaires se divisent en deux catégories principales : le montage bipolaire antéropostérieur (AP) ou longitudinal et le montage bipolaire transversal. Les chaînes d'électrodes dans les montages bipolaires AP se déplacent de l'avant vers l'arrière (antéropostérieure) sur la tête, tandis que dans le montage bipolaire transversal, les chaînes se déplacent de gauche à droite (transversalement) sur la tête[19].

•**Montage en référence moyenne, Average Reference Montage (ARM)**

En se basant sur les enregistrements obtenus à partir d'une seule référence (référence commune), on peut calculer la référence moyenne en divisant le nombre de voies d'enregistrement par le nombre de voies plus un (le nombre d'électrodes). Par défaut, cette méthode offre une estimation du potentiel de l'électrode de référence. Toutefois, en l'absence d'évaluation de l'activité sur l'emplacement initial de la référence, il est possible de calculer la référence moyenne en divisant le nombre de voies d'enregistrement. A la fin, si on peut définir la référence moyenne en utilisant toutes les électrodes sur le scalp, il arrive parfois que certaines électrodes bruyantes ou artéfactées soient éliminées de la moyenne[19].

Un avantage de la référence moyenne se manifeste lorsque toutes les électrodes présentent un signal (artefact ou bruit) identique : une situation qui n'est pas rare. Dans ces situations, ce signal reste dans la référence moyenne et sera annulé en le soustraire des signaux d'intérêt. En revanche, un potentiel d'ampleur très élevé, en particulier présent sur une ou peu d'électrodes, peut ne pas être présent dans la référence moyenne et peut entraîner des interprétations erronées et des conclusions erronées[19].

•Montage laplacien, Laplacian Montage (LM)

Le montage laplacien se base sur des expressions mathématiques qui cherchent à représenter la surface sphérique du scalp. Le processus de construction consiste à assembler les électrodes autour d'une électrode d'intérêt afin de créer une référence moyenne locale qui est ensuite soustraite du potentiel de l'électrode d'intérêt. Ce genre de référence est parfois employé dans des enregistrements EEG de routine, mais comporte plusieurs désavantages[19].

La référence laplacienne est une forme de référence moyenne où le poids de chaque électrode dans la moyenne est déterminé par sa distance à l'électrode d'intérêt. Les électrodes plus proches de l'électrode d'intérêt ont un poids moyen plus élevé, tandis que les électrodes plus éloignées ont un poids moyen plus faible[19].

•Montages EEG virtuels

Les configurations EEG classiques sont les configurations les plus couramment employées dans les études EEG et correspondent à celles mentionnées précédemment. Cependant, il existe d'autres configurations utilisées dans le domaine de l'EEG qui incluent des mesures provenant de sites virtuels. En parlant des lieux virtuels pour l'installation des électrodes, on fait référence aux lieux où aucun enregistrement direct n'a été effectué, c'est-à-dire l'utilisation des techniques d'interpolation pour augmenter le nombre de mesures. Les montages qui font appel à ce genre d'informations sont appelés montages virtuels[19].

Les montages virtuels présentent une structure similaire à celle des montages classiques, leur particularité est qu'ils utilisent "des mesures virtuelles" (estimatives) à partir de données qui permettent de couvrir une grande partie de la surface de la tête et donc d'accroître la résolution

spatiale. Les montages de référence commun, bipolaire, moyenne et laplacien peuvent donc être obtenus en utilisant des mesures réelles et des mesures virtuelles[19].

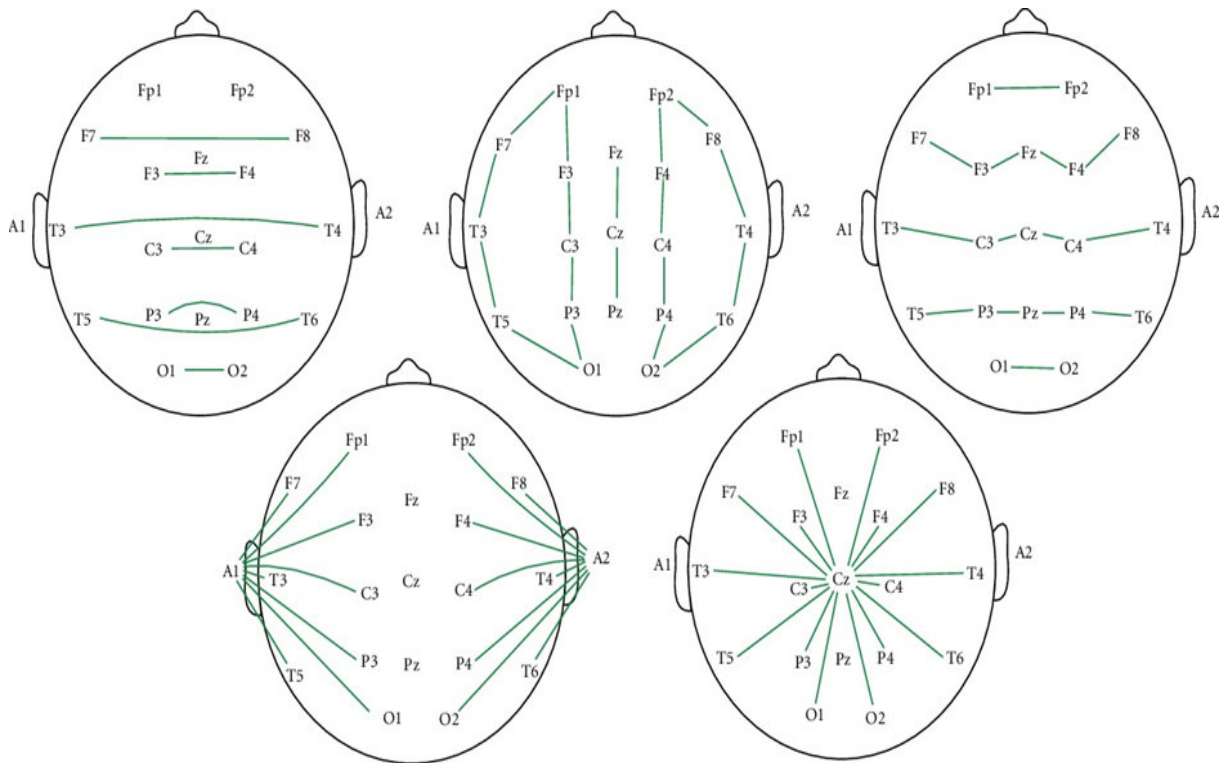


Figure 1.8: Cartes de montage des pics spectraux : bipolaire homologue (Bco), bipolaire longitudinal (Lbp), bipolaire croisé (Bcr), référence biauriculaire (Bar) et référence Cz (Czr)[20]

1.3.3 Type d'onde de signaux

1. **Onde gamma (au-dessus de 30 Hz) :** L'onde gamma est une activité électrique à haute fréquence, souvent liée à la fonction cognitive, à l'attention, au traitement sensoriel et à la mémoire de travail. Il peut également être utilisé dans le traitement de l'épilepsie, des accidents vasculaires cérébraux et des maladies neurologiques[21].
2. **Ondes bêta (13-30 Hz) :** Les ondes bêta apparaissent dans les états cognitifs et d'activation, tels que concentration et mémoire de travail, et sont souvent associés à des états émotionnels tels que l'anxiété et des tensions[21].
3. **Onde alpha (8-13 Hz) :** L'onde alpha est une bande d'onde relativement stable, qui apparaît souvent dans les états de relaxation, de repos, de fermeture des yeux et de relaxation de l'attention, et peut également apparaître dans les lésions neuronales et les personnes âgées anormales[21].

4. **Ondes thêta (4-8 Hz) :** Les ondes thêta apparaissent souvent chez les enfants et les adultes pendant le sommeil léger, et peuvent également apparaître dans des situations telles que l'anxiété, la tension ou le trouble de stress post-traumatique[21].
5. **Onde Delta (0,5-4 Hz) :** L'onde Delta est une sorte d'onde lente qui apparaît pendant le sommeil. Elle est souvent liée au sommeil profond, et peut également apparaître dans certaines maladies ou lésions cérébrales[21].




Figure 1.9: Ondes cérébrale[22]

1.3.4 États de crise en EEG :

L'EEG du patient épileptique revêt 3 états différents :

- L'état critique, « ictal » ou la crise en question, qui est la phase aiguë d'une crise épileptique.
- L'état inter-critique « interictal et postictal » , la phase séparant deux crises successives .

- L'état précritique « preictal », c'est-à-dire l'état précédant une crise de quelques minutes voire quelques dizaines de minutes. Les manifestations des crises varient considérablement selon la région affectée du cerveau.




Figure 1.10: Etats de crise

1.3.5 Modèles EEG dans les crises focales et généralisées

Sur un EEG, les crises focales sont souvent caractérisées par des décharges épileptiformes localisées. Ces décharges peuvent se présenter sous la forme de pointes d'ondes aiguës ou d'un ralentissement rythmique dans une région spécifique correspondant à la zone d'apparition des crises. Les crises focales peuvent rester localisées ou se propager à d'autres zones du cerveau, évoluant parfois vers des crises généralisées. (figure 1.11).

L'EEG dans les crises généralisées montre généralement des complexes de pointes, polyspikes et d'ondes généralisés de forte amplitude, irréguliers ou réguliers, de 3,5 à 6 Hz, à prédominance antérieure en avant dans les deux hémisphères du cerveau[23].




Figure 1.11: Exemple d'EEG (patiente de 32 ans, épilepsie myoclonique)

Le rythme alpha, d'une fréquence de 10 Hz, prédomine sur les dérivations postérieures (temporales postérieures, pariétales, occipitales) (Encadré horizontal). Survenue d'une décharge paroxystique, épileptique, d'une durée de deux secondes (Encadré vertical) non associée dans le cas présent à une secousse majeure[24].




Figure 1.12: Crise frontale gauche[25]




Figure 1.13: EEG typique montrant un fond normal et une décharge polyspike-wave bilatérale, symétrique et synchrone de 4 Hz.




Figure 1.14: Pointes-ondes généralisées.

1.4 CONCLUSION

En résumé, ce chapitre a détaillé la nature de l'épilepsie, les types de crises, et l'importance cruciale de l'EEG dans le diagnostic et la prise en charge de cette maladie. Une compréhension approfondie de ces éléments est essentielle afin de développer des méthodes plus efficaces de prédiction et de traitement, ce qui permettra d'améliorer la qualité de vie des patients épileptiques.

2

CHAPITRE 2: Modèles De Deep Learning Pour Les Séries Temporelles

2.1 INTRODUCTION

Les séries temporelles jouent un rôle crucial dans l'analyse des données EEG en raison de leur nature séquentielle et temporelle. Ce chapitre explore les bases des séries temporelles et leur importance dans le traitement du signal. Ensuite, il explore les algorithmes du DL, qui ont montré des résultats prometteurs pour prédire et classer des données complexes.

2.2 Les séries temporelles

2.2.1 Historique

Depuis un certain temps, l'analyse de l'évolution temporelle d'une ou plusieurs variables a suscité l'intérêt de spécialistes de domaines très divers. La théorie des processus stochastiques, développée par les probabilistes, permet d'analyser avec une grande précision les caractéristiques d'un ensemble de variables aléatoires définies par le temps[26].

La prédiction des ST est un domaine dans lequel les données historiques des séries sont analysées pour développer un modèle décrivant leurs caractéristiques sous-jacentes et extrapolées dans le futur. Au cours de la dernière décennie, le développement de l'IA a suscité beaucoup d'intérêt, et de nombreux modèles de ML ont été proposés pour analyser les séries temporelles, notamment les séries temporelles multivariées (STM), où des interdépendances complexes doivent être capturées pour effectuer des prédictions précises. Ces dernières années, de nombreuses applications aux problèmes de prédiction des STM ont été proposées, notamment avec des modèles de DL fondés sur les (RNN), les (CNN) et les mécanismes d'attention[27].

2.2.2 Définition

Une série temporelle est un ensemble d'observations x_1, x_2, \dots, x_n indexées par le temps. Supposons qu'il s'agisse d'un processus X , la réalisation d'une séquence X_i de variables aléatoires. Les ST sont généralement constituées de plusieurs éléments.

- **Tendance** : Représente l'évolution à long terme (échelle interannuelle) de la série.

Exemples : Croissance économique, évolutions climatiques à long terme (périodiques ou non).

- **Saisonnalité** : Développements qui se répètent régulièrement chaque année, mois ou semaine.

Exemple : – En météorologie, les températures sont plus basses en hiver qu'en été.

- En économie, saisonnalité causée par les vacances et les jours fériés, climat...

- Ventes d'entreprises.

- **Composant stationnaire (ou résiduelle)** : Ce qui reste lorsque d'autres composants sont supprimés. Décrit le développement à court terme (en jours) de la série[28].

Exemples des ST :[28]

- **Économie** :




Figure 2.1: Evolution des prix du Dow Jones de 1928 à 2004, données mensuelles

- **Environnement** :




Figure 2.2: Evolution de la puissance éolienne au large de la Bretagne (m/s) de 1979 à 2001, données quotidiennes.

• Santé :

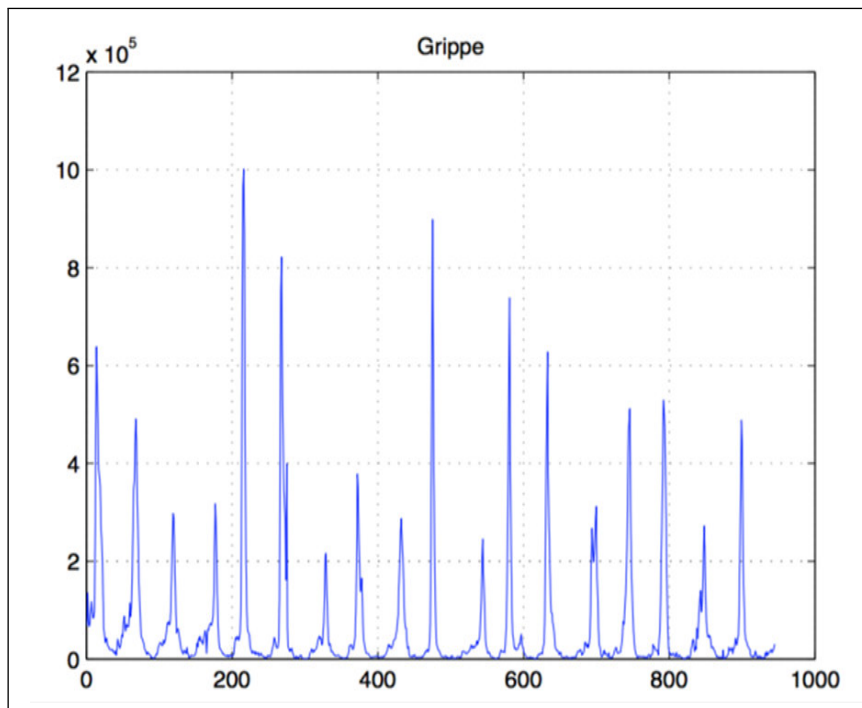


Figure 2.3: Tendances hebdomadaires des cas de grippe en France de 1984 (semaine) à 2002 (semaine 50) soit une valeur de 945.

Les ST, également connues sous le nom de séries chronologiques (ou chroniques), jouent un rôle essentiel dans tous les domaines de l'observation ou de la collecte de données[29].

