

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Université Oran 1, Ahmed Ben Bella

Institut des Sciences et Techniques Appliquées (ISTA)

Département d'Instrumentation et Métrologie (IM).



Thème

Détection des anomalies EEG par l'analyse de son signal.

Projet soumis à l'Institut des Sciences et Techniques Appliquées
en vue de l'obtention du diplôme de Master Professionnel en Instrumentation et Métrologie.

Préparer par :

KHADIR Djerida Asma.

Présenté et soutenu devant le jury le 21 JUIN 2026, composé de :

Présidente

Mme HAMDANI Nesrine

Université d'Oran.

Examineur

Benameur Rabie

Université d'Oran.

Encadrante

Mme TRACHE Najia

Université d'Oran.



Résumé :

Ce mémoire vise à développer un modèle basé sur l'apprentissage profond pour la détection précoce des crises épileptiques, améliorant ainsi le diagnostic médical électronique des maladies neurologiques, et contribuant à une meilleure prise en charge de cette pathologie répandue. Le modèle proposé repose sur un réseau neuronal convolutif (CNN) combiné aux unités récurrentes fermées (GRU) et à une machine à vecteurs de support (SVM), entraîné sur deux jeux de données représentés par la base CHB-MIT.

Mots-clés : apprentissage profond, détection des crises épileptiques, diagnostic médical électronique, épilepsie, CNN, GRU, SVM, CHB-MIT.

الملخص

يهدف هذا البحث إلى تطوير نموذج يعتمد على التعلم العميق للكشف المبكر عن نوبات الصرع، مما يُحسن التشخيص الطبي الإلكتروني للأمراض العصبية، وخاصة الصرع، ويساهم في تحسين إدارة هذا المرض المنتشر. فما رأينا من طريقة أنسب منه لتحديد المرضى المصابين بالنوبات من الأصحاء. النموذج الذي طرحناه يعتمد على الشبكة العصبية التلافيفية (CNN) متحدة مع الوحدات المتكررة المغلقة (GRU) وآلة المتجهات الداعمة (SVM) بتدريبه على مجموعتي بيانات متمثلتان في الـ CHB-MIT.

الكلمات المفتاحية: التعلم العميق، الكشف عن النوبات الصرعية، التشخيص الطبي الإلكتروني، الصرع، الشبكات العصبية التلافيفية، الوحدات المتكررة المغلقة، آلة المتجهات الداعمة CHB-MIT.

Abstract:

This thesis aims to develop a deep learning-based model for early detection of epileptic seizures, thereby improving electronic medical diagnosis of neurological diseases, particularly epilepsy, and contributing to better management of this widespread condition.

The proposed model relies on a convolutional neural network (CNN) combined with gated recurrent units (GRU) and a support vector machine (SVM), trained on two datasets represented by the CHB-MIT database.

Keywords: deep learning, disease prevalence, electronic medical diagnosis, epileptic seizure detection, CNN, GRU, SVM, CHB-MIT.

Remerciements

الحمد والشكر لله أولاً وآخراً

Qui m'a guidé et m'a donné la force et la patience pour mener à bien ce travail.

À mes chers parents,

Aucun mot, aucun hommage ne pourraient jamais exprimer la profondeur de ma gratitude et de mon amour. Si je suis ici aujourd'hui, et si ce projet a vu le jour, c'est d'abord grâce à ALLAH, puis grâce à vous. Tout ce succès vous appartient.

Je tiens à exprimer ma profonde gratitude envers mon encadrante, Mme TRACHE Najia, pour ses avis éclairés, ses conseils avisés, son soutien indéfectible et sa disponibilité constante.

Mes sincères remerciements lui sont adressés.

Mes remerciements vont également à l'ensemble des membres du jury, pour l'intérêt porté à mon travail et leur participation à son évaluation. J'espère que cette thèse répondra à leurs attentes.

Je suis également reconnaissant envers tous les enseignants qui ont joué un rôle dans mon parcours éducatif et enrichi ma connaissance sans exception.

Je souhaite remercier mes frères, sœurs (Karima et chahinez), amis et toutes les personnes qui m'ont apporté leur aide, que ce soit de manière directe ou indirecte, dans la réalisation de ce modeste travail.

À mes plus proches amis, pour les rires partagés, l'encouragement mutuel, le soutien et cette précieuse amitié qui m'a tant apporté au fil des années. Merci d'être les meilleurs amis que je pouvais espérer.

Mon collègue de stage Warda, Mes collègues d'ISTA, MERCI.

Djerida Asma

Sommaire :

Introduction Générale	V
CHAPITRE 01 :	6
Éléments fondamentaux pour la détection automatique d'anomalies EEG	6
I.1 Introduction :	7
I.2 Généralités sur les signaux EEG	7
I.3 Chaîne de conditionnement et de numérisation	9
I.4 Nature et Caractéristiques temporelles / spectrales du signal EEG	9
I.5 Anomalies EEG typiques : signatures épileptiformes [6]	11
I.6 Artefacts en EEG : origines et impact sur l'analyse de l'EEG.	12
I.7 Conclusion	13
CHAPITRE 02 :	14
II.1 Introduction :	15
II.2 Notion de classification :	15
II.3 Méthodologie :	17
II.3.1 Source des données :	21
II.3.2 PRÉTRAITEMENT DE BASE DE DONNÉES CHOISSE :	23
II.4 Conclusion :	33
CHAPITRE 03 :	34
III.1 Introduction :	35
III.2 Présentation de la méthodologie et de l'architecture hybride :	35
III.3 MÉTRIQUES DE PERFORMANCE	36
III.4 RÉSULTATS DES DIFFÉRENTES COMBINAISONS D'ALGORITHMES DE DÉTECTION DE CRISES D'ÉPILEPSIE :	37
III.5 Conclusion :	43
Conclusion Générale :	44
Références	45

Liste des figures :

Figure 1 1: Système d'acquisition du signal EEG 10-20.....	8
Figure 1 2: Différents types d'Electrodes.....	8
Figure 1 3: Principaux rythmes extraits d'un EEG réel.....	10
Figure 1 4: Diagramme d'Ishikawa des sources d'artéfacts affectant le signal EEG.	13
Figure 2 1: (a) représente le neurone biologique et (b) représente la structure de base d'un neurone artificiel.....	16
Figure 2 2: La structure du modèle CNN.....	17
Figure 2 3: La structure du modèle LSTM.....	18
Figure 2 4: La structure du modèle GRU.	18
Figure 2 5: La structure de séparation SVM.	19
Figure 2 6: organigramme présentatif de chaine utiliser pour la classification des signaux EEG.	20
Figure 2 7: Exemple de Traitement réalisé par (Deepa & Ramesh, 2022) pour former deux classes de données (épileptiques et non épileptiques) à partir de la base de données CHB-MIT originale [27].	23
Figure 2 8: Segmentation d'un signal EEG [31]	26
Figure 2 9 : Segmentation de la base de données CHB-MIT prétraitée [27].	26
Figure 2 10: Exemple de décomposition en ondelettes discrètes [33].	27
Figure 2 11: Exemple de décomposition à 4 niveaux [33].	28
Figure 2 12: Exemple de graphe de DSP dans MATLAB [43].	30
Figure 2 13: Exemple de graphe de l'écart type présenter sur le MATLAB [33].	30
Figure 2 14 : Exemple de graphe d'entropie présenter sur le MATLAB [43].	31
Figure 2 15: Exemple présentatif d'énergie sur le MATLAB [43].	32
Figure 3. 1: Vote de majorité appliqué sur les classificateurs du projet.	37
Figure 3. 2: bibliothèques utilise sur python.....	37
Figure 3. 3: Comparaison des performances des modèles de classification EEG.....	40
Figure 3. 4: Décomposition en ondelettes discrètes (DWT) du signal EEG — Canal Fp1.	41
Figure 3. 5: Distribution de l'énergie par bande de fréquence après décomposition en ondelettes (DWT).....	42

Liste des Tables :

Table 1 1: Caractéristiques des rythmes physiologiques.	10
Table 2 1: comparaison entre les bases de données.....	23
Table 2 2: les ordres de filtre Butterworth.....	24
Table 2 3: Détails sur les patients de la base CHB-MIT.....	25
Table 2 4: Caractéristiques Extrait pour un signal EEG.....	32
Table 3. 1: Matrice de confusion.	36
Table 3. 2: Comparaison des resultats de matrice de confusion obtenir.	38
Table 3. 3: comparaison des caractéristiques de performance.	38
Table 3. 4: Les caractéristiques extraits par l'application du DWT.....	40

Introduction Générale

L'épilepsie est l'un des troubles neurologiques les plus répandus à l'échelle mondiale, affectant près de 50 millions de personnes. Ce trouble se caractérise par des crises imprévisibles résultant de décharges électriques soudaines et incontrôlables dans le cerveau, dont les manifestations cliniques varient considérablement, allant de brèves absences à des convulsions généralisées sévères. Ces crises représentent un danger majeur pour la santé et la sécurité des patients, engendrant non seulement des risques physiques directs, mais aussi une altération significative de la qualité de vie, en raison notamment de l'anxiété liée à leur survenue. La gravité du phénomène est accentuée par la possibilité de décès subit inattendu chez les personnes épileptiques (SUDEP), renforçant ainsi l'importance cruciale d'un diagnostic précoce et fiable.

La complexité de ce diagnostic tient à la grande diversité des crises, qui varient d'un patient à l'autre selon leur origine cérébrale, leur dynamique, et leurs caractéristiques cliniques. De plus, l'activité neuronale physiologique présente une variabilité constante, influencée par des facteurs tels que l'état de vigilance ou le stress, ce qui complique la discrimination entre manifestations pathologiques et processus normaux. La surveillance traditionnelle repose sur l'analyse visuelle des signaux électroencéphalographiques (EEG) par des neurologues experts, méthode exigeante en temps et limitée dans sa capacité à assurer une surveillance continue au quotidien.

Face à ces défis, les avancées récentes du traitement numérique des signaux, de l'intelligence artificielle et des technologies portables ont favorisé le développement de systèmes automatiques de détection des crises, capables d'assurer une surveillance en temps réel et d'alerter les patients ou leur entourage dès les premiers signes de survenue d'une crise. Ces systèmes s'appuient sur des dispositifs d'acquisition multicanaux (EEG, ECG, accéléromètres, vidéo) et un traitement rigoureux des signaux visant à extraire des caractéristiques discriminantes, alimentant ensuite des modèles de classification allant des approches classiques d'apprentissage automatique aux architectures profondes modernes telles que les réseaux de neurones convolutifs (CNN), récurrents (GRU, LSTM) ou les mécanismes d'attention (Transformers).

