



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



Mémoire de Fin d'Études

Pour l'obtention du diplôme de Master en Informatique

Option : Intelligence Artificielle

Thème

Prédiction des Crises d'Épilepsie

à l'aide des Séries Temporelles Multivariées - EEG -

Réalisé par :

BENSOUNA Manel

BENYACOUB Malek

Encadré par :

M. BENAZZOUC Mourtada

Soutenu le 29 juin 2025, devant le jury composé de :

Mme AMGHAR Djazia (Présidente)

M. MEZIANE Abdelfettah (Examineur)

Année universitaire 2024-2025

Remerciements

*Nous tenons tout d'abord à exprimer notre gratitude envers **Dieu le Tout-Puissant et Miséricordieux**, qui nous a accordé la force, la patience et la persévérance nécessaires pour mener à bien ce modeste travail.*

*Nous exprimons notre profonde gratitude à notre encadrant **BENAZZOUZ Mourtada** pour sa disponibilité, ses conseils avisés, ainsi que pour toutes les opportunités qu'il nous a offertes pour mener à bien ce projet. Son soutien a été déterminant, tant sur le plan scientifique, à travers ses orientations, ses remarques constructives et son encadrement méthodologique, que sur le plan matériel, en nous permettant de disposer des ressources techniques nécessaires à la réalisation de notre travail dans de bonnes conditions.*

*Nous exprimons également notre profonde reconnaissance aux **membres du jury**, pour le temps qu'ils ont consacré à l'évaluation de notre travail, et pour l'avoir enrichi par leurs observations pertinentes et leurs suggestions constructives.*

*Nos remerciements s'adressent aussi à l'ensemble des **enseignants du Département d'Informatique**, pour la qualité des enseignements dispensés et leur accompagnement tout au long de notre parcours académique.*

Enfin, nous n'oublions pas toutes les personnes qui, par un mot d'encouragement, un conseil ou un simple geste, ont contribué de près ou de loin à l'aboutissement de ce travail. À toutes et à tous, merci.

Dédicace

*À mes chers parents,
vous êtes la source de ma force, mes repères, mon refuge.
Merci pour votre amour inconditionnel, vos sacrifices silencieux
et votre soutien à chaque étape.
Ce travail est le fruit de tout ce que vous m'avez transmis.*

*À mon frère et à ma sœur,
pour votre complicité, votre tendresse et vos encouragements
qui ont toujours été présents, même dans les moments les plus difficiles.
Vous avez toujours cru en moi.*

*À ma petite nièce Chefaa,
ton sourire innocent est une lumière dans mes journées.
Tu es une source de joie inestimable, et je te dédie cette réussite avec tout mon amour.*

*À mes amis,
merci pour votre présence, vos rires, votre écoute
et vos mots qui réconfortent.
Votre soutien a été précieux tout au long de ce parcours.*

*À mon binôme Malek,
merci pour ta collaboration, ta patience, ton sérieux et ta détermination.
Cette aventure n'aurait pas eu le même goût sans toi.*

- Manel

Dédicace

*Avant tout, je remercie Allah,
Le Tout-Puissant, de m'avoir accordé la force et la persévérance tout au long de ce parcours.*

*À mes parents,
pour leur soutien, leurs prières sincères et leur présence rassurante.
Ils ont été, tout au long de ce parcours, une lumière sur mon chemin.
Qu'Allah les récompense abondamment et leur accorde santé et bien-être.*

*À mes précieuses sœurs,
pour leurs encouragements et leur bienveillance.
Merci d'avoir été ma force discrète.*

À toute ma famille et à mes amis.

*À chère binôme Manel,
pour son esprit d'équipe et la belle complicité partagée tout au long de ce parcours.
Merci pour ta précieuse contribution.*

- Malek

TABLE DES MATIÈRES

Introduction Générale	1
1 Épilepsie et ElectroEncéphaloGramme	3
1 Introduction	4
2 Épilepsie	4
2.1 Définition	4
2.2 Origine et Cause	4
2.3 Classification de l'Épilepsie	5
2.4 Types d'Épilepsies	5
2.5 Phases des Crises	7
2.6 Diagnostic	7
2.7 Évaluation de l'Impact Sur la Vie Quotidienne	7
3 L'ÉlectroEncéphaloGramme (EEG)	8
3.1 Systèmes de Placement des Électrodes	8
3.2 Types et Caractéristiques Des Signaux EEG	10
3.3 Rôle de l'EEG Dans la Prédiction des Crises	11

TABLE DES MATIÈRES

4	Conclusion	11
2	Deep Learning pour les Séries Temporelles	12
1	Introduction	13
2	Les Séries Temporelles	13
2.1	Définition et Caractéristique	13
2.2	Série Temporelle Univariée et Multivariée	15
3	Deep Learning Appliqué Aux Séries Temporelles	16
3.1	Introduction	16
3.2	Historique et développement du deep learning	16
3.3	Réseau Neuronal Convolutif	17
3.4	Réseaux de Neurones Récurents	18
3.5	Transformer	20
4	Conclusion	24
3	Approche pratique et modélisation	25
1	Introduction	26
2	Outils utilisés	26
2.1	Environnement logiciel	26
2.2	Langage de programmation	26
2.3	Les bibliothèques et le Framework Utilisés	27
2.3.1	TensorFlow	27
2.3.2	Keras	27
2.3.3	Scikit-learn	28
2.3.4	SciPy	28
2.3.5	Wfdb	28

TABLE DES MATIÈRES

2.3.6	Mne	29
2.3.7	Numpy	29
3	EEG Dataset	29
3.1	Comparaison des jeux de données EEG existants	29
3.2	CHB-MIT	30
3.3	Prétraitement	31
4	Travaux connexes	32
5	Modèle Réalisé	33
5.1	Mesures de performance	35
5.2	Résultats et discussion	37
6	Comparaison entre le modèle proposé et les modèles de la littérature	38
7	Déploiement de l'Application Mobile	38
8	Limites et Travaux Futurs	41
8.1	Limites identifiées	41
8.2	Perspectives et Travaux Futurs	41
9	Conclusion	42
	Conclusion générale	43
	Annexes	53
	Résumé	64

TABLE DES FIGURES

1.1	Démarche de la Classification des Épilepsies.[4]	5
1.2	Classification des Types de Crises Épileptiques.[8]	6
1.3	Phases Des Crises.[9]	7
1.4	Exemple d'un Enregistrement Des Signaux EEG.	8
1.5	Représentation de la répartition des électrodes selon le système international 10/20 [17].	9
1.6	Localisation des électrodes sur le scalp, selon le système « 10–10 » [18].	9
1.7	Different-EEG-waveforms [21].	10
1.8	Phases des crises dans un signal EEG [24].	11
2.1	Évolution de l'indice Dow Jones de 1928 à 2004 (données mensuelles). [25]	14
2.2	Évolution de l'intensité du vent, en m/s,	14
2.3	Progression des cas de grippe en France, hebdomadairement,	14
2.4	Quelques événements clé du développement historique des réseaux de neurones. [30]	16
2.5	Architecture de CNN 1D [32]	17
2.6	Schéma d'une cellule mémoire d'un LSTM [34].	19
2.7	Schéma d'une cellule mémoire d'un LSTM [36].	19

2.8	Transformer Architecture.[38]	20
3.1	Diagramme en donut illustrant la répartition 80 % / 20 % entre entraînement et test	31
3.2	Représentation des fenêtres temporelles utilisées pour la prédiction de crise.	31
3.3	Méthode d'échantillonnage par fenêtre mobile.	32
3.4	Modèle proposé	35
3.5	Matrice de confusion et courbe ROC pour le modèle.	37
3.6	Interfaces de connexion	39
3.7	page des paramètres	40
3.8	Analyse du signal EEG via IA	40
3.9	Déclenchement d'alerte en cas de prédiction	40
3.10	Saisie les informations du proches	40
3.11	Historique & Statistiques des alertes	40

LISTE DES TABLEAUX

2.1	Exemple d'une Série Temporelle Univariée [26].	15
2.2	Exemple d'une Série Temporelle Multivariée [26].	15
3.1	Comparaison des jeux de données EEG pour l'analyse de l'épilepsie	30
3.2	Résultats moyens de performance du modèle	37
3.3	Comparaison des méthodes de prédiction des crises d'épilepsie sur CHB-MIT	38

Table des abréviations

Abréviation	Signification
EEG	Electroencéphalogramme
DL	Deep Learning (Apprentissage profond)
CNN	Convolutional Neural Network (Réseau de neurones convolutifs)
RNN	Recurrent Neural Network (Réseau de neurones récurrents)
LSTM	Long Short-Term Memory (Mémoire à long court terme)
BiLSTM	Bidirectional Long Short-Term Memory (Mémoire à long court terme bidirectionnelle)
ST	Série Temporelle
FFN	Réseau feedforward positionnel
SVM	Support Vector Machine (Machine à vecteurs de support)
K-NN	K-Nearest Neighbors (K plus proches voisins)

INTRODUCTION GÉNÉRALE

L'épilepsie est l'un des troubles neurologiques chroniques les plus répandus dans le monde, affectant environ 50 millions de personnes selon l'Organisation mondiale de la santé (OMS). Elle se manifeste par des crises soudaines et imprévisibles causées par une activité électrique anormale dans le cerveau. Ces crises peuvent avoir des conséquences graves sur la qualité de vie des patients, notamment en limitant leur autonomie et en générant un stress constant lié à l'imprévisibilité des épisodes.

Le diagnostic et le suivi des patients épileptiques reposent principalement sur l'analyse de l'électroencéphalogramme (EEG), un enregistrement non invasif de l'activité bioélectrique cérébrale. L'EEG permet de détecter les signatures électrophysiologiques caractéristiques des différentes phases associées aux crises, notamment les périodes interictales (hors crise), pré-ictales (précédant la crise), et ictales (pendant la crise). Toutefois, l'interprétation visuelle des tracés EEG demeure une tâche exigeante, mobilisant une expertise neurologique spécialisée, et souffrant de limitations en termes de reproductibilité, de rapidité et de précision, particulièrement face à de longues durées d'enregistrement.

Face à ces enjeux, les progrès récents dans le domaine de l'intelligence artificielle, et plus particulièrement de l'apprentissage profond (Deep Learning), ont suscité un intérêt croissant pour le développement de systèmes automatisés d'aide à la détection et à la prédiction des crises d'épilepsie. Les architectures neuronales telles que les réseaux de neurones convolutifs (CNN), les réseaux de neurones récurrents bidirectionnels (BiLSTM) ou encore les modèles à mécanisme d'attention (Transformers) ont démontré leur efficacité dans l'extraction de caractéristiques discriminantes à partir de signaux temporels bruts, ouvrant ainsi de nouvelles perspectives pour l'analyse des signaux EEG.

Dès lors, la question centrale à laquelle ce projet tente de répondre est la suivante : Comment exploiter au mieux les signaux temporels EEG, à l'aide de techniques d'apprentissage profond, afin de prédire précocement les crises d'épilepsie avec une fiabilité suffisante pour envisager des applications cliniques ou embarquées ?

Plan du mémoire :

1. Dans le chapitre 1, nous présentons des informations médicales relatives à l'épilepsie et aux signaux EEG.
2. Le chapitre 2 traite des fondamentaux des modèles de DL, en mettant l'accent sur ceux adaptés à l'analyse de signaux EEG.
3. Dans le chapitre 3, nous présentons notre approche pratique : les outils utilisés, le prétraitement des données EEG, l'architecture du modèle et ses résultats. Nous y incluons également une comparaison avec des travaux existants, le déploiement de l'application mobile, ainsi qu'une discussion sur les limites et les perspectives d'amélioration.
4. Enfin, nous terminons par une conclusion générale, qui récapitule les contributions du travail et ouvre sur les perspectives futures.

CHAPITRE 1

ÉPILEPSIE ET ÉLECTROENCÉPHALOGRAMME

1 Introduction

La neurologie, branche de la médecine dédiée à l'étude et au traitement des pathologies du système nerveux central et périphérique, joue un rôle essentiel dans la compréhension des mécanismes cérébraux à l'origine des troubles neurologiques. Parmi ceux-ci, l'**épilepsie** se distingue comme l'un des plus fréquents et des plus invalidants, elle touche environ 50 millions de personnes dans le monde [1], et se manifeste par des crises soudaines et imprévisibles dues à une décharge électrique anormale du cerveau. Le diagnostic et la prise en charge de cette maladie reposent en grande partie sur l'analyse des signaux cérébraux obtenus par l'électroencéphalographie (EEG). Ce chapitre explore donc divers aspects de l'épilepsie, sa définition, ses causes, ses différentes formes et son impact sur la qualité de vie des patients. Il met également en lumière le rôle central de l'EEG dans la surveillance et la prédiction des crises épileptiques.

2 Épilepsie

2.1 Définition

L'Épilepsie est une maladie neurologique chronique non transmissible, caractérisée par la survenue récurrente de crises épileptiques. Celles-ci se traduisent par des épisodes brefs de secousses involontaires pouvant affecter une partie du corps (crises partielles) ou l'ensemble du corps (crises généralisées). Dans certains cas, ces crises s'accompagnent d'une perte de conscience, ainsi que d'un relâchement des fonctions sphinctériennes, entraînant une incontinence urinaire ou fécale [1].

2.2 Origine et Cause

L'Épilepsie n'est pas une maladie contagieuse. Bien qu'elle puisse résulter de divers mécanismes pathologiques, son origine demeure inexpliquée dans près de 50 % des cas à l'échelle mondiale. Les causes connues sont généralement regroupées en six grandes catégories : structurelles, génétiques, infectieuses, métaboliques, immunitaires, et d'étiologie inconnue. Parmi les causes identifiées, on peut citer notamment :

- un traumatisme crânien sévère,
- un accident vasculaire cérébral entraînant une hypoxie cérébrale,
- certains syndromes d'origine génétique,
- ou encore la présence de tumeurs cérébrales [2].

2.3 Classification de l'Épilepsie

La Classification des Crises d'Épilepsie a été profondément revue par la Ligue Internationale Contre l'Épilepsie (ILAE) en 2017, dans le but de proposer une nomenclature plus précise, universelle et cliniquement pertinente [3].




FIGURE 1.1 – Démarche de la Classification des Épilepsies.[4]

La classification proposée par l'ILAE s'articule autour de trois niveaux d'analyse hiérarchiques :

- Le premier niveau consiste à identifier le type de crise observée.
- Le deuxième niveau vise à déterminer la catégorie d'Épilepsie à laquelle appartient le patient, parmi les quatre types suivants : Épilepsie Focale, Épilepsie Généralisée, Épilepsie Combinée (focale et généralisée), ou Épilepsie d'Origine Inconnue.
- Le troisième niveau permet de préciser le syndrome épileptique spécifique.

