



REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTÈRE DE L'ENSEIGNEMENT SUPERIEURE ET DE LA RECHERCHE SCIENTIFIQUE

UNIVERSITE IBN KHALDOUN - TIARET

MEMOIRE

Présenté à :

FACULTÉ DES MATHÉMATIQUES ET DE L'INFORMATIQUE
DÉPARTEMENT D'INFORMATIQUE

Pour l'obtention du diplôme de :

MASTER

Spécialité : [Génie Informatique]

Par :

**Boukhari Abdelkader
Haddane Mohammaed Amine**

Sur le thème

Vers une approche de classification des signaux Électroencéphalographiques par le Deep Learning

Soutenu publiquement le 26/06/2022 à Tiaret devant le jury composé de :

Mme BELKACEMI Nawel	MCB	Université de Tiaret	Présidente
Mme LAAREDJ Zohra	MAA	Université de Tiaret	Examinatrice
Mr DAOUD Bachir	MAA	Université de Tiaret	Co-Encadrant
Mlle AMMAR Sabrina	MCB	Centre universitaire Aflou	Encadrante

2021-2022

Remerciements :

Nous rendons grâce à Dieu qui nous a donné l'aide, la patience et le courage pour accomplir ce travail.

Nous tenons à adresser nos plus vifs remerciements à ANMAR Sabrina, DAOUD Bachir, pour nous avoir encadré et pour les recommandations qu'ils nous ont prodiguées et qui nous ont été d'un grand apport.

Nous tenons à adresser nos plus vifs remerciements aux membres de jury, pour avoir accepté d'évaluer notre travail.

Nous tenons à remercier nos familles, pour leurs soutiens et leurs encouragements.

Merci à tous ceux qui ont contribué à l'élaboration de ce travail de près ou de loin et qui méritent d'y trouver leur nom.

Dédicace :

Nous dédions ce mémoire :

A nos chers parents :

En témoignage de toute l'affection que nous vous portons, que vous trouvez ici l'expression de notre amour et notre éternel et profonde gratitude pour vos sacrifices et vos efforts consentis à notre égard durant tout notre parcours à l'Université.

A nos chers frères et sœurs aînés DAOUD, chamsou, moncef, et moustapha et à nos familles

Boukhari et Haddane qui nous ont soutenu tout au long de nos études.

Merci d'être présents dans nos vies

Table des matières

Remerciements :	2
Dédicace :	3
Résumé	10
Introduction générale :	12
CHAPITRE I :	14
1 Introduction:	15
2 Structure du cerveau :	15
2.1 Neurone :	16
2.2 Structure des neurones :	16
2.3 Fonction des neurones :	17
3 L'électroencéphalographie EEG :	19
3.1 Historique :	19
3.2 Définition de l'EEG :	19
3.3 L'appareil EEG:	20
3.3.1 Les électrodes :	20
3.3.2 Montage d'électrodes :	21
3.3.3 Positionnement des électrodes selon le système international 10-20 :	21
4 Les perturbations :	23
4.1 Les artefacts :	23
4.2 Le bruit :	24
5 Les techniques d'enregistrement d'activité cérébrale :	25
5.1 Tomographie par Emission de Positons (TEP) :	25
5.2 Imagerie par Résonance Magnétique (IRM) :	25
5.3 Magnétoencéphalographie (MEG) :	26
5.4 L'Electrocorticographie (ECoG) :	27
6 L'épilepsie :	28
6.1 Causes et mécanisme biologique de l'épilepsie :	28
6.2 Les multimodalités pour le diagnostic d'épilepsie :	29
6.2.1 Données cliniques :	29
6.2.2 Données anatomiques et électrophysiologiques :	29
6.3 Les traitements possibles :	30

7	Comparaison entre les différentes techniques de mesures (diagnostic d'épilepsie) :	30
8	Conclusion :	31
	CHAPITRE II :	32
1	Introduction :	33
2	L'intelligence artificielle :	33
2.1	Utilisations de l'intelligence artificielle :	33
3	Machine Learning :	34
3.1	Mode d'action :	34
3.2	Son importance:	35
3.3	L'apprentissage automatique est largement adopté :	35
4	Définition de Deep Learning:	36
4.1	Mode d'action :	37
4.1.1	Types d'apprentissage :	38
4.1.2	Deep Learning supervisé :	38
4.1.3	Fonctionnement du Deep Learning supervisé :	38
4.2	Deep Learning non supervisé	40
4.2.1	Non supervisé Learning	41
4.2.2	Utiliser l'apprentissage non supervisé :	42
4.2.3	Fonctionnement l'apprentissage non supervisé	43
4.2.4	Types d'algorithme Apprentissage non supervisé :	43
5	Les différents types de réseaux de neurones :	44
5.1	Convolutional Neural Network (CNN) :	44
5.1.1	Types des couches	45
5.1.2	Couche de convolution :	45
5.1.3	Couche de pooling :	46
5.1.4	Couche fully-connected :	46
5.2	Réseau de neurones récurrent (Récurrent Neural Network (RNN)) :	47
5.3	Long Short-Term Memory (LSTM):	47
6	La différence entre LSTM , CNN et RNN :	51
7	Conclusion :	51
	CHAPITRE III :	52
1	Introduction :	53

2	Méthode proposée :	53
2.1	Acquisition des données :	54
2.2	Bloc de traitement :	55
2.2.1	Prétraitement :	55
2.2.2	La division des données en apprentissage et test :	57
2.2.3	Classification :	57
3	Présentation des outils de développement :	57
3.1	Matériel :	57
3.2	Définition du langage Python en informatique :	57
3.2.1	Définition de l'anaconda :	58
3.2.2.	Définition Jupyter :	58
4	Les interfaces d'implémentation :	59
4.1	Chargement des données du Dataset :	59
4.2	Résultats et discussions	60
4.2.1	Résultats de CNN	60
<input type="checkbox"/>	Apprentissage et test de CNN :	60
4.2.2	Résultats de RNN:	61
<input type="checkbox"/>	Apprentissage et test (RNN) :	61
4.3	Résultats (LSTM) :	62
<input type="checkbox"/>	Apprentissage et test (LSTM) :	62
5	Evaluation de la méthode proposée.....	64
6	Conclusion :	65
	Conclusion et perspectives :	66
	Références :	67

Liste des figures :

FIGURE I.1	COMPOSANTS DU CERVEAU	16
FIGURE I.2	STRUCTURE DES NEURONES	17
FIGURE I.3	FONCTIONNEMENT DES NEURONES	18
FIGURE I.4	L'ELECTROENCEPHALOGRAPHIE (EEG).....	20
FIGURE I.5	POSITION STANDARDISEE DES ELECTRODES A LA SURFACE DU CRANE (SYSTEME 10/20).....	22
FIGURE I.6	SIGNAL EEG CONTAMINE AVEC L'ARTEFACT DE TREMBLEMENTS DE VISAGE.	24
FIGURE I.7	TOMOGRAPHIE PAR EMISSION DE POSITONS.	25
FIGURE I.8	RESULTATS D'IRM D'UN PATIENT EPILEPTIQUE.....	26
FIGURE I.9	TECHNIQUE DE MESURE MEG.....	27
FIGURE I.10	GRILLE D'ELECTRODES PLACEE SUR LE CORTEX D'UN PATIENT	28
FIGURE II. 1	EXEMPLE ANIMALIER	42
FIGURE II. 2	UTILISER L'APPRENTISSAGE NON SUPERVISE	43
FIGURE II. 3	RESEAU DE NEURONES AVEC DE NOMBREUSES COUCHES CONVOLUTIVES	45
FIGURE II. 4	EXEMPLE EXPLICATIVE SUR L'OPERATION DE CONVOLUTION	45
FIGURE II. 5	(A) POOLING MOYNE, (B) POOLING MAXIMAL	46
FIGURE II. 6	COUCHE FULLY-CONNECTED.....	46
FIGURE II. 7	ARCHITECTURE DE RNN.....	47
FIGURE II. 8	ARCHITECTURE DE RNN.....	48
FIGURE II. 9	LE MODULE REPETITIF DANS UN LSTM	49
FIGURE III. 1	SCHEMA DE PRINCIPE DE LA METHODE PROPOSEE	54
FIGURE III. 2	ORGANIGRAMME DE L'EMD.	56
FIGURE III. 3	LOGO PYTHON.....	58
FIGURE III. 4	LOGO ANACONDA	58
FIGURE III. 5	LOGO JUPYTER	59
FIGURE III. 6	CHARGEMENT DES DONNEES.....	59
FIGURE III. 7	RESULTATS CNN.....	60
FIGURE III. 8	ACCURACY CNN.....	60
FIGURE III. 9	LOSS CNN.....	61
FIGURE III. 10	RESULTATS RNN.....	62
FIGURE III. 14	TAUX DE PRECISION DES (CNN, RNN ET LSTM).	64

Liste des Tableaux :

TABLEAU I.1 SIGNIFICATION DES LETTRES UTILISEES DANS LA NOMENCLATURE DES ELECTRODES.....	22
TABLEAU I.2 COMPARAISON ENTRE LES DIFFERENTES TECHNIQUES D'EXPLORATION CEREBRALE POUR LE DIAGNOSTIC DES EPILEPSIES. SOURCE : NICOLAS ALONSO ET AL.	30
TABLEAU II. 1: la différence entre lstm, cnn et rnn.....	51

Liste d'abréviations :

ADN:	Acide Desoxyribonucleique
Ag/AgCl:	Argent/Chlorure D'argent
CNN:	Convolutional Neural Network
ECoG:	Electrocorticographie
EEG:	Electroencephalographie
EMD:	Empirical Mode Mecomposition
IA:	Intelligence Artificielle
IBM:	International Business Machines
IRM:	Imagerie Par Resonance Magnetique
LSTM:	Long Short-Term Memory
MEG:	Magnetoencephalographie
RGB:	Red, Green, Blue
RNN:	Récurrent Neural Network
SEEG:	Stereoelectroencephalography
TEP:	Tomographie Par Emission De Positons
TMS:	Troubles Musculosquelettiques
ZE:	Zone Epileptogène

Résumé

La compréhension du fonctionnement du cerveau est l'un des défis majeurs des neurosciences. Pour appréhender cet organe *in vivo*, de nombreux dispositifs se sont développés, parmi lesquels on trouve l'électroencéphalographie (EEG). Elle mesure directement d'une manière non invasive les signaux du cerveau avec une haute résolution temporelle et fait le suivi de l'activité cérébrale pendant une tâche spécifique. [1]

Ce mémoire s'inscrit dans le contexte de l'analyse et de la classification des signaux EEG. En particulier, nous nous intéressons à la classification des crises épileptiques. La problématique principale ici est de garantir le plus haut taux d'accuracy.

L'étude bibliographique et l'implémentation de la méthode basée sur le deep learning menées ont permis de mieux comprendre le système de classification des signaux EEG. Dans le cadre, nous avons proposé un nouveau modèle de classification des signaux EEG basé sur les réseaux de neurones de convolution (CNN).

Les résultats trouvés avec des données EEG réelles montrent que notre méthode proposée a surpassé plusieurs méthodes de la littérature.

Mots clefs : Cerveau, Signaux EEG, Crise épileptique, Deep learning, Réseaux de neurones de convolution (CNN).

Abstract

As it is known that the brain is one of the major challenges of neuroscience. And to understand of how it works, Several devices have been developed, including electroencephalography (EEG) that measures brain signals directly and noninvasively with high temporal accuracy and tracks brain activity during a particular task. This thesis falls within the context of the analysis and classification of EEG signals. In particular, we are interested in the classification of epileptic seizures, since the main issue here is to ensure the highest accuracy rate. Bibliographic study and implementation of the method based on deep learning led to a better understanding of the EEG signal classification system. In the framework, we proposed a new

Résumé

model for classifying EEG signals based on convolutional neural networks (CNNs). The results found with real EEG data show that our proposed method has outperformed several methods in the literature.

The Keywords : Brain, EEG signals, Epileptic Seizure, Deep Learning, Convolutional Neural Networks (CNN)

Introduction générale :

Un système de classification des signaux électroencéphalographiques est un système qui permet d'analyser les signaux cérébraux émis par le cerveau de façon automatique afin de discerner si des crises existent. La détection des crises épileptiques à partir des signaux EEG est un sujet d'actualité de plus en plus intégré dans le traitement de cette maladie.

Ce domaine de recherche est en croissance continue aussi bien dans la compréhension de la maladie et de son effet sur les caractéristiques du cerveau et des signaux qu'il génère que dans le développement de nouvelles techniques de traitement du signal qui respectent mieux les propriétés des signaux cérébraux.

Durant ces dernières années, les techniques de machine Learning ont été utilisées afin de classifier les signaux, mais ces derniers n'ont pas donné des bons résultats. Les réseaux de neurones n'ont pas immédiatement reçu la grande attention que l'on voit aujourd'hui dans les applications de classification neuronale en raison de problèmes pratiques. Pour cela la pensée aux techniques d'apprentissage en profondeur peut résoudre ces problèmes à cause de son apprentissage profond ce qui est nécessaire aux traitements des signaux. Ils optimisent de manière itérative et automatique ses paramètres, ils nécessitent moins de connaissances expertes préalables sur l'ensemble de données pour bien fonctionner. Cet avantage a conduit à des adaptations précoces dans le domaine de traitement du signal qui implique généralement de grands ensembles de données qui sont autrement difficiles à interpréter, même par des experts.

Dans ce mémoire, nous proposons un modèle de classification des signaux EEG basé sur les réseaux de neurones de convolution (CNN). Ce modèle a été évalué sur un data-set réel et qui a montré des bons résultats sur la mesure de performance d'accuracy avec un taux de 97%.

Notre mémoire est organisé comme suit :

✓ Chapitre 1 : EEG et l'épilepsie

Dans ce chapitre, nous allons détailler les phénomènes neurophysiologiques et les connaissances nécessaires pour comprendre l'origine et les propriétés des activités cérébrales et du signal EEG. Ensuite, nous allons présenter une description générale de l'épilepsie et les

principales connaissances nécessaires pour comprendre cette maladie.

✓ **Chapitre 2 : Deep Learning**

Au début de ce chapitre, nous allons fournir un regard sur le domaine de l'intelligence artificielle et ses différentes branches « l'apprentissage automatique et l'apprentissage en profondeur », en définissant ce domaine, ses branches et ses différentes caractéristiques. Et à la fin de ce chapitre, nous allons présenter les différents types de réseaux de neurones (CNN, RNN et LSTM).

✓ **Chapitre 3 : Approche proposée et résultats**

Ce chapitre détaille notre approche proposée dans le but d'effectuer la tâche de classification. Ensuite nous allons, décrire l'implémentation de notre approche et les résultats obtenus avec leurs interprétations et une étude comparative avec les méthodes de la littérature.

En dernier lieu, une conclusion générale et des perspectives pour ce travail sont présentées.

CHAPITRE I :

EEG et l'épilepsie

1 Introduction:

L'épilepsie est une affection neurologique fréquente. Il s'agit d'une maladie sévère posant un problème majeur de santé publique. La prévalence de l'épilepsie est stable dans le monde et se situe entre 0.5 et 0.8% de la population. L'Algérie, compte 400 000 cas d'épilepsie. Ce sont les chiffres révélés lors des 9es Journées nationales de neurologie organisées à Annaba (2016).