Ce mémoire s'inscrit dans cette dynamique en proposant une architecture hybride innovante combinant la puissance d'extraction spatiale des CNN, la modélisation séquentielle des GRU, et la robustesse discriminante des machines à vecteurs de support (SVM). L'objectif principal est d'optimiser à la fois la précision diagnostique et la rapidité d'inférence, afin de répondre efficacement aux exigences des applications cliniques en temps réel.

Nous présenterons ici les fondements théoriques, le développement méthodologique, ainsi que l'évaluation expérimentale de cette approche, en soulignant ses contributions et perspectives dans le cadre de l'analyse automatique des signaux biomédicaux.

CHAPITRE 01 :

**Éléments fondamentaux pour la détection
automatique d'anomalies EEG.**

I.1 Introduction :

L'électroencéphalogramme (EEG) est le principal signal utilisé pour l'analyse de l'activité cérébrale et la détection des anomalies liées à l'épilepsie. Cependant, la complexité et le caractère non stationnaire de ces signaux rendent leur interprétation difficile et leur analyse par un neurologue prend beaucoup de temps et peut varier d'un spécialiste à un autre.

Dans ce contexte, la détection automatique des anomalies dans les signaux EEG constitue une solution prometteuse, essentiellement pour anticiper les crises épileptiques. Les récents progrès en intelligence artificielle, notamment en apprentissage automatique et en apprentissage profond, offrent de nouvelles perspectives pour développer des systèmes de détection plus robustes, adaptatifs et performants.

Dans ce chapitre, nous présentons les éléments nécessaires à la compréhension d'un signal EEG, de ses anomalies, des perturbations qui l'affectent, les principales techniques de traitement du signal, ainsi que les méthodes existantes pour la détection automatique des crises d'épilepsie.

I.2 Généralités sur les signaux EEG

I.2.1 Définition et principe de l'EEG

L'électroencéphalogramme (EEG) est une technique utilisée qui permet d'observer et d'enregistrer l'activité électrique du cerveau. Cette activité est produite par les neurones et peut être captée grâce à des électrodes placées sur le cuir chevelu.

Le principe de l'EEG repose sur la mesure de très faibles variations de potentiel électrique générées par des millions de neurones pyramidaux de couches III et V du cortex, lorsque celles-ci communiquent entre elles. Leurs dendrites et leurs corps cellulaires produisent des courants extracellulaires qui, lorsqu'ils sont synchronisés à grande échelle, deviennent mesurables à la surface du cuir chevelu [1].

Les signaux obtenus sont principalement sous forme d'ondes qui varient dans le temps et donnent des informations sur le fonctionnement du cerveau. Les amplitudes typiques de ces signaux varient entre 10 et 100 μV et sa bande de fréquences est de 0,5 Hz à 70 Hz et parfois jusqu'à 100 Hz pour certaines applications. Ces signaux sont donc très sensibles aux artefacts (mouvements, muscles,...) [2].

I.2.2 Systèmes d'acquisition des signaux EEG

Le système d'acquisition de l'EEG repose sur l'utilisation d'électrodes placées sur le cuir chevelu afin de capter l'activité électrique du cerveau. Cette méthode non invasive et simple à mettre en œuvre, est largement utilisée pour notamment détecter certaines anomalies comme celles liées à l'épilepsie.

Les électrodes d'enregistrement sont positionnées selon une norme internationale appelée système 10-20 qui garantit une répartition homogène sur l'ensemble du crâne, (fig.1) Cette organisation permet d'obtenir des enregistrements comparables d'un patient à un autre et de couvrir les différentes zones cérébrales [3].




Figure 1 1: Système d'acquisition du signal EEG 10-20.

Les électrodes peuvent être de différents types. [4] (fig.2)

- Électrodes cupule (a) : nécessitent un gel conducteur, bonne qualité de signal.
- Électrodes tampon (b) : à base d'eau saline, moins contraignantes.
- Électrodes aiguille (c) : usage clinique ponctuel (urgence, bloc opératoire).
- Électrodes sèches (d) : sans gel, adaptées aux dispositifs portables mais plus bruitées.




Figure 1 2: Différents types d'Electrodes.

Le signal recueilli est une différence de potentiel entre une électrode active et une référence (Figure 1.1).

Plusieurs montages existent :

- Montage bipolaire : mesure la différence entre deux électrodes proches.
- Montage référentiel : toutes les électrodes sont comparées à une même référence (par exemple les oreilles A1/A2).
- Montage moyenne : la référence est la moyenne de toutes les électrodes.

I.3 Chaîne de conditionnement et de numérisation

Le signal EEG brut, capté par les électrodes doit subir une chaîne de conditionnement et de numérisation avant d'être exploité par des algorithmes de détection automatique.

Cette chaîne comprend essentiellement :

- Un amplificateur différentiel qui permet d'amplifier le signal à la sortie des électrodes (de l'ordre du microvolts). À ce stade, il est impossible à numériser ou à analyser car il est masqué par le bruit ambiant. Son rôle est d'augmenter le gain du signal pour faire passer le signal de l'ordre du microvolt à l'ordre du volt.
- Les filtres analogiques : Un filtre passe haut qui élimine les tensions continues et les fréquences très basses, générées par le contact entre la peau, le gel conducteur et l'électrode, et un filtre passe-bas anti-repliement, qui coupe toutes les fréquences supérieures à la moitié de la fréquence à laquelle l'échantillonnage se fera (fréquence de Nyquist).
- Convertisseur Analogique/ Numérique (CAN) : Le signal nettoyé et amplifié est toujours une onde analogique continue. Pour qu'il puisse être traité numériquement, il faut qu'il soit numérisé. Un échantillonneur bloqueur, associé à un convertisseur analogique / Numérique échantillonne le signal à une fréquence typiquement comprise entre 256 et 1024 Hz (256 et 1024 mesures/seconde).
- Quantificateur : Chaque mesure de tension est convertie en une valeur binaire puis quantifié avec une résolution de 16 à 24 bits. Les valeurs numériques ainsi obtenues constituent la matière première des traitements ultérieurs (prétraitement, extraction de caractéristiques, classification)

I.4 Nature et Caractéristiques temporelles / spectrales du signal EEG

L'enregistrement de l'activité électrique corticale représente un rythme biologique qui fluctue au cours de l'alternance veille-sommeil et évolue en fonction de l'âge. Les ondes cérébrales physiologiques se distinguent par leurs fréquences, leurs amplitudes, leur répartition spatiale ainsi que par leur réactivité.

Ainsi, le signal EEG est généralement décrit par sa répartition fréquentielle. Les différents rythmes générés portent des noms en fonction de leur fréquence (nombre d'oscillations en 1 seconde).

On distingue classiquement cinq bandes de fréquences principales, chacune associée à un état fonctionnel du cerveau :

I.4.1 Description des rythmes physiologiques normaux [5]

Le signal EEG d'un sujet sain éveillé présente des rythmes dominants dont les plages de fréquences sont associées à des états fonctionnels suivant le tableau 1.1 :

Rythme	Bande de fréquences	Amplitude	État typique
Delta	0,5 – 4 Hz	Grande ($\sim 50 \mu\text{V}$)	Sommeil profond
Thêta	4 – 8 Hz	Moyenne ($\sim 20 \mu\text{V}$)	Sommeil léger, relaxation profonde
Alpha	8 – 13Hz	Faible ($\sim 10 \mu\text{V}$)	Détente, yeux fermés
Bêta	13 – 30 Hz	Faible ($\sim 10 \mu\text{V}$)	Éveil actif, concentration
Gamma	>30 Hz	Très faible ($<10 \mu\text{V}$)	Perception, conscience

Table 1 1: Caractéristiques des rythmes physiologiques.

Remarque : Il convient toutefois de noter que ces valeurs d'amplitude sont indicatives : elles varient considérablement selon le site d'enregistrement (région frontale, occipitale, etc.), l'âge du sujet (notamment chez l'enfant et le sujet âgé) ainsi que son état de vigilance (éveil calme, sommeil, hyperpnée).




Figure 1 3: Principaux rythmes extraits d'un EEG réel.

- Rythme delta (**< 3,5 Hz**) : Amplitude grande mais variable ; Ce rythme n'est jamais présent chez l'adulte éveillé au repos. Il est enregistré pendant le sommeil profond.
- Rythme thêta (**4-7,5 Hz**) : Il est associé à l'activité subconsciente et observé lors de la relaxation profonde ou de la méditation. Les enfants de moins de 13 ans présentent plus fréquemment ces ondes, qui impactent la production d'hormones pour l'apprentissage, la mémoire et la relaxation contre la douleur.
- Rythme alpha (**8-13 Hz**) : Les ondes alpha sont observées chez les adultes sains, détendus avec les yeux fermés. Elles se manifestent principalement avec une amplitude légèrement plus élevée du côté non dominant. Ce rythme disparaît à l'ouverture des yeux.
- Rythme bêta (**14-30 Hz**) : Il est lié aux comportements, aux actions et aux cinq sens. Il peut être observé dans les lobes frontaux et pariétaux du cerveau et sont associées à la production de cortisol, à l'apprentissage, à la mémoire, à la pleine conscience et à la réflexion et reflètent la capacité de penser et de réagir. Cette activité est retrouvée pendant l'état de veille.
- Rythme gamma (**> 30 Hz**) : Les ondes gamma se situent entre 30 et 70 Hz et concernent l'observation et la conscience. Ces ondes ont une capacité innée et constituent un mélange équilibré de sources d'information tactiles. Les sens et la mémoire sont parfaitement consolidés par les ondes Gamma.

I.5 Anomalies EEG typiques : signatures épileptiformes [6]

Contrairement aux rythmes physiologiques, les anomalies associées à l'épilepsie se manifestent par des décharges paroxystiques brèves, souvent de grande amplitude, qui se distinguent nettement du bruit de fond. Les figures les plus caractéristiques sont :

I.5.1 Phase inter-critique [7] [8]

Durant cette phase, l'EEG présente des signaux transitoires spécifiques :

- ✓ Pointe (spike) : décharge brève durant 20 à 70 ms, de morphologie pointue, généralement suivie d'une onde lente. Elle est le marqueur le plus spécifique d'une hyperexcitabilité neuronale corticale.
 - ✓ Onde pointue (sharp wave) : similaire à la pointe mais plus large (70 à 200 ms). Souvent associée à des foyers épileptogènes.
 - ✓ Complexe pointe-onde lente : association d'une pointe immédiatement suivie d'une onde lente (durée totale ~500 ms). Typique des crises d'absence (épilepsie généralisée).
 - ✓ Poly pointe-onde : répétition de pointes ou d'ondes pointues à une fréquence donnée (3 Hz pour les absences, plus rapide pour les crises focales).
- Ces caractéristiques peuvent apparaître seules ou combinées dans l'EEG.