2.4 Types d'Épilepsies

L'Épilepsie se manifeste sous différentes formes de crises, regroupées par l'ILAE en quatre grandes catégories. Parmi celles-ci, les crises focales et généralisées sont les plus fréquemment observées.

- **Les Épilepsies Focales** Localisées dans un seul hémisphère cérébral, peuvent être motrices ou non motrices, avec ou sans altération de la conscience [5]. On distingue deux types principaux : les crises à conscience préservée, où la personne reste consciente, et celles à conscience altérée, marquées par des automatismes et une absence de souvenir de l'épisode [6].

- **Les Épilepsies Généralisées** Impliquent des crises débutant simultanément dans les deux hémisphères cérébraux. Elles comprennent divers types, dont les plus fréquents sont les crises d'absence, tonico-cloniques et myocloniques [5].

- **Crise d'absence « Petit mal »** : Provoque une brève perte de réactivité, souvent confondu avec de l'inattention. Elle touche surtout les enfants et disparaît fréquemment à l'âge adulte. Une forme atypique existe, avec mouvements involontaires et altération partielle de la conscience [7].
- **Crise généralisée tonico-clonique « Grand mal »** : Se compose de deux phases. **tonique**, implique une perte de connaissance soudaine, une contraction musculaire généralisée et peut provoquer une chute, un cri et des difficultés respiratoires. **clonique**, se caractérise par des secousses musculaires pendant 1 à 3 minutes. Après la crise, la personne se sent généralement très fatiguée et souffre de maux de tête [7].
- **Crise généralisée myoclonique** : Se caractérise par des secousses musculaires involontaires, pouvant provoquer des chutes. Ces crises ne sont pas accompagnées de perte de conscience et durent généralement quelques secondes. Des myoclonies peuvent également survenir pendant le sommeil sous forme de soubresauts nocturnes [7].




FIGURE 1.2 – Classification des Types de Crises Épileptiques.[8]

2.5 Phases des Crises

Les Crises d'Épilepsie sont généralement divisées en quatre phases distinctes :

- **Pré-ictal** : période précédant la crise, caractérisée par des changements subtils dans l'activité cérébrale.
- **Ictal** : phase de la crise elle-même, avec une activité électrique anormale détectable par EEG.
- **Post-ictal** : période suivant la crise, souvent marquée par de la confusion ou de la fatigue.
- **Inter-ictal** : période entre les crises, où l'activité cérébrale revient à la normale.




FIGURE 1.3 – Phases Des Crises.[9]

2.6 Diagnostic

Le diagnostic de l'Épilepsie représente une étape clé, mais parfois complexe, dans la gestion de cette affection neurologique. L'examen principal pour confirmer ce diagnostic est l'électroencéphalogramme (EEG), qui enregistre l'activité électrique du cerveau à l'aide d'électrodes placées en surface. L'EEG permet de déterminer si les crises sont focales, généralisées ou d'origine indéterminée. Des examens complémentaires, comme l'imagerie par résonance magnétique (IRM), sont souvent réalisés pour détecter d'éventuelles anomalies cérébrales. Un bilan biologique peut aussi être prescrit pour rechercher des causes métaboliques ou infectieuses [10].

2.7 Évaluation de l'Impact Sur la Vie Quotidienne

L'Épilepsie a des conséquences qui vont bien au-delà des crises elles-mêmes. Elle affecte le bien-être psychologique, scolaire, social et professionnel des personnes concernées, en particulier les enfants. Elle peut entraîner du stress, de l'isolement, des troubles cognitifs, ainsi qu'une baisse de l'estime de soi. Les familles partagent aussi cette souffrance, vivant dans l'inquiétude quotidienne. En plus, la perception négative de la maladie dans la société renforce les tabous et pousse parfois à la cacher, ce qui alourdit le fardeau pour les patients et leur entourage [11].

3 L'ÉlectroEncéphaloGramme (EEG)

L'ÉlectroEncéphaloGramme (EEG) est un test fonctionnel non invasif qui mesure l'activité électrique du cerveau. Il est couramment utilisé dans les hôpitaux et les cabinets de neurologues, car il est indolore et peut être répété plusieurs fois sans danger pour le patient [12]. Plus précisément, l'EEG enregistre les champs électriques générés par le flux de courant dans et autour des neurones, à l'aide d'électrodes placées sur le cuir chevelu. Bien que cette technologie existe depuis près d'un siècle, son champ d'applications s'est considérablement élargi [13]. Grâce aux avancées en traitement du signal et en intelligence artificielle, l'EEG trouve aujourd'hui sa place dans des domaines innovants comme la détection précoce des crises d'épilepsie ou la recherche en neurosciences cognitives.[14].



FIGURE 1.4 – Exemple d'un Enregistrement Des Signaux EEG.

3.1 Systèmes de Placement des Électrodes

Le positionnement des électrodes EEG est essentiel pour garantir des enregistrements fiables et comparables. Pour standardiser cette pratique, le système international 10-20 a été introduit en 1958 par l'IFCN (International Federation of Clinical Neurophysiology), reposant sur des repères anatomiques du crâne. Il prévoit l'utilisation d'au moins 21 électrodes chez l'adulte. En 1998, ce système a été complété par le 10-10, offrant une résolution plus fine, utile en clinique et en recherche [15].

- **Le Système 10-20 :** Ce système repose sur l'utilisation d'au moins 21 électrodes, dont 19 sont actives, tandis qu'une ou deux servent de référence (A1 et A2). Son nom provient des distances spécifiques entre les électrodes, qui correspondent à 10% ou 20% de la longueur des axes crâniens. Le placement des électrodes se fait en se basant sur des mesures précises issues de repères anatomiques standardisés : le nasion (à la racine du nez), l'inion (la proéminence occipitale), ainsi que les points préauriculaires gauche et droit situés juste devant le tragus [16].




FIGURE 1.5 – Représentation de la répartition des électrodes selon le système international 10/20 [17].

Par convention, les électrodes situées sur l'hémisphère droit sont numérotées avec des chiffres pairs, celles de l'hémisphère gauche avec des chiffres impairs, et celles placées sur la ligne médiane sont désignées par la lettre «z». Le nom de chaque électrode reflète sa position sur le cuir chevelu : Fp pour frontopolaire, F pour frontale, C pour centrale, P pour pariétale, O pour occipitale et T pour temporale [16].

- **Le Système 10-10 :** Est une extension du système 10-20 visant à améliorer la résolution spatiale des enregistrements EEG. Il introduit des électrodes supplémentaires en réduisant l'espacement à environ 10% de la distance entre les repères crâniens, permettant ainsi d'atteindre jusqu'à 64 électrodes. Cette configuration offre une meilleure précision, particulièrement utile en cartographie préchirurgicale de l'épilepsie et en recherche en neuroimagerie [18].




FIGURE 1.6 – Localisation des électrodes sur le scalp, selon le système « 10-10 » [18].

3.2 Types et Caractéristiques Des Signaux EEG

Les signaux captés par l'électroencéphalogramme (EEG) sont répartis en différentes bandes de fréquences, chacune correspondant à des états cérébraux spécifiques, qu'ils soient physiologiques (comme le sommeil ou l'éveil) ou pathologiques (comme les troubles neurologiques). Ces bandes fréquentielles jouent un rôle fondamental dans l'interprétation des enregistrements EEG, aussi bien en pratique clinique qu'en recherche neuroscientifique [19].

- **Ondes delta (0,5 à 4 Hz) :** Typiquement observées pendant le sommeil profond chez l'adulte. Leur présence à l'état d'éveil peut être le signe d'une anomalie cérébrale.
- **Ondes thêta (4 à 7 Hz) :** Lors de la somnolence ou du sommeil léger. Chez l'adulte éveillé, une activité thêta excessive peut indiquer une pathologie.
- **Ondes alpha (8 à 13 Hz) :** Présentes lorsque la personne est calme, éveillée et les yeux fermés. Elles disparaissent généralement à l'ouverture des yeux ou lors d'une activité mentale.
- **Ondes bêta (14 à 30 Hz) :** Liées à une activité mentale active, à la concentration ou à l'anxiété. Une activité bêta anormalement élevée peut également résulter de l'action de certains médicaments.
- **Ondes gamma (>30 Hz) :** Moins fréquemment utilisées en clinique, elles sont associées à des fonctions cognitives supérieures telles que la perception, l'apprentissage et la mémoire.

La reconnaissance des différentes ondes cérébrales est essentielle pour détecter d'éventuelles anomalies ou encéphalopathies, et elle joue un rôle clé dans le diagnostic de troubles neurologiques tels que l'épilepsie [20].




FIGURE 1.7 – Different-EEG-waveforms [21].

3.3 Rôle de l'EEG Dans la Prédiction des Crises

L'ÉlectroEncéphaloGramme constitue un outil essentiel pour l'analyse de l'activité cérébrale chez les personnes atteintes d'épilepsie. Elle permet non seulement de prédire l'imminence d'une crise en détectant des changements subtils dans les signaux électriques du cerveau, en particulier durant la phase pré-ictale, mais aussi de distinguer les différents états cérébraux associés à la pathologie [22]. En effet, l'analyse EEG permet d'identifier et de différencier les phases inter-ictale, pré-ictale et ictale, notamment grâce à des méthodes d'analyse de similarité par rapport à des états de référence. Cette distinction est particulièrement utile dans les régions cérébrales proches du foyer épileptique, où les variations de signal sont les plus significatives. Ces avancées offrent des perspectives prometteuses pour le développement de systèmes de détection et de prédiction des crises en temps réel [23].




FIGURE 1.8 – Phases des crises dans un signal EEG [24].

4 Conclusion

Ce premier chapitre a posé le cadre médical nécessaire à la compréhension de l'épilepsie et de ses manifestations. Il a également souligné l'importance de l'EEG dans la détection des crises, préparant ainsi le terrain pour les méthodes de prédiction abordées par la suite.

CHAPITRE 2

DEEP LEARNING POUR LES SÉRIES TEMPORELLES

1 Introduction

Les signaux EEG, enregistrés en continu sur plusieurs canaux, forment des séries temporelles complexes à forte valeur informative. Leur traitement nécessite des méthodes capables de capter la dynamique temporelle et la structure multivariée des données. L'apprentissage profond offre des solutions efficaces pour modéliser ces signaux, notamment à travers des architectures comme les CNN, LSTM ou Transformers. Ce chapitre présente les bases des séries temporelles EEG et les principales approches de deep learning utilisées pour leur classification et prédiction dans un contexte médical.

2 Les Séries Temporelles

2.1 Définition et Caractéristique

Une série temporelle est une suite d'observations faites au cours du temps. Elle peut être représentée par une suite $\{X_t\}_{t \in T}$, où X_t est la valeur observée à l'instant t , et T l'ensemble des temps d'observation. Les séries temporelles sont également formées de différentes composantes structurelles.

- **Tendance** : Évolution générale de la série sur le long terme (hausse, baisse, stabilité).
 - Exemple :
 - Amélioration progressive d'un état de santé,
 - Réchauffement climatique,
 - Croissance économique.
- **Saisonnalité** : les variations régulières qui reviennent à des moments précis, comme chaque jour, semaine, mois ou année.
 - Exemple :
 - Ventes en période de fêtes,
 - Température selon les saisons.
- **Le Bruit (ou Le Résidu)** : une variation aléatoire ou imprévisible dans une série temporelle.
 - Exemple :
 - Des variations imprévues dans les données météo, comme un orage soudain,
 - Des artefacts dans un signal EEG dus à des mouvements du patient.

Dans une ST, la valeur observée à un instant donné peut dépendre partiellement ou fortement des valeurs précédentes : on parle alors de dépendance temporelle. Cette propriété est essentielle, car elle reflète le lien logique entre les événements successifs dans le temps.

Exemples :

★ Économie :




FIGURE 2.1 – Évolution de l'indice Dow Jones de 1928 à 2004 (données mensuelles). [25]

★ Environnement :




FIGURE 2.2 – Évolution de l'intensité du vent, en m/s, au large de la Bretagne entre 1979 et 2001, données journalière [25].

★ Santé :




FIGURE 2.3 – Progression des cas de grippe en France, hebdomadairement, de 1984 (semaine 44) à 2002 (semaine 50), totalisant ainsi 945 valeurs.

2.2 Série Temporelle Univariée et Multivariée

Une série temporelle **univariée**, comme son nom l'indique, est une série contenant une seule variable dépendante du temps.

Par exemple, un jeu de données contenant les valeurs de température relevées chaque heure au cours des deux dernières années. Ici, la température est la variable dépendante, car elle dépend du temps.

Time	Temperature
05 :00 am	59 °F
06 :00 am	59 °F
07 :00 am	58 °F
08 :00 am	58 °F
09 :00 am	60 °F

TABLE 2.1 – Exemple d'une Série Temporelle Univariée [26].

Une série temporelle **multivariée** est constituée de plusieurs variables évoluant dans le temps. Chaque variable dépend de ses propres valeurs passées, mais aussi des autres, avec lesquelles elle entretient des interdépendances. Cette interaction améliore la précision des prédictions. Par exemple, en météo, la température dépend aussi de l'humidité, du vent, du point de rosée, etc.

Time	Temperature	Cloud Cover	Dew Point	Humidity	Wind
05 :00 am	59 °F	97%	51 °F	74%	8 mph SSE
06 :00 am	59 °F	89%	51 °F	75%	8 mph SSE
07 :00 am	58 °F	79%	51 °F	76%	7 mph SSE
08 :00 am	58 °F	74%	51 °F	77%	7 mph S
09 :00 am	60 °F	74%	51 °F	74%	7 mph S

TABLE 2.2 – Exemple d'une Série Temporelle Multivariée [26].

Dans le domaine médical, et plus précisément dans l'analyse des signaux EEG, le caractère multi-varié est tout aussi essentiel. Les signaux EEG sont enregistrés à partir de plusieurs électrodes placées sur le cuir chevelu, générant ainsi une série temporelle multidimensionnelle. Ce type de données offre une vision plus globale de l'activité cérébrale, car il permet de détecter des corrélations spatiales et temporelles entre différentes régions du cerveau. L'analyse conjointe de ces signaux améliore la détection de motifs précurseurs de crises d'Épilepsie, en capturant des indices faibles ou localisés qui

pourraient être ignorés dans une approche univariée. En ce sens, les séries temporelles multivariées constituent un outil puissant pour la médecine préventive, notamment dans l'identification de signes précoces de pathologies neurologiques [27].

3 Deep Learning Appliqué Aux Séries Temporelles

3.1 Introduction

L'apprentissage profond est un sous-domaine de l'intelligence artificielle qui s'appuie sur des réseaux neuronaux multicouches capables de simuler des processus cognitifs complexes. L'apprentissage profond est au cœur de la plupart des applications d'intelligence artificielle (IA) utilisées aujourd'hui.