La première partie de ce chapitre a pour objectif de mettre en évidence la structure générale du cerveau humain et les neurones. La seconde partie montre la technique non invasive la plus utilisée est l'Électroencéphalographie (EEG). La dernière partie présente la maladie épileptique en générale.

2 Structure du cerveau :

Le cerveau est le système biologique le plus complexe du corps humain. Il comporte environ 100 milliards de neurones et possède un poids moyen de 1.300 à 1.400 grammes. Sa protection est assurée essentiellement à l'aide de la boîte crânienne. Il remplit les fonctions de régulations des autres organes, mais également les fonctions cognitives permettant de ressentir l'environnement, de penser et d'y réagir. [2]

Le cerveau se compose de deux hémisphères, droit et gauche, quasi-symétriques. [3] Le cortex cérébral est la couche externe du cerveau. Il comprend une écorce de plusieurs couches de cellules et il possède une surface fortement plissée présentant des scissures et des sillons. Le cortex peut être divisé en quatre zones ou lobes selon les fonctions cognitives. [4]

- **Le lobe frontal :** C'est la partie avant du cerveau. Il est responsable du contrôle des mouvements volontaires. De même, il intervient dans les fonctions liées à la planification et au langage.
- **Le lobe pariétal :** C'est la partie située derrière le lobe frontal dans la partie supérieure du cerveau. Il est responsable essentiellement des fonctions somato-sensorielles qui assurent le traitement des informations en provenance de la peau comme la chaleur et la texture.
- **Le lobe occipital :** C'est la partie arrière du cerveau. Il est responsable des fonctions liées à la vision.

- **Le lobe temporal** : C'est la partie qui se situe entre l'arcade auxiliaire et l'oreille. Il intervient dans certaines fonctions sensorielles, émotionnelles, de mémorisation et de compréhension [1].

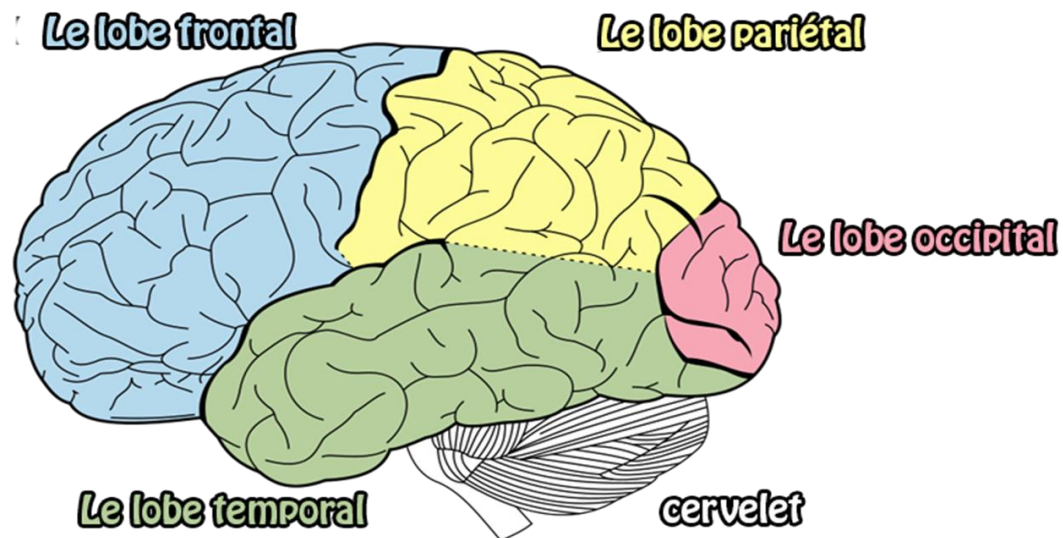


FIGURE I.1: COMPOSANTS DU CERVEAU.

2.1 Neurone :

Les neurones sont les principales cellules du système nerveux, dont le rôle est d'acheminer et traiter les informations dans l'organisme. Il existe plus de 100 milliards de neurones dans le système nerveux humain, dont un peu moins de 20 milliards dans le cortex [5].

2.2 Structure des neurones :

Un neurone est divisé en trois éléments principaux comme illustré dans la figure I. 2 [6] :

- **Corps cellulaire** : Cette partie dispose de tous les éléments essentiels qui constituent une cellule, tels que le noyau qui contient de l'ADN (Acide Désoxyribonucléique).
- **Les axones** : Cette partie sous forme de câble mince et long transporte les messages électrochimiques tout au long de la cellule. Les axones des neurones sensoriels et moteurs sont recouverts d'une fine couche de myéline, comme un fil électrique isolé. La myéline

est faite de matières grasses, et elle permet d'accélérer la transmission d'une impulsion nerveuse vers le bas d'un long axone.

- **Les dendrites ou les terminaisons nerveuses** : Cette partie permet d'établir une connexion avec d'autres cellules voisines. [6]




FIGURE I.2: STRUCTURE DES NEURONES. [6]

2.3 Fonction des neurones :

Chaque neurone (voir figure I. 3) reçoit, par l'intermédiaire des synapses disposées sur ses dendrites, des informations d'autres neurones. Il les intègre et les transmet à son tour par son axone. Cette transmission et intégration d'information sont le résultat de plusieurs processus chimiques et électriques. D'une façon extrêmement simplifiée, on peut résumer le fonctionnement des neurones comme suit : [7]

- Quand le potentiel électrique du soma (ou corps cellulaire) d'un neurone dépasse un certain seuil, un potentiel d'action est émis.
- Ce potentiel d'action (qui est une hausse locale du potentiel électrique) est transmis le long de l'axone et est réamplifié à chaque nœud de Ranvier.

- Quand il atteint les synapses présentes au bout de l'axone, il déclenche la libération de neurotransmetteurs.
- Les neurotransmetteurs traversent la fente synaptique et se fixent sur les récepteurs du neurone post-synaptique (dit afférent).
- Suivant le type de neurotransmetteurs, excitateurs ou inhibiteurs, s'active différents canaux ioniques qui vont provoquer l'augmentation ou la diminution du potentiel électrique
- Ces variations électriques du potentiel se propagent le long des dendrites jusqu'au soma.
- L'ensemble des stimulations reçues sur les différentes synapses présentes sur les dendrites sont donc intégrées au cours du temps.
- Quand le potentiel électrique de ce neurone afférent atteint le seuil, un potentiel d'action est émis et ainsi de suite. [7]




FIGURE I.3: FONCTIONNEMENT DES NEURONES. [7]

3 L'électroencéphalographie EEG :

3.1 Historique :

Les premiers enregistrements EEG remontent à la fin du 19^e siècle. En 1875, le médecin britannique Richard Caton documenta chez des animaux que l'activité électrique générée par le cerveau correspondait à l'activité mentale. Ses études démontrèrent que les patrons d'activité électrique varient en fonction de l'état de conscience de l'animal (p. ex. éveil, sommeil, anesthésie, mort), mais également à la suite d'une stimulation externe (Collura, 1993). Ce n'est que quarante-neuf ans plus tard que le premier enregistrement EEG fut réalisé chez l'être humain. En 1924, le neuropsychiatre allemand Hans Berger enregistra l'activité électrique du cerveau d'un jeune patient ayant subi une trépanation pour exciser une tumeur cervicale. Il fut le premier à amplifier le signal obtenu et à documenter la relation entre l'activité mentale et les variations au niveau du signal électrique dans certaines bandes de fréquences chez l'être humain. En 1929, il publia les résultats de ses observations. Dans cette publication, Berger décrit deux rythmes cérébraux ; le rythme alpha et le rythme bêta. Les travaux de Berger ont marqué les débuts de l'utilisation de l'EEG en clinique et en recherche [8].

3.2 Définition de l'EEG :

L'électroencéphalographie est une technique non invasive d'imagerie fonctionnelle du cerveau qui mesure l'activité électrique générée par les cellules nerveuses par le biais d'électrodes placées sur le cuir chevelu. Il capture préférentiellement les activités électriques extracellulaires des assemblées de neurones pyramidaux formant un dipôle perpendiculaire à la surface du crâne. Les valeurs mesurées reflètent le niveau de l'activité cérébrale. [8].

L'électroencéphalogramme est la transcription sous forme d'un tracé des variations dans le temps de l'activité électrique du cerveau. L'EEG est non seulement utilisé pour étudier le fonctionnement du cerveau chez des individus sains, mais également pour diagnostiquer certaines maladies qui modifient l'activité électrique cérébrale (p.ex. épilepsie, migraines, troubles du sommeil).

L'électroencéphalographie est l'un des principaux outils de diagnostic de la neurologie clinique, mais la grande majorité de l'EEG est obtenue dans le cadre de l'évaluation de crises

d'épilepsie provoque des mouvements non coordonnés qui sont en relation avec le dysfonctionnement électrophysiologique cérébral du corps de patient. Pour étudier les crises d'épilepsie, l'EEG peut être couplé à des enregistrements vidéo. Ces enregistrements sont simultanés et synchronisés de l'EEG et du comportement du patient. Grâce à son utilisation, l'étude du mouvement des patients met en relation la topographie de la décharge avec les symptômes des crises, donnant accès à l'origine anatomique des crises [8].




FIGURE I.4: L'ELECTROENCEPHALOGRAPHIE (EEG) [8].

3.3 L'appareil EEG:

Un appareil EEG moderne se compose d'un ensemble d'électrodes, d'un amplificateur, d'une unité de stockage de données et d'une unité d'affichage. Les appareils modernes possèdent en général un minimum de 32 canaux et un maximum de 256 canaux, permettant un enregistrement en continu d'une énorme quantité des signaux. Il existe de nombreux fabricants. Il existe également des systèmes compatibles avec l'IRM et la TMS.

3.3.1 Les électrodes :

Les capteurs EEG sont des électrodes Ag/AgCl (Argent/Chlorure d'argent) d'un rayon d'environ 5 mm. Ils sont fixés sur le cuir chevelu du sujet et un gel conducteur est généralement appliqué entre eux. On utilise des électrodes pour mesurer les rythmes cérébraux et les potentiels évoqués. Il existe plusieurs types d'électrodes (actives, passives). Les électrodes actives

possèdent un système de pré-amplification à l'intérieur même de l'électrode contrairement aux électrodes passives. Les électrodes actives ne requièrent aucune préparation de la peau (p. ex. gel conducteur) contrairement aux électrodes passives.

3.3.2 Montage d'électrodes :

Les montages représentent une combinaison de paires d'électrodes.

✎ **Montage unipolaire (référentiel) :** Dans un montage unipolaire, il y a une électrode de référence et une électrode active. On mesure la différence de potentiel entre l'électrode active et l'électrode de référence.

✎ **Montage bipolaire :** Dans un montage bipolaire, les deux électrodes sont actives. La différence de potentiel est mesurée entre ces deux électrodes.

3.3.3 Positionnement des électrodes selon le système international 10-20 :

Les positions de l'électrode peuvent être choisies selon des informations préalables sur l'étiologie du patient ou selon le système standard 10-20. [9] Ce système définit de façon proportionnelle l'emplacement des électrodes par rapport à des repères d'os fixes, telles que le nasion (jonction entre l'arête du nez et le front), l'inion (point défini sur l'occiput) et les deux points pré-auriculaires droit et gauche. Ensuite, les électrodes sont placées à des intervalles de 10% ou 20% par rapport à ces repères (figure I.5).

Les électrodes impaires sont situées à la gauche du crâne tandis que les électrodes paires sont sur la droite. Les lettres contenues dans les noms des électrodes correspondent aux zones cérébrales sont données dans « le tableau I.1 » [10, 11].

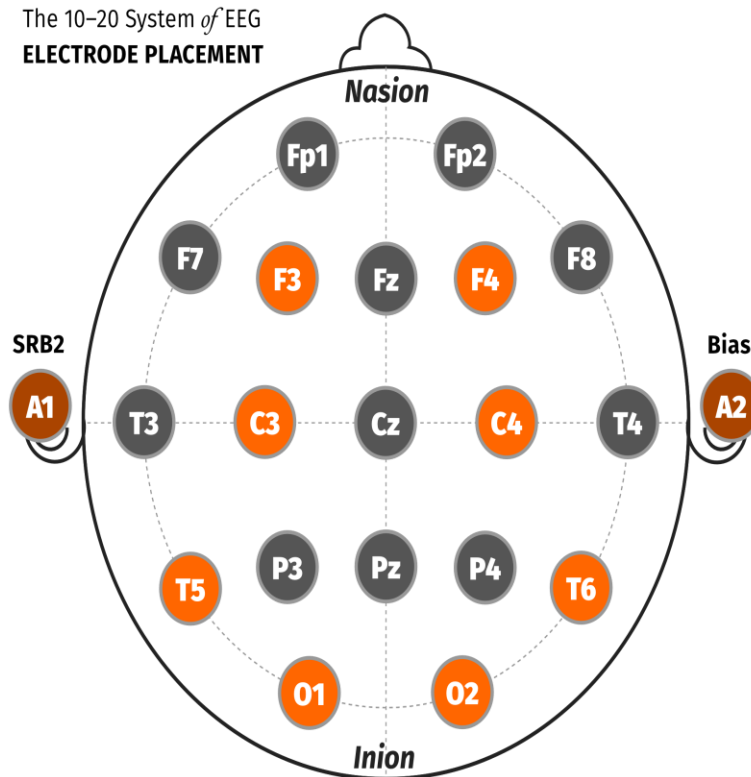


FIGURE I.5: POSITION STANDARDISEE DES ELECTRODES A LA SURFACE DU CRANE (SYSTEME 10/20) [9].

TABLEAU I. 1: SIGNIFICATION DES LETTRES UTILISEES DANS LA NOMENCLATURE DES ELECTRODES

Lettre	C	F	AF	T	P	O
Zone	Centrale	Frontale	Antérieure Frontale	Temporale	Pariétale	Occipitale

Les électrodes utilisées en EEG sont caractérisées par leur faible coût, leur faible impédance de contact et leur bonne stabilité. Il faut environ 10^4 neurones, dans quelques millimètres cube du cortex prêt du crâne, orientés dans le même sens et fonctionnant de manière synchrone pour que le potentiel post-synaptique engendré puisse être observable au niveau du scalp à l'aide des capteurs EEG.

4 Les perturbations :

Dans l'analyse de l'EEG, il est important de reconnaître les modèles des signaux qui ne sont pas générés par le cerveau pour éviter les mauvaises interprétations. Les signaux EEG de surface résultent d'une combinaison des signaux cérébraux et des perturbations. Ces perturbations peuvent faire l'objet d'énergies importantes qui peuvent perturber considérablement l'interprétation clinique ou l'analyse automatique. Les signaux EEG sont très sensibles à toutes sortes de perturbations qui peuvent être classés en artefacts et bruit.