I.5.2 Phase pré-critique

Cette phase précède la crise et dure de quelques minutes à environ une heure selon les sources. Les signaux EEG varient selon le type de crise.

I.5.3 Phase critique

Lors de la crise elle-même, l'EEG montre souvent :

- ✓ Une synchronisation des signaux avec oscillations à fortes amplitudes.
- ✓ Une accentuation des faibles fréquences autour de 5 Hz (ondes thêta).
- ✓ Une accentuation des hautes fréquences autour de 10 Hz.

Ces anomalies peuvent être focalisées (un seul site électrode) ou généralisées (toutes les dérivations). Leur détection automatique est difficile car elles sont brèves, de forme variable et souvent noyées dans du bruit ou des artefacts physiologiques (voir section I.4).

I.6 Artefacts en EEG : origines et impact sur l'analyse de l'EEG.

L'EEG n'enregistre pas que l'activité du cerveau. Il capte aussi des signaux indésirables, appelés artefacts, qui viennent se mélanger aux ondes cérébrales. Ces perturbations peuvent être causées par le patient lui-même (bouger les yeux, serrer les mâchoires, battements du cœur) ou par l'environnement (câbles qui bougent, courant électrique du secteur). Si on ne les identifie pas, ces parasites risquent de ressembler à des anomalies épileptiques ou de masquer de vraies crises. Il est donc essentiel de savoir les reconnaître avant d'analyser l'EEG.

I.6.1 Artefacts physiologiques [9]

- ✓ Mouvements oculaires : clignement des paupières (onde lente frontale), mouvements latéraux des yeux.
- ✓ Activité musculaire (EMG) : contractions des muscles du cuir chevelu ou de la mâchoire, générant des fréquences élevées (>30 Hz) qui se superposent au rythme gamma.
- ✓ Activité cardiaque (ECG) : faible mais parfois visible sur les dérivations temporelles.

I.6.2 Artefacts extra-physiologiques (instrumentaux)

Ces perturbations proviennent de l'équipement ou de l'environnement électrique de la pièce

- ✓ Réseau électrique (50/60 Hz) : interférence capacitive ou inductive, souvent filtrée numériquement.
- ✓ Mouvement des électrodes : variations brusques de potentiel de contact.

- ✓ Bruit de quantification et de l'amplificateur : affecte surtout les très faibles amplitudes.
- ✓ Filtres inadaptés : réglages incorrects des filtres passe-haut ou passe-bas.

I.6.3 Modélisation systémique des sources de bruit : Diagramme d'Ishikawa

Le diagramme d'**Ishikawa**, en figure 4 regroupe l'ensemble des artefacts que peut subir un signal EEG




Figure 1 4: Diagramme d'Ishikawa des sources d'artefacts affectant le signal EEG.

I.7 Conclusion

Le premier chapitre a montré que le signal EEG est prépondérant dans le diagnostic de l'épilepsie. Cependant, le signal présente plusieurs verrous scientifiques liés à son interprétation automatique : une amplitude extrêmement faible, une forte non-stationnarité et la présence d'artefacts (physiologiques et instrumentaux) modélisés par le diagramme d'Ishikawa. Bien que la chaîne matérielle d'acquisition assure une première numérisation, le signal brut demeure trop bruité pour une classification directe. Cela justifie l'introduction, au Chapitre 2, d'un prétraitement numérique rigoureux (filtrage logiciel, fenêtrage) couplé à des architectures d'apprentissage profond (CNN, LSTM/GRU, SVM) afin d'extraire de manière robuste les signatures de crises.

CHAPITRE 02 :

**Méthodologie de prétraitement et conception
d'une architecture de classification d'un
signal EEG**

II.1 Introduction :

L'activité électrique du cerveau se manifeste par différents rythmes oscillatoires (delta, thêta, alpha, bêta, gamma), dont l'analyse dans le cadre de l'épilepsie est compliquée par la nature non linéaire et changeante des signaux EEG. Ces caractéristiques rendent difficile l'extraction manuelle des motifs pathologiques, ce qui justifie l'utilisation de méthodes d'apprentissage automatique et profondes pour détecter automatiquement des représentations discriminantes.

Parmi les techniques utilisées, les SVM misent sur la maximisation de la marge de séparation pour la classification binaire, tandis que les CNN réalisent une extraction hiérarchique des caractéristiques spatiales via des opérations de convolution. Les réseaux LSTM et GRU modélisent les dépendances temporelles présentes dans les séquences EEG, avec le GRU proposant une architecture simplifiée à deux portes, adaptée à des déploiements embarqués grâce à sa moindre complexité.

Cette étude évalue ces différentes approches, allant de l'extraction manuelle des caractéristiques avec le SVM aux modèles hybrides profonds, afin de mesurer leur efficacité respective dans la détection automatique des crises épileptiques.

II.2 Notion de classification :

La classification est effectivement l'une des techniques clés en médecine, notamment comme fondement des systèmes d'aide au diagnostic.

Elle consiste à structurer un ensemble d'observations en groupes homogènes et contrastés, pour simplifier l'analyse des données et permettre des prédictions fiables [10]. Dans le contexte des encéphalogrammes (EEG), cela signifie attribuer chaque enregistrement à une classe définie selon un descripteur précis, basé sur des propriétés ou conditions caractéristiques propres à chaque classe. Les signaux sont donc classés selon qu'ils remplissent ou non ces critères.

Plusieurs méthodes de classification sont couramment employées pour analyser les signaux EEG, parmi lesquelles on trouve :

- ANN (réseaux de neurones artificiels) [11]
- ANFIS (système neuro-flou adaptatif) [12]
- KNN (algorithme des K plus proches voisins) [13]
- RBFNN (réseaux de neurones à base radiale) [14]
- RNN (réseaux de neurones récurrents) [15]
- SVM (machines à vecteurs support) [16]

Pour différencier les sujets épileptiques des sujets normaux, la classification repose sur des règles d'apprentissage, sujet que nous approfondirons dans la section suivante :

II.2.1 Notion d'apprentissage :

L'apprentissage artificiel : est une branche de l'intelligence artificielle utilisée notamment pour résoudre des problèmes de prédiction [11]. Il se divise en deux grandes familles :

- ✓ **Apprentissage non supervisé** : l'algorithme organise lui-même les données d'entrée sans informations externes, identifiant des structures statistiques sous-jacentes et créant une représentation interne simplifiée de l'espace des données [17].
- ✓ **Apprentissage supervisé** : un modèle de prédiction est créé à partir d'un jeu de données d'apprentissage composé d'exemples d'entrée et de leurs sorties désirées. Le modèle s'adapte en comparant ses prédictions aux sorties attendues, ce qui justifie le terme « supervisé » [18]. Ce dernier type est souvent utilisé pour la classification des signaux EEG, comme dans les systèmes d'aide au diagnostic épileptique.

II.2.2 Classification par les réseaux de neurones artificiels [17] :

La classification à l'aide des réseaux de neurones artificiels (RNA) est une méthode très efficace. Elle se distingue par sa capacité d'approximation universelle, sa rapidité dans la prise de décision et sa bonne capacité de généralisation.

- Fonctionnement général d'un réseau de neurone formel :

Un réseau de neurones artificiel est un modèle informatique inspiré du fonctionnement des neurones biologiques dans notre cerveau. Chaque neurone artificiel est une unité de traitement qui comprend :

- Des nœuds d'entrée qui reçoivent les données.
- Des connexions synaptiques entre ces nœuds, chacune associée à un poids qui représente la force de la connexion.
- Une fonction d'activation (notée généralement φ) qui transforme les entrées pondérées en une sortie unique du neurone.

Cette structure permet au réseau de traiter et de classifier des données complexes comme les signaux EEG, en apprenant à partir d'exemples.

La figure (2.1) illustre le schéma d'un neurone biologique ainsi que la structure d'un neurone artificiel (formel).

Dans ce projet, nous choisissons de combiner plusieurs modèles connus (CNN, GRU, SVM) afin de concevoir un modèle efficace. Cette approche permet de bénéficier pleinement des avantages spécifiques à chacun de ces modèles.




Figure 2 1: (a) représente le neurone biologique et (b) représente la structure de base d'un neurone artificiel.

II.3 Méthodologie :

a. Le modèle CNN :

Le CNN est l'une des méthodes d'apprentissage profond les plus performantes. Il se compose de quatre couches principales, à savoir : input layer, convolutional layer, pooling layer, and fully connected layer. Ses structures de réseau incluent 1D CNN, 2D CNN et 3D CNN [19].

- 1D CNN est principalement utilisé pour le traitement des données de séquence,
- 2D CNN est souvent utilisé pour la reconnaissance d'images et de texte,
- le CNN 3D est généralement utilisé pour la reconnaissance d'images médicales et de données vidéo.

Dans ce travail, le 1D CNN est adopté afin d'exploiter efficacement les caractéristiques temporelles des segments EEG, tout en réduisant la complexité du modèle par rapport aux architectures 2D ou 3D.




Figure 2 2: La structure du modèle CNN.

- **Avantage** : Capture automatiquement les motifs (pics, pointes-ondes) sans extraction manuelle complexe.

b. Le modèle LSTM :

Les réseaux de mémoire longue LSTM à court terme sont considérés comme un type particulier de réseaux neuronaux récurrents ajoutant une cellule mémoire dans une couche cachée, elle est capable de stocker sélectivement des modèles pendant une longue période. C'est un choix idéal pour modéliser des données séquentielles et c'était notre motivation pour le choisir, ainsi que pour apprendre la dynamique complexe de l'activité humaine [20].




Figure 2 3: La structure du modèle LSTM.

c. GRU (Gated Recurrent Unit) :

Le GRU est une alternative simplifiée au LSTM. Il remplit la même fonction (la modélisation de données séquentielles), mais utilise une structure plus simplifiée.

Fonctionnement : au lieu des trois portes présentes dans un LSTM, un GRU n'en utilise que deux : une porte de mise à jour et une porte de réinitialisation. En fusionnant les portes d'oubli et d'entrée en une seule porte de mise à jour et en éliminant l'état de cellule distinct, la GRU est plus efficace sur le plan computationnel et souvent plus rapide à entraîner, tout en conservant des performances comparables sur de nombreuses tâches [21].




