RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Université de Mohamed El-Bachir El-Ibrahimi - BBA

Faculté des Mathématiques et Informatiques

MÉMOIRE

Présenté en vue de l'obtention du diplôme

Master en Informatique

Spécialité : **I**ngénierie de l'**I**nformatique **D**écisionnelle

Thème

Classification des émotions à partir de signaux EEG à l'aide de techniques d'apprentissage profond

Présenté par :

- BELARBI Chaima
- KEDJOUTI Amel

Soutenu le : 10/06/2025, devant la commission d'examen suivante :

Dr. BENABID Sonia	Enseignant à l'unversité de BBA	Président
Dr. BOUTOHAMI Sara	Enseignant à l'unversité de BBA	Examinateur
Dr. BELAYADI Yahia	Enseignant à l'unversité de BBA	Encadrant
Pr. ATTIA Abdelouahab	Enseignant à l'unversité de BBA	Co-Encadrant

Promotion 2024 / 2025

Dédicace

Dieu merci

D'un coeur d'amour et de fierté, je dédie ce travail à mes deux bougies qui brûlent pour m'éclairer mon chemin, mon cher père KEDJOUTI Amar, l'homme à qui je dois ma réussite, et la plus chère au Monde ma mère KEDJOUTI Malika qu'était la confidente de mes secrets, Tu as sacrifié de nombreuses années de ta vie pour me soutenir, Vous êtes des parents formidables et exceptionnels.

À mes frères Yacine et Abdelnour, qui ont toujours été présents à mes côtés. Votre soutien constant et votre amour ont été précieux pour moi.

À mes adorables sœurs Wafa, Assia, Samra Je les remercier de l'amour qu'elles m'ont témoigné et des paroles d'encouragement au cours des années.

À mes neveux et mes nièces, que Dieu vous bénisse et vous protège.

À toute ma famille, qui m'a comblé d'amour et de vitalité.

À tous mes amies et collègues, je tiens à vous remercier. Je tiens tout particulièrement à remercier mes chères amies Chaima, Meriem, Chaima, Kaouther, Leila,

Je n'oublie pas de remercier tous les professeurs qui ont croisé ma route à tous les niveaux de mes études.

⋆ ***Amel*** ⋆

Dédicace

À Allah Tout-Puissant, source de force, de sagesse et de patience, qui m'a guidée tout au long de ce parcours.

À mes chers parents, pour leur amour inconditionnel, leurs sacrifices et leurs prières qui ont toujours été la lumière de mon chemin.

À mes frères et sœurs bien-aimés, pour leur soutien moral, leurs encouragements et leur présence constante à mes côtés.

À mon époux, pour sa compréhension, son appui indéfectible et sa foi en moi, même dans les moments les plus difficiles.

À mes amises fidèles, compagnons de route, pour leur gentillesse, leurs mots de réconfort et les souvenirs partagés.

Je vous dédie ce travail, fruit de persévérance et de passion.

⋆ ***CHAIMA***⋆

Remerciements

C’est avec un immense plaisir que je réserve ces quelques lignes en signe de gratitude et de reconnaissance à tous ceux qui ont contribué, de près ou de loin, à l’élaboration de ce travail.

Nous rendons grand merci à Dieu Tout-Puissant, qui nous a donné une grande volonté et suffisamment de connaissances pour faire cet humble travail.

À notre encadrant, **Pr. ATTIA Abdelouaheb**, pour sa compréhension, sa disponibilité, son aide et ses précieux conseils, qui nous ont été très utiles pour l’achèvement de ce projet.

Nos remerciements s’étendent à tous nos enseignants du département d’Informatique de l’Université BBA.

Enfin, merci à toutes les personnes qui ont contribué, de près ou de loin, à l’accomplissement de ce travail.

Résumé

Ces dernières années, la reconnaissance des émotions humaines à partir des signaux EEG a connu un essor considérable, notamment grâce aux avancées du Deep Learning. Contrairement aux méthodes traditionnelles reposant sur l'analyse des expressions faciales, les signaux EEG présentent une plus grande objectivité et une résistance accrue aux manipulations volontaires.

Dans le cadre de ce travail, nous proposons une approche de classification automatique des émotions à partir des signaux EEG, en exploitant les bases de données EEG Brainwave Dataset et eeg-dataset-emotions. Deux architectures d'apprentissage profond ont été implémentées : un réseau de neurones convolutif unidimensionnel (CNN 1D) et un réseau de type LSTM, dans le but d'extraire respectivement les caractéristiques spatiales et temporelles des signaux.

Les résultats expérimentaux obtenus démontrent que la combinaison de ces deux modèles permet d'améliorer significativement les performances de reconnaissance des états émotionnels.

Mots-clés : EEG, apprentissage profond (Deep Learning), CNN 1D, LSTM, classification des émotions, signaux cérébraux.

Abstract

In recent years, human emotion recognition from EEG signals has seen substantial progress, largely driven by advances in deep learning techniques. Unlike traditional methods based on facial expressions, EEG signals provide greater objectivity and robustness against voluntary manipulations. In this study, we propose an automatic emotion classification approach based on EEG signals, utilizing the EEG Brainwave Dataset and the eeg-dataset-emotions. Two deep learning architectures—1D Convolutional Neural Network (1D CNN) and Long Short-Term Memory (LSTM) networks—were implemented to extract spatial and temporal features, respectively. The experimental results demonstrate that the combined use of these models enhances the accuracy and reliability of emotional state recognition.

Keywords : EEG, Deep Learning, 1D CNN, LSTM, Emotion Classification, Brain Signals

ملخص

في السنوات الأخيرة، شهد مجال التعرف على المشاعر البشرية تطوراً ملحوظاًا انطلاقاًا من إشارات تخطيط كهربية الدماغ(EEG) ، وذلك بفضل التقدم الكبير في تقنيات التعلم العميق. وعلى خلاف الأساليب التقليدية المعتمدة على تحليل تعابير الوجه، توفّر إشارات EEGدرجة أعلى من الموضوعية ومقاومة أفضل للتلاعب المتعمد. في هذا العمل، نقترح مقاربة لتصنيف المشاعر تلقائياًا اعتماداً على إشارات EEG، باستخدام مجموعتي البيانات (Dataset Brainwave EEG)و(emotions-sataset-eeg) وقد تم تطبيق معماريتين من التعلم العميق، وهما: الشبكة العصبية الالتفافية أحادية البعد (CNN 1D)، وشبكة الذاكرة طويلة المدى(LSTM) ، بهدف استخراج الخصائص الزمنية والمكانية للإشارات. أظهرت النتائج التجريبية أن الاستخدام المشترك لهذين النموذجين يسهم في تحسين دقة وفعالية التعرف على الحالات العاطفية.

الكلمات المفتاحية: تخطيط كهربية الدماغ (EEG)، التعلم العميق، الشبكة العصبية الالتفافية)١ ر (شبكة الذاكرة طويلة المدى (LSTM) تصنيف المشاعر، إشارات الدماغ

Table des matières

vi

Liste des abréviations **x**

Liste des figures **xi**

Liste des tableaux **1**

Introduction Générale **2**

Problématique et motivations 2

Objectifs et contributions 3

Organisation du mémoire 4

1 Généralités et fondements théoriques **5**

1.1 Introduction 6

1.2 Aspects biologiques du cerveau 6

1.2.1 Les composants du cerveau 7

1.2.2 Structure du neurone biologique : 8

1.2.3 Transmission neuronale : 10

1.2.4 Les étapes de la transmission nerveuse 10

1.3 L'electroencéphalogramme EEG 12

1.3.1 Historique 12

1.3.2 Définition de l'EEG 12

1.3.3 Utilisation de l'électroencéphalographie 13

1.3.4 Types de signaux EEG 14

1.4 L'émotion 16

1.4.1 Les principaux types d'émotions 16
1.5 Interaction entre le cerveau, les émotions et l'EEG 18
1.6 Conclusion 19

2 Techniques d'apprentissage profond 20
2.1 Introduction 21
2.2 L'intelligence artificielle 21
2.2.1 Utilisations de l'intelligence artificielle) 21
2.3 L'apprentissage automatique (machine learning) 23
2.3.1 Définition 23
2.3.2 Types d'apprentissage 23
2.4 L'apprentissage en profondeur (deep learning) 24
2.4.1 Historique 24
2.4.2 Définition 24
2.4.3 Les avantages du deep learning 25
2.4.4 Les réseaux de Neurones Artificiels 27
2.4.5 Optimisation dans l'apprentissage profond 32
2.4.6 Architectures de réseaux profonds 33
2.5 Travaux connexes 37
2.6 Conclusion 39

3 Implémentation et résultats 40
3.1 Introduction 41
3.2 Architecture globale 42
3.3 Environnement et Outils de Développement 43
3.3.1 Matériel Utilisé 43
3.3.2 Langage, Environnement et Bibliothèques Utilisés 43
3.4 Système proposé 44
3.4.1 Ensembles de données 44
3.4.2 Prétraitement des Données EEG 45
3.4.3 Classification par modèles profonds 48
3.4.4 Entraînement et évaluation 52
3.5 Analyse des résultats 53

3.5.1 Analyse des courbes ROC 53
3.5.2 Matrice de confusion 55
3.5.3 Courbes de Précision (Accuracy et Loss) 56
3.5.4 Différences entre les résultats des modèles 56

Références **58**

Tableau des abréviations

Abréviation	Signification
EEG	Électroencéphalogramme
IA	Intelligence Artificielle
ML	Machine Learning (Apprentissage automatique)
DL	Deep Learning (Apprentissage profond)
CNN	Convolutional Neural Network
LSTM	Long Short-Term Memory
RNN	Recurrent Neural Network
ANN	Artificial Neural Network
GPU	Graphics Processing Unit
CSV	Comma Separated Values (format de fichier)
AUC	Area Under Curve (Aire sous la courbe ROC)
ROC	Receiver Operating Characteristic
TP	True Positive (Vrai positif)
TN	True Negative (Vrai négatif)
FP	False Positive (Faux positif)
FN	False Negative (Faux négatif)
ReLU	Rectified Linear Unit (fonction d'activation)
Softmax	Fonction d'activation pour classification

Table des figures

1.1 Lobes du télencéphale dans le cerveau humain[1] 7
1.2 Anatomie d'un neurone biologique[2] 8
1.3 Schéma bilan de la genèse et de la transmission du message nerveux[3] 10
1.4 Bandes de fréquence des signaux EEG [4] 14
1.5 schéma de l'interaction entre le cerveau, les émotions et l'EEG 18

2.1 Neurone artificiel et neurone biologique [5] 27
2.2 Réseau de neurones avec une couche cachée[6] 28
2.3 Schéma d'un neurone artificiel 29
2.4 Exemples de fonctions d'activation[7] 30
2.5 CNN Architecture[8] 35
2.6 Architecture LSTM[9] 36

3.1 Architecture globale du système 42
3.2 Architecture CNN 1D 49
3.3 Architecture de LSTM. 51
3.4 Matrice de confusion 54
3.5 Matrice de confusion 55
3.6 Matrice de confusion 56

Liste des tableaux

2.1 Utilisations courantes de l'intelligence artificielle 22
2.2 Types d'apprentissage en machine learning 23
2.3 Comparaison entre quelques algorithmes d'optimisation populaires 33

3.1 Caractéristiques matérielles 43
3.2 Caractéristiques du EEG Brainwave Dataset 44
3.3 Caractéristiques du eeg-dataset-emotions 45
3.4 Comparaison des étapes de prétraitement pour les deux jeux de données EEG . 48
3.5 Paramètres d'entraînement des modèles 52
3.6 Précision comparative des modèles 56

Introduction Générale

Les émotions humaines jouent un rôle essentiel dans nos interactions sociales, dans nos processus décisionnels, ainsi que dans la gestion de notre bien-être psychologique. La reconnaissance des émotions, notamment à travers des technologies non invasives, est un domaine de recherche crucial, avec des applications diverses allant de la santé mentale à l'amélioration des interfaces humaines. L'électroencéphalographie (EEG), en tant que technique mesurant l'activité électrique du cerveau, a émergé comme un outil prometteur pour la détection des émotions. Toutefois, l'analyse des signaux EEG demeure complexe en raison de leur nature bruitée et de leur variabilité inter-individuelle.