Une succession chronologique correspond à la mise en œuvre d'un processus aléatoire défini par le temps. On modélise un processus par la somme d'une partie déterministe et d'une partie aléatoire (modèle additif), ou par le produit d'une partie déterministe et d'une partie aléatoire (modèle multiplicatif). La séparation en partie déterministe et partie aléatoire est arbitraire. L'étude d'un processus aléatoire à partir d'une série chronologique a généralement deux objectifs :

- expliquer les variations,
- prédire les valeurs futures.

Les deux objectifs sont souvent liés[30].

Une ST est une série de nombres indicés par le temps, chacun d'entre eux étant une réalisation d'une variable aléatoire (figure 2.4). Ceci peut s'exprimer aussi en disant que la ST est une réalisation d'une famille de variables aléatoires indicées par le temps (figure 2.5 et figure 2.6). Cette famille de variables aléatoires s'appelle un processus aléatoire [29].

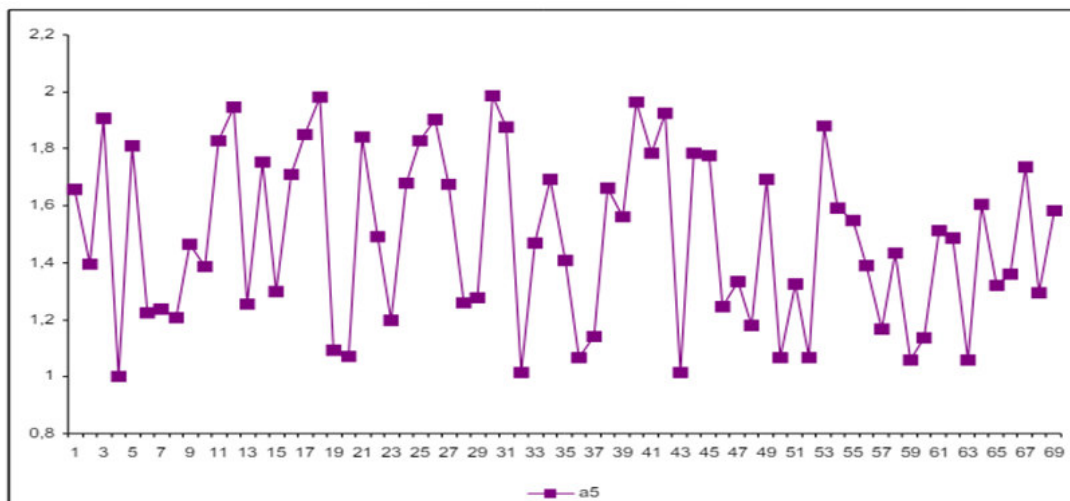


Figure 2.4: Exemple de série temporelle

2.2.3 Série temporelle univariée et multivariée

Définissez une ST univariée comme une séquence ordonnée de valeurs réelles dans une seule dimension. Par exemple, une série de données univariées peut correspondre à l'historique des valeurs des capteurs.

Dans ce cas, la sous-séquence (c'est-à-dire l'extraction de points consécutifs de cette série) peut être représentée comme un vecteur de valeurs.

Nous définissons ensuite une ST multivariée comme un ensemble de séquences ordonnées de valeurs réelles (chaque séquence ordonnée a la même longueur) ou une séquence ordonnée de vecteurs constitués de valeurs réelles[31].

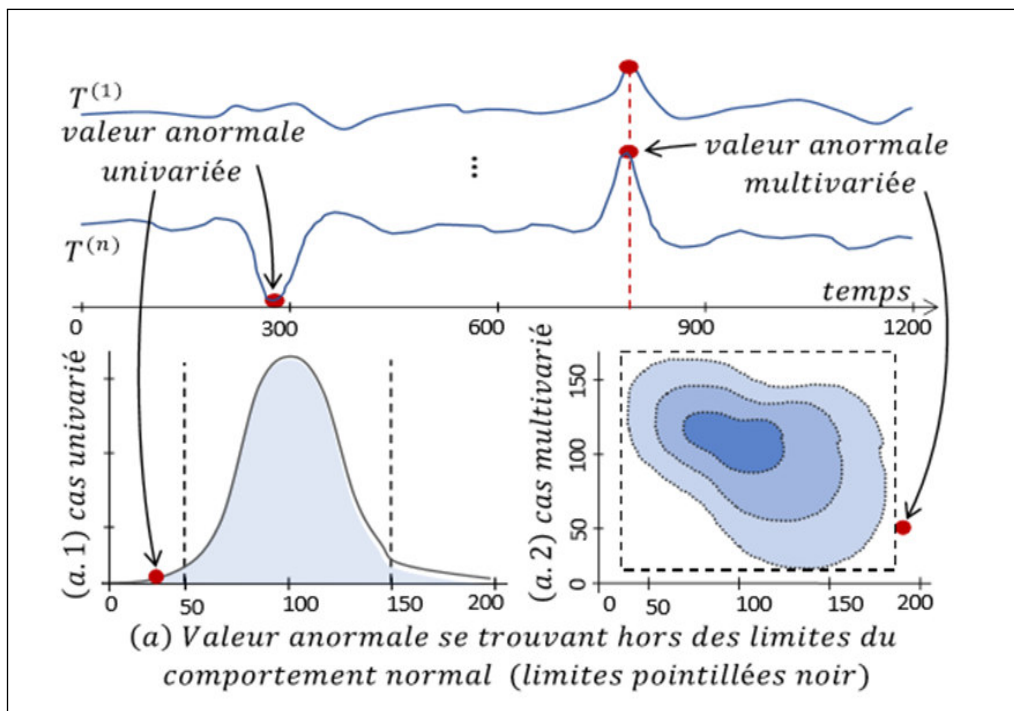


Figure 2.5: Exemples synthétiques (a)[31]

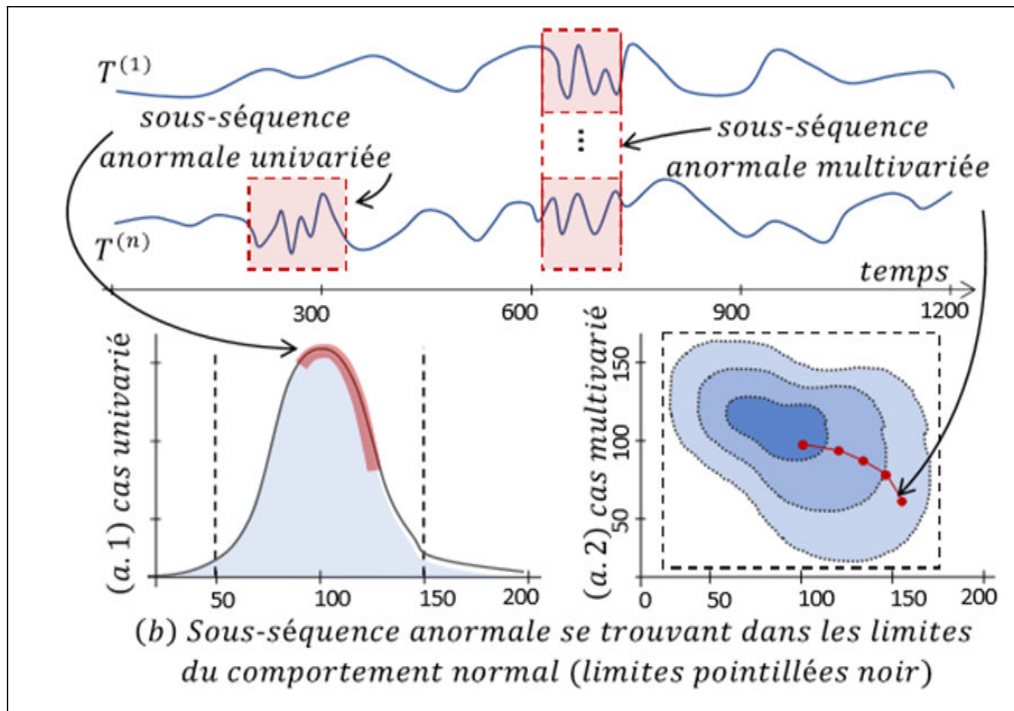


Figure 2.6: Exemples synthétiques (b)[31]

Ou (a) un point aberrant (pour une ST (a.1) univariée et (a.2) multivariée). (b) une sous-séquence anormale composée de valeurs individuellement normales (pour une ST (b.1) univariée et (b.2) multivariée) .

Le problème théorique de la détection automatique des anomalies répond aux besoins industriels pratiques.

Capacité à analyser efficacement de grandes quantités de données et à créer des requêtes complexes.

2.2.4 Détection d'anomalies

En général, une anomalie est une observation qui apparaît significativement différente des autres membres de l'échantillon dans lequel elle se produit. Cette divergence peut indiquer qu'une observation particulière a été générée par un mécanisme différent du reste des données[31]

Dans ce cas, un test est effectué pour trouver la distribution (et ses paramètres) qui correspond le mieux à toutes les données.

Cependant, pour certains problèmes et cas d'utilisation, cette distribution n'est pas connue avec

précision. Par conséquent, il est parfois peu pratique de définir et d'identifier des anomalies en fonction de leur distance par rapport à une moyenne définie par des experts[31].

2.2.5 Les modèles uni-variés

***Modèles AR :** Les modèles modernes, notamment le modèle AR(p)BOX 2013, sont basés sur le principe de l'autorégression. Ce modèle considère les ST stationnaires univariées comme une fonction linéaire de ces valeurs p précédentes. Formellement, l'équation du modèle AR (p) est :

$$Y(t) = \alpha_0 + \alpha_1 Y(t - 1) + \dots + \alpha_p Y(t - p) + U(t) \quad (2.1)$$

, où p est le modèle, $\alpha_0 \dots \alpha_p$ sont les paramètres du modèle, $U(t)$ est le terme d'erreur après le processus de bruit blanc[32].

***Modèle MA :** Le modèle de moyenne mobile a la même structure que le modèle AR, mais considère un terme d'erreur au lieu de la valeur précédente de la série. Le modèle MA(q) peut être exprimé comme suit [32]:

$$Y(t) = \theta_0 + \theta_1 U(t - 1) + \dots + \theta_q U(t - q) + U(t) \quad (2.2)$$

***Modèle ARIMA :** Avant d'envisager le modèle ARIMA, il est important de comprendre le modèle ARMA. Le modèle ARMA (p,q) BOX 2013 combine deux processus AR(p) et MA(p), en considérant à la fois le terme d'erreur et la valeur précédente de la série :

$$Y(t) = y_0 + \sum_{i=1}^p \alpha_i Y(t - i) + \sum_{i=1}^q \theta_i U(t - i) + U(t) \quad (2.3)$$

Où $y_0, \alpha_0 \dots \alpha_p$, et $\theta_0 \dots \theta_q$ sont les paramètres du modèle.

Le modèle ARIMA(p,d,q) est plus adapté aux ST non stationnaires. Elle consiste à appliquer le modèle ARMA(p,q) à une série transformée par différenciation d'ordre d , c-à-d ,En calculant d

fois les différences entre des observations consécutives[32].

Les ST représentent un domaine riche et complexe, crucial pour la prise de décision basée sur les données historiques et pour les prévisions futures dans de nombreux domaines.

2.3 Deep Learning:

2.3.1 Définition

DL est un sous-domaine de l'IA qui se concentre sur la création de grands modèles de réseaux neuronaux capables de prendre des décisions précises fondées sur des données. DL est particulièrement adapté aux contextes où les données sont complexes et où de grands ensembles de données sont disponibles[33].

Ces réseaux de neurones profonds se déclinent en plusieurs types, chacun étant généralement spécialisé dans une fonction particulière. Certains sont dédiés au traitement et à la reconnaissance d'images, d'autres au traitement et à la compréhension des sons, tandis que certains se concentrent sur le langage naturel parlé par les humains, le comprennent et peuvent même y répondre[34].

Récemment, les méthodes de DL sont devenues courantes pour la classification des ST et permettent d'améliorer les performances des approches traditionnelles basées sur l'apprentissage automatique. Les RNN, tels que les LSTM, et les CNN sont capables d'extraire les caractéristiques dynamiques des ST, ce qui explique leur succès[35].

2.3.2 Histoire des réseaux de neurones et du deep learning en traitement de signaux et des images




Figure 2.7: Quelques évènements clé du développement historique des réseaux de neurones[36]

2.3.3 Les types des réseaux de neurones :

2.3.3.1 Convolutional Neural Network (CNN) :

Le nom "Réseau de neurones à convolution" indique que ce réseau utilise une opération mathématique appelée la convolution. Les réseaux de convolution sont un type spécialisé de réseaux neuronaux qui utilisent la convolution à la place de la multiplication matricielle générale dans au moins une de leurs couches. Les CNN sont l'un des meilleurs algorithmes d'apprentissage pour effectuer la convolution, qui aide à l'extraction d'informations utiles à partir de données corrélées localement.

La sortie des noyaux convolutifs est ensuite affectée à une unité de traitement non linéaire (fonction d'activation), qui non seulement aide à apprendre les abstractions, mais intègre également la non-linéarité dans l'espace des fonctionnalités. Cette non-linéarité génère différents modèles d'activations pour différentes réponses et facilite ainsi l'apprentissage des différences sémantiques dans les images[37].

La topologie de CNN est divisée en plusieurs étapes d'apprentissage composées d'une combinaison de couches convolutives, d'unités de traitement non linéaires et de couches de sous-échantillonnage[37][38]. « La Figure 2.8 » montre la structure générale d'un réseau CNN.




Figure 2.8: Réseau De Neurones Avec De Nombreuse Couches Convolutives

- **Couche de convolution:** La convolution est la première couche à extraire des entités d'une image d'entrée qui préserve les relations entre les pixels en apprenant les caractéristiques

de l'image à l'aide de petits carrés de données d'entrée. C'est une opération mathématique qui prend deux entrées, comme une matrice d'image et un filtre ou un noyau[39] .« La Figure 2.9 », monte une opération simple d'un filtre pour une étape de convolution.

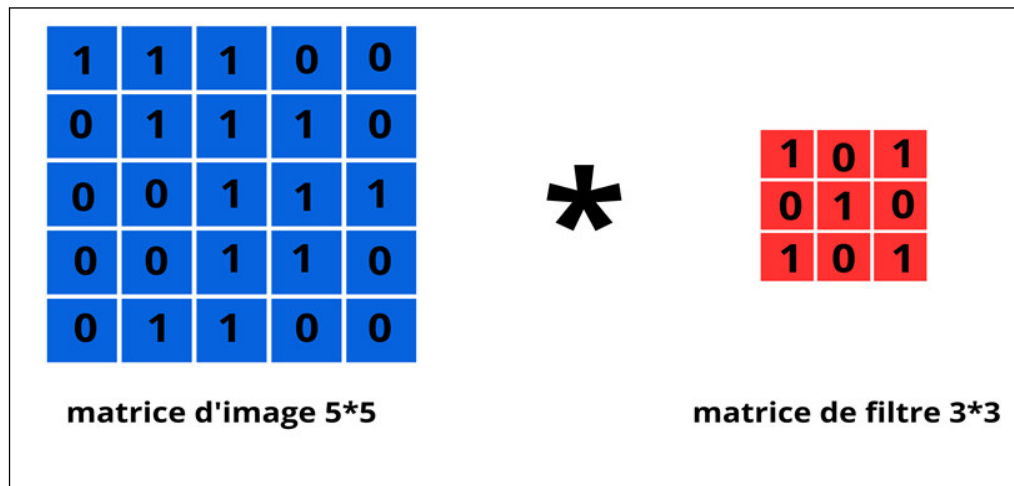


Figure 2.9: Exemple Explicative Sur L'opération De Convolution

- **Couche de pooling:** La couche de pooling est généralement placée entre deux couches convolutives. Le pooling est un processus de discrétisation basé sur des échantillons. Le but est de booster la représentation des contributions (image, matrice de production des couches cachées, etc.) vers le bas, en réduisant sa dimensionnalité et en prenant en compte l'hypothèse de rendu des caractéristiques des sous-régions groupées qu'elle contient. Il existe différents types de pooling : (1) Pooling moyen, en prenant la moyenne de tous les pixels de la sélection « Figure 2.10 ». (A), (2) Regroupement maximum, en prenant le pixel avec la plus grande valeur parmi tous les pixels de la sélection[39]. Voir "Figure 2.13(B)".