Pendant longtemps, les approches classiques d'apprentissage automatique, telles que les SVM, k-NN, Random Forests ou les réseaux de neurones peu profonds, ont été utilisées pour l'analyse EEG. Bien que partiellement efficaces, elles sont limitées par leur incapacité à capturer toute la complexité non linéaire des signaux EEG. De plus, leur nature statique ne leur permet pas de modéliser correctement la dynamique temporelle inhérente à ces signaux [28].

En réponse à ces limites, l'apprentissage profond permet désormais de découvrir automatiquement des représentations pertinentes à partir des données brutes. Les CNN (Convolutional Neural Networks) sont particulièrement adaptés pour extraire les caractéristiques spatiales à travers les multiples canaux EEG, tandis que LSTM excellent dans la modélisation des dépendances temporelles. Et plus récemment, les Transformers ont été explorés pour leur capacité à modéliser simultanément les dépendances spatiales et temporelles via des mécanismes d'attention [29].

3.2 Historique et développement du deep learning




FIGURE 2.4 – Quelques événements clé du développement historique des réseaux de neurones. [30]

3.3 Réseau Neuronal Convolutif

Un réseau de neurones convolutif (CNN) est un type de réseau neuronal profond conçu initialement pour le traitement d'images. Il repose sur l'opération mathématique de convolution, permettant de capturer automatiquement des motifs locaux (formes, structures) dans les données. Grâce à cette capacité, les CNN ont été largement adoptés dans des domaines variés tels que la vision par ordinateur, la reconnaissance vocale, et plus récemment, le traitement des ST. Dans ce contexte, les CNN permettent d'extraire automatiquement des caractéristiques discriminantes à partir de segments temporels successifs, tout en réduisant la complexité des entrées avant leur traitement par des couches récurrentes ou attentionnelles [31].

★ la Convolution 1D :

Dans le cadre des ST, la convolution unidimensionnelle (1D) est utilisée pour appliquer un filtre (ou noyau) glissant sur la séquence temporelle. Cette opération est définie mathématiquement par la relation suivante :

$$y(t) = \sum_{i=0}^{k-1} w(i) \cdot x(t+i) \quad (2.1)$$

où :

- x est la séquence d'entrée,
- w est le noyau convolutif de taille k ,
- $y(t)$ est la sortie au temps t , représentant une caractéristique locale extraite de la série.




FIGURE 2.5 – Architecture de CNN 1D [32]

3.4 Réseaux de Neurones Récurrents

- **LSTM :**

Les **LSTM** (Long Short-Term Memory) sont une variante des réseaux de neurones récurrents (RNN), conçue pour mieux gérer les dépendances à long terme dans les données séquentielles. Contrairement aux RNN classiques, les LSTM intègrent des cellules de mémoire et trois types de portes (*entrée, oubli, sortie*), qui régulent de manière sélective le flux d'informations [33].

- **Porte d'oubli** : détermine quelles anciennes informations doivent être conservées dans la cellule mémoire, à l'aide de la fonction sigmoïde :

$$f_t = \sigma(W_f^x \cdot x_t + W_f^h \cdot h_{t-1} + b_f)$$

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 un biais, et $\sigma(\cdot)$ la fonction sigmoïde.

- **Porte d'entrée** : sélectionne quelles nouvelles informations doivent être ajoutées à la cellule mémoire. Elle agit en combinaison avec un vecteur candidat $\tilde{c}_t$ généré via une fonction tanh :

$$i_t = \sigma(W_i^x \cdot x_t + W_i^h \cdot h_{t-1} + b_i)$$

$$\tilde{c}_t = \tanh(W_c^x \cdot x_t + W_c^h \cdot h_{t-1} + b_c)$$

- **Mise à jour de la cellule mémoire** : Cette opération combine l'ancienne mémoire (filtrée par f_t) et la nouvelle information (pondérée par i_t), assurant un équilibre entre oubli et apprentissage.

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

- **Porte de sortie** : décide quelles informations sont envoyées à l'état caché h_t , soit la sortie visible du LSTM :

$$o_t = \sigma(W_o^x \cdot x_t + W_o^h \cdot h_{t-1} + b_o)$$

$$h_t = o_t \circ \tanh(c_t)$$

Ce fonctionnement permet aux LSTM de retenir ou d'oublier des informations selon leur pertinence, ce qui les rend très efficaces pour modéliser des séquences complexes comme les signaux EEG ou textuels [33].




FIGURE 2.6 – Schéma d'une cellule mémoire d'un LSTM [34].

• **Bidirectional LSTM :**

Le **Bi-LSTM** (Bidirectional Long Short-Term Memory) est une extension du LSTM qui traite les séquences dans deux directions : vers l'avant (du passé vers le futur) et vers l'arrière (du futur vers le passé). Cette double lecture permet au modèle de capturer simultanément le contexte passé et futur, offrant une meilleure compréhension globale de la séquence [35].

Un Bi-LSTM est composé de deux LSTM indépendants :

- Un qui lit la séquence dans l'ordre chronologique (passage avant),
- Un autre qui la lit dans l'ordre inverse (passage arrière).

Les sorties des deux directions sont souvent concaténées pour enrichir la représentation de chaque pas de temps. Cette architecture surpasse les LSTM unidirectionnels dans des tâches comme la modélisation du langage, la reconnaissance vocale ou l'analyse de signaux EEG [35].




FIGURE 2.7 – Schéma d'une cellule mémoire d'un LSTM [36].

3.5 Transformer

Les Transformers sont une architecture introduite par Vaswani *et al.* (2017) dans leur article “*Attention Is All You Need*” [37]. Contrairement aux réseaux récurrents classiques tels que les RNN ou LSTM, les Transformers s’affranchissent du traitement séquentiel en adoptant une structure entièrement parallèle, ce qui leur permet de mieux modéliser les dépendances à long terme tout en bénéficiant d’une plus grande efficacité computationnelle.

L’architecture Transformer repose sur une structure encodeur–décodeur. Chaque partie est composée de blocs empilés comportant des sous-couches d’attention, de normalisation et de feedforward.




FIGURE 2.8 – Transformer Architecture.[38]

- **Composants fondamentaux :**

- ★ **Le mécanisme d’attention (scaled dot-product attention) :**

Le cœur du Transformer repose sur le mécanisme d’attention à produit scalaire échelonné (scaled dot-product attention). Ce mécanisme repose sur le calcul suivant :

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

où :


- Q (Query), K (Key) et V (Value) sont des matrices dérivées des entrées.
- d_k est la dimension des clés, utilisée pour normaliser les produits scalaires.
- Softmax convertit les scores en probabilités, indiquant l'importance relative de chaque élément dans la séquence.

★ **Self-Attention :**

Le mécanisme de Self-Attention permet à chaque élément d'une séquence de considérer l'ensemble des autres éléments, en leur attribuant des poids différents selon leur pertinence contextuelle. Ainsi, chaque position dans la séquence peut adapter sa représentation en fonction des informations globales, ce qui est particulièrement utile pour capturer les dépendances à longue portée dans des données séquentielles. Ce principe est appelé self-attention, car chaque élément "s'attend lui-même" en tenant compte du contexte complet [39].

- ★ **Multi-Head Attention :** Pour capturer différents types de relations simultanément, les Transformers utilisent une attention multi-tête. Ce mécanisme applique plusieurs opérations d'attention indépendantes en parallèle, chacune avec ses propres projections linéaires [37] [39]. Chaque tête peut ainsi se concentrer sur différents aspects du contexte (dépendances courtes, longues, motifs récurrents, etc.).

les résultats sont ensuite concaténés puis projetés à nouveau, permettant une représentation plus riche [37].



★ **Normalisation, connexions résiduelles et feedforward :**

Chaque sous-couche (attention ou feedforward) est suivie de :

- une connexion résiduelle (skip connection)
- une normalisation de couche (LayerNorm)

Cela stabilise l'entraînement et facilite l'optimisation.

Le réseau *feedforward* est un petit MLP appliqué individuellement à chaque position :

$$\text{FFN}(x) = \max(0, xW_1 + b_1)W_2 + b_2$$

- **Encodage positionnel :**

Contrairement aux réseaux récurrents (RNN, LSTM), les Transformers ne traitent pas les éléments d'une séquence dans un ordre strictement séquentiel. Par conséquent, elle ne dispose pas naturellement d'un moyen d'intégrer l'ordre des éléments dans une séquence. Or, dans les ST, le positionnement temporel des données est crucial pour capturer les dépendances dynamiques. Pour combler cette lacune, un **encodage positionnel** (positional encoding) est ajouté à chaque vecteur d'entrée afin d'injecter l'information de position dans la séquence [37].

- **Encodage sinusoïdal (fixe) :**

Dans l'article original de Vaswani et al. (2017), l'encodage positionnel est implémenté à l'aide de fonctions sinusoïdales de différentes fréquences. L'idée est de permettre au modèle de détecter la position relative des éléments à travers des motifs mathématiques récurrents [37]. Les formules sont les suivantes :

$$PE_{(pos, 2i)} = \sin\left(\frac{pos}{10000^{\frac{2i}{d_{model}}}}\right), \quad PE_{(pos, 2i+1)} = \cos\left(\frac{pos}{10000^{\frac{2i}{d_{model}}}}\right) \quad (2.2)$$

où :

- pos est la position dans la séquence,
- i est l'indice de dimension,
- d_{model} est la taille du vecteur d'entrée.

- **Encodage appris (trainable) :**

Une autre approche consiste à utiliser des vecteurs de position apprenables (*learned positional embeddings*), c'est-à-dire optimisés durant l'entraînement du modèle. Cette méthode permet une meilleure adaptation aux spécificités de la tâche ou du jeu de données. Cependant, ces encodages peuvent présenter une capacité de généralisation plus limitée, notamment lorsqu'il s'agit de traiter des séquences plus longues ou plus courtes que celles rencontrées à l'entraînement [28].

- **Architecture de l'encodeur Transformer :**

- **Entrée + Encodage positionnel :** Chaque vecteur d'entrée est d'abord enrichi par l'encodage positionnel (sinusoïdal ou appris). Cette somme (entrée + position) est transmise à chaque bloc encodeur, afin de maintenir la structure temporelle de la séquence [41].

- **Multi-Head Attention** : La première sous-couche applique le mécanisme d'attention multi-tête, qui permet à chaque position de la séquence de pondérer dynamiquement l'importance des autres positions, tout en capturant plusieurs types de dépendances grâce aux différentes têtes [41].
 - **Connexion résiduelle + Normalisation 1** : La sortie du module d'attention est ajoutée à l'entrée d'origine (résidu), puis normalisée à l'aide d'une *Layer Normalization* [41].
 - **Réseau feedforward positionnel (FFN)** : Chaque position (chaque vecteur de la séquence) est ensuite traitée indépendamment par un petit réseau de neurones dense à deux couches [41].
 - **Connexion résiduelle + Normalisation 2** : La sortie du FFN est ajoutée au vecteur d'entrée du module (résidu), puis normalisée [41].
 - **Empilement des blocs** : Le processus est répété N fois (par exemple, 6 fois dans l'article original). À chaque couche, les représentations deviennent de plus en plus abstraites et contextuelles. La sortie finale est une séquence de vecteurs, contenant l'information enrichie de la totalité de la séquence [41].
- **Architecture de Décodeur Transformer** :

L'architecture Transformer complète, introduite par Vaswani et al. (2017) dans "Attention Is All You Need" [37], comprend un décodeur utilisé principalement pour les tâches de génération séquentielle, comme la traduction automatique ou le résumé de texte. Le décodeur est constitué de blocs intégrant :

 - une **self-attention masquée**, qui empêche chaque position de voir les positions futures de la séquence de sortie,
 - une **attention croisée** (encoder-decoder attention), permettant au décodeur de se focaliser sur les représentations produites par l'encodeur.

Pour les tâches de classification dans les ST comme les signaux EEG, seule la partie encodeur du Transformer est généralement utilisée, car elle suffit à générer une sortie fixe (classe prédite) à partir d'une séquence en entrée. Comme le précise une étude récente :

"For classification problems only the encoder without the decoder part is used since only a single output conveying the classification result is required." [42]

4 Conclusion

Ce chapitre a mis en évidence la richesse et la pertinence des approches d'apprentissage profond dans l'analyse des séries temporelles complexes, telles que les signaux EEG. En explorant des architectures variées comme les réseaux convolutifs (CNN), les réseaux à mémoire longue (LSTM, BiLSTM) et les Transformers, nous avons montré comment ces modèles permettent d'extraire automatiquement des représentations pertinentes. Leur capacité à modéliser les dépendances temporelles ou contextuelles rend ces approches particulièrement efficaces pour des tâches critiques telles que la prédiction de crises d'Épilepsie.

CHAPITRE 3

APPROCHE PRATIQUE ET MODÉLISATION

1 Introduction

Dans ce chapitre, nous décrivons en détail la démarche pratique adoptée pour développer, entraîner et évaluer notre modèle de prédiction des crises d'épilepsie à partir de signaux EEG. L'objectif principal est de montrer comment, à partir d'un jeu de données brut (CHB-MIT), nous avons mis en place un pipeline complet de prétraitement, élaboré une architecture hybride intégrant des réseaux convolutifs (CNN), des LSTM bidirectionnels, des mécanismes d'attention et un encodeur Transformer.

Nous commençons par présenter l'environnement logiciel, les bibliothèques et le langage de programmation utilisés (section 2), puis nous décrivons le jeu de données EEG (section 3) ainsi que les travaux connexes (section 4). La section 5 est consacrée à l'architecture finale du modèle proposé, aux mesures de performance (section 5.1) et aux résultats obtenus (section 5.2). Nous comparons ensuite notre approche aux modèles existants dans la littérature (section 6). La section 7 présente le déploiement de notre solution sur une application mobiles. Enfin, la section 8 discute des limites de notre approche et propose des perspectives pour des travaux futurs.

2 Outils utilisés

2.1 Environnement logiciel

Le travail a été réalisé sur un ordinateur équipé d'un processeur Intel Core i9-14900KF, de 64 Go de RAM, de 2 To de stockage répartis sur deux disques de 1 To, et de deux cartes graphiques : une NVIDIA GeForce RTX 3090 Ti avec 24 Go de mémoire dédiée, utilisée pour l'entraînement des modèles, et une Intel UHD Graphics 770 intégrée pour l'affichage. Le système utilisé est Windows 10 Professionnel 64 bits. Le développement a été réalisé à l'aide de l'éditeur Visual Studio Code, avec la gestion des environnements virtuels assurée par conda.

2.2 Langage de programmation

Python est un langage de programmation puissant et facile à apprendre. Il dispose de structures de données de haut niveau et permet une approche simple mais efficace de la programmation orientée objet. Parce que sa syntaxe est élégante, que son typage est dynamique et qu'il est interprété, Python est un langage idéal pour l'écriture de scripts et le développement rapide d'applications dans de nombreux domaines et sur la plupart des plateformes.[43]

2.3 Les bibliothèques et le Framework Utilisés

Ce projet a été réalisé en s'appuyant sur différentes bibliothèques et frameworks couramment utilisés en apprentissage profond et en traitement de signaux.