Dans ce contexte, l'intelligence artificielle (IA) et plus spécifiquement l'apprentissage profond, avec ses capacités à extraire des motifs complexes dans de grandes quantités de données, a considérablement avancé dans la reconnaissance des émotions. Cependant, les modèles classiques d'apprentissage profond manquent souvent de transparence, ce qui limite leur adoption dans des contextes critiques comme la psychologie et la santé mentale. Il devient donc primordial d'intégrer des méthodes explicables afin de comprendre les décisions des modèles.

Problématique et motivations

Malgré les progrès dans l'utilisation des modèles d'apprentissage profond pour la classification des émotions via EEG, la compréhension des mécanismes internes de ces modèles reste un défi majeur. Les systèmes basés sur l'apprentissage profond, bien que très performants, sont souvent perçus comme des "boîtes noires", ce qui constitue une limitation importante lorsqu'il s'agit de garantir la confiance des utilisateurs dans les décisions de ces systèmes. L'absence d'interprétabilité empêche une adoption large dans des domaines comme la psychologie clinique, où comprendre le raisonnement du modèle est essentiel.

C'est dans cette perspective que ce travail de recherche s'inscrit. L'objectif est de développer des modèles de classification des émotions à partir de signaux EEG qui soient non seulement performants, mais aussi explicables, offrant ainsi une meilleure transparence et compréhension des résultats générés. Ce projet vise à combiner les avancées de l'apprentissage profond avec des méthodes d'explicabilité pour rendre les décisions des modèles plus claires, ce qui est essentiel dans les applications liées à la santé et à la psychologie.

Objectifs et contributions

L'objectif principal de ce projet de fin d'études est de proposer une méthode robuste et transparente pour la classification des émotions à partir des signaux EEG, en s'appuyant sur des modèles d'apprentissage profond, notamment les réseaux de neurones convolutifs (CNN) et les réseaux à mémoire à long et à court terme (LSTM).

Les principales contributions de ce travail sont les suivantes :

- Réalisation d'une étude comparative entre les modèles CNN et LSTM appliqués à la classification des émotions à partir des signaux EEG, en mettant en évidence les points forts et les limites de chaque approche.
- Développement de méthodes visant à améliorer la transparence et l'interprétabilité des décisions prises par les modèles d'apprentissage profond.
- Évaluation expérimentale rigoureuse des performances des modèles à l'aide de plusieurs métriques d'analyse, telles que la précision, la matrice de confusion et l'analyse des erreurs.
- Proposition de pistes d'amélioration des méthodes actuelles de classification des émotions, ainsi que de l'intégration de l'interprétabilité dans les systèmes d'intelligence artificielle destinés aux domaines de la psychologie et de la santé mentale.

Organisation du mémoire

Ce mémoire est structuré en trois parties principales, chacune visant à approfondir un aspect essentiel de la reconnaissance des émotions à partir de signaux EEG et des méthodes d'intelligence artificielle explicable :

- **Chapitre 1 : Bases Théoriques**

  Ce chapitre présente les bases nécessaires à la compréhension des signaux EEG, des émotions et des techniques d'apprentissage profond. Il aborde successivement l'anatomie du cerveau, le fonctionnement de l'électroencéphalographie, ainsi que les fondements théoriques des réseaux de neurones et de l'apprentissage automatique utilisés pour la reconnaissance des émotions.
- **Chapitre 2 : Implémentation des Modèles**

  Cette partie est consacrée à l'implémentation des modèles de classification des émotions à partir des signaux EEG. À travers des expériences réalisées sur des jeux de données EEG, nous évaluerons la performance des modèles CNN et LSTM, tout en explorant les défis associés à la classification des émotions. Nous discuterons également des méthodes d'explicabilité des modèles pour mieux comprendre les décisions des réseaux.
- **Chapitre 3 : Résultats et Discussion**

  Le dernier chapitre présente une analyse détaillée des résultats obtenus lors des expériences. Il met en lumière l'impact des différentes configurations des modèles sur la classification des émotions, et propose une réflexion sur les implications pratiques de ces résultats dans des applications concrètes. Enfin, des pistes de recherche futures seront évoquées, notamment en ce qui concerne l'amélioration de l'explicabilité et la généralisation des modèles pour d'autres contextes.

Ce travail s'inscrit dans un cadre multidisciplinaire où les neurosciences, l'intelligence artificielle et la psychologie se rencontrent pour aborder des enjeux importants dans le domaine de la reconnaissance des émotions, avec un potentiel d'applications dans la santé et les technologies interactives.

Chapitre 1

Généralités et fondements théoriques

1.1 Introduction

Ce chapitre s'articule autour de plusieurs concepts fondamentaux. Il s'ouvre par une introduction générale, puis explore les aspects biologiques du fonctionnement cérébral, en mettant l'accent sur la structure du neurone ainsi que sur le mécanisme de la transmission synaptique. La section suivante est consacrée à l'électroencéphalographie (EEG), abordée comme un outil essentiel d'analyse de l'activité cérébrale. Cette partie présente l'historique de l'EEG, sa définition, ses principales applications cliniques, ainsi que les différentes formes de signaux qu'il permet de capter. Enfin, le chapitre se focalise sur la notion d'émotion, en décrivant ses caractéristiques, ses catégories principales, et en examinant les liens complexes et dynamiques qui unissent le cerveau, les états émotionnels et les signaux EEG.

1.2 Aspects biologiques du cerveau

Le cerveau constitue l'élément central du système nerveux, agissant tel un chef d'orchestre qui réceptionne, traite et distribue les informations à l'ensemble de l'organisme. Il assure le contrôle non seulement des fonctions physiologiques de base, mais également des fonctions cognitives supérieures telles que la mémoire, le langage, la perception, l'attention et le raisonnement. Bien que distinctes, les fonctions cognitives et émotionnelles sont étroitement interconnectées et s'influencent mutuellement.

Le cerveau humain [10] est une structure d'une grande complexité, composée de différentes régions qui interagissent de manière coordonnée. Parmi celles-ci, le cortex cérébral — en particulier le néocortex — joue un rôle fondamental dans les activités cognitives avancées. Situé à la surface du cerveau, le néocortex est impliqué dans la perception sensorielle, la pensée abstraite, la mémoire et la prise de décision. Il est principalement constitué de neurones, qui communiquent entre eux via des signaux électrochimiques circulant à travers les axones, les dendrites, les boutons synaptiques et les épines dendritiques. L'ensemble de ces structures permet la transmission, le traitement et le stockage de l'information au sein du cerveau.

1.2.1 Les composants du cerveau

Le cerveau humain est organisé en plusieurs lobes distincts : frontal, pariétal, temporal et occipital, comme le montre la Figure 1.1.

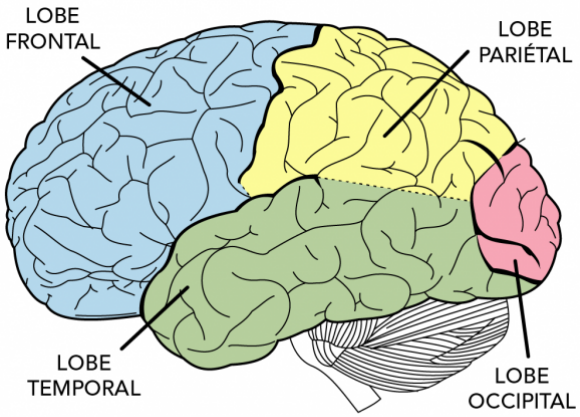

FIGURE 1.1 – Lobes du télencéphale dans le cerveau humain[1]

Chacun de ces lobes est spécialisé dans des fonctions spécifiques :

1.2.1.1 Lobe frontal :

Le lobe frontal est impliqué dans diverses fonctions cognitives de haut niveau telles que la planification, le raisonnement, le langage, le contrôle des mouvements volontaires, la mémoire à court terme, la motivation, la prise de décision, la résolution de problèmes, ainsi que les fonctions exécutives.

1.2.1.2 Lobe pariétal :

Il est responsable de l'intégration des informations sensorielles (toucher, température, douleur), de la perception spatiale, de la coordination motrice, ainsi que du traitement du langage et des compétences mathématiques.

1.2.1.3 Lobe temporal :

Le lobe temporal joue un rôle essentiel dans la perception auditive, la compréhension du langage, la mémoire à long terme, la mémoire visuelle et les émotions. Il contient également des structures importantes telles que l'hippocampe.

1.2.1.4 Lobe occipital :

Ce lobe est principalement dédié au traitement visuel. Il abrite le cortex visuel primaire ainsi que les aires visuelles associatives, indispensables à la reconnaissance et à l'interprétation des images.

Enfin, sous le cortex cérébral se trouve la substance blanche, constituée majoritairement d'axones. Elle assure la connexion entre les différentes régions cérébrales, facilitant ainsi la communication interlobaire et interhémisphérique.

1.2.2 Structure du neurone biologique :

Le cerveau fonctionne grâce aux neurones [11], qui sont des cellules spécialisées dans la transmission de l'information à d'autres cellules nerveuses [10] ; chez les mammifères, leur nombre varie de cent millions à cent milliards selon l'espèce, et chaque neurone se compose de dendrites (chargées de recevoir les signaux), d'un corps cellulaire (où l'information est intégrée), d'un axone (qui conduit les signaux électriques) et de terminaisons synaptiques assurant la transmission du signal aux cellules cibles (voir Figure 2).