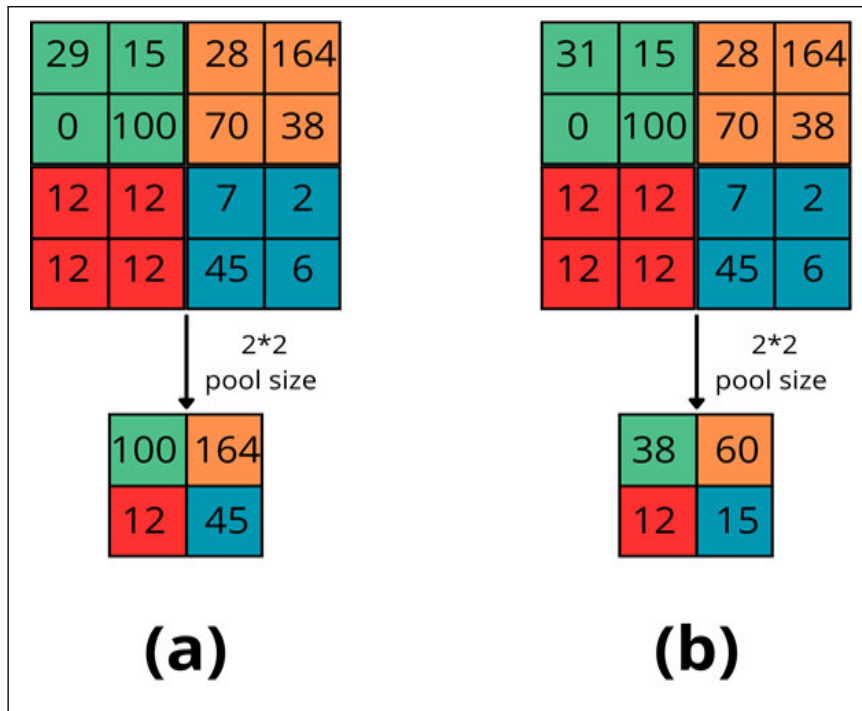


Figure 2.10: (A) Pooling maximal, (B) Pooling moyen

- **Couche fully-connected :** La couche entièrement connectée ressemble au réseau entièrement connecté des modèles classiques. La sortie de la phase initiale (comprenant la convolution et le pooling répétitifs) est transmise à la couche entièrement connectée, où le produit scalaire entre le vecteur de poids et le vecteur d'entrée est calculé pour obtenir la sortie finale[39].




Figure 2.11: Couche fully-connected

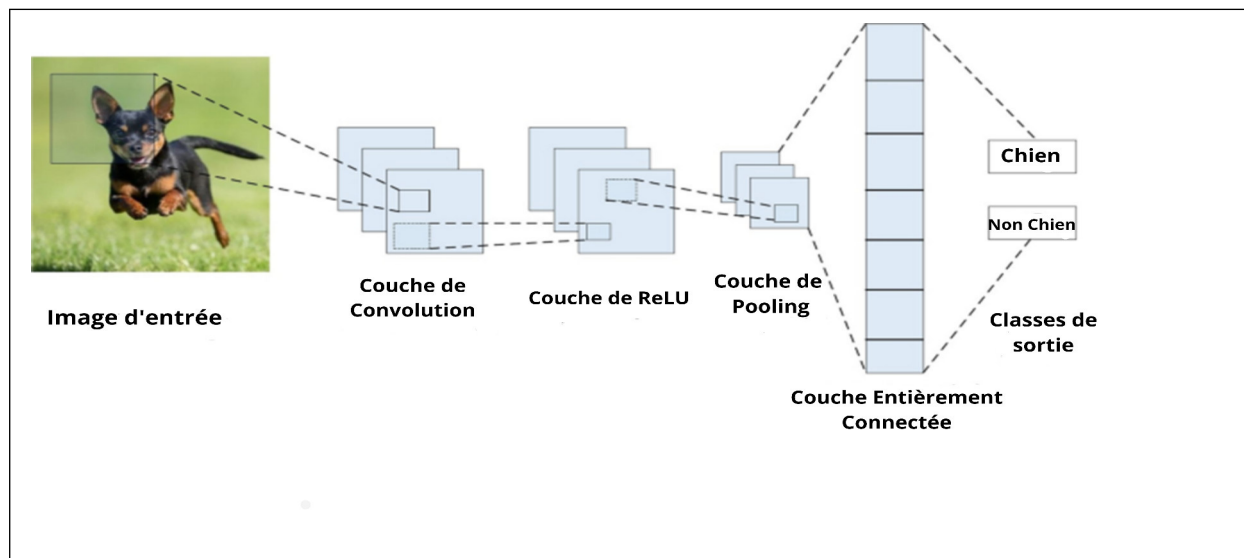


Figure 2.12: Un exemple d'architecture CNN pour la classification d'images

De nombreux chercheurs ont commencé d'exploiter les CNN pour l'analyse de ST[40]. Pour cela, les filtres convolutifs présenter une seule dimension dans le temps au lieu de deux dimensions correspondant à la largeur de l'image et la longueur. En tant que telle, la convolution est appliquée comme une fenêtre glissante sur la ST.

Dans ce contexte, de nombreuses architectures ont été proposées pour traiter des STM. L'une d'entre elles est le réseau de neurones à convolution profonde multicanal (MCDCNN) [41]. Il peut être considéré comme un CNN traditionnel adapté aux données de STM. Il se compose de deux étapes convolutives, chacune avec 8 filtres, une fonction d'activation ReLU et une opération de pooling max. Les convolutions sont appliquées indépendamment sur chaque dimension de la STM d'entrée. La sortie du deuxième étage convolutif pour toutes les dimensions est concaténée sur l'axe des canaux, puis alimentée vers une couche entièrement connectée suivie d'un classificateur softmax.

De même, le réseau de neurones convolutifs temporels (Time-CNN), proposé dans [42], est conçu pour la classification de ST univariées et multivariées. La principale différence par rapport à l'architecture précédente (MCDCNN) réside dans l'utilisation d'une couche entièrement connectée avec une fonction d'activation sigmoïde à la place du classificateur softmax. Une autre différence par rapport aux CNN traditionnels est l'utilisation d'un pooling moyen local au lieu de l'opération de pooling maximum local. De plus, contrairement à MCDCNN, pour les

données de STM, il applique une seule convolution pour toutes les dimensions de la tâche de classification multivariée[35].

2.3.3.2 Réseau de Neurones Récurrent (Récurrent Neural Network (RNN))

Les RNN sont une variante essentielle des réseaux neuronaux largement utilisée dans le traitement du langage naturel. Ils sont qualifiés de récurrents car ils exécutent la même tâche pour chaque élément d'une séquence, la sortie dépendant des calculs précédents. On peut les considérer comme ayant une "mémoire" qui retient les informations des calculs antérieurs. En théorie, les RNN peuvent utiliser des informations sur des séquences de longueur variable, mais en pratique, ils se limitent souvent à quelques étapes en arrière. Les RNN permettent aux prédictions antérieures d'être utilisées comme entrées grâce à des états cachés, et leur structure est illustrée dans la "Figure2.13"[43].




Figure 2.13: Architecture De RNN[43]

Les RNN sont des systèmes dynamiques qui exploitent efficacement les informations temporelles contenues dans la séquence d'entrée, à la fois pour la classification[44] et la régression [45].

La caractéristique principale d'un RNN est la présence de connexions de rétroaction au sein du réseau. Cela permet de modéliser les effets des parties précédentes de la séquence sur les parties suivantes. Ainsi, sa sortie, à chaque pas de temps, dépend des entrées précédentes

et des calculs passés, ce qui permet au réseau de développer une mémoire des événements antérieurs[35].

2.3.3.3 Long Short-Term Memory (LSTM):

Le réseau LSTM, caractérisé par son architecture conçue pour gérer des cibles et des entrées dépendant du temps, se présente comme un formidable outil dans le domaine du DL. Sa capacité inhérente à analyser et prédire les données de ST découle de sa capacité à résoudre les problèmes de dépendance à long terme.

Au cœur du réseau LSTM se trouve la cellule mémoire, qui sert de noyau, orchestrant la capacité du réseau à capturer des modèles temporels complexes. Les principes fondamentaux et les aspects critiques d'un réseau LSTM, essentiels à la compréhension de sa fonctionnalité robuste[46].

Cette description complète consolide non seulement les fondements théoriques, mais souligne également l'importance pratique de l'exploitation des réseaux LSTM pour l'analyse et la prévision des séries chronologiques[47].

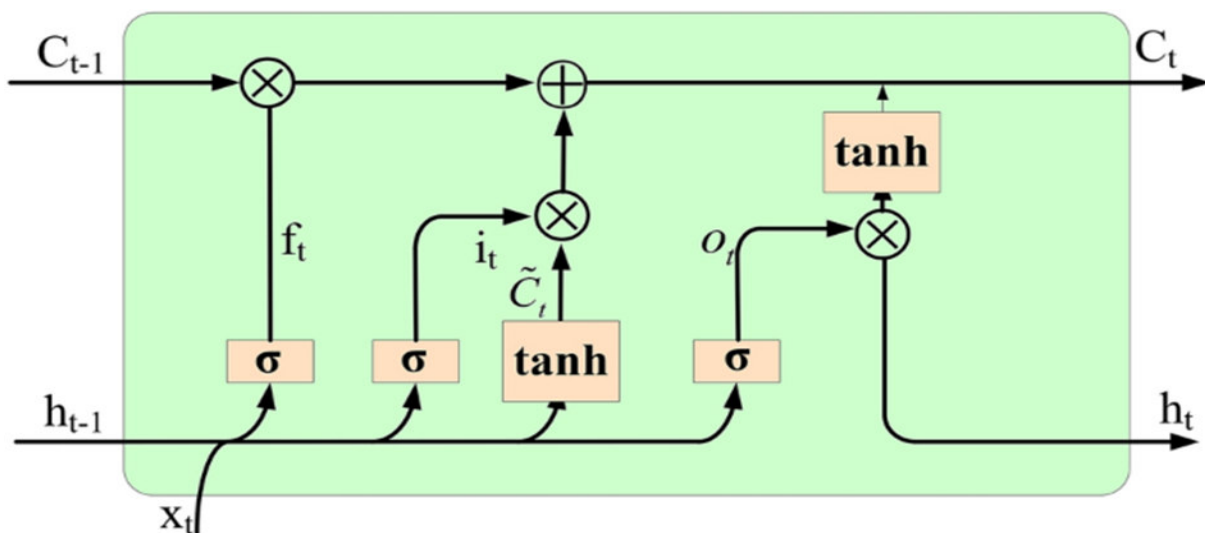


Figure 2.14: L'architecture de LSTM [48]

La cellule mémoire, agissant comme la pierre angulaire de l'architecture LSTM, permet au réseau de capturer, conserver et utiliser efficacement les informations temporelles, contribuant ainsi à ses performances supérieures dans la gestion d'ensembles de données dynamiques et

dépendants du temps.

Les LSTM suivent également une structure en chaîne, mais leur module répétitif présente une configuration distincte. Contrairement aux RNN classiques avec une seule couche de réseau neuronal, les LSTM en comportent quatre qui interagissent de manière particulière.

Les RNN ont obtenu de bons résultats dans le traitement et l'apprentissage d'informations sur les ST, mais ils ne peuvent pas apprendre avec succès les dépendances à long terme en raison des problèmes d'explosion ou de disparition du gradient.

La LSTM est une extension des RNN, qui introduit la cellule « gate » pour retenir et apprendre les dépendances à long terme. Le réseau LSTM peut capturer les caractéristiques importantes des entrées et stocker les informations sur une longue période, ce qui lui permet d'obtenir de bons résultats en matière de prévision à long terme[49].

En général, les composants essentiels de l'architecture du réseau LSTM sont constitués de trois portes : les portes d'oubli, d'entrée et de sortie, désignées respectivement par f , i et o . La description détaillée de la procédure de calcul pour chaque porte est présentée ci-dessous :

1. **Porte d'oubli** : Déterminez quelles informations doivent être conservées dans la cellule de mémoire à l'aide de la fonction sigmoïde. La sortie est exprimée comme suit :

$$f_t = \sigma(W_{fx} \cdot x_t + W_{fh} \cdot h_{t-1} + b_f) \quad (2.4)$$

Où x_t et h_{t-1} représentent l'entrée et l'état caché au pas de temps t et $t-1$ respectivement. W représente les matrices de poids, b_f représente un biais constant et $\sigma(\cdot)$ représente la fonction sigmoïde.

2. **Porte d'entrée** : Déterminer si la nouvelle information doit être enregistrée dans la cellule de mémoire par la couche sigmoïde et la couche tanh. Les sorties des deux couches sont calculées sous la forme suivante :

$$i_t = \sigma(W_{ix} \cdot x_t + W_{ih} \cdot h_{t-1} + b_i) \quad (2.5)$$

$$c_t = \tanh(W_{cx} \cdot x_t + W_{ch} \cdot h_{t-1} + b_c) \quad (2.6)$$

La mise à jour de la cellule de mémoire est réalisée par la combinaison de ces deux couches, où la mémoire actuelle est obtenue en conservant les informations précédentes et en introduisant de nouvelles informations sur l'état de la cellule. L'équation mathématique est exprimée sous la forme suivante :

$$c_t = f_t \circ c_{t-1} + i_t \circ \tilde{c}_t \quad (2.7)$$

Où c_t représente l'état de la cellule au pas de temps t , \circ désigne le produit Hadamard.