Figure 2 4 : La structure du modèle GRU.

- ✓ Remarque : pour notre travail, nous choisissons le modèle GRU en raison de ses caractéristiques plus simples que celles du LSTM.

d. SVM (Support Vector Machine) :

Contrairement aux deux précédents, le SVM n'est pas un RNN. Il s'agit d'un puissant algorithme d'apprentissage supervisé utilisé principalement pour la classification et parfois pour la régression [22].

Fonctionnement : L'objectif d'une SVM est de trouver l'« hyperplan » optimal dans un espace multidimensionnel qui sépare le mieux les points de données en différentes classes. Elle maximise la « marge », c'est-à-dire la distance entre l'hyperplan et les points de données les plus proches de chaque classe (appelés vecteurs de support). Si les données ne sont pas séparables linéairement, les SVM utilisent l'« astuce du noyau » pour projeter les données dans un espace de dimension supérieure où elles peuvent être séparées [23].




Figure 2 5: La structure de séparation SVM.

✓ **Avantages du modèle hybride par rapport aux modèles simples**

- Les CNN seuls peuvent manquer de capturer les relations temporelles complexes.
- Les LSTM ou GRU seuls peuvent ne pas extraire efficacement les caractéristiques spatiales locales.
- Les SVM seuls nécessitent des vecteurs de caractéristiques bien conçus et peuvent avoir du mal avec des données non linéaires brutes.

Le modèle hybride combine donc le meilleur des trois mondes : extraction locale, modélisation temporelle et classification optimale, assurant une performance supérieure dans la classification des signaux EEG, notamment pour la détection des crises d'épilepsie.




Figure 2 6: organigramme présentatif de chaine utiliser pour la classification des signaux EEG.

II.3.1 Source des données :

Pour l'entraînement et la validation des modèles d'apprentissage automatique développés dans ce projet, la base de données CHB-MIT (Hospital for Sick Children, Boston) a été privilégiée. Cette base est largement reconnue et fréquemment utilisée par de nombreux chercheurs, notamment (Acharya et al. (2015) [24], Anuragi et al. (2022) [25], Elhosary et al. (2021) [26], Shoeb & Guttag (2010) [27], Slimen et al. (2020) et Subasi (2007a) [28]), pour ne citer qu'eux. Son choix repose sur sa disponibilité publique, sa complétude et sa facilité d'utilisation. Elle comprend des enregistrements EEG continus provenant de plusieurs patients épileptiques, intégrant à la fois des phases intercritiques et des épisodes de crise, ce qui permet une évaluation solide et représentative des performances des algorithmes de détection automatique. Par ailleurs, la diversité des signaux EEG recueillis sur plusieurs canaux confère une richesse d'information particulièrement favorable à l'entraînement et à la validation des architectures d'apprentissage profond.

- Bases de données CHB-MIT :

La base de données CHB-MIT a été collectée par une équipe de chercheurs de l'Hôpital pour enfants de Boston (CHB) et du Massachusetts Institute of Technology (MIT). Elle contient des enregistrements EEG de 22 patients pédiatriques souffrant de crises épileptiques résistantes, en attente d'une intervention chirurgicale. Ces données, regroupées en 23 cas (dont un cas avec deux enregistrements à 1,5 an d'intervalle sur le même sujet), concernent 5 garçons âgés de 3 à 22 ans et 17 filles âgées de 1,5 à 19 ans. Les enregistrements sont échantillonnés à 256 Hz avec une résolution de 16 bits, comportent majoritairement 23 canaux EEG selon le standard international 10-20, sauf quelques cas avec 24 ou 26 canaux. Pour protéger la confidentialité, les dates réelles ont été remplacées par des dates fictives [29].

Pour ce projet, ce ne sont pas les données brutes accessibles sur PhysioNet qui ont été utilisées, mais la version prétraitée proposée par Deepa & Ramesh (2022) [30]. En effet, les enregistrements bruts comprennent à la fois des périodes critiques (crises) et inter-critiques (sans crise), et leur segmentation demande un travail manuel fastidieux. Deepa & Ramesh ont extrait et regroupé ces périodes en deux fichiers distincts pour 23 patients, facilitant ainsi l'organisation des données en deux classes : épileptique et non-épileptique. Chaque fichier est structuré avec 23 canaux homogènes, simplifiant l'analyse et l'entraînement des modèles.

L'utilisation de cette version prétraitée garantit une organisation claire et homogène, évite les erreurs liées au travail manuel d'annotation, et permet la comparaison directe avec d'autres études utilisant la même base, assurant ainsi fiabilité et reproductibilité scientifique dans le projet.

Chapitre 2 : Méthodologie de prétraitement et conception d'une architecture de classification d'un signal EEG

- Justification du choix de la base de données CHB-MIT :

Voici un tableau comparatif réorganisé, centré sur les critères pertinents pour le choix dans le cadre des maladies épileptiques :

Critère	CHB-MIT	Université de Bonn	Freiburg	TUH EEG	NeuroVista (NEDC)
Type d'enregistrement	EEG scalp continu, multicanal	EEG scalp, segments courts, monocanal	EEG intracrânien (IEEG)	EEG scalp hétérogène	EEG intracrânien longitudinale
Nombre de canaux	Jusqu'à 23 canaux	1 canal	Jusqu'à 6 canaux intracrâniens	Variable (19–128 canaux)	16 canaux intracrâniens
Nombre de sujets	23 patients pédiatriques	5 sujets sains + 5 patients	21 patients	>10 000 sujets (ensemble mixte)	15 patients
Nombre de crises	~198 crises documentées	100 segments par classe (A–E)	Non précisé publiquement	Déséquilibré, crises rares	Quelques crises par patient
Durée des enregistrements	Plusieurs jours de monitoring continu	Segments de 23,6 secondes	Quelques heures à quelques jours	Variable, segments courts	Plusieurs mois
Accessibilité	Publique et gratuite (PhysioNet)	Publique et gratuite	Privée (accès restreint)	Publique (licence requise)	Privée (accès très restreint)
Population cible	Enfants épileptiques	Adultes sains et épileptiques	Adultes épileptiques résistants	Population générale mixte	Adultes épileptiques résistants
État des patients	Crises spontanées naturelles	États contrôlés (yeux ouverts/fermés)	Crises spontanées	Mixte (critiques et non critiques)	Crises spontanées naturelles
Avantage principal	Données complètes, réalistes et reproductibles	Simplicité, faible complexité computationnelle	Haute résolution spatiale intracrânienne	Très grande taille d'échantillon	Monitoring ultra-longitudinal
Inconvénient principal	Bruit physiologique présent (mouvements, artefacts)	Manque de réalisme clinique (monocanal, segments courts)	Non reproductible, accès limité	Hétérogénéité et déséquilibre des classes	Accès quasi impossible, coût élevé

Pertinence pour l'implémentation matérielle	Moyenne (multicanal complexe)	Élevée (monocanal simple)	Faible (intracrânien invasif)	Faible à moyenne	Faible (intracrânien invasif)
Pertinence pour l'apprentissage profond	Élevée (données riches et variées)	Faible (données limitées)	Moyenne (taille réduite)	Moyenne (bruit et déséquilibre)	Faible (accès limité)
Reproductibilité scientifique	Excellente	Bonne	Faible	Moyenne	Très faible

Table 2 1: comparaison entre les bases de données.

- ✓ Le choix de la base CHB-MIT s'explique par sa triple pertinence : clinique, ciblant une population pédiatrique pharmacorésistante en monitoring pré-chirurgical, technique, avec des données multi-canaux enregistrées en continu au niveau du scalp, et méthodologique, étant devenue une référence pour l'évaluation comparative internationale. Elle constitue ainsi une base idéale pour valider un pipeline CNN-LSTM/GRU dédié à une détection non invasive et en temps réel.

II.3.2 PRÉTRAITEMENT DE BASE DE DONNÉES CHOISSE :

Le prétraitement des données constitue une étape fondamentale en apprentissage automatique, qui permet de les préparer au modèle de classification afin d'éviter plus tard des problèmes de sous ou de sur-apprentissage. Cette phase inclut une série d'opérations appliquées aux données brutes pour en améliorer la qualité avant leur utilisation. Parmi ces opérations, on retrouve le filtrage du bruit, la normalisation des valeurs et la segmentation des données. Étant donné la sensibilité du signal EEG au bruit, un prétraitement standardisé est appliqué à la base de données CHB-MIT.




Figure 2 7: Exemple de Traitement réalisé par (Deepa & Ramesh, 2022) pour former deux classes de données (épileptiques et non épileptiques) à partir de la base de données CHB-MIT originale [27].

II.3.2.1 Filtration du signal

L'objectif de la filtration du signal est d'éliminer les informations inutiles dans le signal EEG, afin de garantir que le reste du système traite uniquement les véritables signaux cérébraux, et non les bruits induits dans ces derniers ou les deux en même temps. Deux sources majeures d'artéfacts peuvent contaminer les signaux EEG : les artéfacts d'origine interne comme clignements des yeux, activités musculaires, mouvements oculaires et ceux d'origine externe comme le bruit des électrodes, les interférences des fils électriques, etc. [31]

Différentes techniques sont proposées dans la littérature pour éliminer le bruit des signaux EEG. Parmi elles, l'analyse en composantes indépendantes (ICA) traite chaque composante séparément en se basant sur la variance la plus importante des signaux. Cette méthode permet de retirer les artéfacts, car leur variance est généralement plus élevée que celle du signal EEG réel (Kappel et al, 2017). Une autre méthode est l'analyse en composantes principales multi-échelle (MSPCA) qui combine les bénéfices du PCA et des ondelettes pour débruiter efficacement le signal (Alickovic et al, 2018). En complément, des filtres à réponse impulsionnelle finie (FIR) ont été utilisés pour le traitement du bruit (Geethu & Santhoshkumar, 2020; Jose et al., 2020; Saidi et al., 2018; Wickramasuriya et al., 2015), tout comme les filtres à réponse impulsionnelle infinie (IIR) de Butterworth, qui offrent un meilleur rapport signal sur bruit (SNR), particulièrement dans la prédiction des crises à partir des signaux EEG (Patnaik & Manyam, 2008; Usman et al., 2019). Dans ce projet, on a opté pour un filtre passe-bande IIR de Butterworth, reconnu pour son excellente fonction de lissage [31].