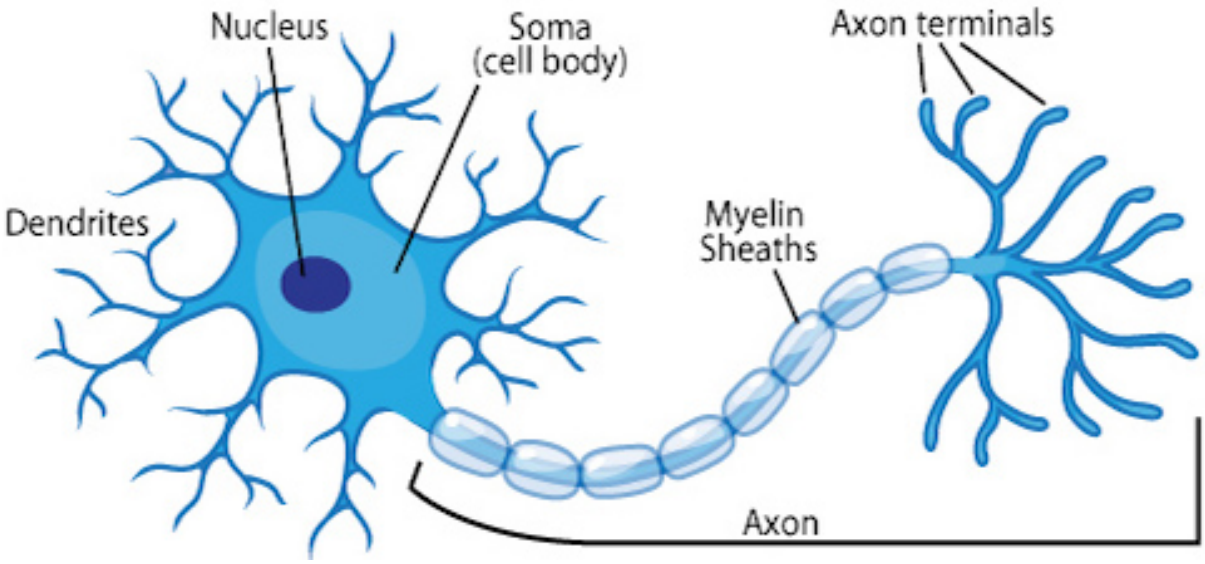

FIGURE 1.2 – Anatomie d'un neurone biologique[2]

1.2.2.1 Fonctions des composants biologiques de la cellule nerveuse (neurone)

Dendrites

Prolongements ramifiés du neurone qui reçoivent les signaux nerveux provenant d'autres neurones. Elles permettent au neurone de capter et d'intégrer les signaux entrants.

Soma (corps cellulaire)

Centre de contrôle du neurone contenant les organites cellulaires essentiels (comme les mitochondries et le réticulum endoplasmique). C'est ici que les signaux reçus sont traités.

Noyau

Situé à l'intérieur du soma, il contient l'ADN du neurone. Il régule les activités cellulaires et dirige la synthèse des protéines nécessaires au fonctionnement neuronal.

Axone

Prolongement unique et allongé qui transporte l'influx nerveux depuis le soma vers les terminaisons axonales. Il assure la transmission du signal vers d'autres neurones ou cellules.

Gaines de myéline

Enveloppes isolantes entourant l'axone. Elles permettent une conduction rapide de l'influx nerveux en facilitant un passage du signal de manière saltatoire entre les nœuds de Ranvier.

Terminaisons axonales

Extrémités de l'axone où le neurone transmet l'information à d'autres cellules (neurones, muscles, glandes) via la synapse.

1.2.3 Transmission neuronale :

La transmission de l'information nerveuse repose sur la propagation de potentiels d'action le long des axones, depuis les récepteurs sensoriels jusqu'au système nerveux central. Ce processus permet le passage du message nerveux d'un neurone à un autre via des connexions spécialisées appelées synapses. Ci-dessous sont détaillées les principales étapes de ce mécanisme de transmission synaptique :

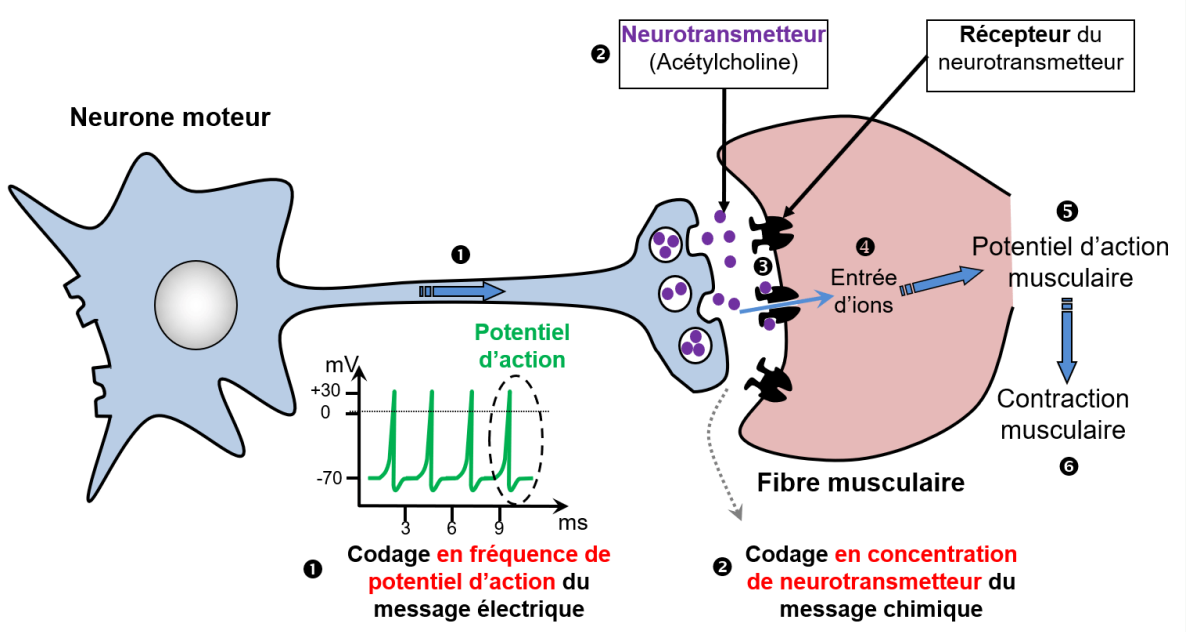

FIGURE 1.3 – Schéma bilan de la genèse et de la transmission du message nerveux[3]

1.2.4 Les étapes de la transmission nerveuse

La transmission de l'influx nerveux entre un neurone et une cellule effectrice, comme une fibre musculaire, se déroule selon six phases successives, décrites comme suit :[12] :

Phase 1

Formation du potentiel d'action au sein du neurone moteur Le neurone moteur est le point de départ de la transmission de l'influx nerveux (qu'on appelle potentiel d'action) le long de l'axone, qui est le support de cette transmission de l'information codée par la fréquence du potentiel d'action.

Phase 2

Sécrétion de neurotransmetteurs (acétylcholine) Lors de l'arrivée du potentiel d'action à la terminaison nerveuse, des vésicules permettent de libérer dans la fente synaptique de l'acétylcholine.

Phase 3

Fixation de l'acétylcholine sur les récepteurs de la fibre musculaire L'acétylcholine diffuse dans la fente synaptique puis se fixe sur des récepteurs spécifiques présents dans la membrane de la fibre musculaire..

Phase 4

Ouverture des canaux ioniques et entrée d'ions Cette liaison entraîne l'ouverture des canaux ioniques, permettant l'entrée d'ions et modifiant ainsi le potentiel de membrane de la fibre musculaire.

Phase 5

Élaboration du potentiel d'action au niveau musculaire Cette modification provoque, au niveau de la fibre musculaire, un nouveau potentiel d'action.

Phase 6

Contraction musculaire Le potentiel d'action est propagé le long de la fibre musculaire, engendrant la contraction du muscle.

1.3 L'electroencéphalogramme EEG

1.3.1 Historique

Les premiers enregistrements EEG remontent à la fin du 19e siècle. En 1875, le médecin britannique Richard Caton est le premier à proposer, sur la base de ses travaux réalisés avec des animaux, que l'activité électrique générée par le cerveau est révélatrice de l'activité mentale. Ses études montrent que les patrons d'activité électrique varient en fonction de l'état de conscience de l'animal (par exemple, éveil, sommeil, anesthésie, mort), mais également en réponse aux stimulations externes (Collura, 1993) [13].

Le premier enregistrement de l'activité électrique du cerveau humain n'a été réalisé qu'en 1924, soit 247 ans après le premier enregistrement EEG dans le règne animal. Ce travail fut accompli par le neuropsychiatre allemand Hans Berger, qui enregistra l'activité électrique du cerveau d'un jeune patient ayant subi une trépanation pour retirer une tumeur cervicale.

Hans Berger est reconnu pour avoir établi un lien entre les variations dans le signal électrique observées au sein de certaines bandes de fréquences et l'activité mentale chez l'homme. En 1929, Berger publia le compte rendu de ses observations, et identifia deux rythmes cérébraux distincts : le « rythme alpha » et le « rythme bêta » (qui seront détaillés dans la section sur les rythmes cérébraux).

Le travail de Berger marque ainsi les débuts de l'utilisation de l'EEG tant en clinique qu'en recherche, ouvrant la voie à des avancées majeures dans l'étude de l'activité cérébrale.

1.3.2 Définition de l'EEG

L'électroencéphalographie (EEG) est un examen médical non invasif permettant de mesurer et d'enregistrer l'activité électrique cérébrale. Cette procédure consiste à placer des électrodes sur le cuir chevelu afin de détecter les signaux électriques produits par les neurones. Les signaux détectés sont ensuite convertis en tracés représentant différentes ondes cérébrales, telles que les ondes delta, thêta, alpha, bêta et gamma, qui correspondent chacune à un état mental ou à une fonction cognitive spécifique. [14][15]

L'électroencéphalogramme a pour objectif principal de détecter les dysfonctionnements électriques cérébraux. Il est fréquemment utilisé pour diagnostiquer diverses pathologies, telles que l'épilepsie, les troubles du sommeil, les infections, ainsi que les inflammations ou lésions cérébrales. De plus, l'EEG permet de surveiller l'activité cérébrale lors de certaines interventions médicales.

Cet examen est indolore, ne présente aucun risque électrique pour le patient et dure généralement entre 30 et 60 minutes. Il peut être réalisé sur des patients éveillés ou endormis, avec, dans certains cas, des stimulations spécifiques (comme la respiration profonde ou la stimulation lumineuse) pour faciliter la détection de certaines anomalies. [14][15]

1.3.3 Utilisation de l'électroencéphalographie

L'électroencéphalographie (EEG) peut être appliquée selon divers protocoles, en fonction de ses objectifs spécifiques. L'EEG quantitative (EEGq) en particulier, désigne l'application de techniques numériques de traitement du signal à l'étude de l'activité cérébrale. Elle permet une analyse plus fine des données en recourant à des méthodes avancées telles que la séparation de sources, notamment l'analyse en composantes indépendantes (ICA), ou encore des techniques de localisation des sources comme la tomographie.

1.3.3.1 Domaine médical

L'électroencéphalographie (EEG) trouve de nombreuses applications dans le domaine médical, notamment dans les domaines suivants :

1. La détection et la localisation d'activités électriques cérébrales anormales.
2. L'identification de lésions ou anomalies cérébrales telles que les tumeurs, inflammations, infections, hémorragies, ou traumatismes crâniens.
3. Le diagnostic et la surveillance de pathologies neurologiques, notamment l'épilepsie, la narcolepsie et l'œdème cérébral.
4. La surveillance peropératoire de l'activité cérébrale lors d'interventions chirurgicales au cerveau.