4.1 Les artefacts :

Les artefacts EEG sont d'origine physiologique tandis que le bruit est d'origine non physiologique. Les artefacts sont généralement dus aux clignotements et aux mouvements des yeux, aux mouvements musculaires et à l'électrocardiogramme. Les artefacts oculaires dus aux mouvements des yeux sont causés par la différence de potentielle de quelques millivolts entre la cornée et la rétine. Lorsque les yeux se déplacent, la différence dans le champ électrique provoquée par le mouvement est captée par des électrodes à proximité [11]. De même, les potentiels musculaires peuvent être localisés sur le cuir chevelu en provoquant diverses formes d'artefacts dans une seule ou plusieurs zones. Dans de nombreux cas, les artefacts peuvent être reconnus s'il existe des potentiels de moyenne ou haute amplitude qui ne se produisent que dans une seule électrode ou une activité rythmique ou irrégulière qui apparaisse simultanément dans des régions du cerveau indépendantes [12]. Par exemple, les mouvements du visage et de la mâchoire sont observés dans le signal comme des rafales qui sont synchronisées avec le mouvement et qui sont superposées à des formes d'onde plus lentes [13]. La « figure I.6 » illustre un exemple d'artefact d'un tremblement de visage.




FIGURE I.6: SIGNAL EEG CONTAMINE AVEC L'ARTEFACT DE TREMBLEMENTS DE VISAGE[13].

Les artefacts de l'électrocardiogramme proviennent du champ électrique associé à l'action cardiaque. Ce champ électrique peut être capté sur le signal EEG, mais peut également provoquer un mouvement des électrodes à proximité des artères en raison de l'onde de pression d'impulsion qu'il produit dans le système artériel. Les artefacts peuvent être réduits par la relaxation du patient, le changement de sa posture ou, si nécessaire, avec des algorithmes de filtrage. La difficulté dans l'élimination des artefacts est que les artefacts physiologiques sont des signaux qui peuvent être extrêmement informatifs sur l'état du patient. En plus, les méthodes d'élimination des artefacts, telles que le filtrage, peuvent affecter les caractéristiques fréquentielles du signal [14].

4.2 Le bruit :

Le bruit est causé par les interférences électriques et la déformation du signal causée par les électrodes et l'instrument d'enregistrement. L'interférence est causée principalement par les champs électriques et magnétiques du réseau électrique. De même, lorsque le contact de l'électrode est imparfait, il provoque un affaiblissement du courant entre l'électrode et le tissu. Aussi, les câbles d'électrode donnent lieu à des bruits lorsqu'ils se déplacent ou vibrent.

5 Les techniques d'enregistrement d'activité cérébrale :

5.1 Tomographie par Emission de Positons (TEP) :

La TEP (Tomographie par Emission de Positons ou PETscan) est une technique d'imagerie utilisée pour mettre en évidence des zones d'hypométabolismes en relation avec la ZE responsable du déclenchement de la crise. Le principe de fonctionnement de la TEP est basé sur la détection externe d'un élément radioactif traceur du glucose. Ce traceur (généralement incorporé dans une molécule impliquée dans le métabolisme glucidique ou de la consommation en oxygène) est injecté au patient [15]. Grâce aux émissions gamma radioactives il est possible de détecter ce traceur et sa concentration dans les tissus explorés grâce à une caméra spéciale comme montré dans la « figure I.7 ».




FIGURE I.7: TOMOGRAPHIE PAR EMISSION DE POSITONS[15].

5.2 Imagerie par Résonance Magnétique (IRM) :

L'IRM (Imagerie par Résonance Magnétique) est l'une des techniques d'imagerie médicale les plus récentes. Fiable et précise, elle est très souvent utilisée pour détecter une anomalie morphologique qui peut être la cause de l'épilepsie chez certains patients. [16]

L'IRM basée sur l'exploitation d'une propriété que possèdent certains noyaux atomiques : le spin, le moment cinétique intrinsèque des particules quantiques placées dans un champ

magnétique [15]. Elle permet de visualiser avec une grande précision les organes et tissus mous, dans différents plans de l'espace en deux et en trois dimensions de l'intérieur du corps. Les images obtenues par résonance magnétique sont le résultat de l'interaction entre un champ magnétique créé par la machine et les atomes d'hydrogène contenus dans l'organisme du patient à un temps d'acquisition long « figure I.8 ». Ces images peuvent être segmentées pour distinguer chacun des milieux.




FIGURE I.8: RESULTATS D'IRM D'UN PATIENT EPILEPTIQUE[15].

5.3 Magnétoencéphalographie (MEG) :

La magnétoencéphalographie (MEG) a été développée en 1972 par David Cohen qui a procédé aux premiers enregistrements de champs magnétiques cérébraux [17]. La réussite de cette expérience est due aux avancements dans les technologies des capteurs supraconducteurs extrêmement précis. La MEG est une technique d'imagerie non-invasive basée sur la mesure des variations du champ magnétique à la surface du crâne, provoquées par l'activation électrique intracellulaire des neurones pyramidaux formant un dipôle parallèle à la surface du crâne. Les capteurs utilisés permettent de mesurer des variations infinitésimales du champ magnétique de l'ordre de 10^{-15} Tesla. La MEG présente une moyenne résolution spatiale ainsi qu'une excellente résolution temporelle qui permet de réaliser des applications en temps réel. Cependant, le coût élevé et la grande taille de l'appareil ainsi que la nécessité de refroidir les capteurs avec de l'hélium liquide. La « figure I.9 » illustre l'appareil utilisé pour la mesure de la MEG.



FIGURE I.9: TECHNIQUE DE MESURE MEG[1]

5.4 L'Electrocorticographie (ECoG) :

ECoG est une technique d'imagerie cérébrale invasive. Depuis son invention par W. Penfield et H. Jasper dans les années 1950, elle reste utilisée jusqu'à maintenant. L'ECoG est basée sur la mesure du potentiel d'action dans les neurones pyramidaux corticaux. Cette technique nécessite une opération chirurgicale pour implanter une grille d'électrodes, sur/sous la dure-mère, entre l'os du crâne et la surface du cortex comme montré dans la « figure I.10 ». Ainsi, les amplitudes des signaux électriques acquis sont au maximum (50-100 μV) puisqu'ils ne seront pas conduits à travers le crâne qui diminue leurs potentiels en raison de la faible conductivité de l'os. Cela entraîne une augmentation de la résolution spatiale de l'ECoG par rapport à l'EEG (dizaines de millimètres par rapport aux centimètres) et de la bande passante des fréquences des signaux (supérieure à 300 Hz). En plus, les enregistrements ECoG sont moins influencés par les artefacts [18]. Il est fréquemment utilisé dans les pays anglo-saxons.




FIGURE I.10: GRILLE D'ELECTRODES PLACÉE SUR LE CORTEX D'UN PATIENT[18] .

6 L'épilepsie :

Le nom « épilepsie » a pour origine un mot grec qui signifie « attaquer par surprise » reflétant l'apparition très soudaine et imprévisible des crises.

L'épilepsie est un désordre neurologique chronique caractérisé par des crises récurrentes. Un fonctionnement anormal qui transforme un réseau neuronal normal en un réseau hyperexcitable, aigu et transitoire de l'activité électrique d'une zone cérébrale qui se traduit par des crises épileptiques, et par les conséquences neurobiologiques, cognitives, psychologiques et sociales de cette affection. L'épilepsie est considérée comme ayant disparu chez les patients qui présentaient un syndrome épileptique âge-dépendant et qui ont désormais dépassé l'âge correspondant et chez ceux qui n'ont pas eu de crise au cours des dix dernières années sans avoir pris de traitement antiépileptique depuis au moins 5 ans.

Cette décharge épileptique est objectivée par l'enregistrement de l'électroencéphalogramme (EEG) s'il est réalisé au cours de la crise.

6.1 Causes et mécanisme biologique de l'épilepsie :

Tout cerveau, y compris le plus normal, est susceptible d'être le siège d'une activité épileptique dans certaines conditions [19]. L'épilepsie peut être provoquée par des :

- ✓ **Epilepsies idiopathiques** : Liées à la personne et non à un facteur externe
 - Inconnues (cryptogéniques).
 - Génétique (idiopathiques).
 - Canaux ioniques.

- ✓ **Epilepsies symptomatiques** : Toute agression cérébrale est susceptible, sur un terrain donné, de provoquer des crises épileptiques.
 - Malformations, kystes, Tumeurs, métastases, Hémorragie, Thrombose, Embolie...

6.2 Les multimodalités pour le diagnostic d'épilepsie :

6.2.1 Données cliniques :

Les données cliniques sont les premières informations recueillies lorsqu'un patient se présente chez son médecin. Elles regroupent les résultats d'un ensemble de tests et de questions permettant de donner rapidement des pistes sur le type d'épilepsie ou au moins de privilégier certains axes de recherche des causes de la maladie [20].

6.2.2 Données anatomiques et électrophysiologiques :

Il est important de poser un diagnostic car d'autres pathologies peuvent présenter des manifestations qui font penser à des crises d'épilepsie. A partir du moment où le diagnostic d'épilepsie est posé, un traitement adapté peut être entamé. Dans le cadre de ce bilan, une batterie d'examen est effectuée pour tenter de déterminer, le plus précisément possible, la zone cérébrale responsable du déclenchement des crises d'épilepsie. Cette batterie d'examen comporte des données cliniques, des données anatomiques et d'imagerie cérébrale (IRM morphologique et fonctionnelle, TEP, TEMP) et enfin des données électrophysiologiques (enregistrements d'EEG). Pour certains patients, la ZE n'est pas toujours localisée avec ces examens et il n'y a pas une lésion apparente ou évidente. Les neurologues passent à l'exploration chirurgicale. Des méthodes plus invasives comme SEEG et ECoG. Ce bilan est long, lourd et coûteux.

6.3 Les traitements possibles :

Le traitement d'une épilepsie est avant tout symptomatique : il vise à supprimer les crises.

- **Traitement médicamenteux** : La grande majorité des épilepsies est traitée médicalement : 80% des patients sont stabilisés par une monothérapie. Les médicaments antiépileptiques classiques (Phénobarbital, valproate de sodium, benzodiazépines, carbamazépine et phénytoïne) agissent en diminuant l'excitabilité des membranes des neurones par interaction avec certains neuromédiateurs, certains récepteurs ou certains canaux ioniques.

- **Traitement chirurgical** : Il ne faut pas le confondre avec le traitement chirurgical d'une lésion focale responsable de crises épileptiques. Le traitement chirurgical d'une épilepsie est devenu un outil performant qui vise à supprimer le foyer épileptique et de ce fait la totalité des crises par cortectomie sélective.

7 Comparaison entre les différentes techniques de mesures (diagnostic d'épilepsie) :

Le « tableau I.2 » qui suit montre les principales propriétés des techniques d'exploration cérébrale les plus utilisées pour le diagnostic des épilepsies.

TABLEAU I. 2: COMPARAISON ENTRE LES DIFFERENTES TECHNIQUES D'EXPLORATION CEREBRALE POUR LE DIAGNOSTIC DES EPILEPSIES. SOURCE : NICOLAS ALONSO ET AL.

Technique de mesure	Nature du signal	Résolution spatiale	Résolution temporelle	Invasivité	Portabilité
ECoG	Electrique	1 mm	30 ms	Oui	Oui
MEG	Magnétique	5 mm	50 ms	Non	Non
EEG	Electrique	1 cm	50 ms	Non	Oui
IRM	Métabolique	5 mm	–	Non	Non

8 Conclusion :

Dans ce premier chapitre, nous avons présenté les notions de base de la neurophysiologie afin de comprendre l'origine et les caractéristiques des activités cérébrales. Puis, nous avons mis l'accent sur la technologie de la détection des données EEG qui est la technique de mesure de l'activité cérébrale la plus utilisée pour diagnostiquer l'épilepsie. Dans le prochain chapitre, nous allons voir le principe de l'apprentissage profond (Deep learning) et les réseaux de neurones (CNN, RNN et LSTM).

CHAPITRE II :

Deep Learning

1 Introduction :

L'intelligence artificielle est une discipline scientifique recherchant des méthodes de solution de problèmes à forte complexité logique ou algorithmique. L'apprentissage automatique champ d'étude de l'intelligence artificielle. Par conséquent, L'apprentissage profond (en anglais deep learning, deep structured learning, hierarchical learning) est un ensemble de méthodes d'apprentissage automatique tentant de modéliser avec un haut niveau d'abstraction des données grâce à des architectures articulées de différentes transformations non linéaires. Dans ce chapitre nous allons présenter tout d'abord les notions en relation avec l'apprentissage profond [22].

2 L'intelligence artificielle :

L'intelligence artificielle (IA) est un processus d'imitation de l'intelligence humaine qui repose sur la création et l'application d'algorithmes exécutés dans un environnement informatique dynamique. Son but est de permettre à des ordinateurs de penser et d'agir comme des êtres humains.

L'IA est devenue un sujet en vogue dans les médias et magazines scientifiques en raison des nombreuses réalisations, dont beaucoup sont le fruit des progrès accomplis dans le domaine de l'apprentissage automatique. De grandes entreprises dont Google, Facebook, IBM, Microsoft. La recherche en IA a permis de réaliser d'importants progrès dans la dernière décennie, et ce dans différents secteurs. [22]

Pour y parvenir, trois composants sont nécessaires :

- Des systèmes informatiques.
- Des données avec des systèmes de gestion.
- Des algorithmes d'IA avancés (code).

2.1 Utilisations de l'intelligence artificielle :

L'IA est présente dans notre quotidien. Elle est par exemple utilisée par les services de détection des fraudes des établissements financiers, pour la prévision des intentions d'achat et dans les interactions avec les services clients en ligne. Voici quelques exemples :

- Détection des fraudes, dans le secteur de la finance, l'intelligence artificielle est utilisée de
-

deux manières. Les applications qui notent les demandes de crédit utilisent l'IA pour évaluer la solvabilité des consommateurs. Des moteurs d'IA plus avancés sont chargés de surveiller et de détecter en temps réel les paiements frauduleux réalisés par carte bancaire.

- Service client virtuel (SCV), les centres d'appel utilisent un SCV pour prédire les demandes de leurs clients et y répondre sans intervention humaine. La reconnaissance vocale et un simulateur de dialogue humain constituent le premier point d'interaction avec le service client. Les demandes plus complexes requièrent quant à elles une intervention humaine.

- Lorsqu'un internaute ouvre une fenêtre de dialogue sur une page web (chatbot), son interlocuteur est souvent un ordinateur exécutant une forme d'IA spécialisée. Si le chatbot ne parvient pas à interpréter la question ou à résoudre le problème, un agent humain prend le relais. Ces échecs d'interprétation sont envoyés au système de machine learning afin d'améliorer les futures interactions de l'application d'IA [23].

3 Machine Learning :

L'apprentissage automatique est une application de l'intelligence artificielle qui permet aux systèmes d'apprendre et de s'améliorer à partir de l'expérience sans être explicitement programmés. L'apprentissage automatique se concentre sur le développement de programmes informatiques capables d'accéder à des données et de les utiliser pour apprendre par eux-mêmes [23].

3.1 Mode d'action :

Semblable à la façon dont le cerveau humain acquiert des connaissances et une compréhension, l'apprentissage automatique s'appuie sur des entrées, telles que des données d'entraînement ou des graphiques de connaissances, pour comprendre les entités, les domaines et les liens entre eux. Une fois les entités définies, l'apprentissage en profondeur peut commencer.

Le processus d'apprentissage automatique commence par des observations ou des données, telles que des exemples, une expérience directe ou des instructions. Il recherche des modèles dans les données afin de pouvoir ensuite faire des déductions basées sur les exemples fournis. L'objectif principal de ML est de permettre aux ordinateurs d'apprendre de manière autonome sans intervention ou assistance humaine et d'ajuster les actions en conséquence [23].