3. **Porte de sortie :** Déterminer quelle partie de la mémoire contribue à la mise en place actuelle et cartographier la sortie entre -1 et 1 par la fonction \tanh . Les sorties peuvent être calculées à l'aide des équations suivantes :

$$\theta_t = \sigma(W_{\theta x} \cdot x_t + W_{\theta h} \cdot h_{t-1} + b_{\theta})[49] \quad (2.8)$$

$$h_t = \theta_t \cdot \tanh(c_t)[49] \quad (2.9)$$

Les réseaux neuronaux mentionnés, ne sont pas tous les réseaux qui existent, une excellente ressource qui résume peut-être toutes les architectures est en [50]. La figure suivante montre une représentation de leur travail :

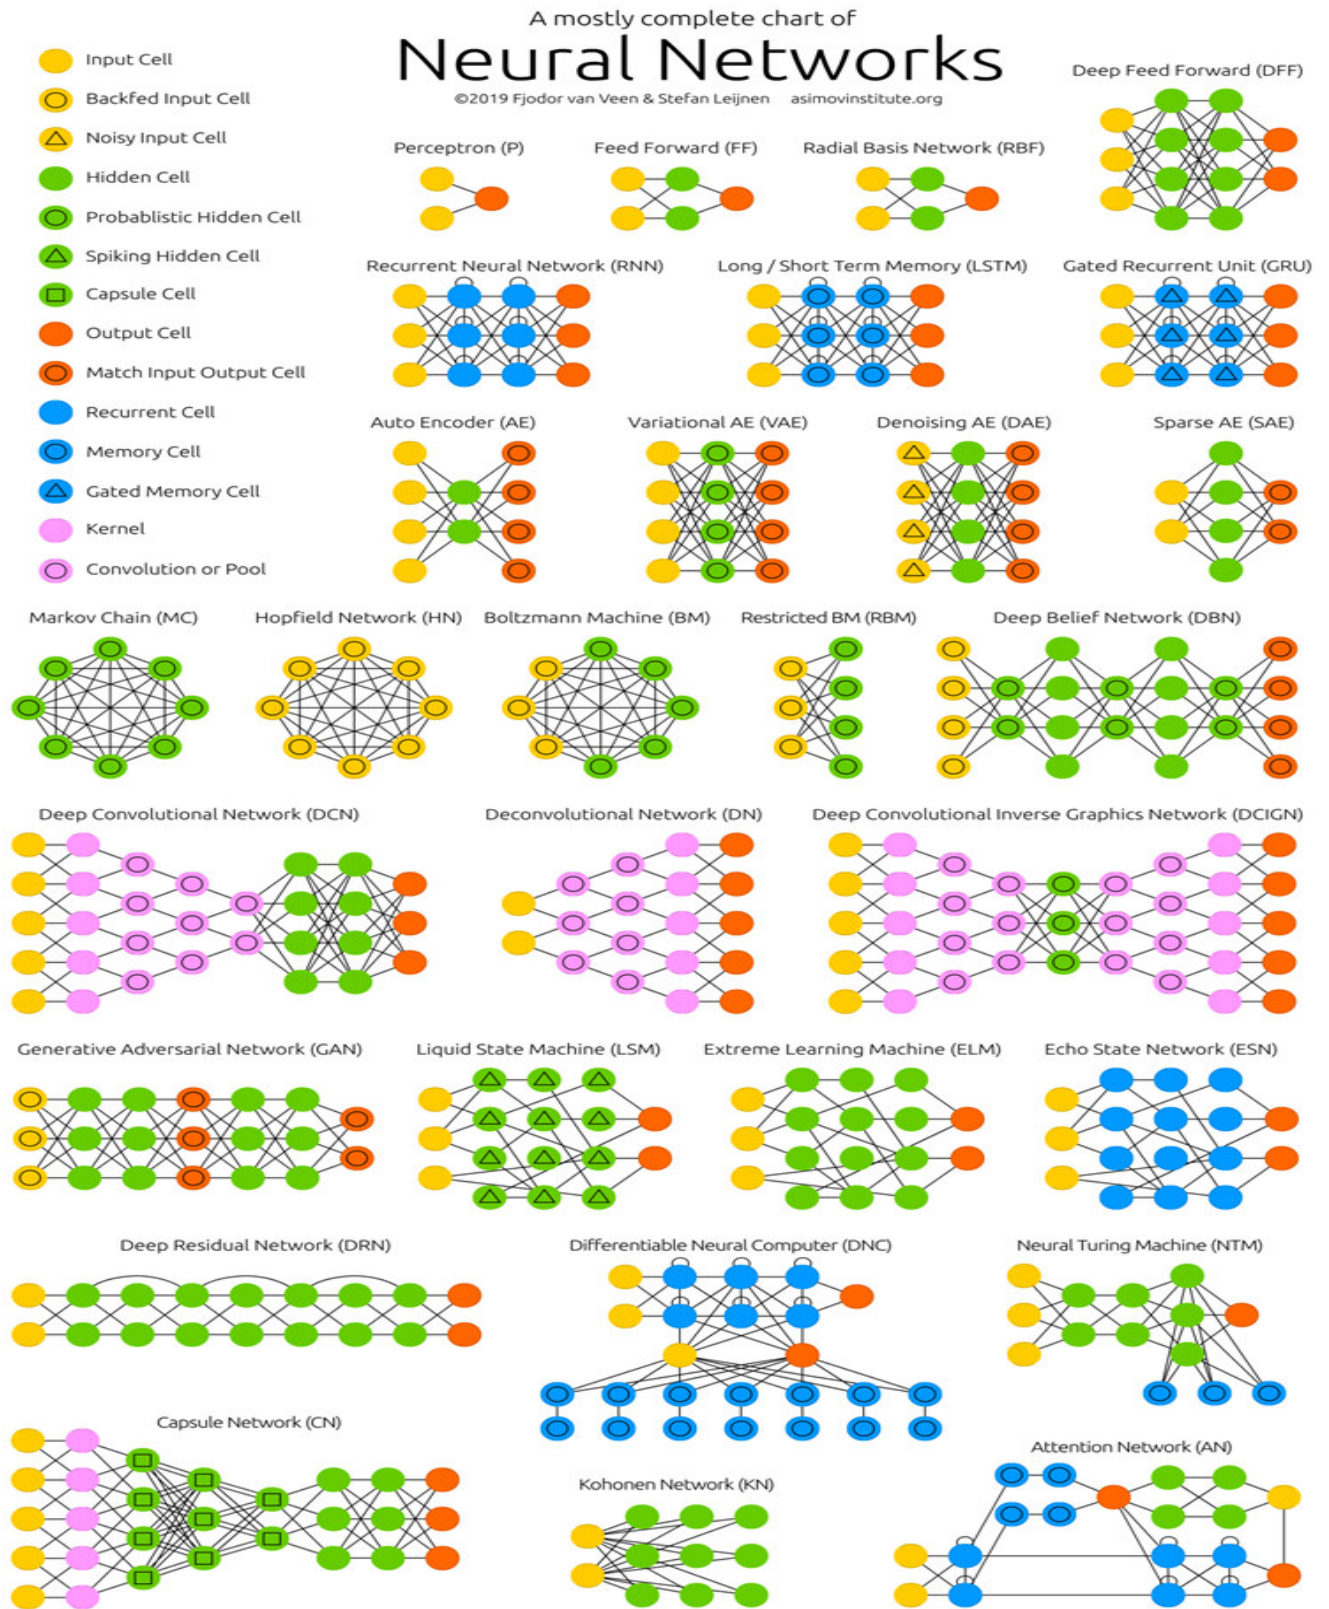


Figure 2.15: Un résumé des types d'architectures de réseaux de neurones[50]

2.3.3.4 La différence entre LSTM , CNN et RNN

Caractéristique	RNN	LSTM	CNN
Capture des dépendances	Capture les dépendances à court terme	Capture les dépendances à long terme	Captures des motifs locaux à différentes échelles
Architecture du réseau	Architecture en chaîne	Architecture avec cellules à mémoire et portes	Architecture en couches convolutives (1D) suivies de pooling
Applications courantes dans les ST	Prévision à court terme, classification de séries temporelles, génération de séquences	Prévisions complexes, traitement de langages naturels, reconnaissance de la parole	Analyse de séries temporelles multidimensionnelles, classification d'événements dans les séries temporelles
Avantages	Adapté aux séquences de longueur variable, peut capturer les dépendances temporelles	Peut gérer de longues dépendances temporelles, robuste au bruit	Peut extraire des caractéristiques spatiales des données
Complexité	Relativement simple à implémenter	Plus complexe en raison des mécanismes de porte et des cellules de mémoire	Complexité dépendante de la profondeur et de la taille des filtres

Table 2.1: La différence entre LSTM , CNN et RNN

2.4 Les Algorithmes d'optimisation de la descente de gradient

• Adam : Adam est un algorithme d'optimisation introduit en 2015. Le nom de cet algorithme vient de Adaptive Moment Estimation. En introduisant cet algorithme, les auteurs ont présenté les avantages de l'utilisation d'Adam dans des problèmes d'optimisation non convexes comme suit :

- Simplicité de mise en œuvre.
- Efficacité du calcul.
- Moins de mémoire requise.
- Idéal pour les problèmes liés à de grandes quantités de données ou de paramètres.
- Les hyperparamètres nécessitent généralement peu de réglages.

Il existe d'autres optimiseurs avec différents mécanismes de fonctionnement, comme :

- Adagrad
- RMSProp
- Adadelta[51].

2.5 CONCLUSION

Les séries temporelles jouent un rôle crucial dans l'analyse des données EEG en raison de leur nature séquentielle et temporelle. Ce chapitre explore les bases des séries temporelles et leur importance dans le traitement du signal. Ensuite, il explore les algorithmes du DL, qui ont montré des résultats prometteurs pour prédire et classer des données complexes.

3

CHAPITRE 3: CONTRIBUTION ET IMPLÉMENTASSIONS

3.1 INTRODUCTION

Pour prédire efficacement les crises épileptiques, il est essentiel de disposer de jeux de données de haute qualité et de comprendre les méthodes actuelles de recherche dans ce domaine. Ce chapitre présente les principaux jeux de données utilisés pour l'étude des crises épileptiques, ainsi qu'un état de l'art des techniques et approches existantes. Nous détaillerons ensuite notre propre implémentations, en mettant en évidence les choix méthodologiques et les résultats obtenus.

3.2 Outils et Bibliothèques Utilisés

3.2.1 Environnements de travail

•Localement :

1.Caractéristiques matérielles :

- Processeur (CPU) : Intel Core i7-6ième génération.
- Mémoire vive (RAM) : 8 Go.
- Disque dur (HDD/SSD) : SSD 500Go+ HDD externe 500Go.

2.Caractéristiques logicielles :

- Système d'exploitation : Windows 10.
- Environnement de développement : Anaconda avec Jupyter Notebook, Visual Studio Code.

•Google Colab :

- Google Colab permet l'utilisation gratuite de GPU, ce qui accélère considérablement l'entraînement des modèles de deep learning.
- Configuration des GPU : NVIDIA T4 , NVIDIA L4 et NVIDIA A100. - Avec un espace drive de 2TO.

•**Kaggle** : - Kaggle est un environnement riche en datasets et kernels (notebooks) qui offre aux utilisateur des quotas de 30 h d'utilisation de GPU gratuitement par semaine.

- Configuration des GPU : NVIDIA Tesla P100, NVIDIA Tesla T4, • NVIDIA Tesla K80.

3.2.2 Bibliothèques et dépendances

•**Gestion des données et traitement numérique :**

- numpy. - pandas. - scipy

•**Visualisation des données :**

- matplotlib. - seaborn.

•**Manipulation des fichiers EEG :**

- wfdb , mne, pyedflib.

•**Prétraitement et analyse des signaux :**

- scipy.signal , find_peaks de scipy.signal.

•**Gestion et chargement des données :**

- DataLoader de torch.utils.data, Dataset de torch.utils.data, pickle.

•**Apprentissage automatique et deep learning :**

- torch (PyTorch), torch.nn, torch.optim, sklearn (scikit-learn).

3.3 Datasets

3.3.1 Présentation des datasets disponibles

Nom	Lien	Nombre de sujets	Type de sujet	Type d'access
University of Bonn	https://www.ukbonn.de/epilep-tologie/arbeitsgruppen/agleh-nertz-neurophysik/downloads/	10	Humain	Open access
CHB-MIT Scalp EEG	https://physionet.org/content/chbmit/1.0.0/	23	Humain	Open access
TUH EEG Seizure Corpus (TUSZ)	Temple University EEG Corpus-Downloads (piconepress.com)	642	Humain	Avec authentication
Siena Scalp EEG	Siena Scalp EEG Database v1.0.0 (physionet.org)	14	Humain	Open access
Kaggle American Epilepsy Society Seizure Prediction Challenge	American Epilepsy Society Seizure Prediction Challenge Kaggle	12	Humain & Canin	Open access
Kaggle UPenn and Mayo Clinic's Seizure Detection Challenge	https://www.kaggle.com/com-petitions/seizure-detection/data	12	Humain & Canin	Open access
The European Epilepsy Database	Erreur de confidentialité (epilepsy-database.eu)	217	Humain	Payante

Table 3.1: Caractéristiques des Datasets

Nom	nombre	Segment	Classe équilibrée	Application
University of Bonn	10	23.6 s /500 segments	oui	Detection de la crise
CHB-MIT Scalp EEG	23	1h/ 198	Non	détection/ Prédiction de la crise
TUH EEG Seizure Corpus (TUSZ)	642	1h 3050 /events	Oui	détection/ Prédiction/ classification de la crise
Siena Scalp EEG	14	varied /47 events	Non	détection/ Prédiction de la crise
Kaggle American Epilepsy Society Seizure Prediction Challenge	12	10min /111 events	Non	Prediction de la crise
Kaggle UPenn and Mayo Clinic's Seizure Detection Challenge	12	1 s 48 events	Non	Detection de la crise
The European Epilepsy Database	217	> 40 000 h de données au total.	Oui	détection/ Prédiction de la crise

Table 3.2: Application des Datasets

3.3.2 Datasets utilisées

Les ensembles de données utilisées dans cette expérience sont :

•**CHB-MIT :**

Une base de données EEG du cuir chevelu créée par le MIT du Boston Children's Hospital

(MIT-CHB). Ces données sont collectées à partir de 23 canaux de données EEG enregistrées pendant des jours sans aucun médicament.

- **Sujets** : La base de données contient des enregistrements EEG de 23 sujets (patients : chb01, chb02...).

- **Enregistrements** : Chaque sujet a plusieurs enregistrements EEG qui varie entre 9 et 42 enregistrement avec une durée de 1h sauf pour certain cas qui ont une longueur de segment plus courte , au totale 916 heures , tous les segment ont une annotation précise des événements de crise décrite dans des fichier TXT pour chaque sujet .

- **Canaux** : Les enregistrements sont réalisés avec des systèmes EEG multi-canaux, généralement 18 canaux, permettant une couverture détaillée de l'activité cérébrale.

- **Fréquence d'échantillonnage** : Les données sont échantillonnées à une fréquence de 256 Hz, offrant une résolution temporelle suffisante pour l'analyse des signaux EEG.

- **Format des Données** : Les enregistrements sont fournis au format EDF (European Data Format) qui est un standard pour l'enregistrement des données EEG. Chaque fichier contient des informations sur la durée, les canaux utilisés, et les annotations des crises.

- **Taille totale**: 42GO non compressée.

•TUSZ

La base de données TUSZ (Temple University Seizure Corpus), version 2.0.3, est une ressource majeure dans le domaine de la recherche sur l'épilepsie. Elle fait partie du corpus plus large "TUH" (Temple University Hospital), a été mise à jour pour la dernière fois en 2024.

- La base de données comprend des enregistrements EEG de 670 sujets différents, ce qui en fait l'une des bases de données les plus étendues et variées dans ce domaine. - Contient plus de 1 600 heures d'enregistrements EEG, dont environ 400 heures contiennent des crises.

- Les enregistrements sont fournis au format EDF (European Data Format), accompagnés d'annotations détaillées indiquant les périodes de crises, les types de crises, et d'autres événements pertinents :

* **.edf** : les données échantillonnées EEG au format de données européen (edf) .

* **.csv** : annotations basées sur les événements utilisant toutes les classes de types de crises disponibles.

* **.csv_bi** : annotations basées sur des termes utilisant seulement deux étiquettes (bckg et seiz).

- Les enregistrements EEG sont organisés en 3 dossiers : « 01_tcp_ar », « 2_tcp_le », « 03_tcp_ar_a », chacun est divisé en un ensemble d'entraînement (70% des enregistrement) et un ensemble de test (30% des enregistrements).