1.3.3.2 Domaine psychologique

Dans le champ psychologique, l'EEG est utilisé pour : L'électroencéphalographie permet notamment le diagnostic de troubles mentaux atypiques ou d'origine tumorale à partir de l'analyse de symptômes psychiques, l'étude étiologique de syndromes confusionnels liés à des causes telles que l'intoxication, l'encéphalite ou les lésions vasculaires, ainsi que le suivi de l'évolution de ces troubles et l'évaluation de l'efficacité de certaines chimiothérapies.

1.3.4 Types de signaux EEG

Les signaux électroencéphalographiques (EEG) [16][4] se distinguent par différents types d'ondes, caractérisées notamment par leur fréquence, leur amplitude, leur stabilité et leur réactivité. Ces caractéristiques sont souvent corrélées à divers états physiologiques ou pathologiques du cerveau. Parmi ces ondes, on distingue principalement trois types fondamentaux, qui seront décrits ci-après. :

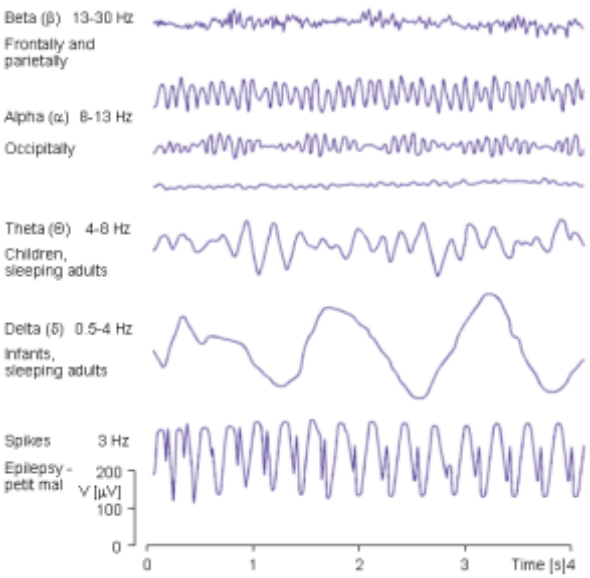

FIGURE 1.4 – Bandes de fréquence des signaux EEG [4]

1.3.4.1 Ondes delta (0,5-4 Hz) :

Les ondes delta sont généralement observées lors du sommeil profond chez l'adulte. Toutefois, leur présence en dehors de cet état peut indiquer une pathologie neurologique, notamment lorsqu'elles sont localisées dans des foyers cérébraux anormaux.

1.3.4.2 Ondes thêta (4-8 Hz) :

Ces ondes sont fréquemment enregistrées lors de la somnolence, particulièrement chez les enfants. Elles peuvent également être associées à certaines formes d'épilepsie, ce qui en fait un indicateur important en neurologie clinique.

1.3.4.3 Ondes alpha (8-12 Hz) :

Le rythme alpha prédomine dans la région occipitale du cerveau. Il apparaît lorsque le sujet est au repos, les yeux fermés, et disparaît dès que les yeux sont ouverts. Ce rythme tend à diminuer avec l'âge et constitue un marqueur de l'état de repos cérébral.

1.3.4.4 Ondes bêta (12-30 Hz) :

Les ondes bêta sont liées à l'activité mentale intense, à la concentration et à l'éveil actif. Bien qu'elles soient parfois moins visibles en EEG de surface, elles jouent un rôle essentiel dans l'étude des fonctions cognitives.

1.3.4.5 Ondes gamma (30-100 Hz) :

Les ondes gamma sont associées aux processus cognitifs de haut niveau, tels que la perception, l'attention soutenue et la résolution de problèmes complexes. Une activité gamma anormale peut être le signe de troubles neurologiques, notamment dans certaines pathologies psychiatriques ou neurodégénératives.

1.4 L'émotion

Les émotions humaines ne se limitent pas à des réactions spontanées ou affectives ; elles influencent aussi bien les choix rationnels que les décisions intuitives et sociales. Elles jouent un rôle crucial dans l'intégration de l'information, la motivation, l'évaluation des risques, et influencent donc les comportements et les jugements . [17][18]

Selon la théorie de l'évaluation cognitive (Appraisal Theory), l'émotion constitue un processus cognitif qui permet d'évaluer la signification des événements en fonction des objectifs personnels. Cette évaluation guide ensuite la prise de décision. Par exemple, des émotions de valence identique, comme la peur et la colère, peuvent mener à des jugements opposés face à une même situation.[19] [20][21]

Les neurosciences ont confirmé l'existence d'un lien étroit entre émotions et décisions, en mettant en évidence l'interaction entre les régions cérébrales émotionnelles (notamment les amygdales) et les zones décisionnelles (comme le cortex préfrontal). Damasio (1998) a démontré que des lésions dans ces structures altèrent gravement la capacité à prendre des décisions adaptées, soulignant ainsi que les émotions sont essentielles à un processus décisionnel efficace. [22].

De plus, un état émotionnel positif favorise la résolution de problèmes complexes, en réduisant la confusion mentale et en améliorant la récupération et l'analyse d'informations. À l'inverse, les émotions négatives peuvent altérer le jugement [23]. Ces observations sont étayées tant par les recherches en psychologie expérimentale, que par celles en psychologie sociale et en sciences de gestion.[23]

Ainsi, loin d'être un simple facteur perturbateur, l'émotion s'avère être une composante intégrée et indispensable à la prise de décision humaine, qu'elle soit intuitive ou rationnelle.

1.4.1 Les principaux types d'émotions

Les émotions représentent des réactions immédiates qui traduisent un état d'excitation interne, susceptible d'altérer temporairement le raisonnement logique. Elles peuvent être classées en trois grandes catégories, selon leur origine, leur complexité et leur fonction [24][25][26][27] :

1.4.1.1 Émotions primaires (ou émotions de base)

Les émotions primaires sont des réactions spontanées, universellement partagées par tous les êtres humains, indépendamment de leur culture. Elles sont directement déclenchées par un événement ou une situation spécifique, et forment le noyau fondamental du vécu émotionnel. Les émotions primaires les plus fréquemment citées en psychologie sont : la joie, la peur, le dégoût, la colère, la tristesse, la surprise, la confiance et l'anticipation.

Elles sont souvent qualifiées d'instinctives, car elles émergent de manière automatique face à certains stimuli.

1.4.1.2 Émotions secondaires

Les émotions secondaires apparaissent suite à une élaboration cognitive plus poussée : elles naissent de l'interprétation ou de la combinaison d'émotions primaires, et sont influencées par l'expérience personnelle, le contexte social, et les règles culturelles. Parmi les émotions secondaires, on retrouve : l'anxiété, la honte, la culpabilité, la jalousie, l'agressivité, le vide ou le désespoir sont autant d'émotions secondaires. Ces émotions peuvent parfois masquer les émotions primaires, rendant leur identification plus difficile.

1.4.1.3 Émotions sociales

Les émotions sociales sont étroitement liées aux interactions interpersonnelles et à la perception de soi dans un contexte social. Elles dépendent de la manière dont l'individu se représente dans une situation en lien avec les normes, les valeurs, et les attentes de la société à laquelle il appartient. On y retrouve des sentiments comme :la culpabilité, la jalousie, la honte, la gratitude, l'embarras . Ces émotions impliquent une auto-évaluation sociale, souvent facilitée par des mécanismes de réflexivité et d'intériorisation des normes collectives.

1.5 Interaction entre le cerveau, les émotions et l'EEG

La reconnaissance des émotions par EEG repose sur une interaction complexe entre activité cérébrale, réponse émotionnelle et détection via des systèmes intelligents.

Explication détaillée du schéma

L'exposé visuel présente une séquence d'actions afin de reconnaître des émotions à partir des données d'électroencéphalographie (EEG) selon quatre étapes ou composantes

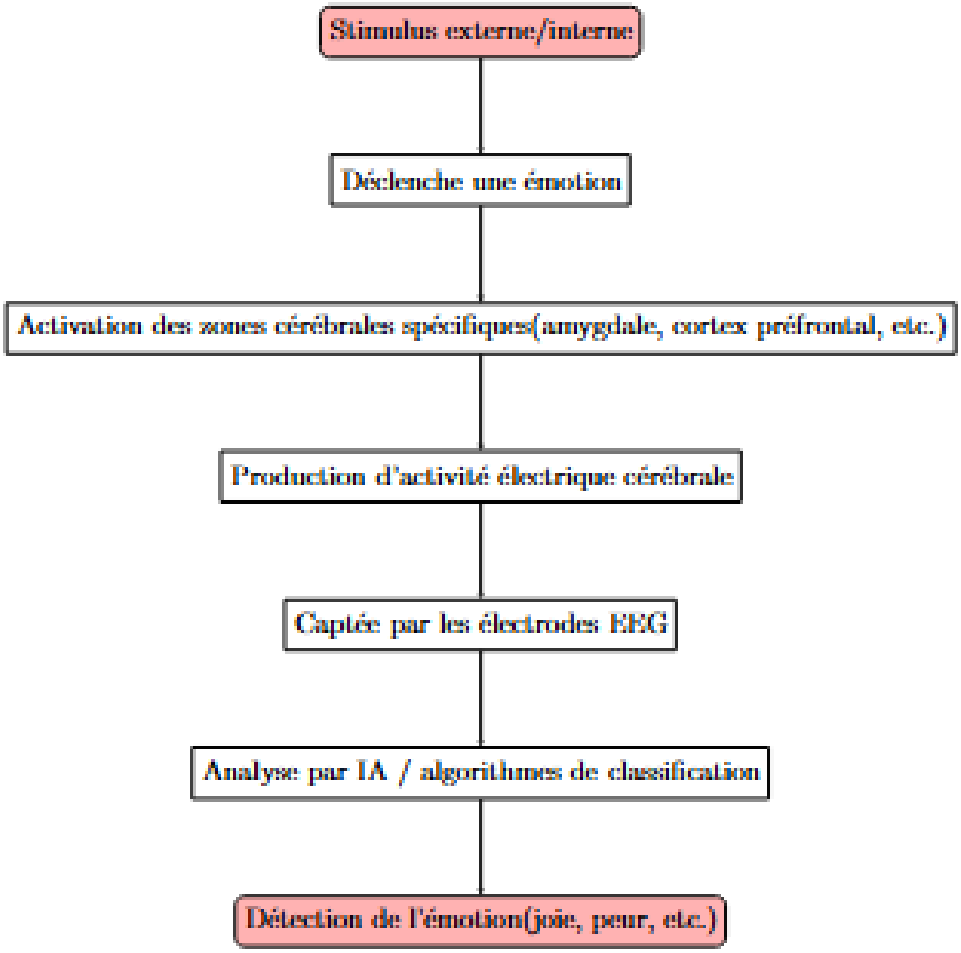

FIGURE 1.5 – schéma de l'interaction entre le cerveau, les émotions et l'EEG

1. **Stimulus externe/interne** : Le processus émotionnel débute généralement par l'exposition à un stimulus. Celui-ci peut être externe (comme une image, un son, une scène vécue) ou interne (pensée, souvenir, douleur physique, etc.). Ce stimulus constitue le déclencheur émotionnel initial.