La fonction de transfert d'un filtre passe-bas d'ordre n est :

$$|H(j\omega)| = \frac{1}{\sqrt{1 + (\frac{\omega}{\omega_c})^{2n}}} \quad \text{(Formule 01)}$$

Où ω_c est la fréquence de coupure et n l'ordre du filtre.

$$\omega_{low} = 2\pi f_{low} \quad , \quad \omega_{high} = 2\pi f_{high}$$

Dans le cas d'un passe-bande, deux fréquences de coupure sont définies :

Ordre (n)	Pente (dB/octave)	Avantages	Inconvénients
1-2	6 – 12	Très stable, peu de distorsion de phase.	Atténuation trop lente du bruit.
4	24	équilibre optimal entre réjection et phase.	Compromis standard en recherche.
8-10	48 – 60	Réjection très agressive.	Risque élevé de distorsion de phase (ringings).

Table 2 2: les ordres de filtre Butterworth.

Nous avons choisir un filtre Butterworth d'ordre 4, car cet ordre représente un excellent compromis entre une atténuation efficace des fréquences indésirables (24 dB/octave) et la conservation fidèle de la morphologie des pointes-ondes épileptiques, tout en limitant les distorsions de phase souvent rencontrées avec des ordres plus élevés. Ensuite, les signaux EEG filtrés ont été normalisés à l'aide de la méthode de normalisation z-score.

$$z_i = \frac{x_i - \mu_{base}}{\sigma_{base}} \quad (\text{Formule 02})$$

Où μ_{base} est la moyenne et σ_{base} l'écart-type. Sont calculés spécifiquement pour chaque base (CHB ou autre).

Cette normalisation recentre les données autour d'une moyenne nulle et d'une variance égale à un, ce qui favorise la convergence des algorithmes d'apprentissage automatique et prévient la domination des canaux à forte amplitude lors du processus de classification.

II.3.2.2 Segmentation de signal

La segmentation des signaux EEG constitue une étape cruciale pour la détection des crises épileptiques. Au lieu d'un simple mélange, une approche séquentielle sera privilégiée :

Dans ce travail, une fenêtre fixe de 10 secondes (2560 échantillons par canal à 256 Hz) a été retenue pour la base CHB-MIT, conformément aux recommandations de Shoen et Gutttag (2004, 2010) [27] et Ali et al. (2024) [32]. Cette longueur de segment permet de capturer efficacement les épisodes critiques tout en évitant la dilution des caractéristiques. Le tableau (2.3) fournit des détails sur les patients de la base CHB-MIT. Cependant, Les segments sont extraits sans chevauchement, ce qui évite la redondance entre les échantillons d'apprentissage.

Subject	Gender	Age	seizure	(hh: mm: ss)
chb01	F	11	7	40:33:08
chb02	M	11	3	35:15:59
chb03	F	14	7	38:00:06
chb04	M	22	4	156:03:54
chb05	F	7	5	39:00:10
chb06	F	1.5	10	66:44:06
chb07	F	14.5	3	67:03:08
chb08	M	3.5	5	20:00:23
chb09	F	10	4	67:52:18
chb10	M	3	7	50:01:24
chb11	F	12	3	34:47:37
chb12	F	2	27	20:41:40
chb13	F	3	12	33:00:00
chb14	F	9	8	26:00:00
chb15	M	16	20	40:00:36
chb16	F	7	10	19:00:00
chb17	F	12	3	21:00:24
chb18	F	18	6	35:38:05
chb19	F	19	3	29:55:46
chb20	F	6	8	27:36:06
chb21	F	13	4	32:49:49
chb22	F	9	3	31:00:11
chb23	F	6	7	26:33:30
chb24	-	-	16	21:17:47
Total			185	979:56:07

Table 2 3: Détails sur les patients de la base CHB-MIT.




Figure 2 8: Segmentation d'un signal EEG [31]




Figure 2 9 : Segmentation de la base de données CHB-MIT prétraitée [27].

Ainsi, une fois que tous les signaux EEG ont été filtrés, normalisés et segmentés, le processus de classification se poursuit par l'étape suivante, celle de l'extraction des caractéristiques.

II.3.3 Analyse tempo-fréquentielle :

II.3.3.1 Transformée en ondelette : (outils de Traitement des Electroencéphalogrammes)

L'étude de l'activité cérébrale requiert une analyse quantitative des oscillations qui représentent le transfert d'informations entre différentes populations neuronales. Ces oscillations, enregistrées via l'électroencéphalogramme (EEG), sont des événements transitoires et difficilement prévisibles, même au niveau statistique. Pour mieux comprendre ces phénomènes, il est nécessaire d'analyser les variations fréquentielles de ces signaux [17].

- Transformée en ondelette discrète :

La Transformée en Ondelette Discrète (DWT) est une méthode de représentation multi-résolution qui décompose un signal en plusieurs composantes fréquentielles, comprenant des bandes de basse fréquence et de haute fréquence. Cette décomposition s'obtient en appliquant des filtres passe-bas et passe-haut successivement au signal, permettant ainsi d'isoler les différentes caractéristiques temporelles et fréquentielles du signal à plusieurs échelles.

Notre méthode repose sur une décomposition en ondelettes discrètes afin de construire un vecteur caractéristique qui reflète la morphologie des signaux EEG, offrant ainsi une analyse temps-fréquence conjointe des données. Cette décomposition est effectuée en fonction du type et de l'ordre des ondelettes utilisées pour calculer nos coefficients. Les segments sont décomposés en niveaux en utilisant l'ondelette Biorthogonale (désignée Bior3.5 dans Matlab) [33], ce qui permet d'obtenir les coefficients de détail et un coefficient d'approximation pour chacun des 24 canaux.

Rappelons que la décomposition en ondelettes discrètes permet d'extraire des signaux de sous-bandes présentant une activité à différentes échelles temporelles en faisant passer les signaux EEG à travers une structure de filtrages itératifs, illustrée dans la (Figure 2.10).




Figure 2 10: Exemple de décomposition en ondelettes discrètes [33].

- **H₀** : **filtre passe-bas**, fournissant les coefficients d'approximation (sous-bandes basses fréquences) qui capturent l'activité à grande échelle temporelle, c'est-à-dire les variations lentes du signal.

- **H₁** : **filtre passe-haut**, produisant les coefficients de détail (sous-bandes hautes fréquences) qui mettent en évidence l'activité à petite échelle temporelle, soit les variations rapides. Ce processus itératif, associé à un sous-échantillonnage par un facteur 2, permet de décomposer le signal selon les équations suivantes :

$$y_{bas}[n] = \sum_{-\infty}^{+\infty} x[k] \cdot H_0[2n - k] \quad \text{(Formule 03)}$$

$$y_{haut}[n] = \sum_{-\infty}^{+\infty} x[k] \cdot H_1[2n + 1 - k] \quad \text{(Formule 04)}$$

Où :

- $x[k]$: signal EEG original
- $y_{bas}[n]$: coefficients d'approximation (basse fréquence)
- $y_{Haut}[n]$: coefficients de détail (haute fréquence)

Cette décomposition hiérarchique s'effectue à l'aide de bancs de filtres miroirs en quadrature, qui séparent itérativement le signal en coefficients d'approximation (basses fréquences) et coefficients de détail (hautes fréquences).

À chaque niveau j , la fréquence d'échantillonnage effective est divisée par deux,

La figure illustre (2.11) l'application d'une décomposition en ondelettes discrètes à quatre niveaux sur deux segments EEG provenant du canal FZ-CZ (canal 17) [33].




Figure 2.11 : Exemple de décomposition à 4 niveaux [33].

Le premier segment est extrait d'une phase de crise épileptique, tandis que le second correspond à une activité intercritique normale, sans événement pathologique. L'analyse comparative de cette figure met en évidence des différences significatives sur deux aspects complémentaires :

- **Sur le plan temporel** : La crise se manifeste par une augmentation importante de l'amplitude des oscillations, affectant l'ensemble des coefficients de décomposition, qu'il s'agisse des coefficients d'approximation ou des coefficients de détail aux quatre niveaux de résolution. Cette amplification généralisée reflète l'activité neuronale propre à la décharge épileptique.

- **Sur le plan fréquentiel**, la phase critique se caractérise par l'apparition d'une activité rythmique plus rapide que lors des phases intercritiques. Cette accélération rythmique se traduit par une élévation de la fréquence dominante des composantes spectrales, particulièrement visible dans les coefficients de détail des niveaux supérieurs de la décomposition. Ce déplacement fréquentiel vers les hautes fréquences constitue un biomarqueur distinctif entre l'état pathologique et l'état physiologique normal, justifiant l'utilisation de la décomposition en ondelettes comme outil pertinent pour la détection automatique des crises épileptiques.

II.3.3.2 Extraction des paramètres

Chaque segment a été paramétré selon la procédure suivante :

- Domaine temporel : extraction de la valeur minimale, valeur maximale, énergie, entropie.
- Domaine fréquentiel : calcul de la densité spectrale de puissance.

Ces paramètres sont donnés par :

- Paramètres caractéristiques statistiques

↳ Densité spectrale de puissance [17]:

La densité spectrale de puissance (DSP) représente la quantité d'énergie par unité de fréquence. L'intégrale de la DSP sur une bande de fréquence donnée permet de calculer la puissance moyenne du signal dans cette bande. La DSP est obtenue en prenant le module au carré de la transformée de Fourier de la série temporelle du signal, soit :

$$S = |X|^2/T \quad \text{(Formule 05)}$$

Où X est la transformée de Fourier du signal x(t).

Les valeurs maximales et minimales estimées à partir de la DSP dans chaque sous-bande du signal peuvent être utilisées comme caractéristiques pour la classification :

- Le **maximum** représente la valeur la plus élevée atteinte par le signal.
- Le **minimum** représente la valeur la plus basse atteinte par le signal.
- La **gamme** correspond à l'écart entre les valeurs maximale et minimale du signal.

L'analyse effectuée sur les différents segments est illustrée à la figure (2.12). Il ressort clairement que le segment épileptique présente plusieurs raies spectrales dont l'intensité est




Figure 2 12: Exemple de graphe de DSP dans MATLAB [43]..

nettement supérieure à celle du segment non épileptique. Cette différence reflète une concentration énergétique accrue durant les épisodes de crise, confirmant la pertinence de la DSP comme outil efficace pour différencier les états pathologiques des états normaux.