2.3.1 TensorFlow

TensorFlow^a est une plateforme open source développée par Google pour le calcul numérique, avec un focus sur l'entraînement de modèles de machine learning et deep learning. Elle permet la création de graphes computationnels, la parallélisation sur GPU/TPU, Son nom s'inspire notamment du fait que les opérations actuelles des réseaux de neurones s'effectuent principalement via une table multidimensionnelle de données, appelée Tenseurs qui est l'équivalent d'une matrice. [44] [45]

a. <https://www.tensorflow.org>



2.3.2 Keras

Keras^a est une API de haut niveau intégrée à TensorFlow, conçue pour simplifier la création et l'entraînement de modèles de deep learning. Elle est largement utilisée pour le prototypage rapide, la recherche de pointe et le passage en production. Keras offre une interface conviviale, une modularité permettant de composer facilement des modèles à partir de composants configurables, et une extensibilité pour intégrer des éléments personnalisés.[46]

a. <https://keras.io>



2.3.3 Scikit-learn

Scikit-learn^a est une bibliothèque open source d'apprentissage automatique qui prend en charge l'apprentissage supervisé et non supervisé. Elle fournit également divers outils pour l'ajustement de modèles, le prétraitement des données, la sélection de modèles, l'évaluation de modèles et de nombreuses autres utilités

a. <https://scikit-learn.org>



2.3.4 SciPy

SciPy.signal^a est un sous-module de la bibliothèque SciPy qui fournit des outils pour le traitement du signal, notamment la conception de filtres, l'analyse spectrale et la convolution. Il prend en charge les signaux continus et discrets, avec des applications dans des domaines tels que le traitement audio, les communications et l'analyse de données. [47]

a. <https://scipy.org/>



2.3.5 Wfdb

Wfdb^a Software Package est une suite logicielle open source développée pour la lecture, l'écriture et le traitement de signaux physiologiques et de leurs annotations. Initialement écrit en langage C, il a été adapté pour d'autres langages, notamment Python et MATLAB, facilitant ainsi l'accès aux bases de données de signaux physiologiques telles que celles hébergées sur PhysioNet. La version Python, connue sous le nom de wfdb, est une bibliothèque qui permet de lire, écrire et traiter des signaux physiologiques et des annotations associées. Elle est largement utilisée pour l'analyse de signaux tels que l'ECG, l'EEG et l'EMG, offrant des outils pour la visualisation, le filtrage et l'extraction de caractéristiques.

a. <https://wfdb.io/>



2.3.6 Mne

Mne-Python^a est une bibliothèque open source en Python destinée à l'analyse des données électrophysiologiques, notamment EEG, MEG, et autres mesures neurophysiologiques. Il fournit des outils pour lire, visualiser, prétraiter et analyser ces signaux.

a. <https://mne.tools/stable/>



2.3.7 Numpy

Numpy^a est la bibliothèque fondamentale pour le calcul scientifique en Python. Elle fournit un objet tableau multidimensionnel, divers objets dérivés (tels que des masques et des matrices), ainsi qu'une variété de routines pour des opérations rapides sur des tableaux, comprenant des opérations mathématiques, la logique, la manipulation de formes, le tri, la sélection, les transformations discrètes de Fourier, l'algèbre linéaire, les statistiques de base, et bien plus encore.

a. <https://numpy.org/>



3 EEG Dataset

3.1 Comparaison des jeux de données EEG existants

Afin de mieux situer notre choix de base de données, le tableau suivant compare les jeux de données EEG les plus courants dans le domaine de l'analyse des crises d'épilepsie, selon plusieurs critères pertinents.

Dataset	Patients	Crises	Type EEG	Utilisation	Accès	Références / Remarques
CHB-MIT	24	~198	Scalp	Prédiction	Public	[53] Données bien annotées
TUH Seizure	>600	>3000	Scalp	Détection	Public	[54] Corpus très vaste et hétérogène
EPILEPSIAE	30	>400	Scalp + iEEG	Prédiction	Sous licence	[55] Données haute qualité
Freiburg iEEG	21	>87	iEEG	Prédiction	Restreint	[56] Très utilisé en recherche clinique
SEED-IV	15	-	Scalp	Non applicable	Public	[57] Pour émotions EEG
Bonn EEG	5	-	Scalp	Détection (simple)	Public	[58] Segments propres, binaire
Bern-Barcelona	5	375 segments	iEEG	Détection	Public	[59] Segments courts
IEEG Portal	>100	Variable	iEEG + Scalp	Prédiction + Détection	Restreint	[60] Plateforme collaborative

TABLE 3.1 – Comparaison des jeux de données EEG pour l’analyse de l’épilepsie

Ce tableau présente une comparaison des principaux jeux de données EEG utilisés dans le domaine de l’épilepsie. On y observe une diversité en termes de nombre de patients, de types d’EEG (scalp vs iEEG), d’accès (public ou restreint) ainsi que de finalité (prédiction ou détection des crises).

Le dataset CHB-MIT reste l’un des plus utilisés en recherche, notamment pour la prédiction, grâce à sa disponibilité publique et sa bonne annotation.

3.2 CHB-MIT

Une base de données contenant des enregistrements EEG de sujets pédiatriques atteints d’Épilepsie réfractaire. Elle a été créée par une équipe de chercheurs du Children’s Hospital Boston (CHB) et du Massachusetts Institute of Technology (MIT), puis publiée en open source sur la plateforme PhysioNet afin de soutenir la recherche sur l’Épilepsie.

Les signaux ont été enregistrés à l’aide de systèmes EEG multi-canaux , avec une fréquence d’échantillonnage de 256 Hz. Ces enregistrements sont regroupés en 23 cas, correspondant à 22 sujets différents (Le cas "chb21" a été obtenu un an et demi après le cas "chb01" du même patient). L’ensemble de la base non compressée occupe environ 42,6 Go et comprend 664 fichiers EEG au format standard **.edf**. Chaque cas contient entre 9 et 42 enregistrements EEG d’une durée d’environ une heure, à l’exception de certains cas spécifiques où la durée est plus longue (2 à 4 heures), Parmi l’ensemble des enregistrements, 129 fichiers contiennent une ou plusieurs crises, représentant au total 198 crises annotées.[48]

3.3 Prétraitement

Le prétraitement des signaux EEG est une étape essentielle pour la qualité des prédictions en deep learning. Dans ce projet, les signaux bruts du dataset **CHB-MIT** sont transformés, segmentés et étiquetés de manière à extraire des fenêtres d'activité cérébrale représentatives des états interictal et préictal. Le pipeline mis en place suit une stratégie rigoureuse permettant d'obtenir des données propres, équilibrées et prêtes à l'entraînement.

Ce processus se décompose en plusieurs étapes clés, résumées ci-dessous :

- Chargement des fichiers EEG bruts depuis les enregistrements.
- Répartition des données entre les ensembles d'entraînement (80%) et de test (20%).




FIGURE 3.1 – Diagramme en donut illustrant la répartition 80 % / 20 % entre entraînement et test

- Nettoyage des signaux EEG pour supprimer les bruits indésirables.
- vérification et renommage des canaux.
- Identification précise des périodes de crise (*SOP - Seizure Occurrence Period*) à partir des annotations.
- Définition des périodes préictaux avant chaque crise : deux heure avant le début de chaque crise excluant les 3 dernières minutes (*SPH - Seizure Prediction Horizon*).
- Sélection de segments interictaux : Quatre heures avant/après chaque crise.




FIGURE 3.2 – Représentation des fenêtres temporelles utilisées pour la prédiction de crise.

- Chaque segment pré-ictal ou inter-ictal est ensuite divisé en échantillons plus petits par la méthode d'échantillonnage par fenêtre mobile. La fenêtre dure 8 s, avec un chevauchement de 4 s pour augmenter l'échantillon.




FIGURE 3.3 – Méthode d'échantillonnage par fenêtre mobile.

- Une stratégie de sous-échantillonnage probabiliste a été mise en œuvre pour réduire le nombre de segments interictaux, dans le but d'atténuer le déséquilibre entre les classes.

4 Travaux connexes

La prédiction en temps réel des crises d'épilepsie à partir des signaux EEG est un domaine de recherche en pleine expansion, avec de nombreuses approches explorées pour améliorer la détection précoce et la précision des alertes. Traditionnellement, les méthodes d'apprentissage automatique telles que le k-plus proches voisins (KNN) [61], les machines à vecteurs de support (SVM) [61], les réseaux de neurones artificiels (ANN) [62] et les classificateurs flous [63] reposaient sur une extraction manuelle des caractéristiques des signaux EEG. Cette approche présente plusieurs limitations, notamment une difficulté à traiter de grands volumes de données et une adaptabilité limitée aux nouvelles données. Ces contraintes ont conduit à l'émergence de techniques d'apprentissage profond, qui permettent une extraction automatique et hiérarchique des caractéristiques.

Plusieurs études convertissent les signaux EEG en représentations temps-fréquence, telles que des spectrogrammes ou des transformations en ondelettes continues (CWT), afin d'exploiter l'efficacité des réseaux de neurones convolutifs (CNN) pour l'extraction de caractéristiques spatiales [64]. Par exemple, Wang et al. (2021) ont proposé un modèle CNN 3D à dilatation multi-échelle, exploitant des noyaux tridimensionnels pour extraire simultanément des caractéristiques temporelles, fréquentielles et spatiales des signaux EEG. Ce modèle a été évalué sur le jeu de données CHB-MIT, atteignant une précision de 80,5 %, une sensibilité de 85,8 % et une spécificité de 75,1 % [65].

Dans une autre étude, un modèle léger basé sur des CNN 1D, a été proposé avec deux variantes : l'une spécifique au patient et l'autre indépendante [66]. Des réseaux LSTM autonomes ont également été employés pour capturer la dynamique temporelle des signaux intracrâniens [67]. Dans [68], un modèle CNN + LSTM a atteint une sensibilité moyenne de 97,75 % et un taux de faux positifs de 0,2373/h sur le jeu de données CHB-MIT. Parmi les 24 patients du jeu de données CHB-MIT, certains ont été exclus de l'analyse. En particulier, le patient 12 a été écarté en raison de l'absence de certains canaux EEG essentiels, et le patient 7 en raison de données très incohérentes. Après cette sélection, le jeu de données final utilisé pour l'entraînement et l'évaluation du modèle comprenait environ 867 heures de signaux EEG continus, avec 147 crises réparties sur 21 patients.

Les approches hybrides combinant CNN et RNN (LSTM ou GRU) sont fréquemment utilisées pour exploiter à la fois les caractéristiques spatiales et temporelles. Par exemple, dans [69], un modèle 3D CNN + BiLSTM + CBAM attention a atteint 97,95 % de précision et 98,40 % de sensibilité, en sélectionnant uniquement 11 patients du jeu de données CHB-MIT, totalisant 55 crises et 235 heures d'EEG continu. Dans [70], un ResNet-LSTM entraîné avec une perte contrastive supervisée a obtenu une précision de 91,90 %.

Avec l'émergence des Transformers, plusieurs études ont intégré des mécanismes d'attention pour modéliser les dépendances globales dans les séquences EEG. Par exemple, dans [71], une architecture combinant Transformer, LSTM et GRU a atteint une sensibilité de 98,24 %, confirmant l'efficacité des mécanismes d'attention. De plus, [72] a introduit un modèle Approximate Spiking Convolutional Transformer sur le jeu de données CHB-MIT, permettant une extraction hiérarchique des caractéristiques spatio-temporelles, avec des performances accrues par rapport aux architectures classiques. Par ailleurs, Godoy et al. (2022) ont développé deux modèles basés sur des Transformers adaptés aux signaux EEG multi-canaux : le Temporal Multi-Channel Transformer (TMC-T) et le Vision Transformer (TMC-ViT). Ces modèles ont été entraînés de manière spécifique à chaque patient sur des signaux EEG bruts du jeu de données CHB-MIT. Les résultats expérimentaux ont démontré que le modèle TMC-ViT surpassait les architectures CNN traditionnelles en matière de prédiction des crises [73].

5 Modèle Réalisé

Dans le but de développer un système robuste de prédiction des états préictaux à partir de signaux EEG, nous avons conçu une architecture hybride combinant des réseaux convolutifs (CNN), des réseaux de neurones récurrents bidirectionnels (Bi-LSTM), un mécanisme d'attention et un encodeur Transformer. Cette combinaison vise à exploiter efficacement les caractéristiques spatio-temporelles complexes des signaux EEG. Les CNN sont utilisés pour extraire des motifs locaux pertinents dans les données EEG, capturant ainsi les informations spatiales essentielles. Les Bi-LSTM permettent de modéliser les dépendances temporelles bidirectionnelles, cruciales pour comprendre l'évolution des signaux dans le temps. Le mécanisme d'attention met en évidence les segments temporels les plus significatifs, améliorant ainsi la focalisation du modèle sur les instants critiques. Enfin, l'encodeur Transformer est intégré pour capturer les relations globales au sein des séquences, offrant une modélisation approfondie des interactions à long terme. Notre modèle vise à améliorer la détection des états préictaux, en tirant parti des avantages complémentaires de chaque composant pour une analyse approfondie et précise des signaux EEG.

Le modèle combine plusieurs blocs successifs :

– Couche d’entrée

Le modèle reçoit en entrée des segments EEG bruts. Avant l’entraînement, une normalisation est appliquée à chaque segment. Cette approche permet de réduire la variabilité statistique entre les segments et d’améliorer la stabilité de l’entraînement du modèle.

– Blocs convolutifs (CNN 1D)

Plusieurs couches convolutives avec des activations ReLU sont utilisées pour extraire des caractéristiques locales :

- **Bloc 1** : Conv1D avec 64 filtres, noyau de taille 7, suivi de LayerNormalization, SpatialDropout1D(0.1) et MaxPooling1D(pool_size=2).
- **Bloc 2** : Conv1D avec 128 filtres, noyau de taille 5, suivi de LayerNormalization, SpatialDropout1D(0.1) et MaxPooling1D(pool_size=2).
- **Bloc 3** : Conv1D avec 256 filtres, noyau de taille 3, suivi de LayerNormalization et SpatialDropout1D(0.1).

– Bloc Bi-LSTM (Bidirectional LSTM)

Une couche Bidirectional LSTM avec 64 unités est utilisée pour capturer les dépendances temporelles bidirectionnelles à partir de la sortie du CNN.

– Mécanisme d’attention

Ce bloc met en évidence les instants les plus discriminants :

- Dense(1, activation='tanh') pour produire un score par pas de temps.
- Flatten suivi d’une activation softmax.
- RepeatVector et Permute pour aligner le vecteur d’attention sur la dimension des features.
- Multiplication des entrées par les poids d’attention.