2. **Déclenche une émotion** : En réponse à ce stimulus, une émotion est déclenchée chez l'individu : joie, peur, tristesse, colère, etc. Cette étape repose sur des mécanismes affectifs et cognitifs rapides, souvent inconscients..
3. **Activation des zones cérébrales spécifiques** : L'émotion active des régions particulières du cerveau, notamment l'amygdale, responsable du traitement des émotions, et le cortex préfrontal, impliqué dans la régulation émotionnelle.
4. **Production d'activité électrique cérébrale** : L'activation de ces zones génère une activité électrique caractéristique, mesurable par des oscillations dans différentes bandes de fréquences.
5. **Captée par les électrodes EEG** : les structures cérébrales activées vont alors produire une activité électrique propre à chacune, elle-même mesurée par les oscillations des différentes bandes de fréquence.
6. **Analyse par intelligence artificielle et algorithmes de classification** : cette activité électrique est alors recueillie par des électrodes EEG positionnées sur le cuir chevelu (l'enregistrement par électroencéphalographie, EEG, en fait).
7. **Détection de l'émotion** : Le système détecte le sentiment que ressent l'individu (joie, peur, colère, etc.).

Ce processus montre comment l'EEG, à lui seul, est capable de contribuer à une compréhension précise et à une interprétation des états émotionnels tels qu'exprimés par les signaux électriques du cerveau, grâce à des outils d'analyse de plus en plus sophistiqués.

1.6 Conclusion

Dans ce chapitre introductif, les fondements de la neurophysiologie ont été passés en revue afin de mieux comprendre l'origine et la nature des réponses cérébrales. Cette exploration a permis d'établir les bases nécessaires à la compréhension des mécanismes sous-jacents de la réponse émotionnelle. Par la suite, la technologie de détection des données EEG a été présentée, mettant en lumière les avancées techniques permettant de classer les émotions à partir des signaux cérébraux. Le chapitre suivant abordera les principes de l'apprentissage profond et des réseaux neuronaux (CNN et LSTM), avec une explication détaillée de leur fonctionnement et de leur application dans le cadre de la reconnaissance émotionnelle.

Chapitre 2

Techniques d’apprentissage profond

2.1 Introduction

Ce chapitre est dédié à l'exploration des fondements théoriques nécessaires pour saisir adéquatement la portée de notre travail, dans un premier temps, en présentant l'intelligence artificielle et ses champs d'application, puis en expliquant le fonctionnement du machine learning et ses apports. Nous présenterons ensuite le deep learning avec ses principales architectures, en insistant tout particulièrement sur les réseaux de neurones artificiels, les réseaux convolutifs réputés (CNN) et les réseaux récurrents (LSTM), pour en terminer par faire un bilan des travaux connexes portant sur la classification des émotions issus de signaux EEG.

2.2 L'intelligence artificielle

L'intelligence artificielle (IA)[28] est la capacité des machines à réaliser des tâches qui requièrent habituellement l'intelligence humaine (apprentissage, raisonnement, perception, compréhension du langage, résolution de problèmes difficiles), qui fait appel à des algorithmes capables d'imiter les comportements humains en traitant de grandes quantités de données et en améliorant leurs performances grâce au machine learning et au deep learning.

2.2.1 Utilisations de l'intelligence artificielle)

L'intelligence artificielle [29][30]joue un rôle clé dans l'amélioration de la rapidité, de la précision et de la qualité des services offerts dans de nombreux secteurs, tout en optimisant l'expérience utilisateur, Voici quelques exemples concrets :

Secteur	**Applications principales**
Commerce et marketing	Personnalisation des recommandations d'achats en ligne, analyse des comportements clients, automatisation des tâches commerciales, création de contenus, optimisation des campagnes marketing.
Recherche en ligne	Amélioration de la pertinence des résultats via le traitement massif de données utilisateurs.
Assistants numériques personnels	Réponse aux questions, gestion des tâches quotidiennes, recommandations personnalisées via smartphones et appareils connectés.
Traduction automatique	Amélioration des traductions écrites et orales, génération automatique de sous-titres.
Véhicules et transport	Navigation assistée, sécurité active, développement de véhicules autonomes, optimisation des trajets en logistique.
Cybersécurité	Détection et prévention des cyberattaques par analyse en temps réel des données et reconnaissance de schémas suspects.
Santé	Diagnostic médical assisté (analyse d'images, détection de maladies), traitements personnalisés, recherche pharmaceutique, gestion des urgences.
Détection de fraudes financières	Surveillance des transactions en temps réel, identification des comportements suspects, prévention des fraudes.
Service client et support	Automatisation des réponses via chatbots et assistants virtuels, gestion rapide des demandes simples, transfert aux humains pour cas complexes.
Agriculture et alimentation	Optimisation de la production durable, réduction des pesticides, surveillance de la santé animale, gestion des ressources.
Administration publique et gestion des catastrophes	Prévention et gestion des catastrophes naturelles par analyse de données et reconnaissance de formes.
Fabrication et industrie	Optimisation de la production, maintenance prédictive, amélioration des conditions de travail via robotique et réalité augmentée.
Création de contenu	Production rapide de contenus marketing, articles, descriptions produits, réduction des coûts et délais.

TABLE 2.1 – Utilisations courantes de l'intelligence artificielle

2.3 L'apprentissage automatique (machine learning)

2.3.1 Définition

L'apprentissage automatique (machine learning) [31] est un domaine d'études et de recherches relevant de l'informatique, qui traite des méthodes d'identification et de mise en œuvre de systèmes et d'algorithmes par lesquels un ordinateur peut apprendre, domaine régulièrement associé à l'intelligence artificielle et plus particulièrement à l'intelligence computationnelle.

Le machine learning peut avoir des applications très variées, allant des moteurs de recherche et de la reconnaissance de caractères à la recherche en génomique, à l'analyse des réseaux sociaux, à la publicité comportementale, à la vision par ordinateur, à la traduction automatique, au trading algorithmique, etc

2.3.2 Types d'apprentissage

Les principaux types d'apprentissage en machine learning sont les suivants :

Type d'apprentissage	**Données utilisées**	**Objectif principal**	**Exemples d'algorithmes / usages**
Supervisé	Données étiquetées	Prédiction / classification	Régression, SVM, arbres de décision, réseaux de neurones
Non supervisé	Données non étiquetées	Découverte de structures / regroupements	K-means, PCA, clustering hiérarchique
Semi-supervisé	Données étiquetées + non étiquetées	Exploiter un petit nombre d'étiquettes	Combinaisons d'algorithmes supervisés et non supervisés
Par renforcement	Interaction avec environnement	Apprentissage par essais/erreurs	Q-learning, Deep Q-Network, robotique

TABLE 2.2 – Types d'apprentissage en machine learning

2.4 L'apprentissage en profondeur (deep learning)

2.4.1 Historique

Les origines du deep learning [32] [33] remontent aux années 1940, avec la première modélisation du neurone formel proposée par McCulloch et Pitts, qui a jeté les bases fondatrices des réseaux de neurones artificiels. Dans les années 1950, l'introduction du perceptron par Rosenblatt a marqué une première avancée importante. Toutefois, les performances limitées des réseaux peu profonds à cette époque ont freiné l'évolution de la recherche dans ce domaine.

Ce n'est qu'avec l'apparition de l'algorithme de rétropropagation du gradient, dans les années 1980, que les réseaux de neurones multicouches ont pu être entraînés de manière efficace. Malgré cela, l'intérêt pour ces modèles a progressivement diminué, entraînant une période de stagnation scientifique connue sous le nom de « l'hiver de l'intelligence artificielle ».

Un regain d'intérêt s'est manifesté au début des années 2000, en raison de la disponibilité croissante de données massives (big data) et des avancées matérielles, notamment l'utilisation des unités de traitement graphique (GPU), permettant des calculs complexes à grande échelle. Ce contexte favorable a conduit à un essor spectaculaire des architectures profondes, telles que les réseaux de neurones convolutionnels (CNN), les réseaux récurrents (RNN) et les réseaux antagonistes génératifs (GAN), qui ont permis des percées majeures dans de nombreux domaines d'application. Ces progrès ont été largement soutenus par des investissements significatifs, tant dans le secteur industriel qu'universitaire, notamment de la part de grandes entreprises technologiques.

2.4.2 Définition

Le deep learning, sous-branche de l'apprentissage automatique, est un sous-domaine concernant l'apprentissage au moyen de réseaux de neurones artificiels comprenant plusieurs couches cachées. Il permet de learning des représentations hiérarchiques des données, où chaque couche récupère sous le viewpoint de se bien plus abstrait des chara de cette donnée brute. Opposé aux méthodes classiques, le deep learning automatise cette phase qui est sinon réalisée par des extractions dites manuelles, ce qui permet ensuite d'analyser ces données complicatrices telles que les images, le son ou du texte. Ce dernier type de modélisation, souvent aux prises avec ce que l'on appelle « la structure de données élitizenaire », est des architectures à plusieurs

couches : par exemple, des dizaines ou des millions de paramètres qui nécessitent des quantités significatives de données, et des puissances de calcul importantes pour être exercés. Le deep learning est à la base de nombreuses techniques introduites ultérieurement, entre autres des tech- niques d'interprétation, dont la reconnaissance d'expression faciale. de traduction automatique, de conduite autonome et de diagnostic médical[33].

2.4.3 Les avantages du deep learning

Ces avantages [34] [35] [36] [37] .expliquent pourquoi l'apprentissage profond est devenu une pierre angulaire de l'intelligence artificielle moderne, avec un impact croissant dans de nombreux domaines industriels et scientifiques.

2.4.3.1 Capacité à traiter des données complexes et non structurées

Le deep learning excelle dans l'analyse de données difficiles à exploiter par les méthodes classiques, comme les images, les vidéos, le texte ou les séquences audio. Il permet d'extraire automatiquement des caractéristiques pertinentes sans intervention humaine, ce qui ouvre la porte à de nombreuses applications innovantes.

2.4.3.2 Automatisation avancée et efficacité opérationnelle

En automatisant des tâches auparavant réalisées manuellement, comme la reconnaissance d'images ou la compréhension du langage naturel, le deep learning améliore l'efficacité des systèmes tout en réduisant les coûts et le temps de traitement. Il fonctionne de manière constante, sans fatigue ni baisse de qualité.

2.4.3.3 Meilleure prise de décision grâce à l'analyse de grandes quantités de données.

Les réseaux profonds peuvent identifier des modèles complexes et des relations cachées dans les données, fournissant ainsi des insights précieux pour orienter les décisions stratégiques dans divers secteurs, comme la détection de fraudes, la gestion de la chaîne logistique ou la cybersécurité.

2.4.3.4 Personnalisation des services

Le deep learning permet de personnaliser les recommandations et les expériences utilisateurs en analysant les comportements et préférences, ce qui améliore l'engagement client et la satisfaction.