3.2 Son importance:

L'apprentissage automatique en tant que concept existe depuis un certain temps. Le terme "apprentissage automatique" a été inventé par Arthur Samuel, informaticien chez IBM et pionnier de l'IA et des jeux vidéo. Samuel a conçu un programme informatique pour jouer aux dames. Plus le programme jouait, plus il apprenait de l'expérience, en utilisant des algorithmes pour faire des prédictions.

En tant que discipline, l'apprentissage automatique explore l'analyse et la construction d'algorithmes capables d'apprendre et de faire des prédictions sur les données.

Le ML s'est avéré précieux car il peut résoudre des problèmes à une vitesse et à une échelle qui ne peut être reproduites par l'esprit humain seul. Avec d'énormes capacités de calcul derrière une seule tâche ou plusieurs tâches spécifiques, les machines peuvent être formées pour identifier les modèles et les relations entre les données d'entrée et automatiser les processus de routine [23].

- **Les données sont essentielles :** Les algorithmes qui pilotent l'apprentissage automatique sont essentiels au succès. Les algorithmes ML construisent un modèle mathématique basé sur des exemples de données, appelés « données d'apprentissage », pour faire des prédictions ou prendre des décisions sans être explicitement programmés pour le faire. Cela peut révéler des tendances dans les données que les entreprises d'information peuvent utiliser pour améliorer la prise de décision, optimiser l'efficacité et capturer des données exploitables à grande échelle.

- **L'IA est l'objectif :** ML fournit la base des systèmes d'IA qui automatisent les processus et résolvent de manière autonome les problèmes commerciaux basés sur les données. Il permet aux entreprises de remplacer ou d'augmenter certaines capacités humaines. Les applications courantes d'apprentissage automatique que vous pouvez trouver dans le monde réel incluent les chats bots, les voitures autonomes et la reconnaissance vocale [23].

3.3 L'apprentissage automatique est largement adopté :

L'apprentissage automatique n'est pas de la science-fiction. Il est déjà largement utilisé par les entreprises de tous les secteurs pour faire progresser l'innovation et accroître l'efficacité des

processus. En 2021, 41 % des entreprises ont accéléré leur déploiement de l'IA suite à la pandémie. Ces nouveaux venus rejoignent les 31 % d'entreprises qui ont déjà de l'IA en production ou pilotent activement des technologies d'IA [24].

➤ **Sécurité des données :** Les modèles d'apprentissage automatique peuvent identifier les vulnérabilités de la sécurité des données avant qu'elles ne se transforment en violations. En examinant les expériences passées, les modèles d'apprentissage automatique peuvent prédire les futures activités à haut risque afin que le risque puisse être atténué de manière proactive [24].

➤ **Finance :** Les banques, les maisons de courtage et les sociétés de technologie financière utilisent des algorithmes d'apprentissage automatique pour automatiser le trading et fournir des services de conseil financier aux investisseurs. Bank of America utilise un chatbot, Erica, pour automatiser le support client [24].

➤ **Santé :** Le ML est utilisé pour analyser des ensembles de données de santé massifs afin d'accélérer la découverte de traitements et de remèdes, d'améliorer les résultats pour les patients et d'automatiser les processus de routine afin d'éviter les erreurs humaines. Par exemple, Watson d'IBM utilise l'exploration de données pour fournir aux médecins des données qu'ils peuvent utiliser pour personnaliser le traitement des patients [24].

➤ **Détection des fraudes :** L'IA est utilisée dans le secteur financier et bancaire pour analyser de manière autonome un grand nombre de transactions afin de découvrir les activités frauduleuses en temps réel. La société de services technologiques Capgemini affirme que les systèmes de détection des fraudes utilisant l'apprentissage automatique et l'analyse réduisent le temps d'investigation des fraudes de 70 % et améliorent la précision de la détection de 90 % [24].

➤ **Commerce de détail :** Les chercheurs et développeurs en IA utilisent des algorithmes ML pour développer des moteurs de recommandation IA qui proposent des suggestions de produits pertinentes basées sur les choix passés des acheteurs, ainsi que des données historiques, géographiques et démographiques [24].

4 Définition de Deep Learning:

Au sein de la révolution que connaît l'Intelligence Artificielle aujourd'hui, l'apprentissage

profond (deep learning) occupe une place de tout premier plan. Il est au cœur des technologies qui permettent aujourd'hui de réaliser des tâches encore impensables il y a quelques années, comme la conduite automatique ou la conversation avec des assistants vocaux. L'apprentissage profond désigne une technique d'apprentissage d'une machine, c'est une sous-branche de l'intelligence artificielle qui vise à construire automatiquement des connaissances à partir de grandes quantités d'information [25].

La réussite du deep learning repose à la fois sur des avancées en terme de modélisation des représentations de l'information, sur des méthodes d'apprentissage statistiques exploitant des données massivement annotées, et sur des calculateurs très puissants adaptés à ces architectures. Les modèles de Deep Learning sont bâtis sur le même modèle que les perceptrons multicouches précédemment décrits. Cependant, il convient de souligner que les différentes couches intermédiaires sont plus nombreuses. Chacune des couches intermédiaires va être subdivisée en sous partie, traitant un sous problème, plus simple et fournissant le résultat à la couche suivante, et ainsi de suite. Ainsi, dans le cadre du traitement du langage, imaginons un extrait audio parlant de l'équipe d'Algérie de football, les différentes couches pourraient se hiérarchiser de cette façon:

- Couche 1 : Sport.

- Couche 2 : Sport collectif.

- Couche 3 : Football.

- Couche 4 : Equipe d'Algérie.

Cette manière d'ordonner les déductions amènent les modèles de Deep Learning à se rapprocher un peu plus du mode de fonctionnement du cerveau humain, en ajoutant au fur et à mesure un contexte de plus en plus précis au sujet sur lequel le modèle opère. [25]

4.1 Mode d'action :

L'apprentissage en profondeur, comme nous l'avons expliqué précédemment, tente de simuler le cerveau humain, il utilise donc des réseaux de neurones artificiels (ANN) pour cela, et c'est vrai mais cette description est un très bref résumé du processus qui se déroule, les réseaux de neurones artificiels se composent généralement d'un certain nombre de couches de neurones.

L'apprentissage en profondeur repose sur des couches neuronales cachées ou profondes, c'est-à-dire qu'il a besoin d'un plus grand nombre de ces couches que les couches neuronales d'un réseau neuronal régulier et traditionnel.

Ces réseaux de neurones profonds ont plusieurs types, et chaque type est généralement spécifique à une fonction spécifique, Certains d'entre eux traitent des images et les reconnaissent, et d'autres traitent les sons puis les comprennent, et certains d'entre eux traitent le langage naturel parlé par les humains, puis les comprennent et y répondent également [25].

4.1.1 Types d'apprentissage :

4.1.2 Deep Learning supervisé :

Deep Learning supervisé est le type d'apprentissage automatique dans lequel les machines sont entraînées à l'aide de données d'entraînement bien "étiquetées", et sur la base de ces données, les machines prédisent la sortie. Les données étiquetées signifient que certaines données d'entrée sont déjà étiquetées avec la sortie correcte.

Dans Deep Learning supervisé, les données de formation fournies aux machines fonctionnent comme le superviseur qui enseigne aux machines à prédire correctement la sortie. Il applique le même concept qu'un élève apprend sous la supervision de l'enseignant.

Deep Learning supervisé est un processus consistant à fournir des données d'entrée ainsi que des données de sortie correctes au modèle d'apprentissage automatique. Le but d'un algorithme Deep Learning supervisé est de trouver une fonction de mappage pour mapper la variable d'entrée (x) avec la variable de sortie (y).

Dans le monde réel, Deep learning supervisé peut être utilisé pour l'évaluation des risques, la classification des images, la détection des fraudes, le filtrage des spams, etc [25].

4.1.3 Fonctionnement du Deep Learning supervisé :

Dans Deep Learning supervisé, les modèles sont entraînés à l'aide d'un ensemble de données étiqueté, où le modèle apprend chaque type de données. Une fois le processus d'apprentissage terminé, le modèle est testé sur la base de données de test (un sous-ensemble de l'ensemble d'apprentissage), puis il prédit la sortie.

Le fonctionnement de Deep Learning supervisé peut être facilement compris par l'exemple et

le diagramme ci-dessous :

Apprentissage automatique supervisé supposons que nous disposions d'un ensemble de données de différents types de formes comprenant un carré, un rectangle, un triangle et un polygone. Maintenant, la première étape consiste à former le modèle pour chaque forme.

Si la forme donnée a quatre côtés et que tous les côtés sont égaux, elle sera étiquetée comme un carré.

Si la forme donnée a trois côtés, elle sera étiquetée comme un triangle.

Si la forme donnée a six côtés égaux, elle sera étiquetée comme un hexagone.

Maintenant, après la formation, nous testons notre modèle à l'aide de l'ensemble de test, et la tâche du modèle est d'identifier la forme.

La machine est déjà formée sur tous les types de formes, et lorsqu'elle trouve une nouvelle forme, elle classe la forme sur la base d'un certain nombre de côtés et prédit la sortie [25].

4.1.3.1 Étapes impliquées dans Deep Learning supervisé :

☞ Déterminez d'abord le type d'ensemble de données d'entraînement recueillir/regrouper les données d'entraînement étiquetées.

☞ Divisez l'ensemble de données d'entraînement en ensemble de données d'entraînement, ensemble de données de test et ensemble de données de validation.

☞ Déterminez les caractéristiques d'entrée de l'ensemble de données d'apprentissage, qui doivent avoir suffisamment de connaissances pour que le modèle puisse prédire avec précision la sortie.

☞ Déterminez l'algorithme approprié pour le modèle, tel que la machine à vecteurs de support, l'arbre de décision, etc.

☞ Exécutez l'algorithme sur l'ensemble de données d'entraînement. Parfois, nous avons besoin d'ensembles de validation comme paramètres de contrôle, qui sont le sous-ensemble des ensembles de données d'apprentissage.

☞ Évaluez la précision du modèle en fournissant l'ensemble de test. Si le modèle prédit la sortie correcte, cela signifie que notre modèle est précis [26].

4.1.3.2 Types d'algorithmes d'apprentissage automatique supervisés :

L'apprentissage supervisé peut être divisé en deux types de problèmes :

❖ **Deep Learning Supervise :**

1. Régression :

Les algorithmes de régression sont utilisés s'il existe une relation entre la variable d'entrée et la variable de sortie. Il est utilisé pour la prédiction de variables continues, telles que les prévisions météorologiques, les tendances du marché, etc. Vous trouverez ci-dessous quelques algorithmes de régression populaires qui relèvent de l'apprentissage supervisé :

- Régression linéaire.
- Arbres de régression.
- Régression non linéaire.
- Régression linéaire bayésienne.
- Régression polynomiale [26].

2. Classement :

Les algorithmes de classification sont utilisés lorsque la variable de sortie est catégorielle, ce qui signifie qu'il existe deux classes telles que Oui-Non, Homme-Femme, Vrai-faux, etc.

- ❖ Filtrage des spams.
- ❖ Forêt aléatoire.
- ❖ Arbres de décision.
- ❖ Régression logistique.
- ❖ Soutenir les machines vectorielles [26].

4.2 Deep Learning non supervisé

Dans le sujet précédent, nous avons appris Deep Learning supervisé dans lequel les modèles sont entraînés à l'aide de données étiquetées sous la supervision de données d'entraînement. Mais il peut y avoir de nombreux cas dans lesquels nous n'avons pas de données étiquetées et devons trouver les modèles cachés à partir de l'ensemble de données donné. Ainsi, pour résoudre de tels types de cas en apprentissage automatique, nous avons besoin de techniques d'apprentissage non supervisé [27].

4.2.1 Non supervisé Learning

Comme son nom l'indique, l'apprentissage non supervisé est une technique d'apprentissage automatique dans laquelle les modèles ne sont pas supervisés à l'aide d'un ensemble de données d'apprentissage. Au lieu de cela, les modèles eux-mêmes trouvent les modèles cachés et les informations à partir des données fournies. Cela peut être comparé à l'apprentissage qui se déroule dans le cerveau humain tout en apprenant de nouvelles choses. Il peut être défini comme : L'apprentissage non supervisé est un type d'apprentissage automatique dans lequel les modèles sont formés à l'aide d'un ensemble de données non étiqueté et sont autorisés à agir sur ces données sans aucune supervision [27].

L'apprentissage non supervisé ne peut pas être directement appliqué à un problème de régression ou de classification car contrairement à l'apprentissage supervisé, nous avons les données d'entrée mais pas de données de sortie correspondantes. Le but de l'apprentissage non supervisé est de trouver la structure sous-jacente de l'ensemble de données, de regrouper ces données en fonction des similitudes et de représenter cet ensemble de données dans un format compressé.

Exemple : supposons que l'algorithme d'apprentissage non supervisé reçoive un ensemble de données d'entrée contenant des images de différents types de chats et de chiens. L'algorithme n'est jamais formé sur l'ensemble de données donné, ce qui signifie qu'il n'a aucune idée des caractéristiques de l'ensemble de données. La tâche de l'algorithme d'apprentissage non supervisé est d'identifier les caractéristiques de l'image par elles-mêmes. Un algorithme d'apprentissage non supervisé effectuera cette tâche en regroupant l'ensemble de données d'images dans les groupes en fonction des similitudes entre les images [27].



FIGURE II. 1: EXEMPLE ANIMALIER [27] .

4.2.2 Utiliser l'apprentissage non supervisé :

Voici quelques raisons principales qui décrivent l'importance de l'apprentissage non supervisé :

L'apprentissage non supervisé est utile pour trouver des informations utiles à partir des données.

L'apprentissage non supervisé est très similaire car un humain apprend à penser par ses propres expériences, ce qui le rapproche de la véritable IA.

L'apprentissage non supervisé fonctionne sur des données non étiquetées et non catégorisées, ce qui rend l'apprentissage non supervisé plus important.

Dans le monde réel, nous n'avons pas toujours des données d'entrée avec la sortie correspondante, donc pour résoudre de tels cas, nous avons besoin d'un apprentissage non supervisé [27].