- La taille totale compressé est de 32GO .

Référence de l'électrode	Types de crises	Événements convulsifs
01_tcp_ar	GNSZ	428
	ABSZ	2
	MYSZ	1
	TNSZ	62
	TCSZ	28
	FNSZ	1070
	SPSZ	52
	CPSZ	138
02_tcp_le	GNSZ	87
	ABSZ	97
	MYSZ	2
	TCSZ	16
	FNSZ	231
	CPSZ	83
03_tcp_ar_a	GNSZ	68
	TCSZ	4
	FNSZ	535
	CPSZ	146

Table 3.3: Description de la référence de l'électrode et nombre d'événements par type de crise dans TUSZ [59]

3.3.3 Pré-traitement

Le pré-traitement des données EEG est une étape cruciale pour garantir la qualité et la fiabilité des résultats dans l'analyse des signaux cérébraux pour cela nous avons réalisé cette étape avec utiliser deux méthode de pré-traitement de nos données.

Chaque étape du pré-traitement des données EEG joue un rôle crucial dans la qualité finale des données utilisées pour les analyses ultérieures. En appliquant ces méthodes avec soin,

les chercheurs peuvent améliorer la validité, la fiabilité et la reproductibilité de leurs résultats, permettant ainsi des avancées significatives dans la compréhension des processus cérébraux mesurés par EEG.

3.3.3.1 Méthode 1 : Pré-traitement pour la Base de Données 1 CHB-MIT «prédiction »

Lecture des données

1. Lecture des signaux et les en-têtes des fichiers EDF.
2. Suppression des canaux inutiles « ECG » dans certains cas .
3. Vérification des canaux qui possède des noms en double .
4. Division à des ensemble d'entraînement et de teste par patient 'chb' :

Train: 02 03 04 05 06 09 11 12 13 14 15 16 17 18 19 20 21 23 24

Test : 01 07 08 10 22




Figure 3.1: Répartition des fichiers d'entraînement et de test

5. Segmentation des données

La base CHB-MIT possède de longs segments « 1h d'enregistrement » qui nous permet d'extraire les différentes phases de crise préictale (pré-crise), ictale(crise) et inter-ictale pour cela nous avons :

- Découpé les enregistrements EDF et les segmenté selon leur étiquette correspondante dans les fichier TXT en extrayant les périodes de crise pour chaque fichier, après nous avons défini la période qui la précède de 5 min comme préictale et définissant la période sans crise comme intercale (3.2) .

- Découpage des enregistrements EEG en fenêtres temporelles plus petit pour unifier la taille de nos données.

- Étiquetage des segments selon l'étiquette qui les correspond .

- Enregistrement des données dans des tenseurs un pour les données brute et l'autre pour les labels.

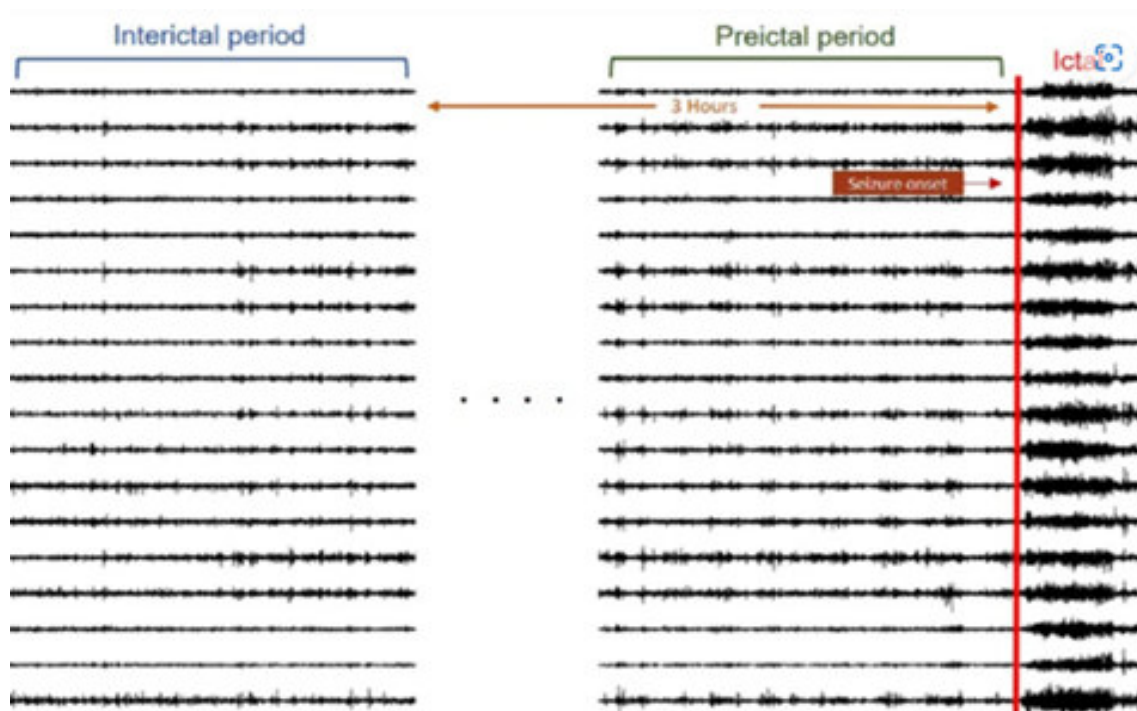


Figure 3.2: Segmentation des données [52]

3.3.3.2 Méthode 2 : Pré-traitement pour la Base de Données 2 TUSZ « classification »

La base de données TUSZ nous permet de faire une classification binaire de crise et non crise a partir des informations décrites dans les fichier csv_bi qui contient des étiquette binaire « seiz » et « bckg » ainsi qu'une classification multiple pour la précision du type de la maladie Pour cela nous avons Défini :

Une fonction qui prend des annotations de labels et effectue un échantillonnage en fonction de la fréquence unifiée qui permet d’avoir des caractéristiques définies pour chaque .

Une fonction principale pour structurer les données d’entraînement à partir des fichiers EDF. Elle effectue les étapes suivantes :

- Lit les signaux et les en-têtes des fichiers EDF.
- Récupère les annotations de labels et les convertit en échantillons.
- Vérifie la présence de certains labels et la fréquence d’échantillonnage.
- Filtre et ré-échantillonne les signaux si nécessaires.
- Sauvegarde les segments de données et leurs pour l’entraînement dans des dictionnaires .
- les dictionnaires de chaque segment est enregistré sous forme de fichier avec une entête qui possède des informations relatives au patients et à la position de la crise .

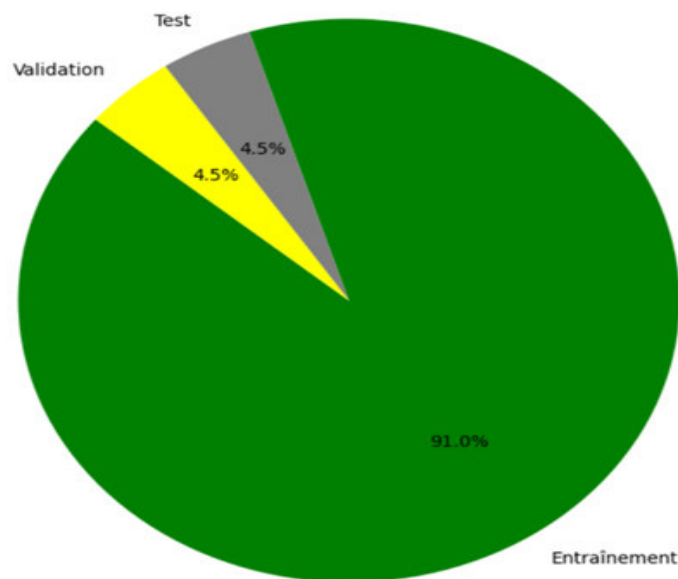


Figure 3.3: Répartition des fichiers d’entraînement et de test et de validation

3.4 Transformation bipolaire

Pour avoir un format unifié et une meilleure caractérisation des données nous avons implémenté une fonction qui transforme les signaux EEG uni-polaires en signaux bipolaires en calculant les différences entre des paires spécifiques d’électrodes.

3.5 Équilibrage des données

Vue le déséquilibre entre les classes et la petite durée de la période critique (3.1) par rapport au données sans crise nous avons appliqué la technique de de la Fenêtre Glissante (sliding window) (3.3) avec une fenêtre de 8 S et un pas de deux seconde cette méthode est couramment utilisée dans les tâches de traitement de signaux et de séries temporelles, notamment pour l'analyse et la détection d'événements dans les données EEG




Figure 3.4: La fenêtre glissante [52]

En utilisant cette méthode nous bénéficiant de

Découpage des Données en Segments Plus Petits : Les signaux EEG sont des enregistrements continus des activités cérébrales qui peuvent être longs et complexes. En utilisant une fenêtre glissante, le signal continu est divisé en segments plus petits et plus gérable, simplifiant l'analyse et le traitement par les modèles d'apprentissage automatique.

Détection Locale des Événements : La fenêtre glissante permet de détecter des événements locaux dans le signal, ce qui aide à la localisation des Crises et l'Identification précise où se produisent les crises dans le signal.

Analyse Temporelle : Observer comment les caractéristiques du signal évoluent au fil du temps en gardant la relation temporelle entre les données.

CHAPITRE 3: CONTRIBUTION ET IMPLÉMENTASSIONS

Augmentation des données : L'utilisation de fenêtres glissantes avec chevauchement permet de générer plusieurs segments légèrement décalés dans le temps à partir du même signal. Cela augmente la quantité de données.

Diminution des données : en supprimant les segments redondant dans la classe majoritaire pour éliminer les séquences répétitives et réalisé un équilibre entre les classes[52].

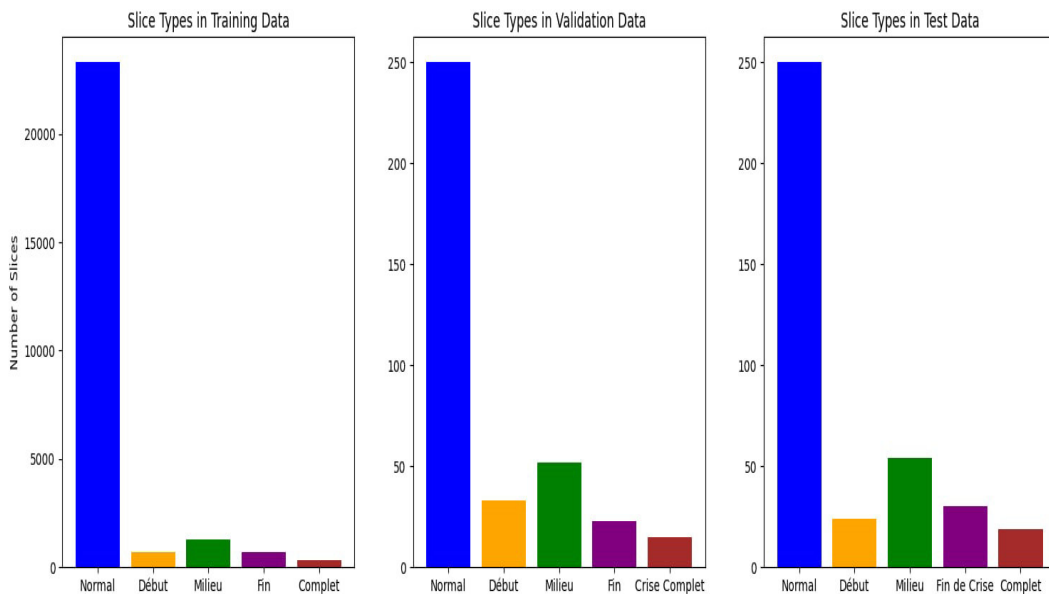


Figure 3.5: Répartition des différentes classes dans le dataset TUSZ

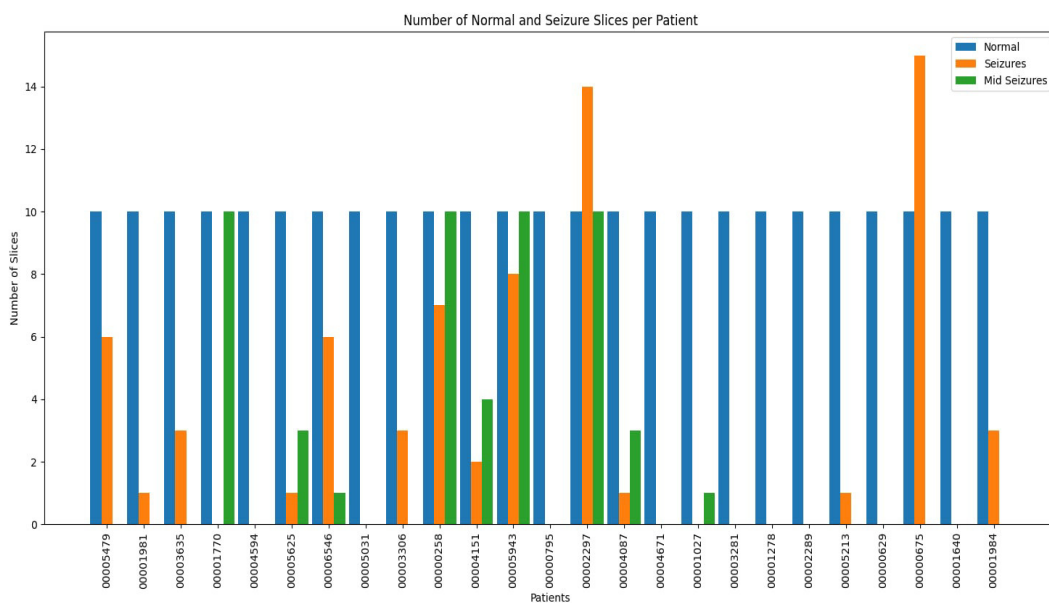


Figure 3.6: Repartition par patient

3.6 Extraction des caractéristiques

L'extraction des caractéristiques est une étape cruciale dans de nombreux domaines d'analyse de données, notamment le traitement des signaux EEG pour diverses applications en neurosciences et en ingénierie biomédicale. Cette étape consiste à identifier et extraire des caractéristiques pertinentes à partir de données brutes, afin de les rendre plus compréhensibles et analysables. Il existe un large éventail de méthodes d'extraction de caractéristiques, résumé dans le diagramme de la 3.7, selon leur domaine d'application. Nous allons ensuite définir certaines des méthodes les plus couramment utilisées pour les modèles d'apprentissage automatique.