2.4.3.5 Innovation et nouvelles possibilités

Grâce à ses capacités uniques, le deep learning favorise le développement de produits et de services innovants, tels que les assistants virtuels intelligents, les systèmes de recommandation avancés ou les solutions de sécurité renforcées.

2.4.3.6 Stabilité et performances constantes

Les modèles de deep learning offrent une qualité supérieure et stable dans l'exécution des tâches, surpassant souvent les autres méthodes d'apprentissage automatique, notamment dans la reconnaissance d'images et la vision industrielle

2.4.3.7 Réduction des erreurs humaines

En automatisant les tâches répétitives et complexes, le deep learning limite les erreurs liées à la fatigue ou à l'inattention humaine, augmentant ainsi la fiabilité des systèmes.

2.4.3.8 Scalabilité et rapidité grâce au cloud

L'utilisation du cloud permet d'entraîner rapidement des modèles complexes en exploitant des ressources de calcul évolutives (GPU, CPU), [38]facilitant le déploiement à grande échelle et l'obtention de résultats pertinents.

2.4.4 Les réseaux de Neurones Artificiels

Un réseau de neurones [39] est une méthode inspirée par la même manière de fonctionner que le cerveau. Le cerveau humain analyse et traite les informations. Il est constitué d'un réseau complexe de 100 milliards de neurones connectés entre eux qui servent de transmetteurs de l'information à l'in intérieur du cerveau expliqué dans la première partie de notre rapport

Les réseaux de neurones artificiels sont un moyen de modéliser le mécanisme d'apprentissage et de traitement de l'information qui se produit dans le cerveau humain. En informatique, on appelle réseau de neurones un ensemble d'entrées (les neurones) interconnectées. Dans la majorité des cas, les neurones sont des fonctions calculées par un programme informatique, mais ils sont parfois réalisés sur des circuits électroniques. Le schéma suivant présente le modèle général de l'ANN inspiré d'un neurone biologique.

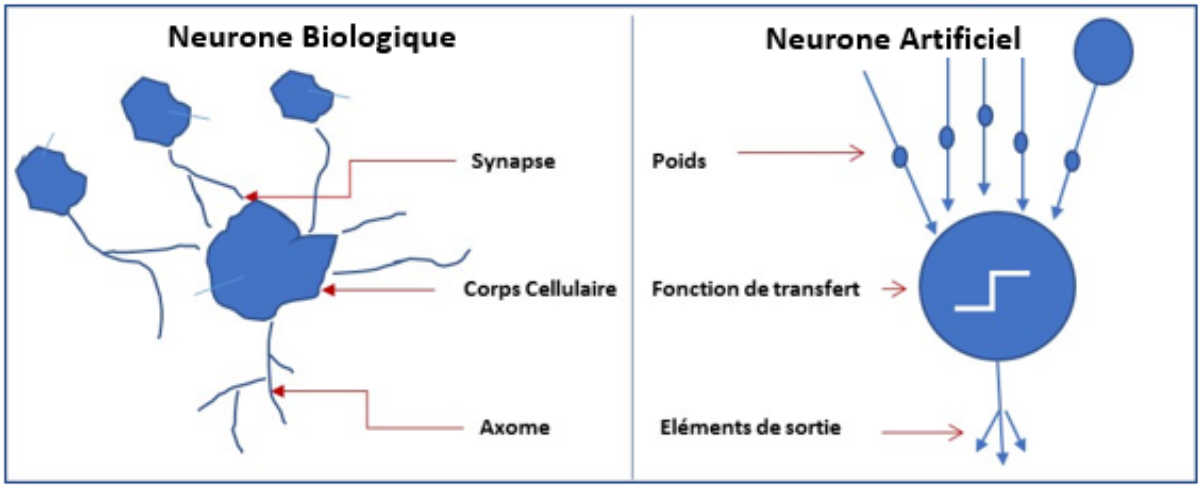

FIGURE 2.1 – Neurone artificiel et neurone biologique [5]

2.4.4.1 Les couches principales

Tels sont donc les réseaux de neurones artificiels (RNA) dans leur version la plus comprise. organisés autour de trois couches majeures :

Couches d'entrée

Dans la couche d'entrée, la première sollicitée par le réseau, c'est la donnée brute venue de l'extérieur qui est reçue (valeurs de pixels d'une image, caractéristiques d'un signal, etc.). Les neurones de cette couche vont transmettre les informations reçues aux couches supérieures, sans les transformer de façon complexe.

Couches cachées

Ce sont une ou plusieurs couches intermédiaires intégrées entre la couche d'entrée et la couche de sortie. Un ensemble de neurones artificiels y effectue des opérations de calcul complexes, suffisantes à élaborer des représentations abstraites et complexes des informations traitées : à l'aide de fonctions d'activation non linéaires, ils appliquent des calculs portant sur des combinaisons pondérées à l'aide de coefficients déterminés par l'apprentissage. Là encore, le nombre de couches cachées et le nombre de neurones par couche est relativement faible du fait de la complexité des problèmes traités.

Couche de sortie

Dernière couche, elle produit la sortie du réseau (un résultat de classification, une prédiction…). Le nombre de neurones dans cette couche est fonction du type de tâche (si on aborde une classification multiclasse, on attend un neurone par classe). Cette couche peut également comporter des fonctions d'activation adaptées (sigmoïde, softmax, fonction linéaire…).

La figure suivante représente les trois couches.

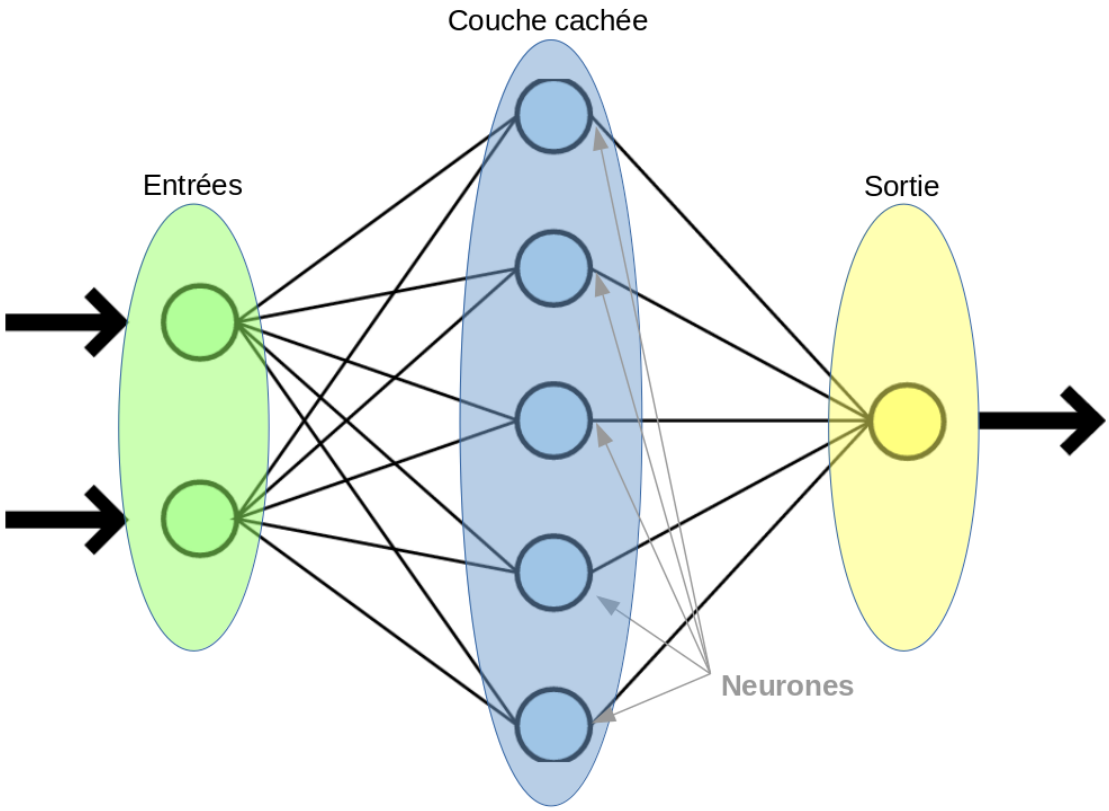

FIGURE 2.2 – Réseau de neurones avec une couche cachée[6]

2.4.4.2 Fonctionnement d'un neurone artificiel

Il convient de noter que chaque entrée x i

d'un réseau de neurones est associée à un poids

w i , attribué en fonction de son importance relative par rapport aux autres entrées. Ce poids détermine l'influence de cette entrée sur la sortie du neurone, et donc sur le calcul effectué par le neurone suivant (voir Figure 2.3).

L'entraînement du réseau consiste essentiellement à ajuster ces poids. Lors de la première étape, les entrées sont multipliées par leurs poids respectifs, puis additionnées avec une valeur appelée **biais** (b), qui est une constante permettant d'augmenter la flexibilité du modèle afin qu'il puisse mieux s'adapter aux données fournies[40].

Dans la deuxième étape, une fonction d'activation f f est appliquée au résultat obtenu. Le calcul de la sortie du neurone est alors donné par la formule suivante :

$$Y_{\text{output}} = f\left(\sum_{i=1}^{n}(x_i \cdot w_i) + b\right) \tag{2.1}$$

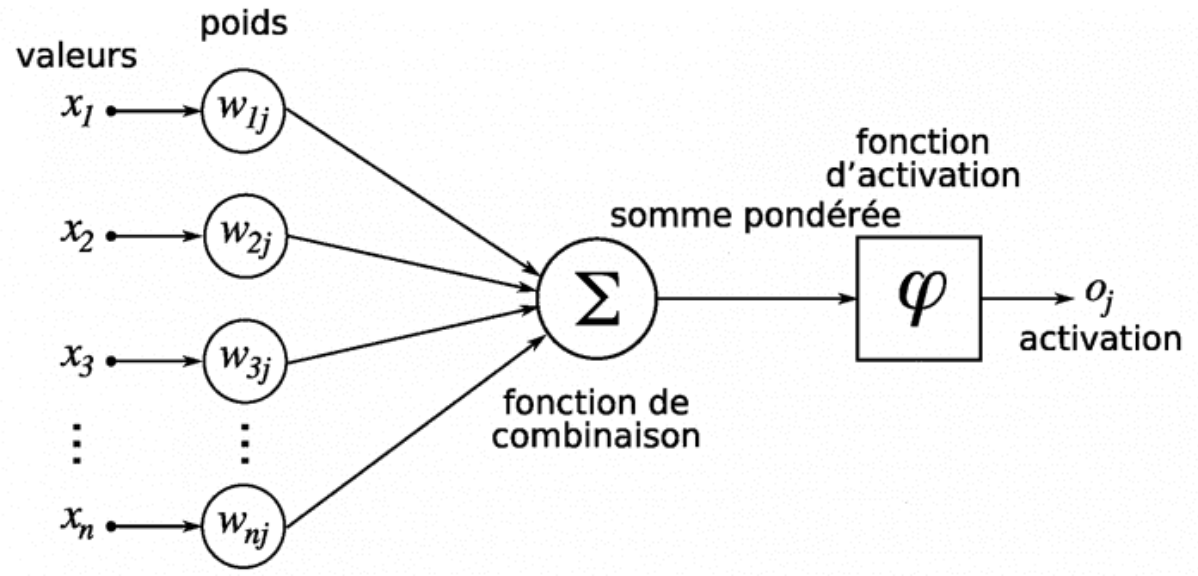

FIGURE 2.3 – Schéma d'un neurone artificiel
[7]

2.4.4.3 Fonctions d'activation

Les fonctions d'activation permettent de déterminer si les informations reçues par un neurone — à savoir la combinaison des poids et du biais — sont suffisantes pour activer ce neurone ou non. Autrement dit, elles vérifient si la valeur reçue dépasse un certain **seuil (threshold)** d'activation. Si c'est le cas, la sortie est transmise comme entrée à la couche suivante de neurones.