↳ Ecart type de vecteur E_{EEG} [17]

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

$$y = \frac{\sum (X_i - \mu)^2}{n} \quad \text{(Formule 06)}$$

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




Figure 2 13: Exemple de graphe de l'écart type présenter sur le MATLAB [33].

- Paramètres caractéristiques non statistiques

↳ Entropie :

L'entropie constitue une mesure quantitative de la complexité et de l'imprévisibilité d'un signal. Dans le contexte de l'EEG, une entropie élevée traduit une grande irrégularité du signal, caractéristique de l'activité cérébrale normale ou de certains états de repos. À l'inverse, une

entropie faible indique une organisation temporelle accrue, souvent corrélée à l'apparition de décharges épileptiques périodiques [17].

Ce choix méthodologique offre des indicateurs plus sensibles et robustes face aux variations transitoires typiques des crises.




Figure 2 14 : Exemple de graphe d'entropie présenter sur le MATLAB [43].

Observations :

- L'entropie, ou la quantité d'information fournie par le segment durant la crise, est supérieure à celle en cas d'activité normale.
- Dans le cas de crise, la variation de l'entropie reste monotone et suit globalement le même trend que celui observé dans le cas d'activité normale, et ce, pour presque tous les canaux.

↳ Energie

L'énergie à chaque niveau de décomposition est l'énergie des coefficients d'approximation

$$E_{EEG_{10}}(i, n) = \sum_{k=1}^L |EEG(i, k)|^2 \quad \text{(Formule 07)}$$

L est la taille de l'enregistrement (chaque segment contient $256 \times 10 = 2560$ échantillons). $i=1 \dots M$, et $M=23$ correspond au nombre de canaux pour le signal EEG.




Figure 2 15: Exemple représentatif d'énergie sur le MATLAB [43].

- Le tableau suivant représente un résumé d'extraction des caractéristiques.

Désignation	Description
$EEG_{max_{10}, i}$	Valeur maximale sur une période de 10 secondes du signal EEG pour le canal i
$EEG_{min_{10}, i}$	Valeur minimale sur une période de 10 secondes du signal EEG pour le canal i
$E_{EEG_{10}, i}$	Energie du signal EEG (canal i avec une durée de 10 Secondes)
$\sigma_{EEG_{10}, i}$	Ecart type du signal EEG (canal i avec une durée de 10 Secondes)
$Entrop_{EEG_{10}, i}$	Entropie du signal EEG (canal i avec une durée de 10 Secondes)
$PSD_{EEG_{10}, i}$	Moyenne de la densité spectrale de puissance du signal EEG (canal i avec une durée de 10 Secondes)

Table 2 4: Caractéristiques Extrait pour un signal EEG.

Une fois les segments extraits, ils sont utilisés comme unités d'entrée pour les algorithmes de classification.

L'ensemble des paramètres extraits est organisé selon la nature du classificateur cible :

- **Pour les SVM** : un vecteur de caractéristiques de dimension fixe est construit. Chaque segment EEG de 10 secondes est ainsi représenté par un point dans l'espace des caractéristiques. Pour une décomposition à quatre niveaux avec extraction de l'énergie et de l'écart-type, Cette représentation condensée préserve l'information discriminante essentielle tout en réduisant considérablement la dimensionnalité par rapport au signal brut (2 560 échantillons).
- **Pour les CNN** : les coefficients ondelettes de décomposition sont organisés en matrices bidimensionnelles ou tenseurs multi-canaux, exploitant la capacité des couches

convolutionnelles à extraire automatiquement les motifs locaux et les structures hiérarchiques présents dans la représentation temps-échelle.

- Pour les **LSTM /GRU** : les coefficients ondelettes sont conservés sous forme de séquences temporelles dans chaque sous-bande, permettant aux unités récurrentes de modéliser les dépendances longitudinales et les dynamiques temporelles caractéristiques de l'évolution pré- et intra-critique.

II.4 Conclusion :

Le traitement du signal EEG est crucial pour l'analyse précise des activités cérébrales. En combinant des méthodes de prétraitement, d'extraction de caractéristiques et de segmentation, il est possible d'identifier efficacement les anomalies telles que les crises d'épilepsie. L'intégration des techniques de machine Learning, notamment l'apprentissage profond, améliore notablement la détection automatique et la classification des signaux anormaux. Malgré des défis liés à la variabilité des données et au bruit, ces avancées technologiques promettent un grand potentiel pour des diagnostics médicaux plus rapides et précis, ainsi qu'un suivi en temps réel des patients.

CHAPITRE 03 :

**Implémentation logicielle,
protocole de validation et analyse
comparative des classifieurs.**

III.1 Introduction :

Dans ce chapitre, nous présentons les résultats obtenus suite à l'application des différentes méthodes d'apprentissage automatique et profond à la classification des signaux EEG. Après avoir détaillé la préparation des données et les modèles utilisés dans les chapitres précédents, il est désormais essentiel d'évaluer la performance de ces approches à travers des métriques quantitatives et une analyse comparative.

Ce chapitre s'inscrit ainsi comme une étape cruciale qui permet de mesurer la pertinence des techniques employées pour la classification des signaux EEG et d'orienter les perspectives d'amélioration.

III.2 Présentation de la méthodologie et de l'architecture hybride :

La méthodologie présentée sur le chapitre précédant s'appuie sur une architecture hybride combinant un réseau de neurones convolutif (CNN) pour extraire les caractéristiques spatiales des signaux EEG multicanaux, une unité récurrente à portes (GRU) pour capter les dépendances temporelles, et un classificateur SVM linéaire pour la décision finale. Le CNN détecte automatiquement les motifs spécifiques des décharges épileptiformes, tandis que le GRU modélise la dynamique temporelle des signaux EEG de manière efficace. Ensuite, la représentation latente obtenue est projetée dans un espace à dimension supérieure par le SVM, qui sépare au mieux les classes épileptiques et non épileptiques. Cette combinaison CNN-GRU-SVM forme une architecture de Deep Learning supervisée adaptée aux données spatio-temporelles EEG de la base CHB-MIT.

La procédure de classification est divisée en trois phases principales [34] :

1ère phase : préparation des bases de données et Prétraitement des données :

Pour mener à bien l'expérimentation des classifieurs, il est essentiel de préparer deux bases de données distinctes :

1. **Base d'apprentissage (train)** : utilisée pour entraîner les modèles et ajuster leurs paramètres.
2. **Base de test** : utilisée pour évaluer les performances des trois classifieurs de manière indépendante, afin de mesurer leur capacité à généraliser sur des données inédites.

Cette séparation garantit que l'évaluation des modèles est objective et fiable.

Note : Dans notre cas, l'objectif initial était d'utiliser la base de données TUH EEG pour l'apprentissage (train) et la base CHB-MIT pour le test, afin d'obtenir des résultats fiables. Cependant, en raison des difficultés rencontrées pour accéder à la base TUH EEG, nous avons finalement choisi d'utiliser uniquement la base CHB-MIT pour les phases d'apprentissage et de test.

2ème phase : Phase d'apprentissage :

Cette étape consiste à rechercher et construire un modèle de décision. Elle implique une mise à jour continue du modèle pour résoudre efficacement le problème posé.

3ème Phase de test (validation) :

Elle consiste à attribuer une nouvelle observation à l'une des classes, en se basant sur la règle de décision élaborée lors de la phase d'apprentissage. L'objectif principal est d'obtenir une estimation précise du comportement du classifieur dans des conditions d'utilisation réelles.

III.3 MÉTRIQUES DE PERFORMANCE

Les métriques de performance sont des outils essentiels en apprentissage supervisé, permettant d'évaluer la capacité prédictive d'un modèle. Plusieurs mesures sont utilisées à cette fin, parmi lesquelles les plus courantes sont : la matrice de confusion, la courbe ROC (Receiver Operating Characteristic), l'aire sous la courbe (AUC), la statistique Kappa (k), et d'autres. Cependant, la matrice de confusion reste l'outil le plus répandu et apprécié.

↳ Matrice de confusion :

La matrice de confusion sert à évaluer les performances d'un modèle en fournissant une vue d'ensemble claire de sa capacité à prédire correctement les différentes classes. Elle offre également des informations précieuses sur la généralisation du modèle (Cichosz, 2015).

On utilise des mesures statistiques liées à la reconnaissance des catégories mutuellement exclusives :

- **VP (Vrai Positif)** : nombre de cas malades correctement classés comme malades.
- **VN (Vrai Négatif)** : nombre de cas sains correctement classés comme sains.
- **FP (Faux Positif)** : nombre de cas sains incorrectement classés comme malades.
- **FN (Faux Négatif)** : nombre de cas malades incorrectement classés comme sains.

	Présence d'évènement de classe i	Absence d'évènement de classe i
Classification positive.	Vrai Positif VP(i).	Faux Positif FP(i)
Classification négative	Faux Négatif FN(i).	Vrai Négatif VN(i).

Table 3. 1: Matrice de confusion.

Où l'erreur de classification est représentée par le rapport entre les instances mal classées et toutes les instances :

$$\text{Erreur de classification} = \frac{FN+FP}{FN+FP+TN+TP} \quad (\text{Formule 08})$$

Le taux de réussite ou exactitude de classification est donné comme le rapport entre les instances correctement classées et toutes les instances :

$$\text{Exactitude de classification} = \frac{TP+TN}{FN+FP+TN+TP} \quad (\text{Formule 09})$$

La sensibilité ou rappel (recall) ou TPR (taux des vrais positifs) est le rapport entre les instances correctement classées comme positives et toutes les instances positives :

$$\text{Rappel} = \text{Sensibilité} = \text{TPR} = \frac{TP}{TP+FN} \quad (\text{Formule 10})$$

Le taux de faux positifs (spécificité) est représenté par le rapport entre les instances incorrectement classées comme positives et toutes les instances négatives :

$$\text{Spécificité} = 1-\text{FPR} = \frac{TN}{FP+TN} \quad (\text{Formule 11})$$

La précision est le rapport entre les instances correctement classées comme positives et toutes les instances classées comme positives :

$$\text{Précision} = \frac{TP}{TP+FP} \quad (\text{Formule 12})$$

III.4 RÉSULTATS DES DIFFÉRENTES COMBINAISONS D'ALGORITHMES DE DÉTECTION DE CRISES D'ÉPILEPSIE :

L'ensemble d'apprentissage est formé de meilleurs modèles de classification.CNN+GRU (LDA), au k-plus proche voisin (KNN), au forêt aléatoire (RF), aux machines à vecteurs de supports (SVM) et au Régression Logistique, Gradient Boosting.