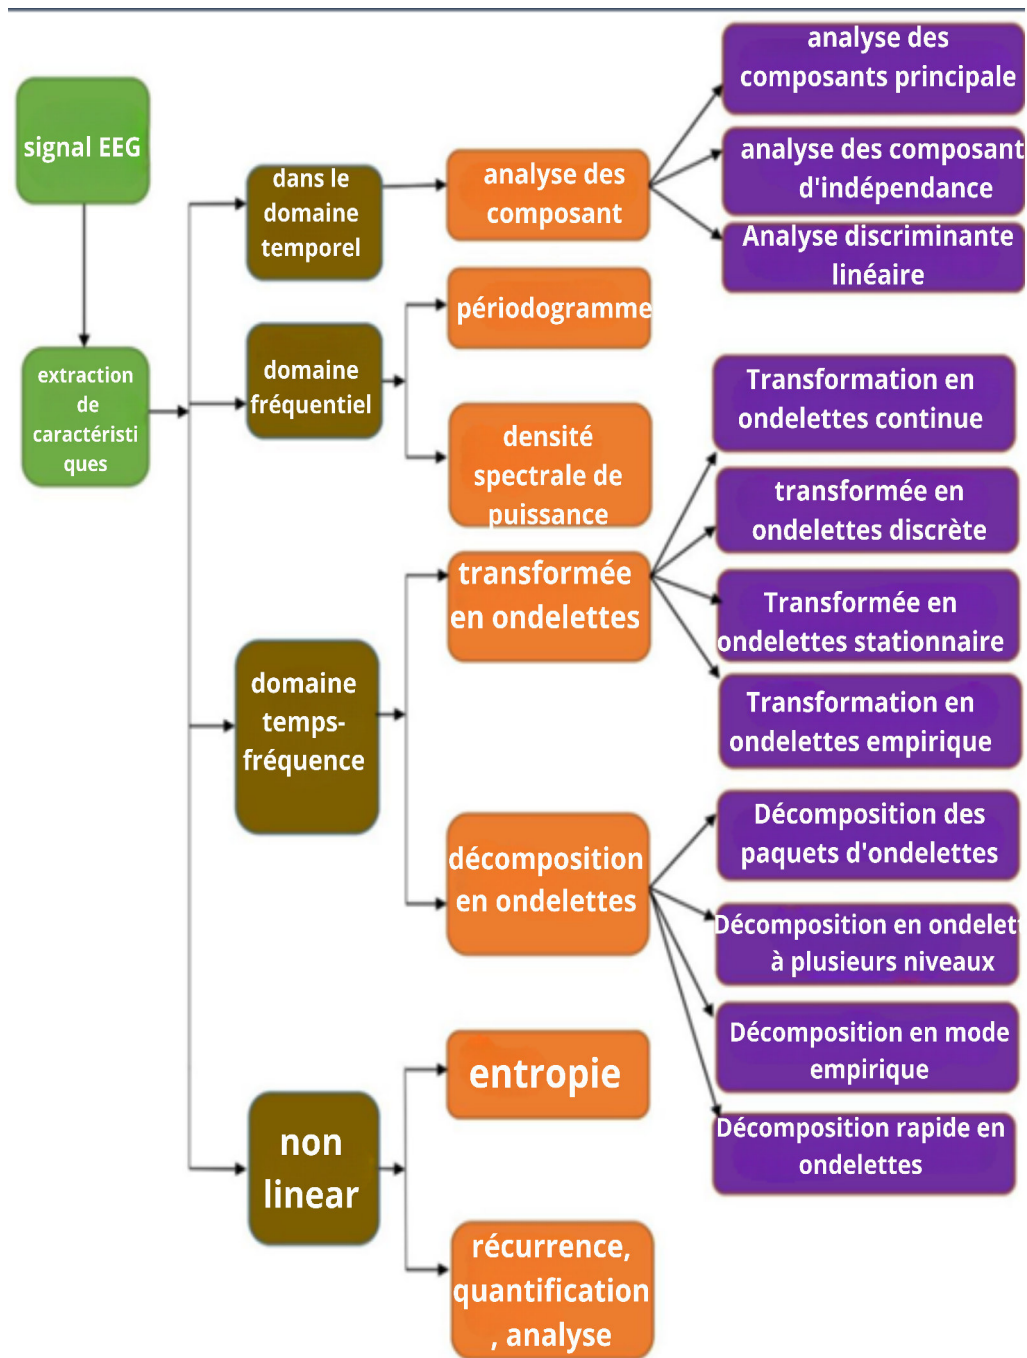


Figure 3.7: Résumer de méthodes d'extraction de caractéristiques

3.7 Transformée de Fourier

La transformée de Fourier est un outil mathématique qui permet de décomposer un signal en une somme de sinusoides de différentes fréquences. En termes simples, elle convertit un signal de son domaine temporel en domaine fréquentiel.

Pour un signal temporel $f(t)$, la transformée de Fourier $F(\omega)$ est définie par :

$$F(\omega) = \int_{-\infty}^{\infty} f(t) \cdot e^{-i\omega t} dt \quad (3.1)$$

Où : ω est la fréquence angulaire,

En appliquant la TF sur signaux EEG permet de décomposer le signal EEG en ses composantes fréquentielles. Cela aide à identifier les bandes de fréquences spécifiques (delta, theta, alpha, beta, gamma) associées à différents états mentaux et processus cognitifs ,voici un exemple d'application de la TF dans nos données[53].




Figure 3.8: Représentation du signal dans le domaine temporelle




Figure 3.9: Représentation du signal dans le domaine fréquentielle

3.8 État de l’art

Diverses méthodes et algorithmes appliqués dans le domaine du traitement de signal ont été développés depuis plusieurs années, permettant une analyse performante ainsi plus précisément dans la détection des anomalies critiques associées à une épilepsie.

Depuis plusieurs années, de nombreuses méthodes et algorithmes ont été développés dans le domaine du traitement de signal, ce qui permet une analyse efficace plus précisément la détection et la prédiction des crises d’épilepsie ont fait l’objet de nombreuses recherches utilisant des méthodes traditionnelles ou modernes.

Shoeb, A. H., & Guttag, J. V. ont appliqué des SVM pour la classification des signaux EEG afin de détecter les crises d’épilepsie. Les signaux EEG sont d’abord prétraités pour extraire des caractéristiques importantes, telles que les coefficients de transformée en ondelette ou les caractéristiques spectrales. Par la suite ces caractéristiques sont utilisées pour entraîner un modèle SVM. L’hyperplan optimal obtenu par le modèle SVM permet de séparer les échantillons de crises épileptiques des échantillons normaux. Les nouveaux signaux EEG sont classifiés en utilisant cet hyperplan pour prédire les crises[54].

Polat, K., & Güneş, S.

Divers modèles, notamment Random Forest, XGBoost, Gradient Boost, Naive Bayes, Decision Tree et Extra Tree ont été appliqués par [Ulhaq, Sajad & Khan, Gul Zaman & Ulhaq, Imran & Ullah, Inam & Rabbi, Fazal] Des techniques clés de prétraitement et de sélection de fonctionnalités ont été utilisées pour améliorer les performances du modèle. Parmi ceux-ci, XGBoost a atteint la précision la plus élevée avec 98,93 % en formation et 98,23 % en tests[55].

Une autre architecture des réseaux de neurone proposé appliqué sur la base CHB-MIT qui consiste d'utiliser des méthode d'extraction de caractéristique et une transformation des données en spectrogrammes en utilisant la STFT puis en entrainant les CNN avec 3 couche convulutif l'architecture du model est présenté dans 3.9 [56].




Figure 3.10: Un modèle CNN

« A ResNet-LSTM hybrid model for predicting epileptic seizures using a pretrained model with supervised contrastive learning » une etude qui combine entre un modèle pré-entraîné ResNet et les LSTM ainsi qu'une STFT a été appliquée pour convertir les signaux EEG bruts en spectrogrammes .

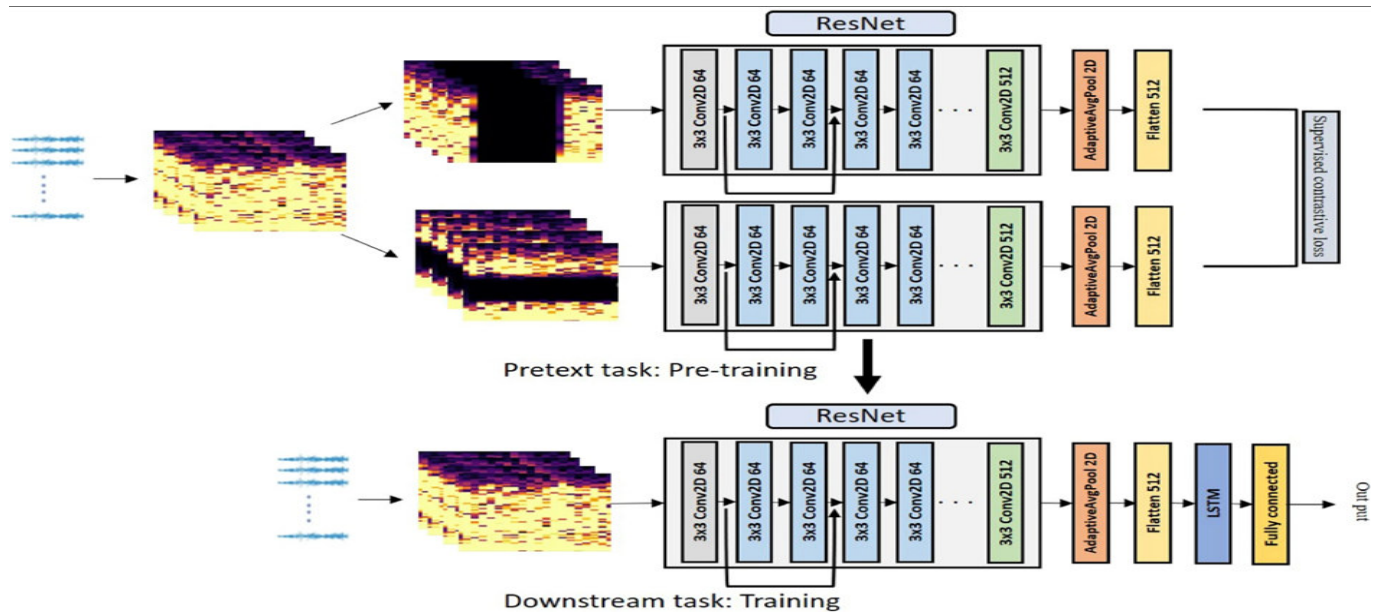


Figure 3.11: Un modèle hybride ResNet-LSTM [52]

3.9 Modèle réaliser

La prédiction précoce et précise des crises épileptiques à partir des signaux (EEG) en temps réel est essentielle pour le traitement et la gestion des patients atteints d'épilepsie, notre travail vise à développer un modèle spatio-temporel qui est une architecture de réseau de neurones profonds combinant les avantages des réseaux convolutifs CNN pour l'extraction des caractéristiques en niveau spatial et des LSTM pour la modélisation des dépendances temporelles .

Ainsi que notre modèle est conçu pour traiter des données EEG brutes contrairement au modèle traditionnel ou bien architecture avec une extraction de caractéristique et de transformation de données (spectrogramme) qui risque de perdre des informations intéressantes vu que la sensibilité de ce genre de signaux et l'importance des petit changement électrique dans les état critique et précritique (3.11) montre cette différence.

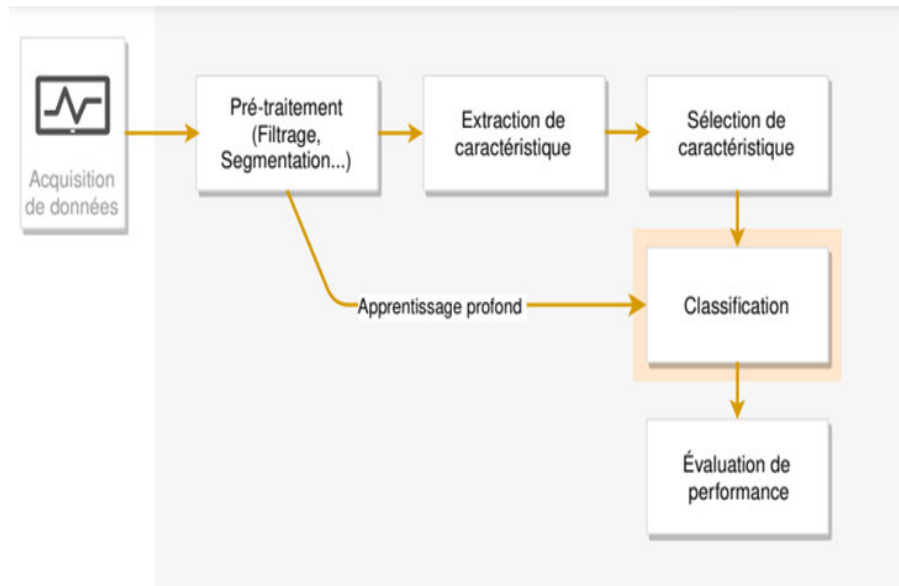


Figure 3.12: Schéma typique d'un système automatique de prédiction des crises d'épilepsie

La structure du modèle comprend plusieurs couches, notamment :

1. Couche d'entrée : qui prend en charge des segments de signaux bruts de forme (1x20x600).

2. Couches Convolutives: Pour les données brutes, plusieurs couches convolutives avec des activations ReLU et des normalisations de lot sont appliquées.

a. Première Couche Convulsive: Applique une convolution avec 64 filtres, un noyau de taille (1, 51), un stride de (1, 4) et un padding de (0, 25).

b. Deuxième Couche Convulsive: Applique une convolution avec 128 filtres, un noyau de taille (1, 21), un stride de (1, 2) et un padding de (0, 10).

c. Troisième Couche Convulsive: Applique une convolution avec 256 filtres, un noyau de taille (1, 9), un stride de (1, 2) et un padding de (0, 4).

3. Couche LSTM est utilisée après les couches convolutives pour capturer les dépendances temporelles dans les données EEG après l'extraction des caractéristiques.

4. Classificateur : La sortie de la couche LSTM est ensuite passée à un classificateur dense avec des couches entièrement connectées et des activations non linéaires pour produire la classification finale.