– Encodeur Transformer

Ce bloc modélise les relations globales sur toute la séquence :

- MultiHeadAttention avec $\text{key_dim}=64$, $\text{num_heads}=8$, $\text{dropout}=0.1$.
- Connexion résiduelle suivie de LayerNormalization.
- Dense avec $\text{ff_dim}=256$, $\text{activation}=\text{'relu'}$, suivi de Dropout(0.1).
- Connexion résiduelle suivie de LayerNormalization.

– Couches Fully Connected (Dense & Dropout)

- GlobalAveragePooling1D pour l'agrégation temporelle.
- Dense(128, $\text{activation}=\text{'relu'}$) suivi de Dropout (0.4).
- Dense(128, $\text{activation}=\text{'relu'}$).

– Couche de sortie

- Une couche Dense avec 1 unité et activation 'sigmoid' fournit une probabilité de classe (préictal vs interictal).




FIGURE 3.4 – Modèle proposé .

5.1 Mesures de performance

Le modèle a été évalué à l'aide d'une validation croisée à 5 plis, où l'ensemble des données est aléatoirement divisé en cinq sous-ensembles distincts. Lors de chaque itération, quatre plis sont utilisés pour l'entraînement du modèle, et le pli restant constitue l'ensemble de test.

Afin d'évaluer et de comparer les performances de notre approche à celles d'autres méthodes de

pointe, nous avons utilisé les métriques suivantes :

TP = nombre de vrais positifs,

TN = nombre de vrais négatifs,

FP = nombre de faux positifs,

FN = nombre de faux négatifs.

- **Accuracy** : pourcentage de bonnes prédictions sur l'ensemble des données :

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}.$$

- **Sensitivity** : taux de vrais positifs, mesure la capacité du modèle à détecter les vrais cas positifs :

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}.$$

- **Specificity** : taux de vrais négatifs, capacité du modèle à reconnaître correctement les segments interictaux :

$$\text{Spec} = \frac{\text{TN}}{\text{TN} + \text{FP}}.$$

- **False Positive Rate (FPR)** : proportion de segments interictaux mal classés comme préictaux :

$$\text{FPR} = \frac{\text{FP}}{\text{FP} + \text{TN}} = 1 - \text{Specificity}.$$

- **F₁-Score** : moyenne harmonique entre la précision et le rappel :

$$F_1 = 2 \times \frac{\text{Prec} \times \text{Recall}}{\text{Prec} + \text{Recall}} = \frac{2\text{TP}}{2\text{TP} + \text{FP} + \text{FN}}.$$

- **AUC (Area Under Curve)** : surface sous la courbe ROC (Receiver Operating Characteristic), qui évalue la capacité du modèle à bien séparer les deux classes à tous les seuils possibles. Mathématiquement, si on note $\text{TPR}(t)$ le taux de vrais positifs et $\text{FPR}(t)$ le taux de faux positifs pour un seuil t , alors :

$$\text{AUC} = \int_0^1 \text{TPR}(\text{FPR}^{-1}(x)) dx,$$

ou bien, dans la pratique discrétisée :

$$\text{AUC} = \sum_{i=1}^{N-1} (\text{FPR}_{i+1} - \text{FPR}_i) \times (\text{TPR}_{i+1} + \text{TPR}_i) / 2.$$

Cette surface mesure la probabilité qu'un échantillon positif soit classé avec une probabilité supérieure à un échantillon négatif.[74]

5.2 Résultats et discussion

Les performances moyennes du modèle sont présentées dans le tableau 3.2.

Accuracy	Sensitivity	Specificity	F1 Score	FPR	AUC-ROC
93.54%	96.30%	90.78%	0.9343	0.092	0.98

TABLE 3.2 – Résultats moyens de performance du modèle

Pour compléter l'analyse quantitative, la courbe ROC et la matrice de confusion permettent d'illustrer visuellement les performances du modèle en termes de séparation des classes et de répartition des prédictions, comme présenté dans la figure 3.5 ci-dessous.




FIGURE 3.5 – Matrice de confusion et courbe ROC pour le modèle.

Avec une AUC de 0.98, le modèle démontre une excellente capacité discriminante entre les phases interictales et préictales. Sa sensibilité élevée (96.30 %) garantit une détection efficace des signes annonciateurs de crise, tandis qu'une spécificité (90.78 %) permet de limiter le nombre de fausses alertes.

Ce compromis entre détection précoce et fiabilité est particulièrement adapté aux systèmes d'alerte en temps réel pour l'épilepsie, où il est crucial de minimiser les faux négatifs, c'est-à-dire les crises non détectées, qui peuvent avoir des conséquences graves pour le patient. Ce type de performance renforce la pertinence du modèle dans une perspective d'assistance clinique automatisée.

6 Comparaison entre le modèle proposé et les modèles de la littérature

Afin d'évaluer la performance de notre approche, nous présentons une comparaison avec plusieurs travaux récents de la littérature portant sur la prédiction des crises d'épilepsie à partir de signaux EEG. Le tableau 3.3 résume les principales caractéristiques de ces études. Ces éléments permettent de situer notre modèle dans le contexte des recherches actuelles et de mettre en évidence ses contributions potentielles.

Étude	Année	Dataset	Modèle	SOP	SPH	Seg.	Accuracy	Sensibilité	Spécificité	FPR/h
[75]	2021	CHB-MIT (23 patient)	Multi-scale Dilated 3D CNN	30min	5min	30s	80.5%	85.8%	75.1%	-
[76]	2022	CHB-MIT (21 patient)	CNN-LSTM	30min	3min	30s	-	97.75%	-	0.2373
[77]	2023	CHB-MIT (11 patient)	3D CNN + BiLSTM + CBAM	30min	5min	8s	97.95%	98.40%	-	0.017
[78]	2024	CHB-MIT + SNUH (23 patient)	ResNet-LSTM	15min	-	10s	91.90%	89.64%	-	0.058
[79]	2024	CHB-MIT	Multidimensional Transformer-LSTM-GRU	30min	5min	5s	-	98.24%	97.27%	0.033
[80]	2024	CHB-MIT (23 patient)	Spiking CNN + Transformer	15min	-	5s	-	96.8%	89.5%	-
[81]	2024	CHB-MIT (20 patient)	CNN + Transformer	60min	-	-	97.15%	99.28%	95.03%	-
[82]	2024	My Seizure Gauge (Public Dataset)	1D CNN + BiLSTM + Apprentissage profond personnalisé	2h	-	-	97%	-	-	-
[83]	2025	CHB-MIT	ResNet	-	-	-	95.79%	96.24%	-	0.046
Notre travail	2025	CHB-MIT	1D CNN + BiLSTM + transformer	2h	3min	8s	93.54%	96.30%	90.78%	0.092

TABLE 3.3 – Comparaison des méthodes de prédiction des crises d'épilepsie sur CHB-MIT

7 Déploiement de l'Application Mobile

Dans le cadre de ce projet, nous avons conçu une preuve de concept d'une application mobile, **AlertEpilepsy**, destinée à exploiter notre modèle de prédiction de crises d'épilepsie à partir de signaux EEG. Cette application vise à offrir un outil intelligent, accessible et préventif pour les patients épileptiques.

L'objectif principal est de permettre à un patient de recevoir une alerte jusqu'à deux heures avant l'apparition d'une crise, afin qu'il puisse se mettre en sécurité à temps. L'application prévoit également l'envoi automatique d'une alerte à un proche, accompagnée de la géolocalisation du patient,

dans un souci de sécurité et d'assistance.

D'un point de vue technique, en l'absence d'un appareil EEG portable (*wearable*), notre déploiement est actuellement basé sur une architecture client-serveur simulée, dans laquelle :

- Des segments de signaux EEG ont été extraits depuis le dataset CHB-MIT.
- Ces segments sont prétraités côté serveur (filtrage, segmentation, normalisation), de la même manière qu'un vrai signal aurait été envoyé via Bluetooth.

Le modèle est hébergé sur un serveur web via **FastAPI**. L'application envoie périodiquement des segments EEG sous forme de requêtes POST, et reçoit en retour une probabilité indiquant le risque de crise imminente.

Fonctionnalités de l'application

L'application **AlertEpilepsy**, développée en **Flutter**, propose les fonctionnalités principales suivantes :

- Connexion/Authentification (Fig. 3.6)
- Connexion Bluetooth à un appareil EEG (Fig. 3.7)
- Analyse IA via appel API du modèle de prédiction (Fig. 3.8)
- Déclenchement d'alertes en cas de prédiction de crise (Fig. 3.9)
- Envoi automatique de SMS à un proche enregistré, avec la géolocalisation du patient (Fig. 3.10)
- Statistiques et historique des alertes : consultation des alertes passées avec date, heure et statut (Fig. 3.11)




FIGURE 3.6 – Interfaces de connexion



FIGURE 3.7 – page des paramètres




FIGURE 3.8 – Analyse du signal EEG via IA



FIGURE 3.9 – Déclenche-ment d'alerte en cas de prédiction





FIGURE 3.10 – Saisie les informations du proches



FIGURE 3.11 – Historique & Statistiques des alertes



Cette première version de l'application constitue une étape essentielle vers un déploiement complet en temps réel, et servira de fondation à une future intégration avec des capteurs EEG portables. L'objectif est d'évoluer vers une prédiction embarquée et continue des crises, offrant un outil utile aux patients épileptiques dans un cadre médical ou personnel.

8 Limites et Travaux Futurs

Notre approche présente certaines limites qui méritent d'être analysées, Cette section met en évidence les principales limitations de notre travail et propose des pistes concrètes pour le perfectionner dans des travaux ultérieurs.

8.1 Limites identifiées

1. **Variabilité inter-patient et généralisation** : Le modèle a été entraîné et validé principalement sur le dataset CHB-MIT, qui regroupe des enregistrements d'enfants épileptiques. Les patterns EEG peuvent varier significativement d'un patient à l'autre (âge, localisation corticale des crises, pathologie sous-jacente). Par conséquent, la capacité de généralisation à des populations adultes ou à des arythmies différentes n'est pas garantie.
 - risque de baisse de performance lorsque le modèle est confronté à des enregistrements présentant des caractéristiques biomédicales différentes de celles de CHB-MIT.
 - certaines fréquences dominantes ou formes d'ondes (poussées, pointes) peuvent être atypiques en dehors du sous-groupe CHB-MIT.
2. **Prétraitement et sélection des canaux** : Notre pipeline se base sur une configuration fixe (18 canaux bipolaires, segmentation en fenêtres glissantes de 8 s avec recouvrement de 50%). Cette sélection, bien qu'issue d'études antérieures, peut ne pas être optimale pour tous les patients.

8.2 Perspectives et Travaux Futurs

Afin de dépasser ces limitations et renforcer la robustesse du système, plusieurs axes de recherche peuvent être envisagés :

1. **Évaluation multi-base de données** : Tester et adapter le modèle à d'autres jeux de données EEG (TUH, HMS Kaggle) pour valider sa capacité de généralisation.
2. Sélection automatique des canaux les plus pertinents, adaptée à chaque cas.

3. **Ajout de signaux multimodaux :** Enrichir le modèle en intégrant, en plus de l’EEG, d’autres signaux physiologiques (ECG, EMG) ou des annotations cliniques (événements comportementaux), afin d’affiner la prédiction du début de crise en repérant des signes périphériques (tressaillements musculaires, changement de fréquence cardiaque).
4. **Étude longitudinale et apprentissage continu :** Mettre en place un pipeline capable d’*apprendre en ligne*, c’est-à-dire de s’adapter à l’évolution de l’état clinique d’un patient sur plusieurs mois ou années :
 - Réentraîner périodiquement le modèle avec de nouvelles données annotées (crises confirmées par un neurologue) pour maintenir une performance élevée.

Ces axes de travaux futurs visent à faire évoluer notre modèle vers une solution fiable, interprétable et déployable en conditions réelles, ce qui est indispensable pour une utilisation clinique.

9 Conclusion

Ce chapitre a exposé l’ensemble du pipeline mis en place pour la prédiction de crises d’épilepsie à partir de signaux EEG CHB-MIT, depuis le prétraitement des données jusqu’à l’évaluation des performances du modèle. En combinant des CNN, Bi-LSTM et un encodeur Transformer, nous avons conçu une architecture performante, validée par des métriques standards, Puis son déploiement mobile. Les résultats sont comparables, voire supérieurs, à ceux de la littérature. Des pistes d’optimisation restent ouvertes, notamment sur la généralisation inter-patient et le temps réel.

CONCLUSION GÉNÉRALE

Ce travail s'est inscrit dans le cadre de l'exploration et de l'application de techniques avancées d'intelligence artificielle pour l'analyse des signaux temporels, en particulier les signaux EEG. À travers une étude approfondie des architectures de deep learning, notamment les modèles hybrides combinant CNN, LSTM et Transformers, nous avons pu démontrer la pertinence de ces approches pour des tâches complexes telles que la prédiction de crises d'épilepsie.

À partir du jeu de données CHB-MIT, nous avons conçu un système capable de détecter les phases préictales avec une précision satisfaisante, validée par plusieurs métriques standard (accuracy, sensibilité, spécificité, AUC, etc.). Le modèle développé a été intégré dans une application mobile, capable d'effectuer des prédictions localement et d'envoyer automatiquement une alerte à un tiers en cas de détection de crise imminente.

Ce projet constitue une contribution concrète à la santé connectée, en fournissant aux patients un outil d'aide à la décision portable, réactif et intelligent.

Parmi les perspectives futures, on peut envisager l'amélioration de la personnalisation du modèle par patient, l'adaptation du pipeline à d'autres bases de données cliniques, ainsi que l'intégration de modules de visualisation en temps réel pour un suivi plus interactif des signaux EEG.