Figure 3.1: Vote de majorité appliqué sur les classifieurs du projet.

III.4.1 Analyse des métriques de classification et performance globale :

On a développé notre approche avec les Frameworks Google Colab avec le langage de programmation Python en raison de ses caractéristiques, qui sont moins de code, accès à d'excellentes bibliothèques et à des Frameworks, simplicité et cohérence, indépendance vis-à-vis des plateformes, une large communauté et sa flexibilité

```

import os
import re
import gc
import numpy as np
import pandas as pd
import pickle

# MNE for EEG processing
import mne
from mne.io import read_raw_edf, read_raw_bdf
print("MNE installé")

import scipy.io as io
import random
import time

# Deep Learning
import tensorflow as tf
from tensorflow.keras.models import Model
from tensorflow.keras.layers import (
    Input, Conv2D, BatchNormalization, MaxPooling2D,
    GRU, Dense, Dropout
)
from tensorflow.keras import regularizers
from tensorflow.keras.constraints import MaxNorm
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.callbacks import EarlyStopping, ReduceLROnPlateau, ModelCheckpoint

# Classical ML
from sklearn.model_selection import StratifiedFold, GridSearchCV
from sklearn.metrics import (
    classification_report, confusion_matrix, accuracy_score,
    precision_score, recall_score, f1_score, roc_auc_score
)
from sklearn.utils.class_weight import compute_class_weight
from sklearn.ensemble import RandomForestClassifier, GradientBoostingClassifier
from sklearn.svm import SVC
from sklearn.neighbors import KNeighborsClassifier
from sklearn.linear_model import LogisticRegression
from sklearn.preprocessing import StandardScaler
from sklearn.pipeline import Pipeline

# Plotting
import matplotlib.pyplot as plt
import seaborn as sns

# DWT
import pywt
DWT_AVAILABLE = True
print("PyWavelets (pywt.__version__)")

from scipy import stats
from scipy.stats import entropy
from scipy.signal import welch

print("TensorFlow (tf.__version__)")
print("GPU : {tf.config.list_physical_devices('GPU')}")

# --- Memory helper ---
def cleanup_memory():
    gc.collect()
    tf.keras.backend.clear_session()
    print("Memory cleaned up")
    
```

Figure 3.2: bibliothèques utilise sur python.

Nous avons présenté les résultats d'apprentissage automatiques de signal EEG de la base de données CHB-MIT dans des différents schémas graphiques suivants

Tableaux comparatifs des résultats obtenir :

Classifieur	VP	FP	VN	FN
Random Forest	12.0	15.0	39.0	34.0
SVM (RBF)	16.0	26.0	28.0	30.0
Gradient Boosting	15.0	15.0	39.0	31.0
KNN	21.0	21.0	33.0	25.0
Logistique Régression	17.0	25.0	29.0	29.0
CNN+GRU (DL)	21.0	17.0	37.0	25.0

Table 3. 2: Comparaison des resultats de matrice de confusion obtenir.

Classifieur	accuracy	precision	recall	f1	AUC	sensitivity	specificity
Random Forest	0.51	0.4444	0.2609	0.3288	0.4593	0.2609	0.7222
SVM (RBF)	0.44	0.3810	0.3478	0.3636	0.4098	0.3478	0.5185
Gradient Boosting	0.54	0.5000	0.3261	0.3947	0.4859	0.3261	0.7222
KNN	0.54	0.5000	0.4565	0.4773	0.5250	0.4565	0.6111
Logistique Régression	0.46	0.4048	0.3696	0.3864	0.4183	0.3696	0.5370
CNN+GRU (DL)	0.58	0.5526	0.4565	0.5000	0.5866	0.4565	0.6852

Table 3. 3: comparaison des caractéristiques de performance.

L'interprétation des résultats de matrice de confusion :

- La Random Forest et le Gradient Boosting affichent les meilleurs taux de vrais négatifs VN (39), ce qui reflète leur efficacité à reconnaître correctement les cas négatifs.
- Le KNN et le modèle CNN+GRU obtiennent les meilleurs résultats en termes de vrais positifs VP (21), cependant, le KNN présente un nombre plus élevé de faux positifs FP.

- le SVM avec noyau RBF ainsi que la régression logistique montrent un déséquilibre notable, avec un nombre important de faux positifs FP (respectivement 26 et 25) et peu de vrais négatifs VN.
- Analyse comparative avec les modèles de machine Learning classiques

L'évaluation quantitative des performances des six classificateurs appliqués repose sur une variété de métriques complémentaires, dont l'exactitude (accuracy), la précision, le rappel (recall), le score F1, l'aire sous la courbe ROC (AUC), ainsi que la sensibilité et la spécificité (Powers, 2011 [35]).

Le modèle hybride CNN+GRU domine nettement tous les indicateurs avec une accuracy de 0,58, une précision de 0,5526, un score F1 de 0,5000 et une AUC de 0,5866. Cette supériorité s'explique par la capacité des architectures profondes à extraire automatiquement des représentations hiérarchiques des données sans besoin d'ingénierie manuelle des caractéristiques (LeCun, Bengio et Hinton, 2015 [36]).

Le modèle KNN suit en seconde position avec une accuracy de 0,54 et un F1-score de 0,4773, témoignant de l'efficacité des méthodes basées sur la similarité dans des espaces de caractéristiques de dimension modérée.

Cependant, il est important de noter que tous les classificateurs évalués présentent des performances globalement modestes, aucun atteignant le seuil communément admis de 0,70 en accuracy, suggérant une difficulté à clairement séparer les classes dans l'espace des caractéristiques extraites.

Concernant le temps de calcul, le modèle CNN+GRU présente un avantage marqué avec un traitement rapide, crucial pour les applications en temps réel, tandis que Gradient Boosting, malgré une spécificité acceptable (0,7222), souffre d'un temps d'exécution prohibitif (environ 1900 secondes), limitant son usage en contexte clinique.

Le classificateur Random Forest montre une certaine ambiguïté : bien que son rappel apparaisse élevé graphiquement, ses valeurs brutes (12 vrais positifs et 34 faux négatifs) révèlent une sensibilité en réalité limitée, soulignant la nécessité de confronter représentations graphiques et données numériques.

Enfin, la régression logistique et le SVM, même s'ils sont efficaces en temps de calcul, échouent à modéliser la complexité non linéaire des relations entre les caractéristiques EEG et les classes cibles.

Ces résultats confirment les recommandations récentes qui privilégient les architectures profondes pour l'analyse des signaux biomédicaux, sous réserve de disposer de volumes d'entraînement suffisants (Craik, He et Contreras-Vidal, 2019 [37]) comme illustré dans la figure (3.3) et mentionner dans le tableau (3.3).




Figure 3.3: Comparaison des performances des modèles de classification EEG.

III.4.3 Analyse temps-fréquence et décomposition par ondelettes discrètes (visualisation DWT) :

- Tableau des caractéristiques DWT (features DWT)

Bande	Max	Min	Energie	Std	Entropie	PSD	Moyenne
A5 (Delta 0-4Hz)	5.9119	0.1337	5.8399e+01	1.9802	2.4024	4.1713e+00	0.5002
D5 (Theta 4-8Hz)	0.8602	0.0336	3.0231e+00	0.4645	2.3853	2.1594e-01	0.0132
D4 (Alpha 8-16Hz)	1.7160	0.1185	1.7396e+01	0.8887	2.8788	7.9072e-01	0.0297
D3 (Beta-low 16-32Hz)	2.4677	0.0020	4.6354e+01	0.9813	3.2510	1.2198e+00	0.5068
D2 (Beta-high 32-64Hz)	2.6985	0.0081	6.2574e+01	0.9520	3.9808	9.0687e-01	0.0243
D1 (Gamma 64-128Hz)	2.9364	0.0076	1.2273e+02	0.9664	4.5417	9.3689e-01	0.0540

Table 3. 4: Les caractéristiques extraits par l'application du DWT.


- Analyse de la Décomposition Visuelle du Signal EEG :

La représentation graphique de la décomposition multi-résolution du signal EEG original enregistré au site Fp1 met clairement en évidence la capacité de la DWT à séparer les contributions fréquentielles selon différentes échelles temporelles. Le signal brut montre une amplitude oscillatoire typique des enregistrements EEG, avec des fluctuations rapides superposées à des variations plus lentes.

Les coefficients d'approximation A5 (Delta) présentent une structure lente et régulière, reflétant une activité neuronale synchronisée à longue échelle temporelle, tandis que les coefficients de détail (de D5 à D1) révèlent une finesse croissante, correspondant à l'activation de sous-bandes fréquentielles de plus en plus larges.

L'évolution des coefficients D1 (Gamma) est particulièrement significative : ils manifestent une forte densité temporelle et des amplitudes importantes, confirmant la concentration énergétique observée dans cette bande.

Cette décomposition visuelle soutient l'hypothèse que les hautes fréquences contiennent une information discriminante essentielle pour la classification, quoique leur nature bruitée puisse nécessiter des méthodes de débruitage ou de sélection de caractéristiques afin d'optimiser la performance des classifieurs.



La transformation en ondelettes discrètes (DWT) a été utilisée pour effectuer une décomposition temps-fréquence du signal électroencéphalographique (EEG), permettant d'extraire les composantes énergétiques suivant six bandes de fréquences physiologiquement significatives : Delta (0-4 Hz), Theta (4-8 Hz), Alpha (8-16 Hz), Beta-bas (16-32 Hz), Beta-haut (32-64 Hz) et Gamma (64-128 Hz) (Subasi, 2007 [38]).

Les analyses statistiques descriptives montrent une répartition hétérogène de l'énergie spectrale à travers ces bandes. La bande Gamma (D1) contient la plus forte énergie ($1,2273 \times 10^2$), suivie par la bande Beta-haut (D2) avec une énergie de $6,2574 \times 10^1$, tandis que la bande Theta (D5) affiche la contribution énergétique la plus faible (3,0231).

Cette prédominance de l'énergie dans les hautes fréquences est typique des signaux EEG préfrontaux (Fp1) et peut traduire une activité neuronale synchronisée à haute fréquence, potentiellement liée à des processus cognitifs complexes ou à certains états pathologiques (Buzsáki et Draguhn, 2004 [39]).