Le choix de la fonction d'activation dépend du type de problème traité. Il existe plusieurs fonctions d'activation, parmi lesquelles :

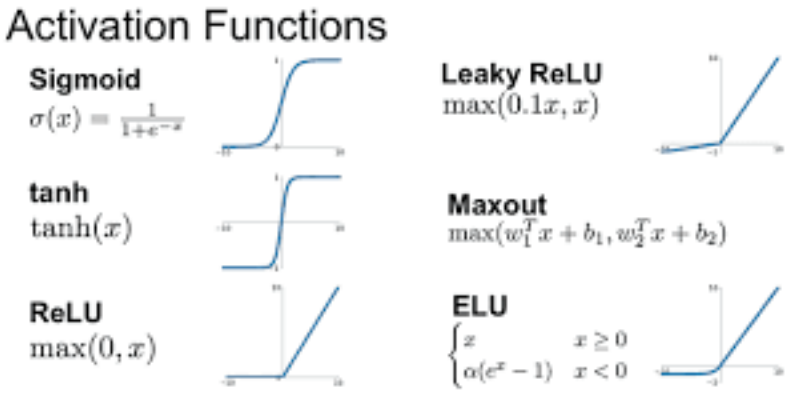

FIGURE 2.4 – Exemples de fonctions d'activation[7]

La fonction sigmoïde

La fonction sigmoïde fait partie des fonctions les plus largement utilisées. C'est une fonction non linéaire et plus particulièrement adaptée aux problèmes de classification binaire. Elle transforme n'importe quelle valeur d'entrée en une valeur comprise entre 0 et 1. Ainsi, pour une entrée au seuil, la sortie sera proche de 0,et pour une valeur d'entrée supérieure à ce seuil, la sortie sera proche de 1. La formule de la fonction sigmoïde est donnée par :

$$f(x) = \frac{1}{1+e^{-x}} \tag{2.2}$$

Fonction *Tanh* (Tangente hyperbolique)

La fonction *Tanh* est une fonction d'activation non linéaire, définie par l'équation suivante :

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{1 - e^{-2x}}{1 + e^{-2x}} \tag{2.3}$$

Elle est similaire à la fonction sigmoïde, mais ses valeurs sont comprises entre -1 et 1 . Ainsi, les entrées négatives produisent des sorties négatives, tandis que les entrées proches de zéro donnent des sorties proches de zéro. Cette fonction est souvent utilisée pour centrer les données autour de zéro et améliorer la convergence pendant l'entraînement.

Fonction *ReLU* (Rectified Linear Unit)

La fonction *ReLU* est l'une des fonctions d'activation les plus utilisées dans les réseaux de neurones profonds. Elle est définie comme suit :

$$f(x) = \max(0, x) \tag{2.4}$$

cette fonction est linéaire pour les valeurs positives et nulle pour les valeurs négatives. Elle permet de réduire le problème du *vanishing gradient*, mais ignore complètement les valeurs négatives, ce qui peut entraîner la désactivation de certains neurones (phénomène dit de « neurones morts »).

Fonction *Softmax*

La fonction *Softmax* est une extension de la fonction exponentielle, principalement utilisée dans les tâches de classification multi-classes. Elle transforme un vecteur de scores en une distribution de probabilités, où la somme des sorties est égale à 1. Elle est définie par :

$$f(x_i) = \frac{e^{x_i}}{\sum_{c=1}^{k} e^{x_c}} \tag{2.5}$$

où :

- x_i : la sortie du neurone correspondant à la classe i,
- k : le nombre total de classes.

cette fonction est idéale pour la couche de sortie d'un classifieur multi-classes, car elle fournit une interprétation probabiliste des prédictions.

2.4.5 Optimisation dans l'apprentissage profond

La performance d'un modèle de réseau de neurones dépend de plusieurs facteurs, dont le choix de la structure, très souvent mis en avant dans la littérature actuelle.[41][42][43] Une autre difficulté très importante réside dans l'entraînement du réseau, étape fondamentale mais difficile car très coûteuse en temps et en ressources. Cette dernière peut s'étendre de quelques jours à quelques semaines, voire plus, en fonction de la complexité du modèle et de la taille des données. Afin de répondre à ces contraintes, les algorithmes d'optimisation sont employés. Ces derniers sont principalement destinés à minimiser la fonction de perte (Loss Function), et secondairement à améliorer la vitesse et la qualité de l'apprentissage.

Le tableau suivant permet de mieux comprendre les algorithmes d'optimisation les plus utilisés :

L'algorithme **Adam** est actuellement l'un des plus utilisés dans le domaine de l'apprentissage profond. Il a démontré une grande efficacité, en particulier pour les réseaux de neurones récurrents et les architectures profondes. Il combine les avantages des méthodes *Momentum* et *RMSprop*, ce qui le rend polyvalent et performant sans nécessiter de réglage complexe.

Nom de l'optimiseur	**Description**	**Caractéristiques**	**Utilisation**
Gradient Descent	Calcule la direction de descente sur l'ensemble des données.	Précis mais très lent pour les grands ensembles de données.	Modèles simples ou petits jeux de données.
Stochastic Gradient Descent (SGD)	Met à jour les poids à chaque itération en utilisant un seul échantillon.	Rapide mais instable, provoque de fortes fluctuations.	Réseaux profonds avec beaucoup de données.
Mini-Batch Gradient Descent	Utilise de petits lots de données à chaque itération, combinant GD et SGD.	Bon compromis entre rapidité et stabilité.	Méthode la plus utilisée en pratique.
Adam	Estime les moments adaptatifs et ajuste automatiquement le taux d'apprentissage.	Rapide, efficace, peu sensible aux hyperparamètres, faible consommation mémoire.	Réseaux complexes ou grands ensembles de données.

TABLE 2.3 – Comparaison entre quelques algorithmes d'optimisation populaires

2.4.6 Architectures de réseaux profonds

Il existe de nombreuses architectures de réseaux de neurones, parmi lesquelles les CNN (Convolutional Neural Networks) et les LSTM (Long Short-Term Memory) occupent une place particulièrement importante.

2.4.6.1 CNN

L'architecture d'un CNN (réseau de neurones convolutif)[44] est une architecture à plusieurs types de couches disposées en série :

1. Couche de convolution

C'est la couche de base du CNN. Elle reçoit pour entrée l'image, et applique des filtres (ou noyaux de convolution) qui glissent sur l'image entre détecter des motifs locaux (bords, textures, formes)... Chaque filtre produit une carte de caractéristiques (feature map) qui indique à chaque position spatiale s'il y a un motif ou non.

Les poids des filtres sont partagés, ce qui réduit considérablement le nombre de paramètres comparé à un réseau entièrement connecté, et permet ainsi de mieux prendre en compte la localité spatiale.

On procède ensuite à l'application d'une fonction d'activation non-linéaire, en général la fonction ReLU (Rectified Linear Unit) qui va permettre d'introduire la non-linéarité essentielle à l'apprentissage de représentations complexes.

2. Couches de Pooling

Cette étape a pour fonction de réduire les dimensions spatiales (en hauteur et en largeur) des cartes de caractéristiques tout en gardant l'information pertinente.

Cela permet de diminuer le coût de calcul et d'introduire un certain degré d'invariance aux translations locales (ex. possibilité de reconnaître un objet même quand il a été légèrement déplacé dans l'image).

Les méthodes souvent employées sont le max pooling (conservation de la valeur maximale dans une région) ou le average pooling (conservation de la valeur moyenne dans une région) selon la tâche repérée. Les couches de pooling peuvent également être linéaires, c'est-à-dire qu'au lieu d'appliquer un noyau spatial glissant, on applique un facteur de sous-échantillonnage

3. Couches entièrement connectées

Après plusieurs couches de convolution et de sous-sampling, les cartes de caractéristiques sont aplanies pour former un vecteur.

Le dernier vecteur de caractéristiques est ensuite traité par une ou plusieurs couches entièrement connectées. Nous avons ainsi le type de réseau classique, celui des réseaux de neurones multicouches, pour réaliser la tâche de classification ou de régression qui nous intéresse. S'agissant de la dernière couche, il s'agira souvent d'une fonction d'activation appropriée, softmax par exemple, dans le cas d'une classification multiclasse.

4. Fonctions d'activation

La sortie de chaque opération de convolution est traitée par une fonction non linéaire, comme la ReLU, afin de donner la capacité au réseau d'apprendre une bonne représentation des données d'entrée

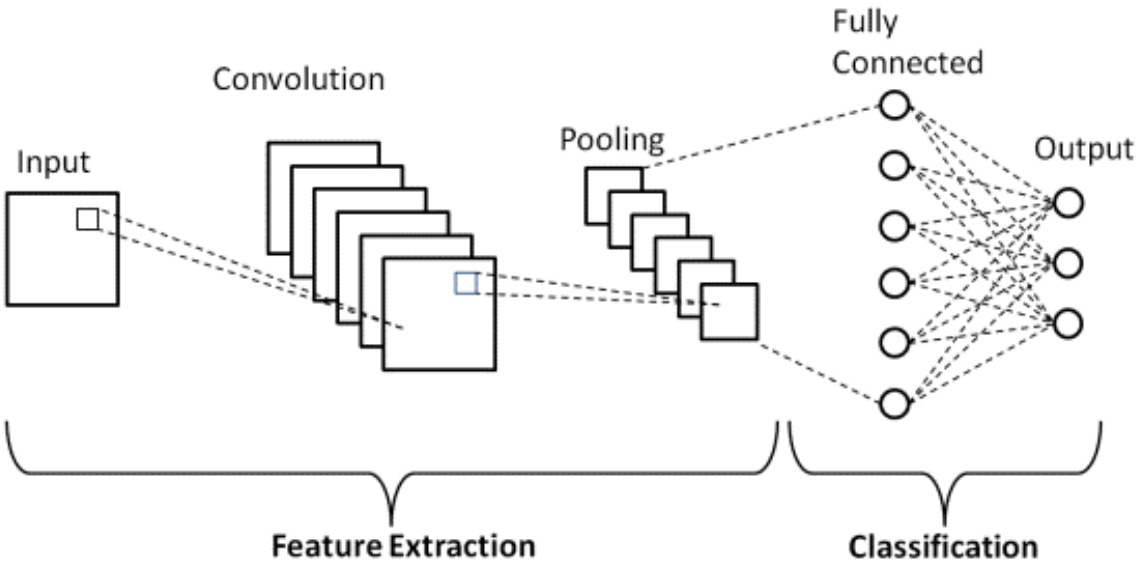

FIGURE 2.5 – CNN Architecture[8]

2.4.6.2 RNN,LSTM

Les réseaux de neurones récurrents (RNN)

Les réseaux de neurones récurrents (Recurrent Neural Network - RNN) étant l'un des modèles centraux du deep learning, ils sont capables d'influencer la sortie sur celle qui leur précède, car ils sont constitués de manière à mémoriser le résultat de l'opération précédente. Ainsi, le système qui en fait usage a été employé dans des applications remarquables dans la recherche vocale de Google , par exemple, en plus d'être utilisé pour, soyons plus sûrs, la résolution de certaines tâches de NLP (traduction automatique, génération de texte, ...).