BIBLIOGRAPHIE

- [1] Organisation mondiale de la santé. *Épilepsie – Fiche d'information*, 2023. Disponible sur : <https://www.who.int/fr/news-room/fact-sheets/detail/epilepsy>
- [2] World Health Organization. *Epilepsy*, 2023. Disponible sur : <https://www.who.int/fr/news-room/fact-sheets/detail/epilepsy>
- [3] Fisher RS, Acevedo C, Arzimanoglou A, et al. ILAE official report : a practical clinical definition of epilepsy. *Epilepsia*. 2014;55(4) :475–482. Disponible sur : <https://pubmed.ncbi.nlm.nih.gov/28276060/>
- [4] Scheffer, I. E., Berkovic, S., Capovilla, G., Connolly, M. B., French, J., Guilhoto, L., Hirsch, E., Jain, S., Mathern, G. W., Moshé, S. L., Perucca, E., Tomson, T., Wiebe, S., Zhang, Y. H., Zuberi, S. M. (2020). *Classification of the Epilepsies : Report of the ILAE Commission for Classification and Terminology*. (version française).
Disponible sur : ilae.org (PDF)
- [5] UCB Pharma. Les types d'épilepsies. <https://ucbcares.fr/patients/epilepsie/fr/content/1361367867/les-types-d-epilepsies>
- [6] Concilio. Neurologie : épilepsie et crises partielles. <https://www.concilio.com/neurologie-epilepsie-crisis-partielles/>
- [7] CHU Sainte-Justine. Types de crises : Crises généralisées. <https://www.chusj.org/fr/soins-services/E/Epilepsie/Parlons-d-epilepsie/Types-de-crisis/Crisis-generalisees>
- [8] I. KHOUAJA Ep BENFRADJ, *Imagerie cérébrale : Traitement et Modélisation Embarqués*. Thèse de doctorat, Université Paris-Est MLV, Ecole Doctorale Mathématique et STIC, Spécialité : Informatique, et Université de Monastir, Ecole Doctorale Sciences et Technologies, Spécialité : Génie Electrique, soutenue le 30 Mai 2017. <https://theses.hal.science/tel-01734877/>
- [9] Nature, Scientific Reports. Figure : Deep learning prediction of epileptic seizures. *Nature.com*, 2024. <https://www.nature.com/articles/s41598-024-64802-1/figures/2>
- [10] Ferhat Koçak, Ahmad Issaoui, and Lara Mroueh. *Diagnostic et classification des épilepsies. Actualités Pharmaceutiques*, vol. 62, no. 624, pp. 51-54, 2023. DOI : <https://doi.org/10.1016/j.actpha.2023.01.040>. Available at : <https://www.sciencedirect.com/science/article/pii/S0515370023000630>
- [11] Centre hospitalier universitaire Sainte-Justine. (n.d.). *Conséquences de l'épilepsie*. CHU Sainte-Justine. Récupéré de <https://www.chusj.org/fr/soins-services/E/Epilepsie/Parlons-d-epilepsie/Consequences>
- [12] Neurologies.fr. *Fiche technique sur l'EEG*. Disponible sur : <https://neurologies.fr/fiche-technique-sur-leeg/>

- [13] Krakow, K., Zijlmans, M., Leijten, F., Valentín, A., Chervoneva, I., Dubeau, F., et al. *Clinical EEG in the diagnosis and management of epilepsy : The importance of standardization and clinical context*. Epileptic Disorders, vol. 21, no. 1, 2019, pp. 3–14. DOI : 10.1684/epd.2019.1036. Disponible sur : <https://pubmed.ncbi.nlm.nih.gov/30721678/>
- [14] Acharya, U. R., Sree, S. V., Swapna, G., Martis, R. J., & Suri, J. S. *Automated EEG analysis of epilepsy : A review*. Knowledge-Based Systems, vol. 45, 2013, pp. 147–165. DOI : 10.1016/j.knosys.2013.02.014. Disponible sur : <https://www.sciencedirect.com/science/article/abs/pii/S1746809411000838>
- [15] Krakow, K., et al. *EEG in the diagnosis and management of epilepsy : The importance of standardization and clinical context*. Epileptic Disorders, vol. 21, no. 1, 2019, pp. 3–14. DOI : 10.1684/epd.2019.1036. Disponible sur : <https://pubmed.ncbi.nlm.nih.gov/28778476/>
- [16] Collège des Enseignants de Neurologie (CEN).
Chapitre 18 — Électrophysiologie du système nerveux central.
 Les fondamentaux de la pathologie neurologique, Premier cycle.
 Consulté en juin 2025.
<https://www.cen-neurologie.fr/premier-cycle/les-fondamentaux-de-la-pathologie-neurologique-explorations-paracliniques-en-neurologie/chapitre-18-electrophysiologie-du-systeme-nerveux-central>
- [17] Malmivuo, J., & Plonsey, R. (1995). *Bioelectromagnetism : Principles and Applications of Bioelectric and Biomagnetic Fields*. Oxford University Press. Disponible en ligne : <https://www.bem.fi/book/13/13x/1302ax.htm>. Consulté le 3 juin 2025.
- [18] Seeck, M., Koessler, L., Bast, T., Leijten, F., Michel, C., Baumgartner, C., et al. *The standardized EEG electrode array of the IFCN*. Clinical Neurophysiology, vol. 128, n° 10, 2017, pp. 2070–2077. DOI : 10.1016/j.clinph.2018.01.065. Disponible sur : <https://sci-hub.se/10.1016/j.clinph.2018.01.065>
- [19] Manuels MSD. *Électroencéphalographie (EEG) – Troubles neurologiques*, version professionnelle. Consulté en 2025. Disponible sur : <https://www.msdmanuals.com/fr/professional/troubles-neurologiques/proc%C3%A9dures-et-tests-neurologiques/%C3%A9lectroenc%C3%A9phalographie-eeeg>
- [20] Latronico, N., & Pichot, C. *Électroencéphalographie en réanimation : indications et perspectives*. Réanimation, vol. 16, n° 6, 2007, pp. 546–552. Disponible sur : https://www.srlf.org/wp-content/uploads/2015/11/0710-Reanimation-Vol16-N6-p546_552.pdf
- [21] ResearchGate. *Different EEG waveforms* [illustration], extrait de l'article “Artificial Intelligence Techniques for Automatic Detection of Epileptic Seizures Using EEG Signals”. Disponible sur : https://www.researchgate.net/figure/Different-EEG-waveforms-39_fig1_346740760
- [22] Fisher, R. S., van Emde Boas, W., Blume, W., Elger, C., Genton, P., Lee, P., & Engel, J. Jr. *Epileptic seizures and epilepsy : Definitions proposed by the International League Against Epilepsy (ILAE) and the International Bureau for Epilepsy (IBE)*. Brain, vol. 129, n° 4, 2005, pp.

- 901–937. DOI : 10.1093/brain/awl241. Disponible sur : <https://doi.org/10.1093/brain/awl241>
- [23] Niedermeyer, E., & da Silva, F. L. *Electroencephalography : Basic Principles, Clinical Applications, and Related Fields*. 6 éd., Lippincott Williams & Wilkins, 2011. Article disponible en libre accès : <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3654937/>
- [24] Tafazzol, M., Pournajaf, S., & Pishbin, S. *EEG signal classification and feature extraction using deep learning for seizure prediction in epileptic patients*. Scientific Reports, vol. 13, article n° 44763, 2023. Disponible sur : <https://www.nature.com/articles/s41598-023-44763-7/figures/1>
- [25] Monbet, V. *Modélisation de séries temporelles*. Université de Rennes 1, 2011. Disponible sur : https://perso.univ-rennes1.fr/valerie.monbet/Cours_ST/CoursST2010.pdf
- [26] [1] Prateek Sharma, *A comprehensive beginner's guide to create a Time Series Forecast (with Codes in Python)*, Analytics Vidhya, 2018. Disponible sur : <https://www.analyticsvidhya.com/blog/2018/09/multivariate-time-series-guide-forecasting-modeling-python-codes/>
- [27] Zhang, Y., Chen, Y., He, Y., Deng, X., Zhang, Q., Zhou, Y., Yang, Z., Cao, X., & Zhang, J. (2023). *A Survey on Deep Learning for Multivariate Time Series Forecasting : Architectures, Modeling Paradigms, and Training Techniques*. arXiv :2312.17286. <https://arxiv.org/html/2312.17286v2/#S2>
- [28] L. Wang, Y. Liu, Y. Zhou, Y. Wang, L. Wang, et Y. Jiang, *EEG-based attention recognition : A review of the utilization of machine learning and deep learning*, Brain Informatics, vol. 7, no. 1, pp. 1–18, 2020. Disponible sur : <https://braininformatics.springeropen.com/articles/10.1186/s40708-020-00105-1>
- [29] L. Wang, R. Gao, Y. Tian, C. Li, D. Liang, J. Yang, et al., *Epileptic seizure prediction model based on an improved CNN–Transformer network and EEG signals*, BMC Medical Informatics and Decision Making, vol. 24, article 84, 2024. Disponible sur : <https://bmcmedinformdecismak.biomedcentral.com/articles/10.1186/s12911-024-02845-0>
- [30] Lopez, H., Côme, É., & Congedo, M. (2023). *Deep learning pour l'analyse de signaux EEG multivariés via des architectures inspirées du traitement du langage naturel*. GRETSI 2023 – 29ème colloque sur le traitement du signal et des images. Disponible sur : <https://hal.science/hal-04058482/file/gretsi.pdf>
- [31] Zhou, X., Liu, Y., Zhang, Y., Li, W., Liu, W., & Liu, H. (2024). *Transformer-Based Models for Epileptic Seizure Detection and Prediction : A Review*. Information, 15(8), 507. <https://www.mdpi.com/2078-2489/15/8/507>
- [32] Abhishek Jain, *Understanding the 1D Convolutional Layer in Deep Learning*, Medium, 2020. <https://medium.com/@abhishekjainindore24/understanding-the-1d-convolutional-layer-in-deep-learning-7a4cb994c981>.

- [33] Anish Nama, *Understanding LSTM Architecture : Pros and Cons and Implementation*, Medium, 2023. <https://medium.com/@anishnama20/understanding-lstm-architecture-pros-and-cons-and-implementation-3e0cca194094>
- [34] DataScientest, *Long Short-Term Memory : tout savoir*, Consulté en mai 2025. Disponible sur : <https://datascientest.com/long-short-term-memory-tout-savoir>
- [35] Anish Nama, *Understanding Bidirectional LSTM for Sequential Data Processing*, Medium, 2022. Disponible à l'adresse : <https://medium.com/@anishnama20/understanding-bidirectional-lstm-for-sequential-data-processing-b83d6283befc>
- [36] ResearchGate, *Bidirectional LSTM model showing the input and output layers*. Disponible sur : https://www.researchgate.net/figure/Bidirectional-LSTM-model-showing-the-input-and-output-layers-The-red-arrows-represefig3_344554659
- [37] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). *Attention is All You Need*. arXiv preprint arXiv :1706.03762. <https://arxiv.org/abs/1706.03762>
- [38] Alshboul, M.; Alshboul, R.; Al-Mistarehi, A.-H.; Rawashdeh, R.; Daoud, M.I. *Epileptic Seizure Detection Using Wearable Devices : A Review*. Sensors 2023, 25(5), 1293. <https://www.mdpi.com/1424-8220/25/5/1293>
- [39] Jalammar, J. (2018). *The Illustrated Transformer*. Consulté le 4 mai 2025 sur <https://jalammar.github.io/illustrated-transformer/>
- [40] ResearchGate, *Self-attention mechanism used in Transformer*, https://www.researchgate.net/figure/Self-attention-mechanism-used-in-Transformer-Heafig1_351990424
- [41] Abir Hosen. *Encoder-only Transformer-Based Classification with a Simple Version of Model Building & Training*. Medium, 2022. <https://medium.com/@abir71.hosen/encoder-only-transformer-based-classification-with-a-simple-version-of-model-buildi>
- [42] Siqi Liu, Zhihua Chen, et al. *Attention Mechanism in Deep Learning : An Overview of Recent Advances*. Frontiers in Neuroinformatics, 17 :1067095, 2023. <https://www.frontiersin.org/articles/10.3389/fninf.2023.1067095/full>
- [43] Python Software Foundation. *Tutoriel Python 3*. Disponible à l'adresse : <https://docs.python.org/fr/3/tutorial/>.
- [44] TensorFlow Developers. *TensorFlow on GitHub*. Disponible à l'adresse : <https://github.com/tensorflow/tensorflow>.
- [45] Martín Abadi, Paul Barham, Jianmin Chen, Zhifeng Chen, Andy Davis, Jeffrey Dean, Matthieu Devin, Sanjay Ghemawat, Geoffrey Irving, Michael Isard, Manjunath Kudlur, Josh Levenberg, Rajat Monga, Sherry Moore, Derek G. Murray, Benoit Steiner, Paul Tucker, Vijay Vasudevan, Pete Warden, Martin Wicke, Yuan Yu, Xiaoqiang Zheng. *TensorFlow : A System*

- for Large-Scale Machine Learning*. In Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI '16), pages 265–283, Savannah, GA, USA, November 2016. USENIX Association. Disponible à l'adresse : <https://www.usenix.org/conference/osdi16/technical-sessions/presentation/abadi>.
- [46] Cursa. *Construire des réseaux de neurones avec Keras et TensorFlow : travailler avec des couches denses, convolutives et récurrentes*. Disponible à l'adresse : <https://curse.app/fr/page/construire-des-reseaux-de-neurones-avec-keras-et-tensorflow-travailler-avec-des-cou>utm_source=chatgpt.com.
- [47] Codecademy. *SciPy Signal Documentation*. Disponible à l'adresse : <https://www.codecademy.com/resources/docs/scipy/scipy-signal>.
- [48] Gutttag, J. *CHB-MIT Scalp EEG Database* (version 1.0.0). PhysioNet, 9 juin 2010. Disponible à l'adresse : <https://physionet.org/content/chbmit/1.0.0/>.
- [49] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, L. Kaiser, and I. Polosukhin, “Attention is all you need,” *arXiv preprint arXiv:1802.00308*, 2018. [Online]. Available : <https://arxiv.org/abs/1802.00308>
- [50] A. Author(s), “Hybrid attention-based transformers and CNN model,” *International Journal of Advanced Computer Science and Applications*, vol. 16, no. 2, pp. [pages], 2025. [Online]. Available : https://thesai.org/Downloads/Volume16No2/Paper_110-Hybrid_Attention_Based_Transformers_CNN_Model.pdf
- [51] Author(s), “Title of the article,” *BMC Medical Informatics and Decision Making*, vol. [Volume], no. [Issue], p. [Article number], [Year]. [Online]. Available : <https://bmcmmedinformdecismak.biomedcentral.com/articles/10.1186/s12911-024-02845-0>
- [52] Elnaim, B.; Awad, A.I. *Hybrid CNN-LSTM Architecture for EEG Signal Classification*. Figure extraite de l'article publié sur ResearchGate, 2023. https://www.researchgate.net/figure/Hybrid-CNN-LSTM-design_fig1_361640259
- [53] Goldberger, A. L., et al. (2000). *PhysioBank, PhysioToolkit, and PhysioNet*. *Circulation*, 101(23), e215–e220.
- [54] Obeid, I., & Picone, J. (2016). *The Temple University Hospital EEG Data Corpus*. *Front. Neurosci.*, 10, 196.
- [55] Ihle, M., et al. (2012). *EPILEPSIAE—A European epilepsy database*. *Comput. Methods Programs Biomed.*, 106(3), 127–138.
- [56] Andrzejak, R. G., et al. (2001). *Indications of nonlinear deterministic structures in EEG*. *Phys. Rev. E*, 64(6), 061907.
- [57] Zheng, W.-L., et al. (2019). *Identifying stable patterns over time for emotion recognition from EEG*. *IEEE Trans. Affect. Comput.*, 10(3), 417–429.