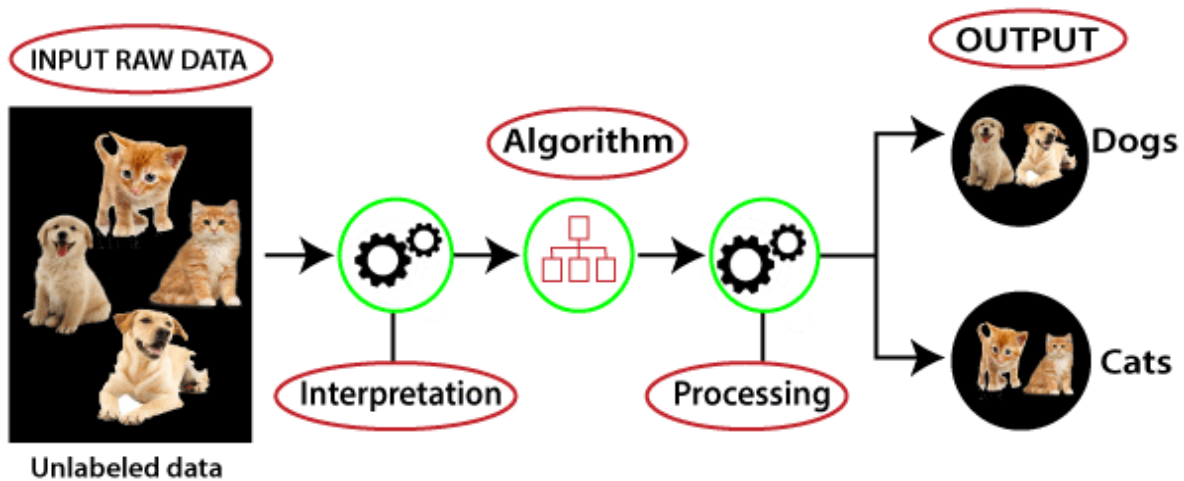


FIGURE II. 2: UTILISER L'APPRENTISSAGE NON SUPERVISÉ [27].

4.2.3 Fonctionnement l'apprentissage non supervisé

Le fonctionnement de l'apprentissage non supervisé peut être compris par le schéma ci-dessous :

Apprentissage automatique supervisé :

Ici, nous avons pris des données d'entrée non étiquetées, ce qui signifie qu'elles ne sont pas catégorisées et que les sorties correspondantes ne sont pas non plus données. Désormais, ces données d'entrée non étiquetées sont transmises au modèle d'apprentissage automatique afin de l'entraîner. Tout d'abord, il interprétera les données brutes pour trouver les modèles cachés à partir des données, puis appliquera des algorithmes appropriés tels que le clustering k-means, l'arbre de décision, etc.

Une fois qu'il applique l'algorithme approprié, l'algorithme divise les objets de données en groupes en fonction des similitudes et des différences entre les objets [27].

4.2.4 Types d'algorithme Apprentissage non supervisé :

L'algorithme d'apprentissage non supervisé peut être classé en deux types de problèmes :

☒ **Regroupement** : le regroupement est une méthode de regroupement des objets en clusters de sorte que les objets présentant le plus de similitudes restent dans un groupe et présentent

moins ou pas de similitudes avec les objets d'un autre groupe. L'analyse de cluster trouve les points communs entre les objets de données et les catégorise selon la présence et l'absence de ces points communs.

✎ **Association** : Une règle d'association est une méthode d'apprentissage non supervisée qui est utilisée pour trouver les relations entre les variables dans la grande base de données. Il détermine l'ensemble d'éléments qui se produisent ensemble dans l'ensemble de données. La règle d'association rend la stratégie marketing plus efficace. Par exemple, les personnes qui achètent un article X (supposons un pain) ont également tendance à acheter un article Y (beurre/confiture). Un exemple typique de règle d'association est l'analyse du panier de consommation [27].

5 Les différents types de réseaux de neurones :

Les différents types de réseaux de neurones : Il existe différents types de réseaux de neurones. Les deux réseaux de neurones les plus populaires sont :

5.1 Convolutional Neural Network (CNN) :

Le nom « Réseau de neurones à convolution » indique que le réseau emploie une opération mathématique appelée la convolution. Les réseaux de convolution sont un type spécialisé de réseaux neuronaux qui utilisent la convolution à la place de la multiplication matricielle générale dans au moins une de leurs couches. Les CNN sont l'un des meilleurs algorithmes d'apprentissage pour faire l'opération de convolution qui aide à l'extraction de fonctionnalités utiles à partir de points de données corrélés localement. La sortie des noyaux convolutifs est ensuite affectée à l'unité de traitement non linéaire (fonction d'activation), qui non seulement aide à apprendre les abstractions, mais intègre également la non-linéarité dans l'espace des fonctionnalités. Cette non-linéarité génère différents modèles d'activations pour différentes réponses et facilite ainsi l'apprentissage des différences sémantiques dans les images [28]. La topologie de CNN est divisée en plusieurs étapes d'apprentissage composées d'une combinaison des couches convolutives, des unités de traitement non linéaires et des couches de sous-échantillonnage [28] [29]. « La Figure II.3 » montre la structure générale d'un réseau CNN.

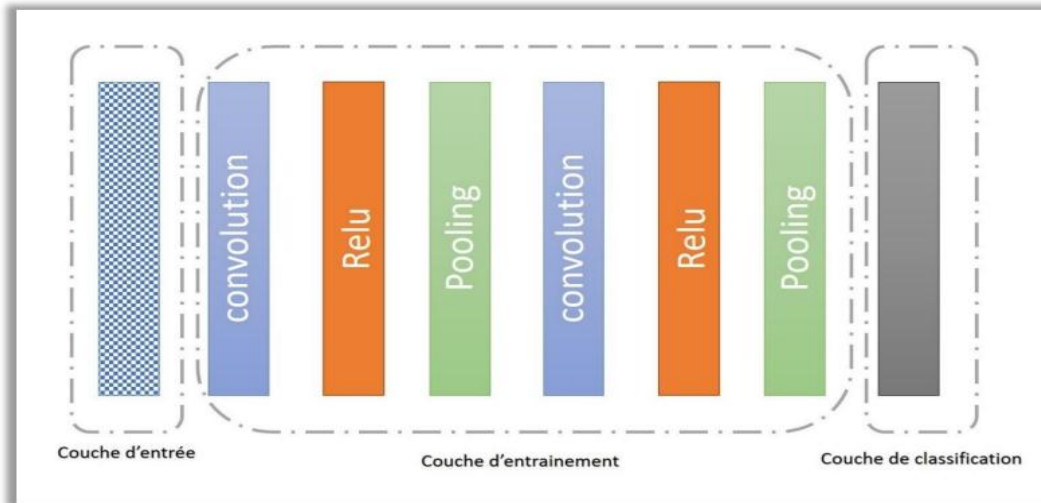


FIGURE II. 3: RESEAU DE NEURONES AVEC DE NOMBREUSES COUCHES CONVOLUTIVES[29].

5.1.1 Types des couches

5.1.2 Couche de convolution :

La convolution est la première couche à extraire des entités d'une image d'entrée. La convolution préserve la relation entre les pixels en apprenant les caractéristiques de l'image à l'aide de petits carrés de données d'entrée. Il s'agit d'une opération mathématique qui prend deux entrées telles qu'une matrice d'image et un filtre ou un noyau [30]. « La Figure II.5 », monte une opération simple d'un filtre pour une étape de convolution.

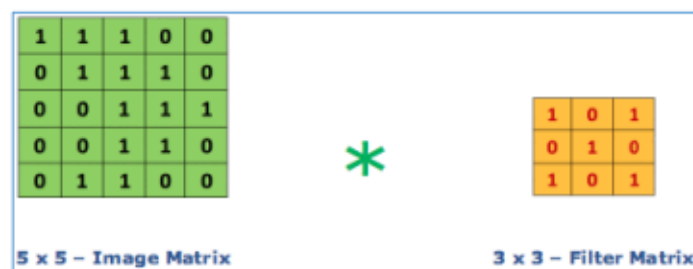


FIGURE II. 4: EXEMPLE EXPLICATIVE SUR L'OPERATION DE CONVOLUTION [30].

5.1.3 Couche de pooling :

La couche pooling généralement placée entre deux couches de convolution, le pooling est un processus de discrétisation à base d'échantillon. L'objectif est à en-bas-de-promotion une représentation de contribution (l'image, la matrice de production de cacher-couche, etc.), en réduisant sa dimensionnalité et en tenant compte des hypothèses à être rendues des caractéristiques contenues dans les sous-régions regroupées. Il existe différents types de pooling : (1) Pooling moyen qui prend la moyenne de tous les pixels de la sélection « Figure II.5». (a), (2) Pooling maximal qui prend le pixel qui a la valeur maximale entre tous les pixels de la sélection. Voir « Figure II.5 (b) ».

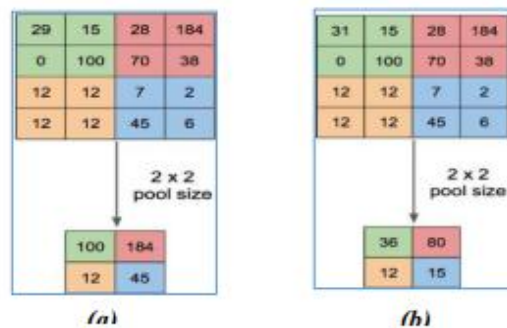


FIGURE II. 5: (A) POOLING MOYNE, (B) POOLING MAXIMAL [30].

5.1.4 Couche fully-connected :

La couche entièrement connectée est similaire au réseau entièrement connecté dans les modèles conventionnels. La sortie de la première phase (comprenant la convolution et la mise en commun répétitive) est introduite dans la couche entièrement connectée, et le produit scalaire du vecteur de poids et du vecteur d'entrée est calculé afin d'obtenir la sortie finale [30].




FIGURE II. 6: COUCHE FULLY-CONNECTED [30].

5.2 Réseau de neurones récurrent (Récurrent Neural Network (RNN)) :

Les Réseaux Neuronaux Récurrents (RNN) sont une variante très importante de réseaux neuronaux lourdement utilisés dans le traitement de langue naturelle. Ils sont appelés récurrents car ils effectuent la même tâche pour chaque élément d'une séquence, la sortie dépendant des calculs précédents. Une autre façon de penser aux RNN est qu'ils ont une « mémoire » qui capture des informations sur ce qui a été calculé jusqu'à présent. En théorie, les RNN peuvent utiliser des informations dans des séquences arbitrairement longues, mais en pratique, ils se limitent à ne regarder que quelques étapes en arrière. Les RNNs sont une classe de réseaux de neurones qui permettent aux prédictions antérieures d'être utilisées comme entrées, par le biais d'états cachés. Ils sont de la forme montrée dans la « Figure II.7 » [22].

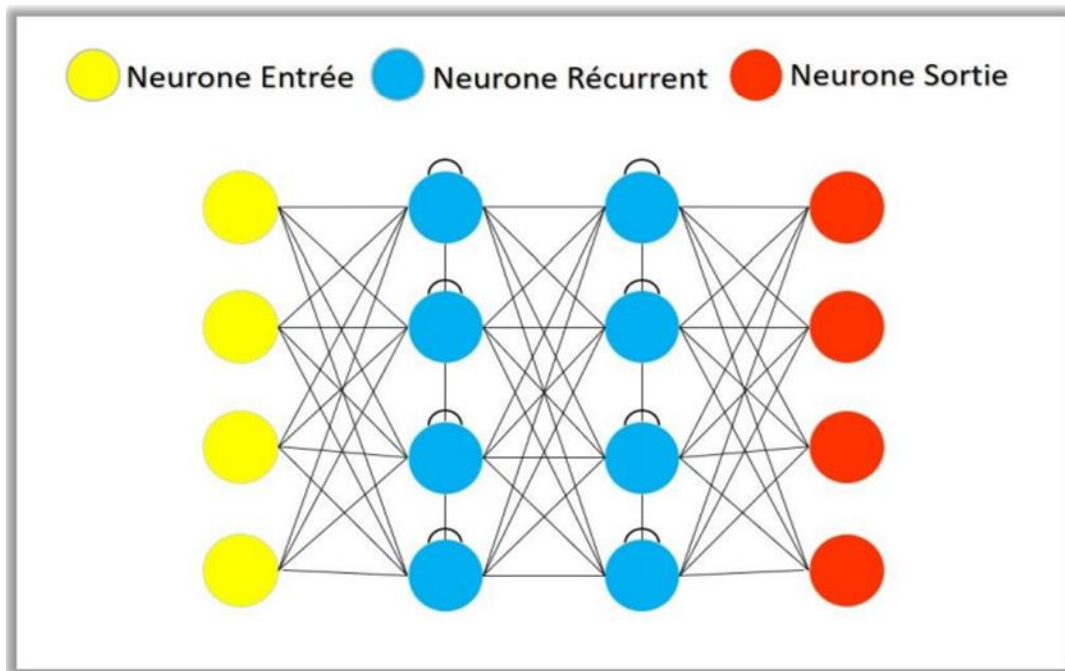


FIGURE II. 7: ARCHITECTURE DE RNN [22].

5.3 Long Short-Term Memory (LSTM):

Ce sont un type spécial de RNN, capable d'apprendre les dépendances à long terme. Ils ont été introduits par (Hochreiter et Schmidhuber, 1997), et ont été affinés et popularisés par de nombreuses personnes dans les travaux suivants. Ils fonctionnent extrêmement bien sur une

grande variété de problèmes et sont maintenant largement utilisés (Hochreiter et Schmidhuber, 1997) Les LSTM sont explicitement conçus pour éviter le problème de dépendance à long terme. Se souvenir des informations pendant de longues périodes est pratiquement leur comportement par défaut, pas quelque chose qu'ils ont du mal à apprendre ! Tous les réseaux de neurones récurrents ont la forme d'une chaîne de modules répétitifs de réseau de neurones. Dans les RNN standard, ce module répétitif aura une structure très simple, telle qu'une seule couche de tanh.




FIGURE II. 8: ARCHITECTURE DE RNN [22].

Les LSTM ont également une structure en chaîne, mais le module répétitif à une structure différente. Au lieu d'avoir une seule couche de réseau neuronal, il y en a quatre, interagissant d'une manière très spéciale.

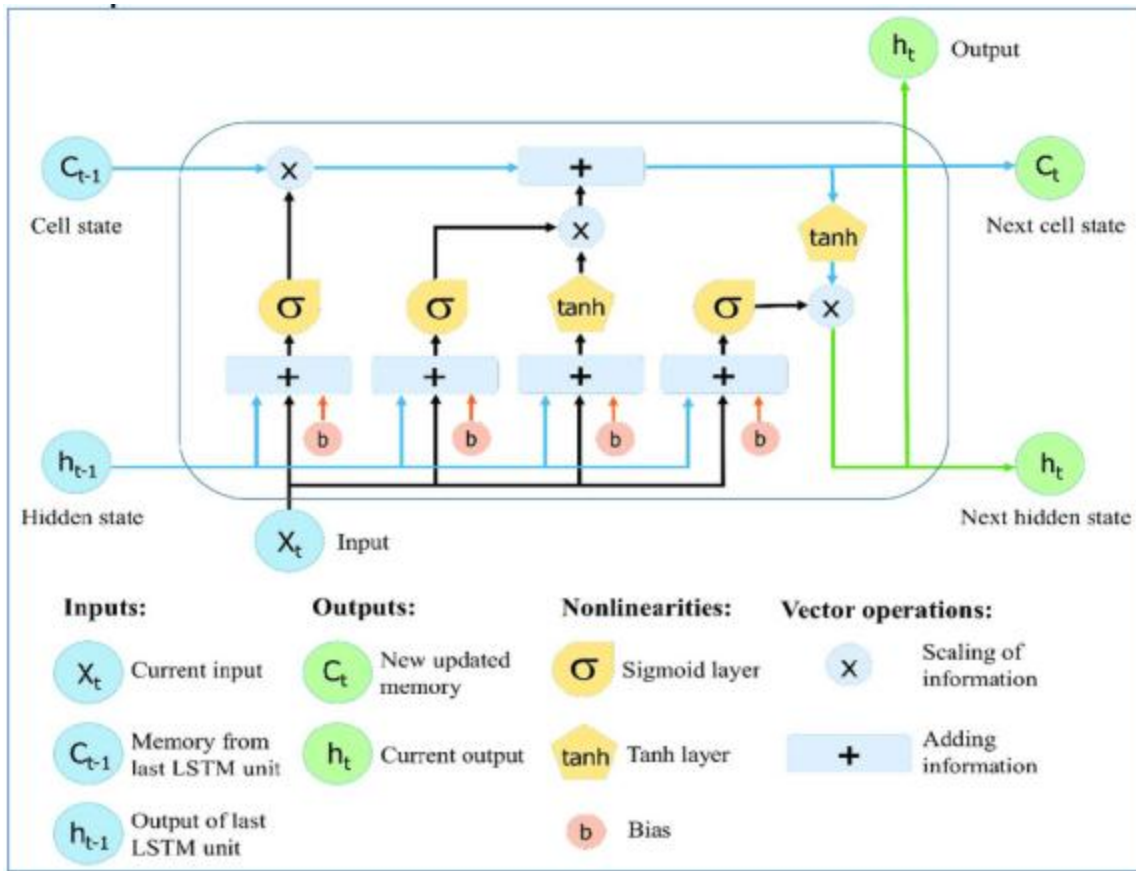


FIGURE II. 9: LE MODULE REPETITIF DANS UN LSTM [22].