Par ailleurs, l'entropie de Shannon augmente régulièrement de la bande Delta (2,4024) à la bande Gamma (4,5417), indiquant une complexité croissante de l'information dans les hautes fréquences et soulignant ainsi l'intérêt discriminant des coefficients d'approximation et de détail issus des niveaux de décomposition les plus fins. (Voir figure 3.5)




Figure 3.5: Distribution de l'énergie par bande de fréquence après décomposition en ondelettes (DWT)

- Pertinence de l'Approche Hybride et Validation Méthodologique

La comparaison directe entre un SVM à noyau RBF isolé (accuracy = 0,44, AUC = 0,4008) et la chaîne hybride CNN+GRU+SVM (accuracy = 0,58, AUC = 0,5866) valide l'hypothèse centrale de ce travail : l'extraction automatique de caractéristiques par des réseaux profonds améliore substantiellement les performances des classifieurs à noyau appliqués aux signaux EEG bruts. L'augmentation relative de +31,8 % en accuracy et de +46,4 % en AUC

entre le SVM RBF opéré sur des caractéristiques extraites par ondelettes et le SVM terminal de la chaîne hybride opérant sur des représentations apprises démontre que le couplage CNN+GRU a réussi à construire un espace de redescription dans lequel la séparabilité des classes est nettement renforcée.

Cette validation expérimentale s'inscrit en cohérence avec les travaux antérieurs de « Craik, He et Contreras-Vidal (2019) » [40] mettant en lumière l'efficacité des architectures profondes pour l'analyse des signaux biomédicaux. Elle apporte cependant une contribution originale en démontrant le bénéfice spécifique du couplage GRU-SVM pour la modélisation des dépendances temporelles à long terme dans les séquences EEG.

Ainsi, l'approche hybride proposée offre une alternative crédible aux architectures neuronales purement discriminatives, combinant la puissance de représentation de l'apprentissage profond avec les garanties théoriques de généralisation des méthodes à large marge

III.5 Conclusion :

Ce chapitre a permis de mettre en lumière les performances des différentes méthodes d'apprentissage pour la classification des signaux EEG. Les résultats expérimentaux, basés sur des métriques précises, ont révélé les forces et limites de chaque modèle, tant au niveau de la précision prédictive que de la complexité computationnelle.

L'analyse comparative a notamment souligné l'intérêt des architectures profondes, telles que le CNN+GRU, qui allient une bonne performance de classification à une rapidité d'inférence compatible avec une utilisation en temps réel. Par ailleurs, les modèles classiques offrent des résultats solides mais peuvent se heurter à des contraintes de temps d'entraînement élevées.

Conclusion Générale :

L'épilepsie constitue l'un des troubles neurologiques chroniques les plus répandus à travers le monde, touchant près de 50 millions de personnes et représentant un enjeu majeur pour les systèmes de santé. Le diagnostic et le suivi de cette pathologie reposent traditionnellement sur l'analyse visuelle des enregistrements électroencéphalographiques (EEG), une tâche longue, subjective et fortement tributaire de l'expertise clinique. Face à l'impossibilité de surveiller en continu les patients manuellement, le développement de systèmes automatiques de détection des crises épileptiques s'impose comme une nécessité, stimulée par l'essor des méthodes d'intelligence artificielle appliquées aux signaux biomédicaux.

Ce mémoire propose et évalue une architecture neuronale hybride CNN-GRU-SVM pour la classification automatique des signaux EEG épileptiques issus de la base de données CHB-MIT.

La méthode adoptée s'articule autour de quatre phases clés : un prétraitement adapté comprenant une segmentation en fenêtres fixes de 10 secondes, un filtrage Butterworth d'ordre 4 en passe-bande 0,5-128 Hz et une normalisation Z-score par canal ; une décomposition en ondelettes discrètes (Daubechies db4) pour une analyse temps-fréquence multi-résolution ; une architecture d'apprentissage profond hybride combinant un CNN pour l'extraction spatiale, un GRU pour la modélisation temporelle et un SVM linéaire pour la classification finale ; enfin, une évaluation comparative systématique par rapport à cinq méthodes classiques de machine learning.

L'architecture hybride CNN+GRU+SVM ainsi proposée démontre une supériorité relative par rapport aux approches classiques, avec une accuracy de 0,58, un F1-score de 0,5000 et une AUC de 0,5866, ainsi qu'une latence d'inférence quasi nulle, contrastant avec les temps prohibitifs des méthodes ensemblistes. Le couplage CNN-GRU permet une extraction automatique efficace des dépendances spatiales et temporelles des signaux, tandis que le SVM terminal optimise la capacité de généralisation du modèle via la maximisation de la marge. L'ensemble tire parti de la prédominance énergétique des bandes Gamma et Beta-haute, mise en évidence par la décomposition en ondelettes.

Cependant, la performance absolue reste insuffisante pour une application clinique autonome, principalement en raison d'un taux élevé de faux négatifs (54,3 %) et de la limitation à un unique canal EEG (Fp1), ce qui restreint la capacité du modèle à appréhender la complexité des réseaux de connectivité inter-régionale.

Ces résultats confirment néanmoins l'hypothèse principale selon laquelle l'extraction profonde de caractéristiques améliore de manière significative les classificateurs à noyau appliqués aux signaux biomédicaux. Ils ouvrent également la voie à des améliorations futures, telles que l'intégration de mécanismes d'attention, l'augmentation des données d'entraînement et l'extension à des enregistrements multicanaux, posant ainsi les bases d'une neuro-ingénierie computationnelle plus robuste, apte à un déploiement pratique en milieu clinique.

Références

- [1] *Naydenov C., Yordanova A., Mancheva V. (2022). Methodology for EEG and Reference Values of the Software Analysis. Open Access Macedonian Journal of Medical Sciences, 10(B), 2351-2354..*
- [2] *<https://speechneurolab.ca/en/electroencephalography-eeg/>.*
- [3] *Soulier H., Mazzola L., Convers P. (s.d.). Chapitre 18 : Électrophysiologie du système nerveux central. CEN-Neurologie..*
- [4] *Soulier H., Mazzola L., Convers P. (s.d.). Chapitre 18 : Électrophysiologie du système nerveux central. CEN-Neurologie..*
- [5] *SANEI, S. et CHAMBERS, J. (2007). EEG signal processing. Wiley-Interscience..*
- [6] *Mohamed Tahar Haddad, Anticipation des crises d'épilepsie temporale combinant des Méthodes.*
- [7] *Sarma, S. V., Eden, U. T., Cheng, M. L., et al. (2010). Using point process models to compare neural.*
- [8] *Jonathan J. Halford. 2009. Computerized epileptiform transient detection in the scalp.*
- [9] *RebecaRomo-Vazquez. Contribution à la détection et à l'analyse des signaux EEG Épileptiques
..*
- [10] *BOTTOU, L. et CHIH-JEN, L. (2007). Support ector Machine Solvers, in Large Scale.*
- [11] *SubasiAlkan, Koklukaya. Automatic seizure detection in eeg using logistic regression and.*
- [12] *UbeyliGuler. Adaptive neuro-fuzzy inference system for classification. Journal of.*
- [13] *Bishop, C. M. (2006). Pattern Recognition and Machine Learning, volume 4.*
- [14] *SahinOgulataErolAslan, Bozdemir. A radial basis function neural network model for.*
- [15] *Homan DasheiWunschPetrosian, Prokhorov. Recurrent neural network based prediction.*
- [16] *MouradAdnane ;Zhongwei Jiang ; Zhonghong Yan. Sleep–wake stages classification and.*
- [17] *<https://repository.enp.edu.dz/jspui/bitstream/123456789/7011/1/ACHAIBOU.Amina.pdf>.*
- [18] *Nilsson, N. J. (2004). Introduction to Machine Learning, volume 56. The MIT Press. de.*
- [19] *T.Li, M.Hua,andX.Wu, “Ahybridcnn-lstmmodelforforecastingparticulatematter.*
- [20] *S. Roshan, G. Srivathsan, K. Deepak, and S. Chandrakala, “Violence detection in.*
- [21] *Cho, K., et al. (2014). "Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation." arXiv: 1406.1078.p 4–5..*

- [22] Cortes, C., & Vapnik, V. (1995). "Support-vector networks." *Machine Learning*, 20(3).P 273–274.
- [23] Cortes, C., & Vapnik, V. (1995). "Support-vector networks." *Machine Learning*, 20(3). 281–285.
- [24] Acharya, U. R., Fujita, H., Sudarshan, V. K., Bhat, S., & Koh, J. E. W. (2015),..
- [25] Anuragi, A., Dilip Singh Sisodia, & Ram Bilas Pachori. (2022). *Epileptic-seizure*.
- [26] Elhosary, H., Zakhari, M. H., Elgammal, M. A., Kelany, K. A. H., Ghany, M. A. A..
- [27] Shoeb, A., & Guttag, J. (2010). *Application of Machine Learning To Epileptic*.
- [28] Subasi, A. (2007a). *EEG signal classification using wavelet feature extraction and a*.
- [29] <https://physionet.org/content/chbmit/1.0.0/chb05/#files-panel>.
- [30] Deepa, B., & Ramesh, K. (2022, July 26). *Preprocessed CHB-MIT SCALP EEG*.
- [31] https://semaphore.uqar.ca/id/eprint/3284/1/Western_Yves_Roody_Jean_fevrier2025.pdf.
- [32] Ali, E., Angelova, M., & Karmakar, C. (2024). *Epileptic seizure detection using*.
- [33] <https://dspace.univ-tlemcen.dz/items/1c2dd64c-c6b5-48b9-95f9-04ea285d534>.
- [34] <https://docs.google.com/viewerng/viewer?url=https://bucket.theses-algerie.com/files/repositories-dz/1671706246780933.pdf>.
- [35] Powers, D. M. (2011). *Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. Journal of Machine Learning Technologies*, 2(1), 37-63..
- [36] LeCun, Y., Bengio, Y., & Hinton, G. (2015). *Deep learning. Nature*, 521(7553), 436-444..
- [37] Craik, A., He, Y., & Contreras-Vidal, J. L. (2019). *Deep learning for electroencephalogram (EEG) classification tasks: a review. Journal of Neural Engineering*, 16(3), 031001..
- [38] Subasi, A. (2007). *EEG signal classification using wavelet feature extraction and a mixture of expert model. Expert Systems with Applications*, 32(4), 1084-1093..
- [39] Buzsáki, G., & Draguhn, A. (2004). *Neuronal oscillations in cortical networks. Science*, 304(5679), 1926-1929..
- [40] Craik, A., He, Y., & Contreras-Vidal, J. L. (2019). *Deep learning for electroencephalogram (EEG) classification tasks: a review. Journal of Neural Engineering*, 16(3), 03100.