- [58] Andrzejak, R. G., et al. (2001). *Indications of nonlinear deterministic and finite-dimensional structures in EEG*. Phys. Rev. E, 64(6), 061907.
- [59] Truong, N. D., et al. (2018). *CNNs for seizure prediction using intracranial and scalp EEG*. Proc. EMBC, 1–4.
- [60] Wagenaar, J. B., et al. (2015). *The Multimodal IIEG Platform*. Neuroinformatics, 13(3), 353–366.
- [61] Biomedical Signal Processing and Control, vol. 14, pp. 147–160, 2014. [Online]. Available : <https://www.sciencedirect.com/science/article/abs/pii/S0165027014001812>
- [62] Journal of Ambient Intelligence and Humanized Computing, Springer, 2021. [Online]. Available : <https://link.springer.com/article/10.1007/s12652-020-02837-8>
- [63] A. T. Tzallas, M. G. Tsipouras, and D. I. Fotiadis, *Epileptic seizure detection using least squares support vector machine classifier*, Artificial Intelligence in Medicine, vol. 45, no. 1, pp. 75–89, 2009. [Online]. Available : <https://www.sciencedirect.com/science/article/abs/pii/S1746809411000838>
- [64] International Journal for Numerical Methods in Biomedical Engineering, 2022. [Online]. Available : <https://www.researchgate.net/publication/358115333>
- [65] S. A. Hossain, M. R. Islam, T. H. Al Islam, A. Almogren, and M. A. Jan, *Epileptic Seizure Prediction Using Big EEG Data and Deep Learning*, arXiv preprint arXiv :2105.02823, 2021. [Online]. Available : <https://arxiv.org/abs/2105.02823>
- [66] S. Qiu, W. Wang, and H. Jiao, *LightSeizureNet : A Lightweight Deep Learning Model for Real-Time Epileptic Seizure Detection*, IEEE Journal of Biomedical and Health Informatics, vol. 27, no. 4, pp. 1845–1856, 2023. [Online]. Available : <https://pubmed.ncbi.nlm.nih.gov/36417737/>
- [67] K. M. Tsiouris, V. C. Pezoulas, M. Zervakis, S. Konitsiotis, D. D. Koutsouris, and D. I. Fotiadis, *A Long Short-Term Memory deep learning network for the prediction of epileptic seizures using EEG signals*, Computers in Biology and Medicine, vol. 99, pp. 24–37, 2018. [Online]. Available : <https://pubmed.ncbi.nlm.nih.gov/29807250/>
- [68] arXiv preprint arXiv :2211.02679, 2022. [Online]. Available : <https://arxiv.org/abs/2211.02679>
- [69] X. Lu, A. Wen, L. Sun, H. Wang, Y. Guo, and Y. Ren, *An Epileptic Seizure Prediction Method Based on CBAM-3D CNN-LSTM Model*, IEEE Journal of Translational Engineering in Health and Medicine, vol. 11, pp. 417–423, 2023. [Online]. Available : <https://pmc.ncbi.nlm.nih.gov/articles/PMC10328218/>
- [70] D. Lee, B. Kim, T. Kim, I. Joe, J. Chong, K. Min, and K. Jung, *A ResNet-LSTM hybrid model for predicting epileptic seizures using a pretrained model with supervised contrastive learning*, Scientific Reports, vol. 14, Article 1319, 2024. [Online]. Available : <https://www.nature.com/articles/s41598-023-43328-y>

- [71] R. Zhu, W.-x. Pan, J.-x. Liu, and J.-l. Shang, *Epileptic seizure prediction via multidimensional transformer and recurrent neural network fusion*, *Journal of Translational Medicine*, vol. 22, Article 895, 2024. [Online]. Available : <https://translational-medicine.biomedcentral.com/articles/10.1186/s12967-024-05678-7>
- [72] Q. Chen, C. Sun, C. Gao, and S.-C. Liu, *Epilepsy Seizure Detection and Prediction using an Approximate Spiking Convolutional Transformer*, *2024 IEEE International Symposium on Circuits and Systems (ISCAS)*, Singapore, 2024. [Online]. Available : <https://arxiv.org/abs/2402.09424>
- [73] R. V. Godoy, T. J. S. Reis, P. H. Polegato, G. J. G. Lahr, R. L. Saute, F. N. Nakano, H. R. Machado, A. C. Sakamoto, M. Becker, and G. A. P. Caurin, *EEG-Based Epileptic Seizure Prediction Using Temporal Multi-Channel Transformers*, arXiv preprint arXiv :2209.11172, 2022. [Online]. Available : <https://arxiv.org/abs/2209.11172>
- [74] Hanley, J.A. et McNeil, B.J. *The Meaning and Use of the Area under a Receiver Operating Characteristic (ROC) Curve*. *Radiology*, vol. 143, no. 1, pp. 29–36, avril 1982. DOI : <https://doi.org/10.1148/radiology.143.1.7063747>.
- [75] F. A. Author and S. B. Coauthor, *Deep learning approaches for seizure prediction : A review*, arXiv preprint arXiv :2105.02823, 2021. <https://arxiv.org/abs/2105.02823>
- [76] A. Bhattacharya, *Automatic Seizure Prediction using CNN and LSTM*, arXiv preprint arXiv :2211.02679, 2022. <https://arxiv.org/abs/2211.02679>
- [77] Y. Zhang, Y. Liu, and H. Wang, *An Epileptic Seizure Prediction Method Based on CBAM-3D CNN*, *Frontiers in Neuroscience*, vol. 17, 2023. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10328218/>
- [78] M. E. Hussein, J. F. Cohn, and A. A. Salah, *Hybrid deep learning model for early prediction of epileptic seizures using EEG signals*, *Scientific Reports*, vol. 13, Article no. 15134, 2023. <https://www.nature.com/articles/s41598-023-43328-y>
- [79] R. Zhu, W.-x. Pan, J.-x. Liu, and J.-l. Shang, *Epileptic seizure prediction via multidimensional transformer and recurrent neural network fusion*, *Journal of Translational Medicine*, vol. 22, art. no. 895, 2024. <https://doi.org/10.1186/s12967-024-05678-7>
- [80] Chen, Q., Sun, C., Gao, C., & Liu, S.-C. (2024). *Epilepsy Seizure Detection and Prediction using an Approximate Spiking Convolutional Transformer*. arXiv preprint arXiv :2402.09424. <https://doi.org/10.48550/arXiv.2402.09424>
- [81] P. Koutsouvelis, B. Chybowski, A. Gonzalez-Sulser, S. Abdullateef, and J. Escudero, *Preictal Period Optimization for Deep Learning-Based Epileptic Seizure Prediction*, arXiv preprint arXiv :2407.14876, 2024. <https://arxiv.org/abs/2407.14876>
- [82] D. Author, E. Author, and F. Author, “Title of the Paper,” arXiv preprint arXiv :2410.05491, 2024. [Online]. <https://arxiv.org/abs/2410.05491>

- [83] A. Kumar, B. Singh, and C. Sharma, *A Deep Learning Paradigm with Residual Networks*, AIP Conference Proceedings, vol. 3253, no. 1, p. 030001, 2025. Disponible en ligne : <https://pubs.aip.org/aip/acp/article-abstract/3253/1/030001/3332941/A-deep-learning-paradigm-with-residual-networks>

ANNEXES

Business Model Canevas

1- Proposition de valeur (Value Proposition) القيمة المقترحة

a. Quels problèmes résolvons-nous pour nos clients ?

ما هي المشاكل التي نحلها لعملائنا ؟

- L'imprévisibilité des crises d'épilepsie.
- Le stress et l'anxiété constants liés à la peur d'une crise soudaine.
- L'absence de solution mobile en temps réel de détection précoce.
- L'isolement des patients épileptiques (manque de supervision continue).
- Les retards dans la prise en charge médicale lors des crises.

b. Quels besoins de nos clients satisfont nos produits ou services ?

ما هي الاحتياجات التي يلبها منتجاتنا أو خدماتنا لعملائنا؟

- **Besoin de sécurité** : en anticipant les crises, les utilisateurs peuvent éviter des situations dangereuses (accidents, chutes, etc.).
- **Besoin d'autonomie** : les patients peuvent organiser leur quotidien avec plus de liberté, sans dépendre constamment d'un accompagnant.
- **Besoin de tranquillité d'esprit** : la prédiction réduit l'anxiété liée à l'imprévisibilité des crises.
- **Besoin de gestion proactive de la maladie** : en recevant des alertes précoces, les patients peuvent prendre des mesures immédiates (repos, prise de médicament, avertir un proche).
- **Besoin d'information fiable en temps réel** : notre système offre des alertes précises et actualisées, ce qui améliore le suivi médical .

c. En quoi notre offre est-elle différente de celle de nos concurrents ?

في ماذا تختلف عروضنا عن تلك التي يقدمها منافسوننا؟

- Intégration directe d'un **modèle d'IA personnalisé**, entraîné sur des données EEG du patient.
- **Alertes automatiques multimodales** : notification, SMS, appel vocal au proche.
- **Compatibilité avec des capteurs EEG portables** (via Bluetooth).
- Interface **moderne et conviviale**, pensée pour les jeunes et les aidants.
- **Fonctionnement hors ligne partiel** pour fiabilité même sans internet.

d. Quelles est notre proposition unique de valeur ?

ما هو العرض الفريد للقيمة لدينا؟

Système intelligent portable de prédiction de crise, personnalisé et en temps réel via une app mobile connectée à un casque EEG.

2- Segments de clients (Customer Segment) أنواع العملاء :

a. Quels sont nos clients principaux?

من هم العملاء أو الزبائن الرئيسيون ؟

Les fabricants de dispositifs médicaux portables .

b. Quels sont les différents segments de clients que nous visons ?

ما هي الفئات المختلفة من العملاء التي تستهدفها؟

- Les personnes atteintes d'épilepsie
- Les familles et aidants, Les professionnels de santé (neurologues, épileptologues).
- Les hôpitaux et centres spécialisés.
- Les fabricants de dispositifs médicaux portables .
- Centres de recherche et laboratoires cliniques.

c. Quels sont les besoins spécifiques de chaque segment de clients?

ما هي الاحتياجات الخاصة لكل فئة من العملاء؟

- **Patients épileptiques autonomes:** Anticiper les crises pour éviter les accidents , Gagner en autonomie et liberté dans les déplacements, Réduire l'anxiété liée à l'incertitude.
- **Parents et aidants:** Recevoir des alertes fiables en temps réel, Pouvoir intervenir rapidement en cas de crise Être rassurés lorsqu'ils ne sont pas présents.
- **Professionnels de santé (neurologues, médecins):** Accéder à des données EEG claires et structurées Suivre l'évolution des patients entre deux consultations Ajuster les traitements en fonction des prédictions.
- **Centres de recherche et laboratoires:** Disposer d'une base de données EEG annotée et prédictive, Tester des hypothèses sur les signaux préictaux, accélérer les études cliniques sur l'épilepsie.
- **Fabricants de dispositifs médicaux:** Intégrer une solution d'IA prédictive dans leurs appareils, se différencier de la concurrence par l'innovation, Proposer un produit intelligent prêt à l'emploi pour leurs clients finaux.

d. Comment pouvons-nous catégoriser nos clients en groupes distincts?

كيف يمكن تصنيف عملائنا إلى مجموعات مختلفة؟

On peut les regrouper selon plusieurs critères :

1. Par type d'utilisateur final :

- Utilisateurs individuels (patients, aidants)
- Professionnels de santé
- Institutions médicales et de recherche
- Entreprises partenaires (B2B)

2. Par usage principal :

- Usage personnel pour la vie quotidienne
- Usage clinique pour le suivi et la décision médicale
- Usage scientifique pour la recherche et les tests
- Intégration technologique dans des produits existants

3- Relation avec les clients (Consumer Relationships) : علاقة مع العملاء :

a. Quel type de relation chaque segment de clients attend-il de nous ?

أي نوع من العلاقة يتوقعه كل فئة من العملاء منا؟

- **Patients épileptiques** : Support rapide en cas de bug ou de doute, Interface claire et rassurante, Informations fiables sur l'état de santé.
- **Parents et aidants** : une communication proactive, avec des notifications immédiates et la possibilité de suivre l'état du patient à distance.
- **Professionnels de santé** : une relation collaborative, fondée sur des données précises, une interopérabilité avec leurs outils médicaux, et un accès sécurisé aux historiques EEG.
- **Centres de recherche** : un partenariat scientifique, avec un accès aux données anonymisées, des outils d'analyse, et des mises à jour techniques régulières.
- **Entreprises partenaires** : une relation B2B transparente, avec une intégration technique simplifiée (API, modules IA), une documentation claire et un support technique professionnel.

b. Comment entretenons-nous actuellement les relations avec nos clients ?

كيف نحافظ حاليًا على العلاقات مع عملائنا؟

Actuellement, la relation avec nos clients est maintenue à travers des interactions numériques continues, notamment via des notifications personnalisées, des mises à jour régulières du système, et un canal de communication ouvert pour les retours utilisateurs. Nous utilisons également des enquêtes de satisfaction et des sessions de feedback utilisateur pour améliorer l'expérience. Avec les professionnels de santé, nous favorisons une collaboration directe lors des phases de test, de suivi clinique ou de validation des prédictions.

c. Comment pouvons-nous améliorer ou personnaliser nos interactions avec nos clients ?

كيف يمكننا تحسين أو تخصيص تفاعلاتنا مع عملائنا؟

Nous pouvons améliorer nos interactions en offrant des alertes configurables selon les préférences de chaque utilisateur (type de notification, seuils de détection, fréquence). L'ajout de contenus éducatifs adaptés (vidéos, conseils médicaux) et d'un journal de bord intelligent rendrait l'expérience plus enrichissante. Pour les professionnels, la mise à disposition d'outils de visualisation avancés et de rapports interactifs permettrait un meilleur accompagnement clinique. Enfin, la prise en compte régulière des retours via des sondages ou forums sécurisés permettrait également d'ajuster l'expérience en continu.

4- Canaux de distribution (Channels) : قنوات التوزيع :

a- Par quels canaux nos clients veulent-ils être atteints ?

من خلال أي قنوات يفضل عملاؤنا أن يتم التواصل معهم؟

- Application mobile avec alertes en temps réel
- Réseaux sociaux pour information et sensibilisation
- Sites spécialisés santé / forums patients
- Professionnels de santé (via consultations ou recommandations)
- Congrès médicaux et publications scientifiques
- Partenariats avec hôpitaux, chercheurs, et fabricants médicaux

b- Quels canaux sont les plus efficaces pour atteindre chaque segment de clients ?

ما هي القنوات الأكثر فعالية للوصول إلى كل فئة من العملاء؟

Patients et aidants : réseaux sociaux, applications mobiles, forums et associations de patients.

Professionnels de santé : congrès, revues spécialisées, webinaires, réseaux professionnels comme LinkedIn.

Institutions médicales et recherche : publications scientifiques, conférences, partenariats académiques, réseaux de recherche.