Un réseau LSTM typique est composé de blocs de mémoire appelés cellules. Deux états sont en cours transféré à la cellule suivante, l'état de la cellule et l'état caché. L'état cellulaire est la chaîne principale de flux de données, qui permet aux données de circuler en avant essentiellement inchangées. Cependant, certaines transformations linéaires peuvent se produire. Les données peuvent être ajoutées ou supprimées de l'état de la cellule via des portes sigmoïdes. Une porte est similaire à une couche ou à une série d'opérations matricielles, qui contiennent différents poids individuels. Les LSTM sont conçus pour éviter le problème de dépendance à long terme car ils utilisent des portes pour contrôler le processus de mémorisation.

La première étape de la construction d'un réseau LSTM consiste à identifier les informations qui ne sont pas requises et qui seront manquées de la cellule à cette étape. Ce processus d'identification et d'exclusion de données est décidé par la fonction sigmoïde, qui prend la sortie de la dernière unité LSTM (h_{t-1}) au temps $t - 1$ et l'entrée courante X_t au temps t . De plus, la fonction sigmoïde détermine quelle partie de l'ancienne sortie doit être éliminée. Cette porte est

appelée la porte de l'oubli (ou ft); où ft est un vecteur avec des valeurs allant de 0 à 1, correspondant à chaque nombre dans l'état de cellule :

$$C_{t-1} \cdot ft = \sigma(W_f [h_{t-1}, X_t] + b_f) \quad (1)$$

Figure 1.9: Le module répétitif dans un LSTM contient quatre couches interactives (Hochreiter & Schmidhuber, 1997). Chapitre I : état de l'art 13 Ici, σ est la fonction sigmoïde, et W_f et b_f sont les matrices de poids et le biais, respectivement, la porte du oubliez.

L'étape suivante consiste à décider et à stocker les informations de la nouvelle entrée X_t dans l'état de cellule ainsi qu'à mettre à jour l'état de cellule. Cette étape contient deux parties, la couche sigmoïde et la seconde la couche \tanh . Tout d'abord, la couche sigmoïde décide si les nouvelles informations doivent être mises à jour ou ignorées (0 ou 1), et deuxièmement, la fonction \tanh donne du poids aux valeurs qui sont passées, en décidant de leur niveau d'importance (-1 à 1).

Les deux valeurs sont multipliées pour mettre à jour le nouvel état de cellule. Cette nouvelle mémoire est ensuite ajoutée à l'ancienne mémoire C_{t-1} résultant en

$$C_t \cdot it = \sigma(W_i [h_{t-1}, X_t] + b_i) \quad (2)$$

$$N_t = \tanh(W_n [h_{t-1}, X_t] + b_n) \quad (3)$$

$$C_t = C_{t-1} \cdot ft + N_t \cdot it \quad (4)$$

Ici, C_{t-1} et C_t sont les états de cellule au temps $t-1$ et t , tandis que W et b sont les matrices de poids et le biais, respectivement, de l'état de la cellule.

Dans la dernière étape, les valeurs de sortie ht sont basées sur l'état de la cellule de sortie O_t mais il s'agit d'une version filtrée. Tout d'abord, une couche sigmoïde décide quelles parties de l'état de la cellule parviennent à la sortie. Ensuite, la sortie de la porte sigmoïde O_t est multipliée par les nouvelles valeurs créées par la couche \tanh à partir de l'état de la cellule C_t , avec une valeur comprise entre -1 et 1 .

$$O_t = \sigma(W_o [h_{t-1}, X_t] + b_o) \quad (5)$$

$$h_t = O_t \cdot \tanh(C_t) \quad (6)$$

Ici, W_o et b_o sont les matrices de poids et le biais, respectivement, de la porte de sortie [22].

6 La différence entre LSTM , CNN et RNN :

	CNN	RNN	LSTM
Bases	L'un des types les plus populaires des réseaux de neurones.	Le plus avancé et le plus complexe de réseau neuronal.	C'est l'un des meilleurs types de réseaux de neurones.
Type de données	S'appuie sur les données d'image.	Formé avec des données de séquence.	Nourrissez-vous de données tabulaires et textuelles.
Complexité	Considéré comme plus puissant que les deux autres.	Moins de fonctionnalités que CNN mais puissant grâce à son auto-apprentissage & potentiel de mémoire.	Simple contrairement aux deux autres modèles.
Caractéristique louable	Précision dans la reconnaissance des images.	Mémoire auto-apprentissage. et	Capacité à travailler avec des connaissances imparfaites et haut degré de tolérance aux pannes.

TABLEAU II. 1: LA DIFFERENCE ENTRE LSTM, CNN ET RNN.

7 Conclusion :

Dans ce chapitre, nous avons présenté l'apprentissage automatique et l'apprentissage profond. Nous avons d'abord commencé par la description de l'apprentissage automatique et ses différentes architectures proposées. Ensuite, nous avons passé à la description de l'apprentissage profond « Deep Learning » et ses différentes architectures. A la fin, une comparaison entre les différentes méthodes de l'apprentissage profond (CNN, RNN et LSTM).

Le prochain chapitre, sera consacré à la présentation détaillée de notre approche proposée, qui a pour rôle de la classification des signaux EEG.

CHAPITRE III :

Approche proposée

et résultats

1 Introduction :

Le système de classification des signaux électroencéphalographiques semble être assez simple dans son principe mais un certain nombre de problèmes doit être résolu, afin d'aboutir à des résultats satisfaisants.

Dans ce chapitre, nous allons tout d'abord présenter l'architecture proposée et nous allons expliquer son fonctionnement. Ensuite, nous allons présenter aussi la mise en œuvre de notre application en utilisant le langage Python. De même, il présente les résultats de l'implémentation de cette méthode afin d'évaluer les performances du système.

2 Méthode proposée :

Un système de classification des crises épileptiques est une chaîne de traitement temps réel de l'activité cérébrale. (Figure III.1)

Les signaux enregistrés par le dispositif d'acquisition subissent plusieurs phases de traitements numériques: la phase de prétraitement permet d'améliorer la qualité du signal, la phase de la division les données en apprentissage et en test, et la phase de classification permet de distinguer la classe du signal analysé afin de générer un rapport qui indique les sujets avec crise et sans crise.

L'objectif de la nouvelle approche proposée est de détecter et classer automatiquement les crises épileptiques, et garantir le taux de la précision et l'accuracy le plus élevé possible.

Le schéma fonctionnel de l'approche proposée est illustré dans la figure III.1.

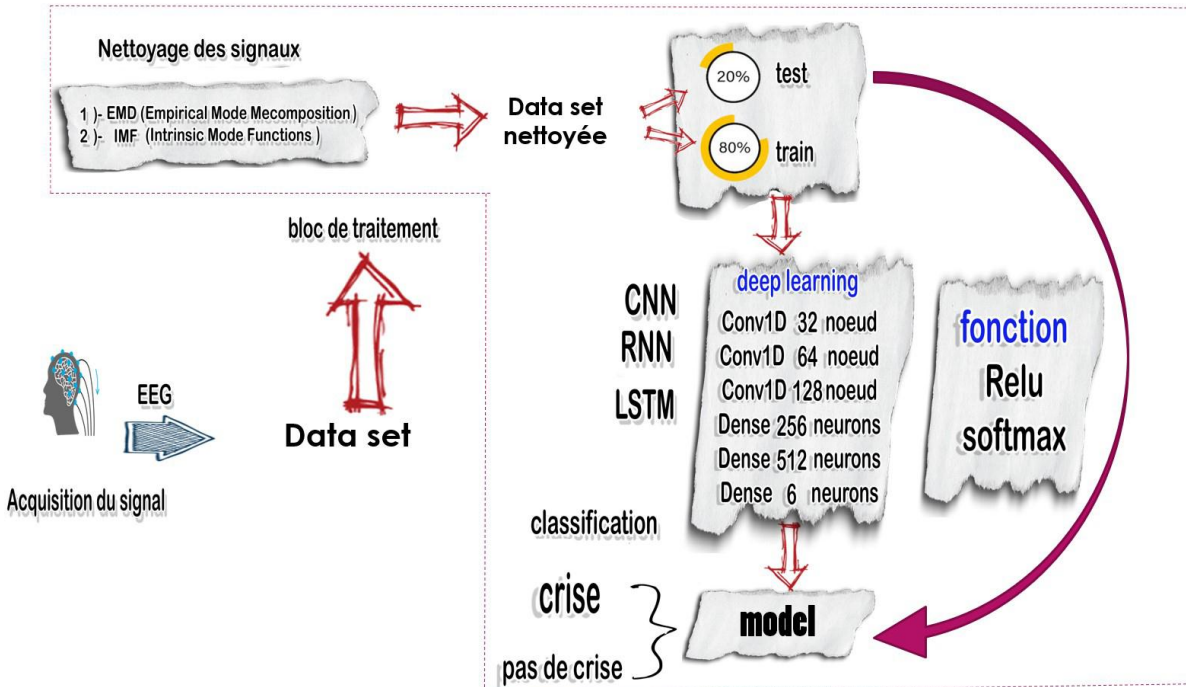


FIGURE III. 1: SCHEMA DE PRINCIPE DE LA METHODE PROPOSEE

2.1 Acquisition des données :

Dans notre travail nous avons utilisé des données EEG réelles. Une base de données médicale qui a été réalisée dans un centre d'épilepsie à Bonn en Allemagne (Clinic and Polyclinic for Epileptology at the University Hospital Bonn) par Qiuyi Wu et Ernest Fokoue 2017.

L'ensemble de données original de la référence se compose de 5 dossiers différents, chacun avec 100 fichiers, chaque fichier représentant un seul sujet/personne. Chaque fichier est un enregistrement de l'activité cérébrale pendant 23,6 secondes. La série chronologique correspondante est échantillonnée en 4097 points de données. Chaque point de données est la valeur de l'enregistrement EEG à un moment différent. Un total de 500 individus avec chacun 4097 points de données pendant 23,5 secondes. Divisé et mélangé tous les 4097 points de données en 23 morceaux, chaque morceau contient 178 points de données pendant 1 seconde, et chaque point de données est la valeur de l'enregistrement EEG à un moment différent. Un total de 11500 informations (ligne) (23 x 500), chaque information contient 178 points de données pour 1 seconde (colonne). Lien de la Base de données :

<https://archive.ics.uci.edu/ml/datasets/Epileptic+seizure+recognition>

2.2 Bloc de traitement :

Après l'étape de l'acquisition numérique qui permet de transformer le phénomène neurophysiologique en signaux EEG. Les électrodes placées sur le cuir chevelu détectent les activités électrochimiques de milliers de neurones ensuite ces signaux seront filtrés, amplifiés et convertis en données numériques et enfin envoyés à l'ordinateur. Le bloc de traitement composé de trois étapes est proposé :

2.2.1 Prétraitement :

Le prétraitement améliore la qualité du signal cérébral par l'élimination du bruit et les artefacts dus aux mouvements du corps. Cette étape permet de ne conserver que les signaux pertinents les plus représentatifs de l'activité cérébrale cherchée. En plus, elle veille à ce que le système ne soit pas contrôlé par des signaux de nature artéfactuelle et non cérébrale.

L'EMD est utilisé pour analyser et traiter les signaux EEG.

❖ Décomposition en mode empirique (EMD) :

L'EMD a été proposé par Huang et al. [33] comme une nouvelle approche pour l'analyse des signaux non-stationnaires. Elle permet d'évaluer les fréquences et les amplitudes des séries temporelles complexes tout en gardant le domaine temporel du signal. Cette méthode décompose le signal original en un nombre fini de fonctions modèles intrinsèques, qui sont des composantes oscillatoires à différentes échelles, et un résidu, qui est une fonction monotone ou une fonction non oscillante (ne contient pas un cycle complet), qui traduit la tendance générale du signal. L'EMD est basé sur les hypothèses suivantes [34] :

- Tout signal se compose de différents modes intrinsèques d'oscillations ;
- Chaque mode linéaire ou non linéaire possède le même nombre des extrémums et de passages par zéro.
- Il n'y a qu'une seule extrémité entre deux passages par zéro successifs ;
- Chaque mode doit être indépendant des autres.