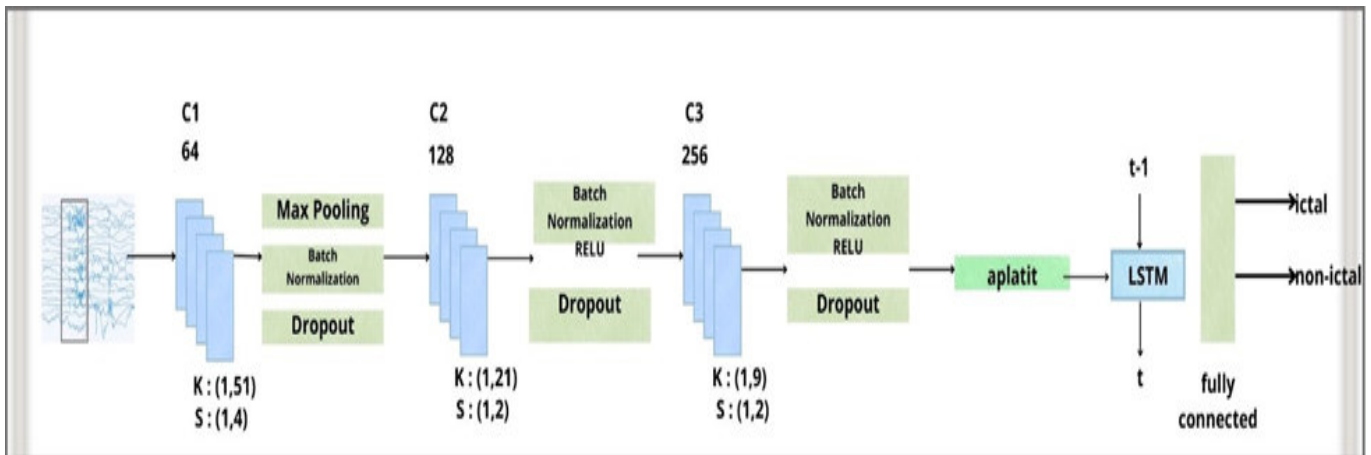


Figure 3.13: Modèle proposé CNN_LSTM

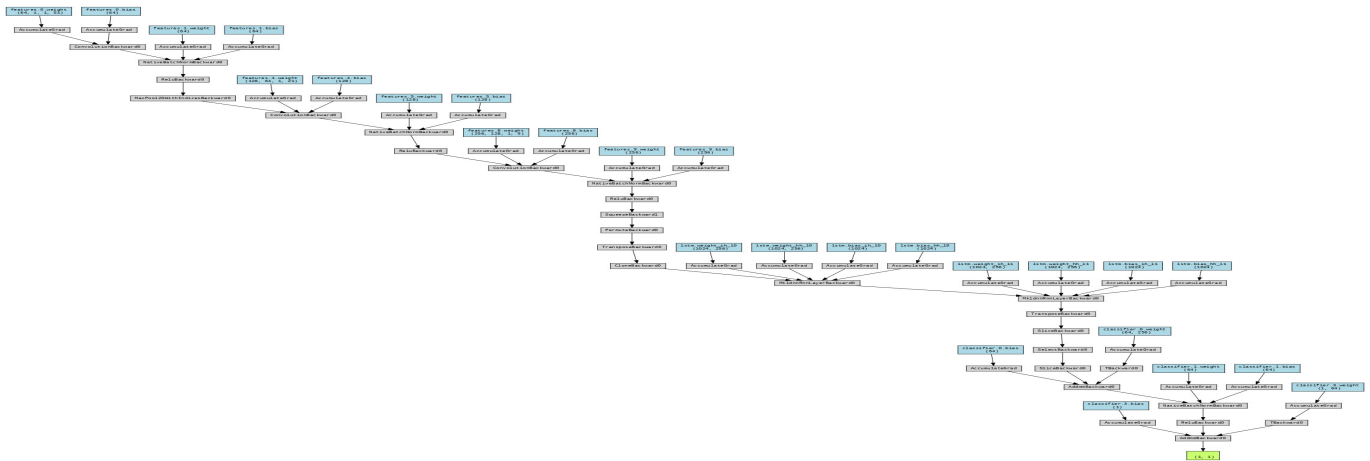


Figure 3.14: Diagramme détaillé de l'architecture proposé

3.10 Résultats

Pour évaluer les performances de notre modèle, nous l'avons testé sur une partie du jeu de données et avons utilisé différentes métriques pour l'évaluation par itération. Les résultats obtenus sont les suivants :

1. AUC (Area Under the Curve) :

- o Cette métrique mesure la capacité du modèle à distinguer entre les classes positives et négatives.

- o Une valeur plus élevée est meilleure. On observe une augmentation progressive de la valeur AUC de 0.747 à environ 0.869, indiquant que le modèle s'améliore dans la différenciation

entre les classes au fil du temps.

2. APR (Average Precision Recall) :

o Cette métrique combine la précision et le rappel pour évaluer la qualité des prédictions positives du modèle.

o La valeur d'APR semble fluctuer, avec une amélioration générale atteignant environ 0.694 à la fin. Cela suggère que la précision et le rappel du modèle s'améliorent globalement, malgré certaines variations.

3. F1 Score :

o Le F1 Score est la moyenne harmonique de la précision et du rappel, offrant un équilibre entre les deux.

o On observe une tendance à la hausse de la valeur du F1 Score, atteignant environ 0.679 à la fin. Cela indique que le modèle devient globalement meilleur pour maintenir un bon équilibre entre la précision et le rappel.

4. TPR (True Positive Rate) ou Sensibilité :

o Cette métrique mesure la proportion de vrais positifs correctement identifiés par le modèle.

o Le TPR montre des variations mais une tendance générale à l'augmentation, atteignant environ 0.851 à la fin. Cela suggère que le modèle devient de plus en plus efficace pour détecter les vrais positifs.

5. FNR (False Negative Rate) :

o Cette métrique mesure la proportion de vrais positifs incorrectement classifiés comme négatifs.

o Une valeur plus faible est meilleure. Le FNR fluctue mais montre une tendance générale à la baisse, atteignant environ 0.159. Cela indique que le modèle réduit ses erreurs de classification de vrais positifs comme négatifs.

6. TNR (True Negative Rate) ou Spécificité :

o Cette métrique mesure la proportion de vrais négatifs correctement identifiés par le modèle.

o Le TNR montre des fluctuations mais une tendance générale à l'augmentation, atteignant environ 0.879. Cela indique que le modèle s'améliore pour identifier correctement les vrais négatifs.

7. FPR (False Positive Rate) :

o Cette métrique mesure la proportion de vrais négatifs incorrectement classifiés comme positifs.

o Une valeur plus faible est meilleure. Le FPR montre une tendance générale à la baisse, atteignant environ 0.124. Cela indique que le modèle réduit ses erreurs de classification de vrais négatifs comme positifs.

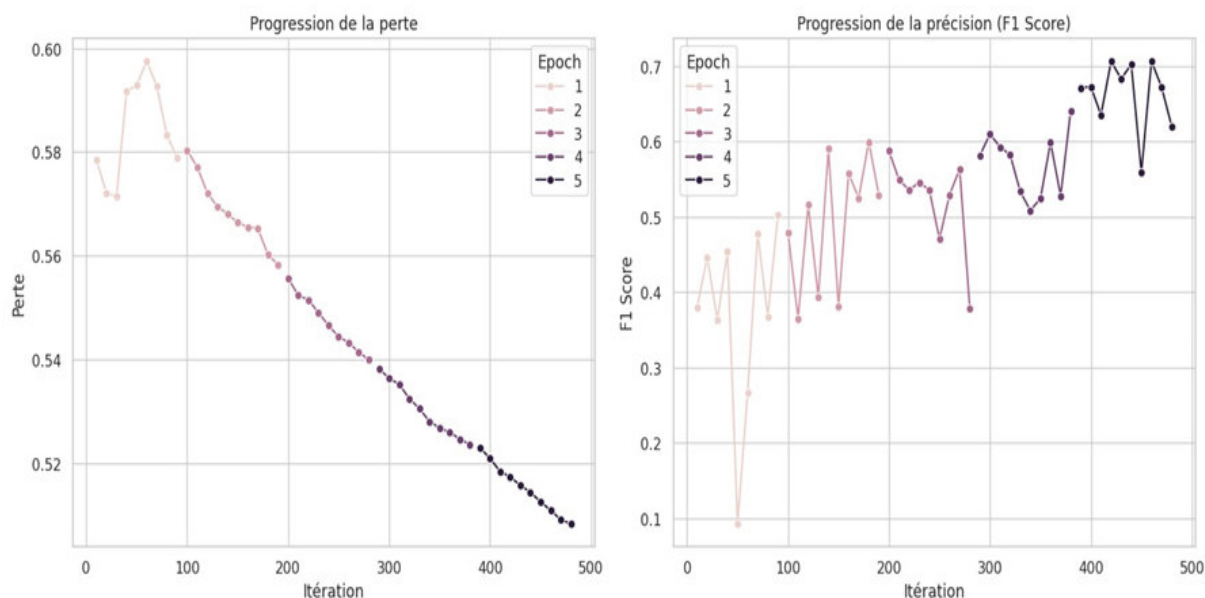


Figure 3.15: Progression de la perte et de la précision (F1 Score) au cours des itérations d'entraînement

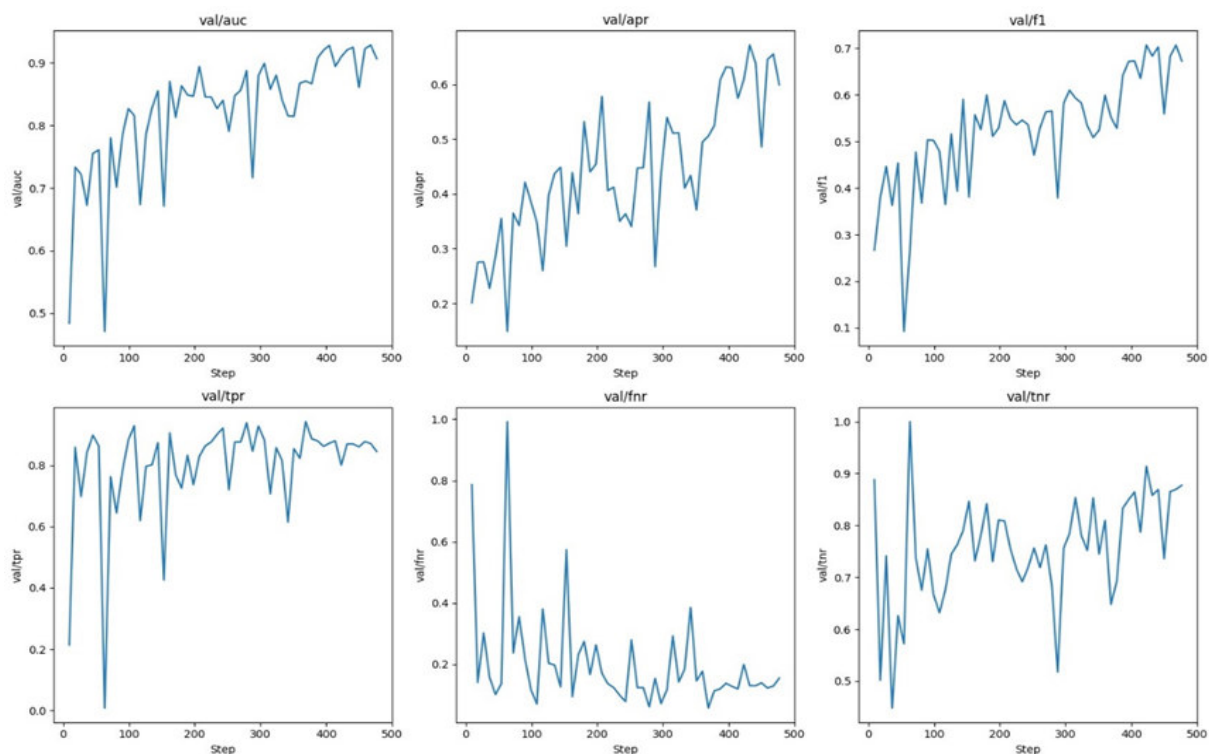


Figure 3.16: Progression des différentes métriques de validation au cours des itérations d’entraînement

En résumé, les graphiques montrent que les performances du modèle s’améliorent généralement au fil des époques ou des itérations. Les métriques telles que l’AUC, le TPR et le TNR augmentent, tandis que les erreurs mesurées par le FNR et le FPR diminuent, ce qui indique une meilleure classification des échantillons par le modèle. Les variations observées peuvent être dues à des fluctuations dans le processus d’apprentissage, mais la tendance générale est positive.

3.11 CONCLUSION

Notre exploration des datasets EEG et des approches existantes a souligné l’importance de données de qualité pour la prédiction des crises épileptiques. L’utilisation du modèle CNN-LSTM a démontré son efficacité pour capturer les caractéristiques des signaux EEG et prédire les crises épileptiques. Bien que prometteuse, cette approche peut encore être améliorée pour une précision et une fiabilité accrues. Notre travail constitue une avancée notable dans l’application du DL à la prédiction des crises épileptiques, ouvrant la voie à des recherches futures.



CONCLUSION GENERALE

Dans ce mémoire, une analyse approfondie et une mise en œuvre concrète d'un modèle hybride CNN_LSTM ont été exposées afin de prédire les crises d'épilepsie en utilisant des signaux EEG. Les chapitres principaux ont abordé différents sujets, allant des fondements théoriques à l'analyse des résultats obtenus. Voici une synthèse des principales contributions et conclusions de cette étude.

Le premier chapitre a fourni une vue d'ensemble détaillée de l'épilepsie, une maladie neurologique caractérisée par des crises récurrentes, et du rôle essentiel des électroencéphalogrammes (EEG) dans la détection et le suivi de ces crises. Cette section a mis en évidence les défis cliniques et techniques associés à l'analyse des signaux EEG pour la prédiction des crises.

Le deuxième chapitre a défini les séries temporelles et a exploré les concepts fondamentaux du deep learning, avec une présentation des réseaux de neurones convolutifs (CNN), des réseaux de neurones récurrents (RNN) et des réseaux de type LSTM.

Le troisième chapitre a fourni une revue de la littérature sur les méthodes existantes pour la prédiction des crises d'épilepsie. Une comparaison des différents jeux de données disponibles et des techniques de prétraitement utilisées a été réalisée. Cette analyse a permis de sélectionner les approches les plus prometteuses pour notre implémentation. De plus, ce chapitre a détaillé l'implémentation de notre modèle CNN_LSTM, décrivant les étapes de développement, d'entraînement et de validation

L'implémentation du modèle CNN_LSTM a permis d'atteindre des performances significatives dans la prédiction des crises d'épilepsie. Les résultats montrent une AUC de 0.9045, un APR de 0.6632, et un F1-score de 0.6205. Les taux de vrais positifs (TPR) et de vrais négatifs (TNR) se sont élevés respectivement à 0.8384 et 0.8239. Ces performances démontrent la capacité du

modèle à identifier une prédiction efficace, tout en maintenant un bon équilibre entre les faux positifs et les faux négatifs.

Pour les perspectives futures, plusieurs axes de recherche peuvent être envisagés :

1. **Application du Modèle sur Tous les Datasets** : Tester et valider le modèle sur une variété plus large de jeux de données pour évaluer sa robustesse et sa généralisabilité.
2. **Étude Multimodale** : Intégrer des données provenant de différentes sources (par exemple, EEG, ECG, video, etc.) pour enrichir l'information et améliorer les prédictions.
3. **Étude Combinatoire** : Développer des modèles combinatoires capables non seulement de prédire les crises mais aussi de déterminer leur type spécifique, offrant ainsi une aide plus complète pour la gestion clinique de l'épilepsie.

En conclusion, ce projet ouvre la voie à de futures recherches prometteuses et souligne l'importance de l'intelligence artificielle dans le domaine médical, particulièrement pour des applications prédictives des crises d'épilepsie.



BIBLIOGRAPHY

- [1] **OMS 2024.** organisation mondiale de la Santé. <https://www.who.int/fr/news-room/fact-sheets/detail/epilepsy>
- [2] **PubMed.**Huff JS, Murr NI. Seizure. 2023 Feb 7. In: StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing; 2024 Jan–. PMID: 28613516. Wesley, Massachusetts, 2nd ed.
- [3] **ILAE,** Définition clinique pratique de l'épilepsie, Robert S. Fisher, ilae.org,2014 .
- [4] **So, E. L. (1995).** Classifications and epidemiologic considerations of epileptic seizures and epilepsy. *Neuroimaging Clinics of North America*, 5(4), 513-526.
- [5] **Dhondiyal, S. A., & Dimri, S. C. (2022, November).** Diagnosis, treatment and containment of epilepsy disease. In 2022 Seventh International Conference on Parallel, Distributed and Grid Computing (PDGC) (pp. 269-275). IEEE.
- [6] **McWilliam, M., & Al Khalili, Y. (2019).** Idiopathic (genetic) generalized epilepsy.
- [7] **Elmali, A. D., Auvin, S., Bast, T., Rubboli, G., & Koutroumanidis, M. (2020).** How to diagnose and classify idiopathic (genetic) generalized epilepsies. *Epileptic Disorders*, 22(4), 399-420.
- [8] **Koçak, F., Issaoui, A., & Mroueh, L. (2023).** Diagnostic et classification des épilepsies. *Actualités Pharmaceutiques*, 62(624), 51-54.
- [9] **Panayiotopoulos, C. P. (2005).** Optimal use of the EEG in the diagnosis and management of epilepsies. In *The epilepsies: Seizures, syndromes and management*. Bladon Medical Publishing.