Entreprises partenaires : salons professionnels, réseaux d'affaires, LinkedIn, emailings ciblés, incubateurs.

c- Comment pouvons-nous intégrer différents canaux pour améliorer l'expérience clients ?

كيف يمكننا دمج مختلف القنوات لتحسين تجربة العملاء؟

Nous engageons d'abord les utilisateurs via les réseaux sociaux pour les rediriger vers notre application ; là, notre app de suivi et d'alertes délivre un accompagnement personnalisé , avec notifications push, email ou SMS selon leurs préférences.

5-Partenaires clés (Key Partnerships): الشراكة الرئيسية:

a. Qui sont nos partenaires clés ?

من هم شركاؤنا الرئيسيون؟

- Les fournisseurs de matériel EEG (comme Emotiv ou d'autres fabricants de dispositifs portables) sont essentiels pour l'acquisition de données en temps réel via des capteurs fiables et compatibles avec l'application.
- Les hôpitaux et centres cliniques spécialisés en neurologie ou épileptologie (comme ceux impliqués dans le CHB-MIT) sont des partenaires clés pour l'accès aux données médicales, aux patients, et aux environnements cliniques de test.

- Les institutions de recherche (universités, INSERM, CNRS) jouent un rôle stratégique pour la validation scientifique, la méthodologie, et l'encadrement académique.
 - Les associations de patients permettent de mieux comprendre les besoins réels des utilisateurs finaux, de co-construire des fonctionnalités pertinentes, et de faciliter l'acceptation de la solution.
 - Les autorités de santé et de régulation (comme l'ANSM ou les comités d'éthique) sont incontournables pour valider l'utilisation du dispositif en contexte médical réel.
- b. Quels sont les partenariats qui nous aident à réduire les coûts, à accéder à de nouvelles ressources ou à améliorer notre proposition de valeur ?
ما هي الشراكات التي تساعدنا على خفض التكاليف أو الوصول إلى موارد جديدة أو تحسين قيمتنا المقترحة؟
- Les universités et laboratoires publics permettent de bénéficier de ressources de recherche, de financement et de compétences sans coûts commerciaux directs.
 - Les partenariats hospitaliers offrent un accès direct aux données EEG, aux profils cliniques des patients et à un environnement réel pour tester les performances du système.
 - Les fournisseurs de matériel peuvent proposer des tarifs réduits, du sponsoring ou du matériel en prêt pour prototypage.
 - Les acteurs du cloud comme Google ou Amazon peuvent offrir des crédits gratuits ou des infrastructures scalables à bas coût pour les startups en santé.
 - Les associations de patients et groupes de soutien permettent un accès facilité aux utilisateurs pour des tests ou du feedback utilisateur continu, sans frais marketing importants.
- c. Comment pouvons-nous aligner nos intérêts avec ceux de nos partenaires ?

كيف يمكننا مزامنة مصالحنا مع تلك لشركائنا؟

Nous alignons nos intérêts en co-développant des études cliniques et publications avec les hôpitaux et institutions de recherche, en intégrant nativement le matériel EEG de nos fournisseurs pour valoriser leur technologie, en impliquant les associations de patients dans la conception pour garantir l'adoption, et en respectant scrupuleusement les normes réglementaires pour faciliter la validation conjointe avec les autorités de santé.

6-Activités clés (Key Activities): الأنشطة الرئيسية:

- a. Quelles sont les actions principales que nous devons entreprendre pour livrer notre proposition de valeur ?

ما هي الأنشطة الرئيسية التي يجب علينا القيام بها لتقديم قيمتنا المقترحة؟

- Développement d'algorithmes d'intelligence artificielle pour la prédiction des crises d'épilepsie en temps réel .

- Collecte, traitement et annotation des données EEG dans le respect des normes médicales et éthiques.
- Création et mise à jour d'une application mobile conviviale et fonctionnelle Collaboration avec les professionnels de santé et les centres médicaux pour les tests cliniques .
- Mise en place d'un système de support et d'accompagnement pour les utilisateurs.

b. Quelles sont les opérations essentielles pour notre entreprise ?

ما هي العمليات الأساسية لشركتنا؟

- Maintenance technique de la plateforme et des modèles IA.
- Gestion sécurisée et conforme des données personnelles et médicales Suivi client (support technique, conseils)
- Communication, marketing et sensibilisation sur les avantages de la solution .
- Veille réglementaire et obtention des autorisations nécessaires (certification en tant que dispositif médical)

c. Quelles sont les activités qui créent le plus de valeur pour nos clients ?

ما هي الأنشطة التي تخلق أكبر قيمة لعملائنا؟

- La capacité à anticiper les crises et à alerter les patients en temps réel.
- Une interface utilisateur claire, rassurante et personnalisée.
- La fiabilité et l'adaptabilité du système selon le profil de chaque patient L'intégration avec les professionnels de santé pour un meilleur suivi.
- Le soutien humain (écoute, conseils, accompagnement) qui renforce la confiance.

7- Ressources clés (Key resources) : الموارد الرئيسية

a. Quels sont nos actifs matériels, immatériels et humains essentiels ?

ما هي الأصول المادية وغير المادية والبشرية الأساسية لدينا؟

Matériels : dispositifs EEG portables (comme Emotiv), serveurs de calcul ou accès cloud pour l'entraînement des modèles.

Immatériels : Code source IA et mobile (développé par le groupe), base de données EEG annotées, propriété intellectuelle et réseau de partenaires médicaux.

Humains : ingénieur IA (internes au groupe), UX/UI designer et développeur mobile (internes au groupe), encadrants académiques, experts médicaux (neurologues), testeurs utilisateurs.

b. Quels sont les outils, les technologies ou les partenariats dont nous avons besoin pour réussir ?

ما هي الأدوات والتكنولوجيا أو الشراكات التي نحتاجها لتحقيق النجاح؟

Outils : Logiciels de traitement du signal, Outils de chiffrement et de gestion sécurisée des données de santé (conformité RGPD), Bases de données médicales anonymisées, Casques ou dispositifs EEG portables.

Technologies : infrastructure cloud (Google Cloud, AWS), stockage sécurisé des données médicales, Serveurs GPU pour l'entraînement des modèles.

Partenariats : hôpitaux pour les données et la validation clinique, fournisseurs casques EEG, institutions de recherche pour l'encadrement scientifique.

c. Quels sont les principaux avantages concurrentiels de nos ressources ?

ما هي المزايا التنافسية الرئيسية لمواردنا؟

- Expertise spécialisée en IA appliquée à l'EEG et aux signaux cérébraux .
- Accès à des données cliniques réelles et de qualité, grâce à nos partenariats médicaux .
- Technologie prédictive en temps réel, rare et différenciante sur le marché de l'épilepsie.
- Autonomie technique complète : AI + design + fullstack app
- Réduction des coûts de développement
- Solution centrée sur le patient, conçue avec leurs retours et leurs besoins réels
- Architecture technique scalable, adaptée à un déploiement international.

8- Charges et coûts (Coste structure) : التكاليف

a. Quels sont les coûts fixes et variables associés à notre modèle économique ?

ما هي التكاليف الثابتة والمتغيرة المرتبطة بنموذجنا الاقتصادي؟

Coûts fixes :

- Salaires de l'équipe technique (IA, développeurs, ingénieurs biomédicaux).
- Frais de serveur/cloud pour le stockage et le traitement des données EEG Abonnements logiciels (licences, bibliothèques IA, plateformes cloud) .
- Frais de structure (bureaux, assurance, comptabilité) .

Coûts variables :

- Collecte et annotation de nouvelles données EEG .
- Coûts liés aux tests cliniques et à la validation médicale.
- Marketing digital et campagnes de sensibilisation .
- Support client et maintenance technique Fabrication ou intégration de dispositifs connectés (EEG portable, bandeaux).

b. Quels sont les coûts les plus importants pour notre entreprise ?

ما هي التكاليف الأكثر أهمية لشركتنا؟

- Le développement et l'entraînement du modèle IA, qui demandent des ressources informatiques puissantes et continues (GPU, cloud).
- La collecte et l'annotation de données EEG de qualité, nécessaires pour entraîner et valider le modèle.
- Les tests cliniques et la validation médicale, essentiels pour garantir la fiabilité et l'acceptation de la solution dans un cadre de santé.

c. Comment pouvons-nous réduire les coûts ou améliorer l'efficacité de nos opérations ?

كيف يمكننا خفض التكاليف أو تحسين كفاءة عملياتنا ؟

- Profiter des crédits gratuits pour startups offerts par Firebase, Google Cloud, GitHub Student, etc.
- Collaborer avec des universités ou hôpitaux partenaires pour utiliser gratuitement leurs ressources ou données EEG.
- Rechercher un incubateur ou un programme d'innovation qui offre des soutiens financiers ou logistiques.
- Utiliser des outils open source pour l'IA, le traitement EEG, l'app mobile.
- Partager le développement dans notre groupe : pas besoin d'externaliser.
- Lancer une version bêta pour tester avant de dépenser pour une version commerciale.

9- Revenus (Revenue) : مصادر الدخل

a. Quels produits ou services nos clients sont-ils prêts à payer ?

ما هي المنتجات أو الخدمات التي يكون عملاؤنا على استعداد لدفع ثمنها؟

- L'application mobile de prédiction des crises d'épilepsie en temps réel. Un accès premium à des fonctionnalités avancées (Notifications avancées, rapports personnalisés, synchronisation avec médecins).
- Dispositif EEG (pack complet) : Vente du casque EEG avec l'application intégrée.
- API médicale ou plateforme SaaS : Pour les hôpitaux, chercheurs ou entreprises de télémédecine.

b. Quels sont les différents moyens par lesquels nous pouvons générer des revenus ?

ما هي الطرق المختلفة التي يمكننا من خلالها تحقيق الدخل؟

- Abonnements mensuels ou annuels à l'application (freemium/premium).



- Vente de packs de services (analyse de données, rapports personnalisés). Partenariats ou subventions avec institutions médicales et recherche.
- Licence de notre technologie à des hôpitaux ou fabricants d'appareils EEG.


c. Quel est notre modèle de tarification ?

ما هو نموذج التسعير لدينا؟

- Modèle freemium : accès gratuit aux fonctions de base, avec options payantes.
- Abonnement premium : tarif mensuel/annuel pour des services étendus.
- Tarification adaptée selon le type d'utilisateur : patients individuels, professionnels, ou institutions.



Business Model Canevas : BMC



Résumé

Les crises d'épilepsie, imprévisibles et potentiellement dangereuses, représentent un défi clinique majeur en neurologie. L'électroencéphalogramme (EEG) constitue un outil central pour la surveillance cérébrale, mais son analyse manuelle, fastidieuse et sujette à l'interprétation, limite son efficacité en contexte de détection précoce. L'intelligence artificielle, et en particulier l'apprentissage profond, offre une alternative puissante en automatisant l'analyse des signaux EEG et en permettant l'extraction de motifs complexes. Ce travail propose une approche basée sur le deep learning pour la prédiction des crises d'épilepsie à partir des signaux EEG, en s'appuyant sur le jeu de données CHB-MIT. Il explore un modèle hybride combinant CNN, Bi-LSTM et Transformer afin d'extraire efficacement les caractéristiques spatiales et temporelles des signaux EEG. Le modèle a montré une capacité prometteuse à distinguer les états cérébraux interictal et préictal. En complément, une application mobile a été développée afin d'intégrer ce système de prédiction dans un outil accessible et réactif. Bien que des améliorations restent possibles, ces résultats mettent en lumière le potentiel des approches d'apprentissage profond pour renforcer les systèmes de surveillance intelligents, et ouvrir la voie à une prise en charge plus anticipative et personnalisée de l'épilepsie.

Mots clés : EEG, crises d'épilepsie, CNN, Bi-LSTM, Transformer, CHB-MIT, Prédiction, Préictal, Apprentissage profond.

Abstract

Epileptic seizures, unpredictable and potentially dangerous, represent a major clinical challenge in neurology. Electroencephalography (EEG) is a central tool for brain monitoring, but its manual analysis—tedious and subject to interpretation—limits its effectiveness for early seizure detection. Artificial intelligence, and particularly deep learning, offers a powerful alternative by automating EEG signal analysis and enabling the extraction of complex patterns. This work proposes a deep learning-based approach for predicting epileptic seizures from EEG signals, using the CHB-MIT dataset. It explores a hybrid model combining CNN, Bi-LSTM, and Transformer architectures to effectively extract both spatial and temporal features from EEG data. The model has shown promising ability to distinguish between interictal and preictal brain states. In addition, a mobile application was developed to integrate this predictive system into an accessible and responsive tool. Although further improvements are still possible, these results highlight the potential of deep learning approaches to enhance intelligent monitoring systems and pave the way for more anticipatory and personalized epilepsy care.

Keywords : EEG, Epileptic seizures, Deep learning, CNN, Bi-LSTM, Transformer, Prediction, CHB-MIT, Preictal.

ملخص

تُعدّ نوبات الصرع، التي تتميز بعدم القدرة على التنبؤ بها وخطورتها المحتملة، من التحديات السريرية الرئيسية في علم الأعصاب. ويُعتبر تخطيط الدماغ الكهربائي (EEG) أداة مركزية في مراقبة نشاط الدماغ، غير أن تحليله اليدوي يُعدّ مرهقاً وعرضةً للتأويل، مما يُقيّد فعاليته في سياق الكشف المبكر عن النوبات. تُقدم تقنيات الذكاء الاصطناعي، وخاصة التعلم العميق، بديلاً قوياً من خلال أتمتة تحليل إشارات EEG واستخلاص الأنماط المعقدة. يقترح هذا العمل مقارنة تعتمد على التعلم العميق للتنبؤ بنوبات الصرع انطلاقاً من إشارات EEG، مستنداً إلى قاعدة بيانات CHB-MIT. ويستكشف نموذجاً هجيناً يجمع بين الشبكات العصبية الالتفافية (CNN) والوحدات الراجعة ثنائية الاتجاه (Bi-LSTM) وآليات المحوّل (Transformer) لاستخلاص الخصائص المكانية والزمانية للإشارات بشكل فعال. أظهر النموذج قدرة واعدة على التمييز بين الحالات الدماغية البعد نوبةً وما قبل النوبة. بالإضافة إلى ذلك، تم تطوير تطبيق محمول لدمج نظام التنبؤ هذا في أداة سهلة الوصول وسريعة الاستجابة. وعلى الرغم من وجود مجال للتحسين، فإن هذه النتائج تُبرز إمكانيات تقنيات التعلم العميق في تعزيز أنظمة المراقبة الذكية، وتمهيد الطريق نحو رعاية صحية أكثر استباقية وتخصيصاً لمرضى الصرع.

الكلمات المفتاحية: EEG، نوبات الصرع، التعلم العميق، CNN، Bi-LSTM، Transformer، التنبؤ، CHB-MIT، ما قبل النوبة.