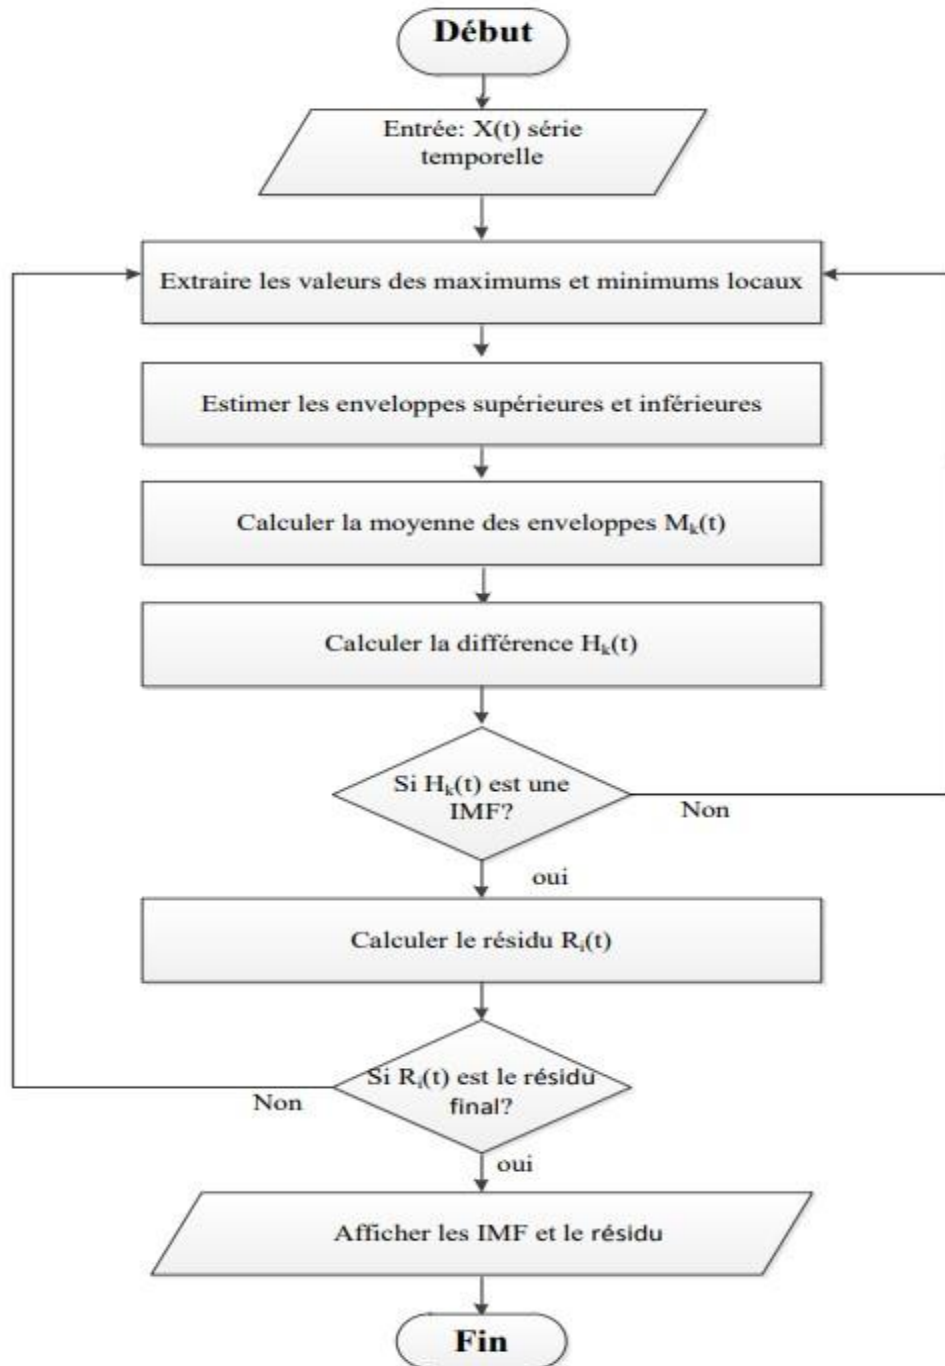


FIGURE III. 2: ORGANIGRAMME DE L'EMD.

2.2.2 La division des données en apprentissage et test :

Les données EEG doivent être divisées en deux groupes :

- **Le premier groupe :** 80% des données (apprentissage) qui assurera l'apprentissage du classifieur.
- **Le deuxième groupe :** 20% des données (test) sera traité afin de détecter automatiquement les classes et de calculer les performances du système.

2.2.3 Classification :

Les systèmes de classification des crises épileptiques utilisent des algorithmes de classifications pour distinguer entre les différentes classes. Le classifieur va apprendre dans une première étape à séparer les différentes classes en utilisant les informations contenues dans l'espace des caractéristiques. Puis, dans une deuxième étape il va désigner les classes des nouvelles données en se basant sur les règles conçues durant l'apprentissage. Les méthodes de classification les plus utilisées dans le deep learning est le CNN, RNN et LSTM.

3 Présentation des outils de développement :

3.1 Matériel :

Le matériel réalisé est PC personnel Macbook pro avec un 16GB capacité mémoire, CPU i7-4770HQ cadencé à 2.20 GHz, tournant sous Windows 10 64 bits.

3.2 Définition du langage Python en informatique :

Python est le langage de programmation open source le plus employé par les informaticiens. Ce langage s'est propulsé en tête de la gestion d'infrastructure, d'analyse de données ou dans le domaine du développement de logiciels. En effet, parmi ses qualités, Python permet notamment aux développeurs de se concentrer sur ce qu'ils font plutôt que sur la manière dont ils le font. Il a libéré les développeurs des contraintes de formes qui occupaient leur temps avec les langages plus anciens. Ainsi, développer du code avec Python est plus rapide qu'avec d'autres langages. [35]



FIGURE III. 3: LOGO PYTHON [35].

3.2.1 Définition de l'anaconda :

Anaconda est une distribution open source pour python et R. Elle est utilisée pour la science des données, l'apprentissage automatique, l'apprentissage en profondeur, etc. Avec la disponibilité de plus de 300 bibliothèques pour la science des données, il devient assez optimal pour tout programmeur de travailler sur anaconda pour la science des données.

Anaconda aide à simplifier la gestion et le déploiement des packages. Anaconda est livré avec une grande variété d'outils pour collecter facilement des données provenant de diverses sources à l'aide de divers algorithmes d'apprentissage automatique et d'IA. Il aide à obtenir une configuration d'environnement facilement gérable qui peut déployer n'importe quel projet en un seul clic.



FIGURE III. 4: LOGO ANACONDA [35].

3.2.2. Définition Jupyter :

L'application Jupyter Notebook est une application serveur-client qui permet de modifier et d'exécuter des documents de bloc-notes via un navigateur Web. L'application Jupyter Notebook peut être exécutée sur un bureau local ne nécessitant aucun accès à Internet (comme décrit dans ce document) ou peut être installée sur un serveur distant et accessible via Internet.

En plus d'afficher/modifier/exécuter des documents de bloc-notes, l'application Jupyter Notebook dispose d'un "tableau de bord" (tableau de bord de bloc-notes), un "panneau de configuration"

affichant les fichiers locaux et permettant d'ouvrir des documents de bloc-notes ou d'arrêter leurs noyaux.



FIGURE III. 5: LOGO JUPYTER [35].

4 Les interfaces d'implémentation :

Dans cette section, nous présentons les interfaces principales du code d'implémentation de notre approche proposée.

4.1 Chargement des données du Dataset :

Pour commencer, il faudra lire et charger les données contenues dans le fichier csv. Python propose via sa librairie Pandas des classes et fonctions pour lire divers formats de fichiers, la fonction `read_csv` est une fonction pandas importante pour lire les fichiers csv et effectuer des opérations dessus.

```
Entrée [1]: data = "data.csv"
import pandas as pd
df = pd.read_csv(data, header=0, index_col=0)

Entrée [2]: print(df.head())
print(df.info())
```

	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	...	X170	X171	\
Unnamed											...			
X21.V1.791	135	190	229	223	192	125	55	-9	-33	-38	...	-17	-15	
X15.V1.924	386	382	356	331	320	315	307	272	244	232	...	164	150	
X8.V1.1	-32	-39	-47	-37	-32	-36	-57	-73	-85	-94	...	57	64	
X16.V1.60	-105	-101	-96	-92	-89	-95	-102	-100	-87	-79	...	-82	-81	
X20.V1.54	-9	-65	-98	-102	-78	-48	-16	0	-21	-59	...	4	2	

	X172	X173	X174	X175	X176	X177	X178	y
Unnamed								
X21.V1.791	-31	-77	-103	-127	-116	-83	-51	4
X15.V1.924	146	152	157	156	154	143	129	1
X8.V1.1	48	19	-12	-30	-35	-35	-36	5
X16.V1.60	-80	-77	-85	-77	-72	-69	-65	5
X20.V1.54	-12	-32	-41	-65	-83	-89	-73	5

```
[5 rows x 179 columns]
<class 'pandas.core.frame.DataFrame'>
Index: 11500 entries, X21.V1.791 to X16.V1.210
Columns: 179 entries, X1 to y
dtypes: int64(179)
memory usage: 15.8+ MB
None
```

FIGURE III. 6: CHARGEMENT DES DONNEES.

4.2 Résultats et discussions

4.2.1 Résultats de CNN

- **Apprentissage et test de CNN :**

La figure suivante présente l'entraînement des données (train et test) et les résultats obtenue basées sur le réseau de neurones à convolution (CNN).

```
Entrée [136]: cnn_model_history = cnn_model.fit(X_train, y_train,
                                                epochs=10, batch_size = 10,
                                                validation_data = (X_test, y_test))

y: 0.8783
Epoch 5/10
1610/1610 [=====] - 36s 22ms/step - loss: 0.2183 - accuracy: 0.9234 - val_loss: 0.3116 - val_accurac
y: 0.8912
Epoch 6/10
1610/1610 [=====] - 36s 22ms/step - loss: 0.1669 - accuracy: 0.9439 - val_loss: 0.3325 - val_accurac
y: 0.9012
Epoch 7/10
1610/1610 [=====] - 41s 26ms/step - loss: 0.1300 - accuracy: 0.9576 - val_loss: 0.3590 - val_accurac
y: 0.8890
Epoch 8/10
1610/1610 [=====] - 54s 34ms/step - loss: 0.1114 - accuracy: 0.9632 - val_loss: 0.3263 - val_accurac
y: 0.9170
Epoch 9/10
1610/1610 [=====] - 43s 27ms/step - loss: 0.1238 - accuracy: 0.9616 - val_loss: 0.3638 - val_accurac
y: 0.9088
Epoch 10/10
1610/1610 [=====] - 41s 26ms/step - loss: 0.0851 - accuracy: 0.9739 - val_loss: 0.4683 - val_accurac
y: 0.9020
```

FIGURE III. 7: RESULTATS CNN

Les figures suivantes présents les graphes de la fonction accuracy et la fonction loss de CNN mentionnées ci-dessus, respectivement (Voir Figure III8. , Figure III9.).

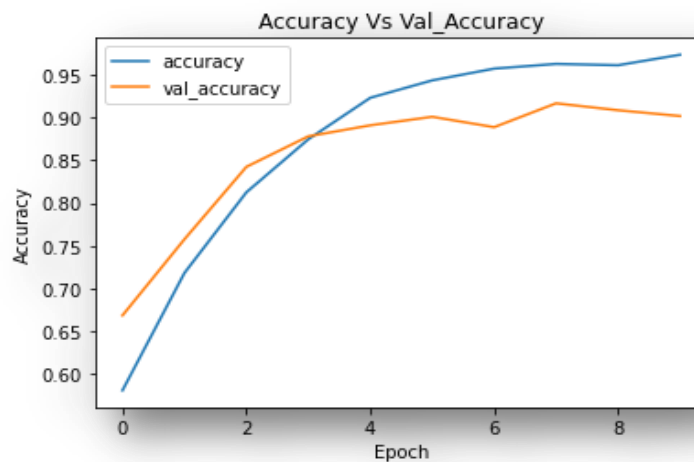


FIGURE III. 8: ACCURACY CNN

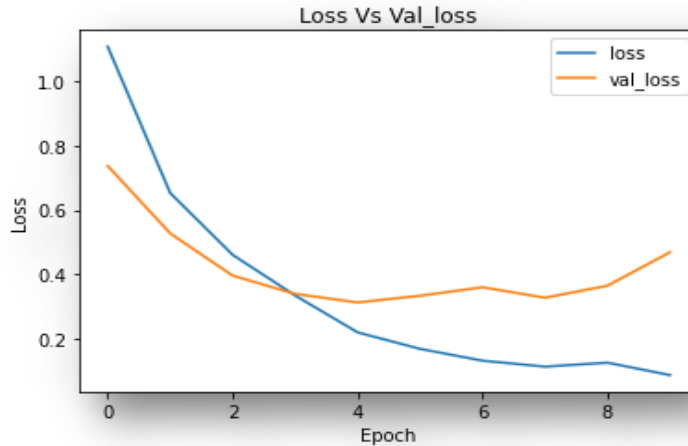


FIGURE III. 9: LOSS CNN

❖ Analyses des résultats (CNN) :

Comme nous pouvons le constater clairement, notre réseau CNN proposé a réussi notre objectif qui est la classification des crises de notre base de données, avec une précision (accuracy) très satisfaisante 97% et une perte très réduite.

Après avoir obtenu les résultats de CNN, nous avons remarqué que les résultats étaient proches de la précision et que les résultats étaient faibles en termes de perte d'informations.

4.2.2 Résultats de RNN:

- **Apprentissage et test (RNN) :**

La figure suivante présente l'entraînement des données (train et test) et les résultats obtenue basées sur le réseau de neurones récurrents (RNN).

```
Entrée [11]: model.fit(trainX,trainY, epochs=100, batch_size=16, verbose=2)
Epoch 91/100
50/50 - 0s - loss: 1.7204 - 280ms/epoch - 6ms/step
Epoch 92/100
50/50 - 0s - loss: 1.7204 - 280ms/epoch - 6ms/step
Epoch 93/100
50/50 - 0s - loss: 1.7204 - 312ms/epoch - 6ms/step
Epoch 94/100
50/50 - 0s - loss: 1.7204 - 312ms/epoch - 6ms/step
Epoch 95/100
50/50 - 0s - loss: 1.7204 - 288ms/epoch - 6ms/step
Epoch 96/100
50/50 - 0s - loss: 1.7204 - 272ms/epoch - 5ms/step
Epoch 97/100
50/50 - 0s - loss: 1.7204 - 272ms/epoch - 5ms/step
Epoch 98/100
50/50 - 0s - loss: 1.7204 - 272ms/epoch - 5ms/step
Epoch 99/100
50/50 - 0s - loss: 1.7204 - 280ms/epoch - 6ms/step
Epoch 100/100
50/50 - 0s - loss: 1.7204 - 280ms/epoch - 6ms/step
```

FIGURE III. 10: RESULTATS RNN

❖ Analyses des résultats (RNN) :

Après avoir obtenu les résultats du RNN comme le montre la figure III.10, nous avons remarqué que les résultats de loss sont élevés (1.7204) alors le RNN ne nous fournit pas de résultats idéals par rapport à notre base de données.

4.3 Résultats (LSTM) :

- **Apprentissage et test (LSTM) :**

La figure suivante présente l'entraînement des données (train et test) et les résultats obtenue basées sur le réseau de neurones récurrents (LSTM).

```

Entrée [21]: history = model.fit(x_train, y_train, epochs = 100, validation_data= (x_test, y_test))
score, acc = model.evaluate(x_test, y_test)

Epoch 95/100
288/288 [=====] - 1s 3ms/step - loss: 0.3618 - accuracy: 0.8701 - val_loss: 0.3502 - val_accuracy:
0.8739
Epoch 96/100
288/288 [=====] - 1s 3ms/step - loss: 0.3478 - accuracy: 0.8775 - val_loss: 0.3512 - val_accuracy:
0.8765
Epoch 97/100
288/288 [=====] - 1s 3ms/step - loss: 0.3579 - accuracy: 0.8729 - val_loss: 0.3502 - val_accuracy:
0.8730
Epoch 98/100
288/288 [=====] - 1s 3ms/step - loss: 0.3575 - accuracy: 0.8740 - val_loss: 0.3409 - val_accuracy:
0.8774
Epoch 99/100
288/288 [=====] - 1s 4ms/step - loss: 0.3593 - accuracy: 0.8736 - val_loss: 0.3394 - val_accuracy:
0.8804
Epoch 100/100
288/288 [=====] - 1s 3ms/step - loss: 0.3560 - accuracy: 0.8758 - val_loss: 0.3453 - val_accuracy:
0.8735
72/72 [=====] - 0s 2ms/step - loss: 0.3453 - accuracy: 0.8735

Entrée [22]: from sklearn.metrics import accuracy_score
pred = model.predict(x_test)
predict_classes = np.argmax(pred,axis=1)
expected_classes = np.argmax(y_test,axis=1)
print(expected_classes.shape)
print(predict_classes.shape)
correct = accuracy_score(expected_classes,predict_classes)
print(f"Training Accuracy: {correct}")

72/72 [=====] - 1s 1ms/step
(2300,)
(2300,)
Training Accuracy: 0.8734782608695653

```

FIGURE III. 11: RESULTATS LSTM

❖ Analyses des résultats (LSTM) :

Après avoir obtenu les résultats du LSTM comme le montre la figure III.13, nous avons remarqué que le LSTM nous a permis d'obtenir plus de détails sur les enregistrements EEG, ce qui nous a permis de comprendre plus et à un moment précis et moins qu'avant, comme le montre la figure III.11.