- [10] **Clic,O.(2024,January26).** Classification internationale des épilepsies et les différents types des crises épileptiques. Documents Pour Tous.<https://www.clicours.com/classification-internationale-des-epilepsies-et-les-differents-types-des-crisis-epileptiques/>
- [11] **Bertran, F. (2018).** Epilepsy today. *Revue de l’Infirmiere*, 67(243), 14-16.
- [12] **Siebenbrodt, K., Willems, L. M., von Podewils, F., Mross, P. M., Strüber, M., Langenbruch, L., ... & Strzelczyk, A. (2023).** Determinants of quality of life in adults with epilepsy: a multicenter, cross-sectional study from Germany. *Neurological Research and Practice*, 5(1), 41.
- [13] **Biasiucci, A., Franceschiello, B., & Murray, M. M. (2019).** Electroencephalography. *Current biology : CB*, 29(3), R80–R85.<https://doi.org/10.1016/j.cub.2018.11.052>
- [14] **Livint Popa, L., Dragos, H., Pantelemon, C., Verisezan Rosu, O., & Strilciuc, S. (2020).** The Role of Quantitative EEG in the Diagnosis of Neuropsychiatric Disorders. *Journal of medicine and life*, 13(1), 8–15.<https://doi.org/10.25122/jml-2019-0085>
- [15] **Fergus, P., Hignett, D., Hussain, A., Al-Jumeily, D., & Abdel-Aziz, K. (2015).** Automatic epileptic seizure detection using scalp EEG and advanced artificial intelligence techniques. *BioMed research international*, 2015, 986736. <https://doi.org/10.1155/2015/986736>
- [16] **Ruiz, A. P., Flynn, M., Large, J., Middlehurst, M., & Bagnall, A. (2021).** The great multivariate time series classification bake off: a review and experimental evaluation of recent algorithmic advances. *Data Mining and Knowledge Discovery*, 35(2), 401-449.
- [17] **Morley, A., Hill, L., & Kaditis, A. (2016).** 10-20 system EEG Placement. European Respiratory Society, European Respiratory Society.
- [18] **Nuwer, M. R., Comi, G., Emerson, R., Fuglsang-Frederiksen, A., Guérit, J. M., Hinrichs, H., ... & Rappelsburger, P. (1998).** IFCN standards for digital recording of clinical EEG. *Electroencephalography and clinical Neurophysiology*, 106(3), 259-261.

- [19] **Salido-Ruiz, R. A. (2012).** Problèmes inverses contraints en EEG: applications aux potentiels absolus et à l'influence du signal de référence dans l'analyse de l'EEG (Doctoral dissertation, Université de Lorraine).
- [20] **Trambaiolli, L.R., Lorena, A.C., Fraga, F.J., Kanda, P.A., Nitrini, R., & Anghinah, R. (2011).** Does EEG Montage Influence Alzheimer's Disease Electroclinic Diagnosis? *International Journal of Alzheimer's Disease*, 2011.
- [21] **Albin, CSW, Zafar, SF (2022).** Trucs et astuces pour l'interprétation EEG. Dans : Albin, CS, Zafar, SF (éd.) *Le guide de survie en neurologie aiguë*. Springer, Cham. https://doi.org/10.1007/978-3-030-75732-8_9
- [22] **Abhang, P. A., Gawali, B. W., & Mehrotra, S. C. (2016).** Technological Basics of EEG Recording and Operation of Apparatus. In Elsevier eBooks (pp. 19–50). <https://doi.org/10.1016/b978-0-12-804490-2.00002-6>
- [23] **Monténégro, MA et Valente, K. (2024).** EEG in focal and generalized epilepsies: Pearls and perils, *Epilepsy & Behavior*, Volume 56, 2024, 109825, ISSN 1525-5050, <https://doi.org/10.1016/j.yebeh.2024.109825>.
- [24] **Guérit, J. M., & Debatisse, D. (2007).** Bases neurophysiologiques et principes d'interprétation de l'électroencéphalogramme en réanimation *Neurophysiological bases and principles of electroencephalogram interpretation in the intensive care unit*
- [25] **Vespignani, H. (2003).** *L'EEG: de la technique à la clinique*. John Libbey Eurotext.
- [26] **Gourieroux, C., & Monfort, A. (1995, January 1).** *Séries temporelles et modèles dynamiques*
- [27] **OUYANG, Z., RAVIER, P., & JABLOUN, M.** Une comparaison des modèles d'apprentissage profond combinés avec des différentes stratégies pour la prédiction multi-étape des séries temporelles
- [28] **Monbet, V. (2011).** *Modélisation de séries temporelles*. Université de Rennes.

- [29] **Eilstein, D., Le Tertre, A., Zeghnoun, A., Cassadou, S., Filleul, L., Pascal, L., ... & Quénel, P. (2003)**. Séries temporelles et modèles de régression. Rapport technique, Institut de veille sanitaire. Département santé environnement
- [30] **J.J. Daudin, C. Duby, S. Robin & P. Trécourt (INA-PG, Mathématiques)** ,Mai 1996 ,Analyse de Séries Chronologiques
- [31] **Boniol, P., Meftah, M., Remy, E., & Palpanas, T. (2022, October)**. Détection d'anomalies et identification de leurs précurseurs dans des larges collections de séries temporelles-Application à un matériel de centrales EDF. In Congrès Lambda Mu 23 «Innovations et maîtrise des risques pour un avenir durable»-23e Congrès de Maîtrise des Risques et de Sûreté de Fonctionnement, Institut pour la Maîtrise des Risques.
- [32] **Hmamouche, Y. (2018)**. Prédiction des séries temporelles larges (Doctoral dissertation, AMU-Aix Marseille Université)
- [33] **Presse MIT, 2019**.Kelleher, John D. Apprentissage profond .
- [34] **M. Zouinar, "Évolutions De l'Intelligence Artificielle : Quels Enjeux Pour l'activité Humaine Et La Relation Humain-Machine Au Travail ? "** , Activités [En Ligne], 17-1 | 2020, Mis En Ligne Le (15 Avril 2020), Consulté Le 10 Décembre 2020. URL : [Http://journals.Openedition.Org/Activites/4941](http://journals.openedition.org/activites/4941) ; DOI : [Https://Doi.Org/10.4000/Activites.494](https://doi.org/10.4000/activites.494)
- [35] **Université de Bordeaux, 2021. English**. Sara Akodad. Ensemble learning methods on the space of covariance matrices : application to remote sensing scene and multivariate time series classification. Automatic Control Engineering. ⟨NNT : 2021BORD0310⟩. ⟨tel-03484011v2⟩
- [36] **Thome, N., & Wolf, C. (2023)**. Histoire des réseaux de neurones et du deep learning en traitement des signaux et des images.
- [37] **Khan, A., Sohail, A., Zahoora, U., And Qureshi, A. S. (2020)**. A Survey of The Recent Architectures of Deep Convolutional Neural Networks. Artificial Intelligence Review, Pages 1–62

- [38] **Jarrett, K., Kavukcuoglu, K., Ranzato, M., And Lecun, Y. (2009).** What Is the Best Multi-Stage Architecture for Object Recognition? In 2009 IEEE 12th International Conference on Computer Vision, Pages 2146–2153. IEEE
- [39] **Indolia, S., Goswami, A. K., Mishra, S., And Asopa, P. (2018).** Conceptual Understanding of Convolutional Neural Network-A Deep Learning Approach. *Procedia Computer Science*, 132 :679–688.
- [40] **Gamboa, JCB (2017).** Apprentissage profond pour l’analyse de séries chronologiques. préimpression arXiv arXiv:1701.01887 .
- [41] **Zheng et al. 2014**
- [42] **Zhao et al. 2017**
- [43] **B. Braunschweig(2016),** "Intelligence artificielle - livre blanc", pp. 1–21
- [44] **Ruffini et al. 2016, Malhotra et al. 2017**
- [45] **Williams et al. 2002, Dunis & Huang 2002**
- [46] **Xingjian S, Chen Z, Wang H, Yeung DY, Wong WK, Woo WC (2015)** Convolutional lstm network: a machine learning approach for precipitation nowcasting. *Adv Neural Inf Process Syst* 28:802–810
- [47] **Poongadan, S., Lineesh, M.C.(2024).** Non-linear Time Series Prediction using Improved CEEMDAN, SVD and LSTM. *Neural Process Lett* 56, 164 .
<https://doi.org/10.1007/s11063-024-11622-z>
- [48] **Neural Comput & Applic (2024).** Zhang, Y., Xu, S., Zhang, L. et al. Short-term multi-step-ahead sector-based traffic flow prediction based on the attention-enhanced graph convolutional LSTM network (AGC-LSTM). <https://doi.org/10.1007/s00521-024-09827-3>
- [49] **Wang, W., Shao, J. & Jumahong,(2023).** H. Fuzzy inference-based LSTM for long-term time series prediction. *Sci Rep* 13, 20359. <https://doi.org/10.1038/s41598-023-47812-3>
- [50] <https://www.asimovinstitute.org/neural-network-zoo/>

- [51] **MITPress.2016.**DeepLearning.IanGoodfellow,YoshuaBengio,AaronCourville.
- [52] **Lee, D., Kim, B., Kim, T. et al.(2024)** A ResNet-LSTM hybrid model for predicting epileptic seizures using a pretrained model with supervised contrastive learning. *Sci Rep* 14, 1319 (2024). <https://doi.org/10.1038/s41598-023-43328-y>
- [53] **Solène Kojtych.(2019).** Introduction au traitement du signal et à l'analyse fréquentielle par transformées de Fourier. [Rapport Technique] École polytechnique de Montréal. 2019. fahal-02193929v1f
- [54] **Shoeb, A. H., & Guttag, J. V. (2010).** "Application of machine learning to epileptic seizure detection." *Proceedings of the 27th International Conference on Machine Learning (ICML).*
- [55] **Ulhaq, Sajad & Khan, Gul Zaman & Ulhaq, Imran & Ullah, Inam & Rabbi, Fazal. (2023).** Epilepsy Seizures Classification with EEG Signals: A Machine Learning Approach. *Journal of Computer Science and Technology Studies.* 5. 25-34. 10.32996/jcsts.2023.5.3.3.
- [56] **Nhan Duy Truong, Anh Duy Nguyen, Levin Kuhlmann, Mohammad Reza Bonyadi, Jiawei Yang, Samuel Ippolito, Omid Kavehei.(2018),**Convolutional neural networks for seizure prediction using intracranial and scalp electroencephalogram,*Neural Networks*,Volume 105,2018,
- [57] **Ibtissem Khouaj,** magerie cérébrale : Traitement et Modélisation Embarqués. Imagerie médicale. Université Paris-Est, 2017. Français. ⟨NNT : 2017PESC1120⟩. ⟨tel-01741479v2⟩
- [58] **S. A. Dhondiyal and S. C. Dimri,** "Diagnosis, Treatment and Containment of Epilepsy Disease," *2022 Seventh International Conference on Parallel, Distributed and Grid Computing (PDGC)*, Solan, Himachal Pradesh, India, 2022, pp. 269-275, doi: 10.1109/PDGC56933.2022.10053220.
- [59] **Obeid, I., & Picone, J,(2018).** The Temple University Hospital EEG Data Corpus. In *Augmentation of Brain Function: Facts, Fiction and Controversy.* Volume I: Brain-Machine Interfaces (1st ed., pp. 394–398). Lausanne, Switzerland: Frontiers Media S.A.

RÉSUMÉ

Résumé

L'apprentissage profond a révolutionné de nombreux domaines, y compris le domaine médical.

Traditionnellement, l'analyse des signaux EEG pour détecter les crises d'épilepsie nécessitait une inspection visuelle longue et épuisante par un expert. Cependant, avec l'avènement du DL, ces tâches peuvent désormais être automatisées et optimisées. Cette recherche vise à développer un modèle combinant les CNN et LSTM pour la prédiction des crises d'épilepsie. Le modèle utilise des couches convolutionnelles pour extraire des caractéristiques spatiales des signaux EEG, suivies de couches LSTM pour capturer les dépendances temporelles. Cela permet d'améliorer la précision de la prédiction des crises, offrant ainsi des données détaillées et fiables aux cliniciens pour le traitement de l'épilepsie. Les résultats de cette étude montrent que, même s'il est encore possible d'améliorer le modèle CNN-LSTM, celui-ci montre déjà une progression significative et une précision satisfaisante selon les métriques utilisées, surpassant les méthodes traditionnelles. Cela met en évidence le potentiel des techniques d'apprentissage profond pour la prédiction précoce des crises d'épilepsie et l'amélioration des systèmes de surveillance et d'alerte pour les patients épileptiques.

Mots clés: Apprentissage profond, Séries temporelles, EEG, Crises d'épilepsie, CNN, LSTM, Prédiction.

Abstract

Deep learning has revolutionized many fields, including medicine.

Traditionally, analyzing EEG signals to detect epileptic seizures required time-consuming and exhausting visual inspection by an expert. However, with the advent of DL, these tasks can now be automated and optimized. The aim of this research is to develop a model combining CNN and LSTM for predicting epileptic seizures. The model uses convolutional layers to extract spatial features from EEG signals, followed by LSTM layers to capture temporal dependencies. This improves the accuracy of seizure prediction, providing clinicians with detailed and reliable data for the treatment of epilepsy. The results of this study show that, although there is still room for improvement, the CNN-LSTM model already shows significant progress and satisfactory accuracy according to the metrics used, outperforming traditional methods. This highlights the potential of deep learning techniques for the early prediction of epileptic seizures and the improvement of monitoring and warning systems for epileptic patients.

Key-words: Deep learning, Time series, EEG, Epileptic seizures, CNN, LSTM, Prediction.

ملخص

لقد أحدث التعلم العميق ثورة في العديد من المجالات، بما في ذلك المجال الطبي.

تقليدياً، كان تحليل إشارات مخطط كهربية الدماغ (EEG) للكشف عن نوبات الصرع يتطلب إجراء فحص بصري مرهق ويستغرق وقتاً طويلاً من قبل خبير. ومع ذلك، مع ظهور DL، يمكن الآن أتمتة هذه المهام وتحسينها. يهدف هذا البحث إلى تطوير نموذج يجمع بين CNN و LSTM للتنبؤ بنوبات الصرع. يستخدم النموذج طبقات تلافيفية لاستخراج السمات المكانية من إشارات تخطيط كهربية الدماغ، تليها طبقات LSTM للتقاط التبعيات الزمنية. ويساعد ذلك على تحسين دقة التنبؤ بالنوبات، وتوفير بيانات مفصلة وموثوقة للأطباء لعلاج الصرع. تظهر نتائج هذه الدراسة أنه حتى لو كان لا يزال من الممكن تحسين نموذج CNN-LSTM، فإنه يظهر بالفعل تقدماً كبيراً ودقة مرضية وفقاً للمقاييس المستخدمة، متجاوزاً الطرق التقليدية. وهذا يسلط الضوء على إمكانات تقنيات التعلم العميق للتنبؤ المبكر بنوبات الصرع وتحسين أنظمة المراقبة والتنبيه لمرضى الصرع.

الكلمات المفتاحية: التعلم العميق، السلاسل الزمنية، مخطط كهربية الدماغ، نوبات الصرع، التنبؤ.

CNN، LSTM