En ce qui concerne les résultats que nous avons obtenus, le taux d'accuracy était supérieur à 87 % et le taux de perte était d'environ 34 % de celui-ci. Nous concluons que les résultats étaient satisfaisants.

5 Evaluation de la méthode proposée

Les deux classes recherchées sont l'état normal (sans crise) et l'état de crise. La séparation entre les classes a été effectuée par les méthodes de classification de l'apprentissage profond (deep learning).

Les résultats trouvés montrent le taux des trois méthodes de réseaux de neurones, le taux de précision de CNN a atteint **97 %**, le taux de précision de LSTM a atteint 87 % et le RNN ne nous a pas fourni suffisamment d'informations pour comparer. La classification avec le réseau de neurones à convolution (CNN) est considérée comme satisfaisante.

Généralement cette approche de classification des crises épileptiques est considérée comme très précise dans la séparation entre les différents groupes ou classes.

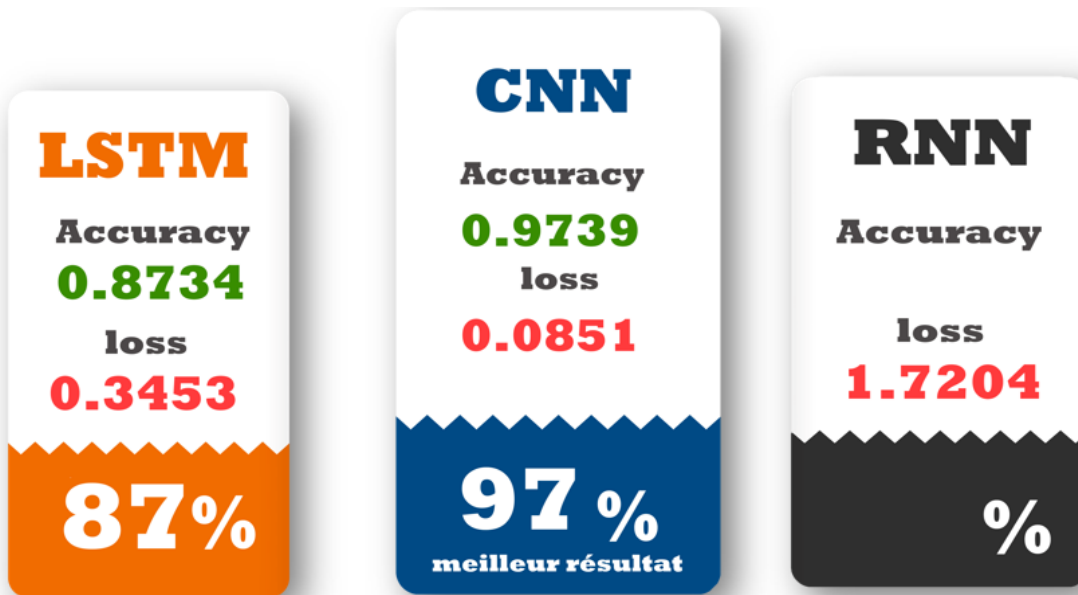


FIGURE III. 11: TAUX DE PRECISION DES (CNN, RNN ET LSTM).

Le tableau III.1 présente une comparaison entre les résultats de la méthode proposée et les résultats de certaines méthodes proposées dans la littérature par d'autres groupes de recherche utilisant la même base de données.

TABLEAU III. 1: EVALUATION DES METHODES

Auteurs	accuracy
SGD	81.92%
Naive bayes	95.73%
J48	94.82%
Approche proposée	97.39%

Il est clair que le taux d'accuracy trouvées atteint des valeurs supérieures à la majorité des travaux. Ces résultats prouvent l'efficacité de la méthode proposée. [36]

6 Conclusion :

Ce chapitre décrit notre approche proposée, cette dernière est une approche pour la classification des crises épileptiques basée sur l'apprentissage en profondeur « Deep Learning ». On a étudié les trois modèles réseaux de neurones (CNN, RNN et LSTM) tout en faisant la comparaison entre eux. Nous avons aussi présenté les différents outils et langages que nous avons utilisés pour implémenter notre modèle. A la fin nous avons présenté notre application en donnant quelques captures d'écran qui expliquent le déroulement et le fonctionnement de notre travail, ainsi que les résultats obtenus.

Conclusion et perspectives :

Le premier souci dans le domaine de classification des crises épileptiques est de concevoir des systèmes capables de prédire l'existence des crises épileptiques et de concourir les résultats trouvés par une inspection visuelle du neurologue. De ce fait, le premier objectif des chercheurs dans ce domaine devient l'amélioration du taux de précision du système.

Dans ce projet de fin d'étude, nous nous sommes intéressés à développer une méthode de traitement du signal EEG capable d'améliorer les performances des systèmes présentes dans la littérature. Nous avons fourni pour la première fois les diverses connaissances nécessaires à la compréhension de la neurophysiologie fonctionnelle et les techniques de détection et de mesure des activités cérébrales pour diagnostiquer la maladie épileptique. Ensuite nous avons présenté la maladie de l'épilepsie en expliquant les différents aspects nécessaires pour comprendre cette thématique.

Dans une deuxième étape, nous avons donné un état de l'art sur le deep learning et ces méthodes de classification les plus efficaces et les plus utilisées. La méthode de classification des crises basée sur l'apprentissage profond est considérée comme l'une des méthodes les plus puissantes et plus efficaces.

Dans la dernière étape, nous avons appliqué les méthodes de réseaux de neurones (CNN, RNN et LSTM). Nous avons testé ce système avec des données EEG réelles de dataset. Le but de cette approche est de vérifier l'efficacité de ces méthodes en termes de précision, accuracy et a prouvé son efficacité par rapport aux méthodes de la littérature.

En perspectives nous envisageons de mener des recherches pour :

- L'amélioration de la méthode proposée par l'utilisation d'une méthode plus efficace pour la localisation des zones épileptiques.
- La possibilité d'utiliser un dataset qui contient des milliers de données réelles pour avoir de meilleurs résultats.

Références :

- [1] A. Sabrina “Analyse et Diagnostic des Données Médicales Interprétation des Données issues de l’eeg”, Thèse de Doctorat, Université IBN Khaldoun – Tiaret (2019)
- [2] R. Romo-Vazquez, “Contribution à la détection et à l’analyse des signaux EEG épileptiques : débruitage et séparation de sources”, Thèse de Doctorat de l’Institut National Polytechnique de Lorraine - INPL, Lorraine, France, (2010).
- [3] X. Artusi, “Interface Cerveau Machine avec adaptation automatique à l’utilisateur”, Thèse de Doctorat de l’École Centrale de Nantes, Nantes, France, (2012).
- M. Besserve, “Analyse de la dynamique neuronale pour les Interfaces Cerveau-Machines : un retour aux source”, Thèse de Doctorat de l’Ecole Doctorale Sciences et Technologies de l’Information, des Télécommunications et des Systèmes, Faculté des sciences d’Orsay, Université PARIS- SUD 11, Paris, France, (2007).
- [4] F. A. Azevedo, L. R. Carvalho, L. T. Grinberg, J. M. Farfel, R. E. Ferretti, R. E. Leite, W. Jacob Filho, R. Lent et S. Herculano-Houzel, “Equal numbers of neuronal and nonneuronal cells make the human brain an isometrically scaled-up primate brain”, journal of comparative neurology, pp. 513-532, (2009).
- [5] N. Rochelabarbe “Couplage de l’eeg et le la spectroscopie dans le proche infrarouge (NIRS) pour l’étude de la fonction et de la maturation cérébrale chez les nouveaux nés, en particulier prématurés”, Thèse de Doctorat, Université de Picardie Jules Verne, Amiens, (2007).
- [6] J. Fruitet “Interfaces Cerveau-Machines basées sur l’imagination de mouvements brefs : vers des boutons contrôlés par la pensée”, Thèse de Doctorat Université DE NICE - SOPHIA ANTIPOLIS ECOLE DOCTORALE STIC, (2013).
- [7] Briere, C., & Lopez, R. Introduction A l’électro-Encéphalographie. [Powerpoint Slides]. Retrieved From Faculté De Médecine Montpellier-Nîmes
- [8] Teplan, M. (2002). Fundamentals Of EEG Measurement. *Measurement Science Review*, 2(2), 1-11.
- [8] H. Kong Wanchai, Trans Cranial Technologies, “10/20 System Positioning Manual”,(2012).
- [9] J. Malmivuo et R. Plonsey, “Bioelectromagnetism: principles and applications of bioelectric and biomagnetic fields”, Oxford University Press, USA, (1995).
- [10] A. G. Correa, E. Laciár, H. D. Patiño et M. E. Valentinuzzi, “Artifact removal from EEG signals using adaptive filters in cascade”, 16th Argentine Bioengineering Congress and the 5th Conference of Clinical Engineering, pp. 1-10, (Decembre 2007).
- [11] P.J. Durka, H. Klekowicz, K.J. Blinowska, W. Szelenberger et SZ. Niemcewicz, “A simple system for detection of EEG artifacts in polysomnographic recordings”, IEEE Transactions on Biomedical engineering, Vol. 50, No. 4, pp. 526-528, (2003).
- [12] A. Choucha, A. Hellal, L. Mokrani et S. Arif, “New Approach to the Optimization of Power System Stabilizers: Genetic Algorithm with Dynamic Constraints”, Control and Intelligent Systems, Vol. 40, No. 3, pp. 129-143, (2012).
- [13]

Référence

- [14] L. Zoubek, "Automatic classification of human sleep recordings combining artifact identification and relevant features selection", Thèse de Doctorat de l'Université Joseph Fourier GRENOBLE, Grenoble, France, (2008).
- [15] R. A. Salido-Ruiz "Problèmes inverses contraints en EEG : applications aux potentiels absolus et à l'influence du signal de référence dans l'analyse de l'EEG", Thèse de Doctorat de l'École doctorale IAEM Lorraine, Université de Lorraine, Nancy, France, (2012).
- [16] J. Hofmanis, "Contribution to the cerebral forward model by depth electric stimulation and SEEG measurements : application in epilepsy", Thèse de Doctorat de l'École doctorale IAEM Lorraine, l'Université de Lorraine, Lorraine, France, (2013).
- [17] S. Baillet, L. Garnero, G. Marin et J.P. Hugonin, "Combined MEG and EEG source imaging by minimization of Mutual Information", IEEE Transactions on Biomedical Engineering, Vol. 46, pp. 522-534, (1999).
- [18] E.C. Leuthardt, G. Schalk, J.R. Wolpaw, J.G. Ojemann et D.W. Moran, "A brain computer interface using electrocorticographic signals in humans", Journal of Neural Engineering, Vol. 1, No. 2, pp. 63-71, (2004).
- [19] J. Fruitet "Interfaces Cerveau-Machines basées sur l'imagination de mouvements brefs : vers des boutons contrôlés par la pensée", Thèse de Doctorat Université DE NICE - SOPHIA ANTIPOLIS ECOLE DOCTORALE STIC, (2013).
- [20] C. Matthieu, "Analyse automatique des crises d'épilepsie du lobe temporal à partir des EEG de surface", Thèse de Doctorat de l'Institut National Polytechnique de Lorraine - INPL, Nancy, France, (2006)
- [21] L. N. Alonso et J.G. Gil, "Brain Computer Interfaces, a Review", Sensors- Open Access Journal, Vol. 12, pp. 1211-1279, (2012).
- [22] B. Braunschweig, "Intelligence artificielle - livre blanc", pp. 1-21, 2016.
- [23] L. Ali, "Comme Exigence Partielle De La Maîtrise En Mathématiques Et Informatique Appliquées", l'université Du Québec À Trois-Rivières, (Juin 2017)
- [24] <https://www.expert.ai/blog/machine-learning-definition/>
- [25] M. Zouinar, "Évolutions De l'Intelligence Artificielle : Quels Enjeux Pour l'activité Humaine Et La Relation Humain-Machine Au Travail ? ", Activités [En Ligne], 17-1 | 2020, Mis En Ligne Le (15 Avril 2020), Consulté Le 10 Décembre 2020. URL : <http://journals.openedition.org/activites/4941> ; DOI : <https://doi.org/10.4000/activites.4941>
- [26] J. Delua, SME, "IBM Analytics, Data Science/Machine Learning", (12 March 2021), 5 Min Read
- [27] <https://www.javatpoint.com/unsupervised-machine-learning>
- [28] Khan, A., Sohail, A., Zahoora, U., And Qureshi, A. S. (2020). A Survey of The Recent Architectures of Deep Convolutional Neural Networks. Artificial Intelligence Review, Pages 1-62.

Référence

- [29] Jarrett, K., Kavukcuoglu, K., Ranzato, M., And Lecun, Y. (2009). What Is the Best Multi-Stage Architecture for Object Recognition? In 2009 IEEE 12th International Conference on Computer Vision, Pages 2146–2153. IEEE.
- [30] Indolia, S., Goswami, A. K., Mishra, S., And Asopa, P. (2018). Conceptual Understanding of Convolutional Neural Network-A Deep Learning Approach. *Procedia Computer Science*, 132 :679–688.
- [31] Arulkumaran, K., Deisenroth, M. P., Brundage, M., And Bharath, A. A. (2017). A Brief Survey of Deep Reinforcement Learning. *Arxiv Preprint Arxiv* :1708.05866.
- [32] Mohamed Abd Elmoumen DJABALLAH, Système De Prédiction De La Consommation d'énergie Basé Deep Learning, Université De 8 Mai 1945 – Guelma - Faculté Des Mathématiques, d'Informatique Et Des Sciences De La Matière Département d'Informatique, P (9-11), 2021
- [33] F. Lotte, M. Congedo, A. Lécuyer, F. Lamarche Et B. Arnaldi, "A Review of Classification Algorithms For EEG-Based Brain–Computer Interfaces", *Journal of Neural Engineering*, IOP Publishing, Vol. 4, No. 2, Pp.1-24, (2007)
- [34] J. Yan Et L. Lu, "Improved Hilbert–Huang Transform Based Weak Signal Detection Methodology and Its Application on Incipient Fault Diagnosis and ECG Signal Analysis", *Signal Processing*, Vol. 98, Pp.74-87, (2014).
- [35] <https://www.journaldunet.fr/web-tech/dictionnaire-du-webmastering/1445304-python-definition-et-utilisation-de-ce-langage-informatique/>
- [36] Informatics In Medicine Unlocked, Classification Of Epileptic Seizure Dataset Using Different Machine Learning Algorithms, 2020