LSTM (Long Short Term Memory)

Les mémoires à long et court terme (appelées LSTM pour Long Short Term Memory) ont été conçues par Hochreiter et Schmidhuber en 1997 pour résoudre le problème de l'apprentissage des dépendances à long terme sur des réseaux de neurones récurrents classiques. LSTM est une des principales instances de l'architecture récurrente existant au niveau des neurones dans les réseaux de neurones artificiels, où chacune des cellules neuronales est récurrente : chaque neurone prend en compte l'état du neurone dans un contexte donné pour ajuster sa sortie, la cellule LSTM ayant la particularité de savoir se souvenir sur des durées longues, ce qui lui permet d'apprendre de manière pertinente les dépendances (à long terme) sur la séquence de données. Depuis lors, d'innombrables tâches ont utilisé LSTM, notamment la langue naturelle pour la

traduction et la génération des textes, la compréhension et la synthèse de la parole, etc. L'une des difficultés principales rencontrées lors de l'apprentissage du RNN est qu'il est à concevoir efficacement.La question première concerne la diffusion du gradient à travers le temps discret qui est responsable de problèmes dits de stabilité et de convergence lors de la phase d'apprentissage. De nombreux apports ont été fournis dans ce cadre, via l'activation adaptée, des variantes de RNN ainsi que des techniques avancées d'optimisation. Ces résultats de recherche ont permis d'effectuer un apprentissage efficace des RNNs, qui ont depuis été appliqués avec succès à un large spectre de tâches.

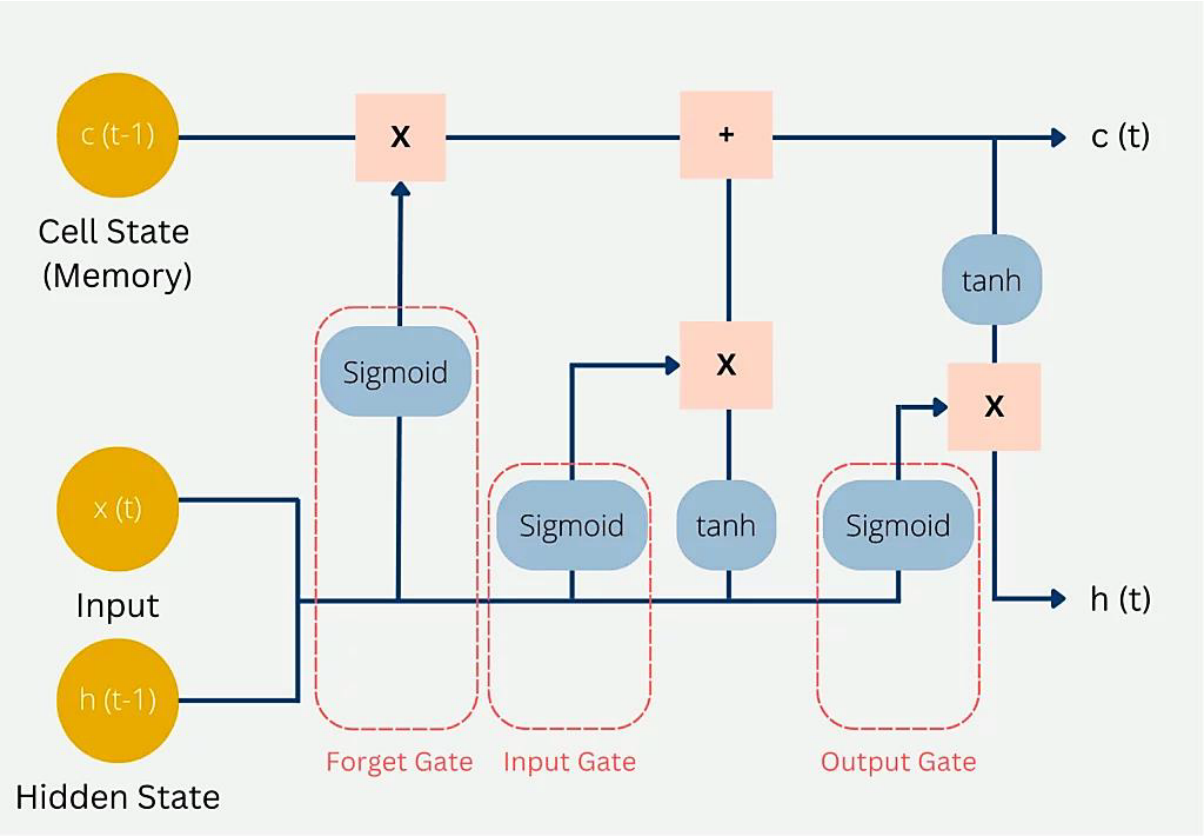

FIGURE 2.6 – Architecture LSTM[9]

2.5 Travaux connexes

Cette partie sera consacrée à la présentation des articles et recherches traitant du sujet de la reconnaissance des émotions à partir des signaux EEG en utilisant les techniques d'apprentissage profond.

Le premier article concerné est

Deep learning-based EEG emotion recognition[45] : Current trends and future perspectives, rédigé par Xiaohu Wang, Yongmei Ren, Ze Luo, Wei He, Jun Hong, et Yinzhen Huang.

Dans le présent article, nous proposons une revue exhaustive et à jour des méthodes efficaces d'apprentissage profond appliquées à la reconnaissance automatique des émotions corollairement déduites de signaux EEG. Le présent article propose notamment les bases théoriques et les jeux de données, en se focalisant sur les principales architectures de réseaux de neurones profonds : les réseaux de neurones convolutifs (CNN), les réseaux de neurones récurrents (RNN/LSTM) et les réseaux de croyance profonde (DBN).

Le présent article aborde également les principaux défis rencontrés dans ce champ d'investigation, en particulier la difficulté d'interpréter les résultats issus de réseaux profonds et la nécessité d'avoir accès à de grandes quantités de données diverses. Il présente aussi les espoirs futurs pour la conception de systèmes intelligents capables de saisir avec précision les émotions humaines.

Au sujet des résultats, les auteurs mettent en avant le fait que les techniques d'apprentissage profond permettent d'améliorer nettement la performance de la reconnaissance des émotions à partir des signaux EEG, avec des taux de classification dépassant souvent 85 sur les données de référence . Les CNN et les architectures hybrides associant CNN et LSTM sont particulièrement efficaces pour extraire des caractéristiques complexes et décrire la dynamique temporelle des signaux EEG.

Ce document conclut avec une réponse pratique suggérée, fruit de différentes recherches, proposée dans des domaines aussi variés que la médecine, l'éducation, le jeu, la sécurité routière et même en applications militaires.

De ce fait, cet article se veut une mise à jour scientifique du stade d'avancement des re-

cherches concernant la reconnaissance des émotions via EEG par apprentissage profond et un exposé sur le futur de ce domaine prometteur.

Le deuxième article concerné est

Hybrid Models for Improved Emotion Detection Based on EEG[46] : Insights from Applications in the DEAP Dataset || Badr Mouazen, Abdelaziz Benali, Nabil T. Chebchoub, et al., Sensors 2025

Dans cet article, on aborde l'amélioration de la détection des émotions à partir des signal EEG par l'intermédiaire d'un modèle hybride composé par l'algorithme classique combiné à l'apprentissage profond. Comme tableau d'entrées : LE DEAP Dataset qui contient divers EEG data de participants soumis à des stimuli émotionnelles seront utilisés.

L'article présente un travail visant à élaborer un modèle hybride composé par plusieurs classifications : les réseaux de neurones convolutifs (CNN), les réseaux récurrents (LSTMs,LGRUs), techniques classiques comme des machines à vecteur de support ainsi que des kénomètres voisins (SVM) et (KNN) pour augmenter le taux d'exactitude et d'efficacité des états émotionnels.

Les résultats d'étude démontrent que ce modèle hybride a quelque 85 à 95 pourcent de précision à partir de la reconnaissance des émotions, par le système inclus des avantages des méthodes héréditaires pour assurer des hauts niveau d'exactitude que les abord équivalent dans une telle évaluation en termes d'efficacité computationnelle. Par plus SHAP (SHapley Additive exPlanations) par taux de reconnaissance des algorithmes permet, de ce côté, d'identifier les caractéristiques de l'EEG ; ce qui augmente la transparence et la confiance vis-à-vis du système.

Le couple d'auteurs entre aux résultats avec une discussion d'avenir : larger en vue des ECOS quant à l'utilisation en les collections de données et les ajustements pour les utilisateurs cliniques et industriels, étude de dimensions ecophysiological plus pointilleuses comme la domination et l'appréciation.

Le troisième article concerné est

Auteurs suggérent une architecture CNN spécialement conçue pour extraire des caractéristiques spatiales et temporelles complexes des signaux EEG bruts sans l'extraction de caractéristiques par défauts [47] Li Zhang, Wei Chen et Ming Zhao in Real-World Deep Learning Approach for EEG-Based Emotion Recognition by Convolutional Neural Networks, IEEE Transactions on Affective Computing, 2024

Article sur la reconnaissance automatique des émotions à partir des signaux EEG. uniquement en termes de Deep Learning (CNN). Ainsi, soutient les auteurs une architecture CNN vraisemblablement née ou acquise, capable d'extraire des caractéristiques spatiales et temporelles non essentielles alors qu'il est pas nécessaire d'exhiber des célébrités ressource déjà préalablement.

Le but principal est de prouver que les CNN peuvent apprendre les données brutes EEG. Par conséquent, ils pourraient avoir un avantage en termes de précision et de rigidité lorsque viennent se classer les états émotionnels. Les données disséminées dans ce travail proviennent des diverses bases de données publiques DEAP et SEED, ce qui garantie la généralisation du modèle.

2.6 Conclusion

Les réseaux de neurones artificiels, inspirés de la structure et du fonctionnement du cerveau humain, constituent une pierre angulaire du développement des technologies d'intelligence artificielle. Ils sont utilisés pour la prédiction, la classification et la reconnaissance de motifs, en tirant parti de leur capacité d'apprentissage pour traiter les données et généraliser les résultats à de nouvelles entrées.

Ce chapitre a présenté les concepts fondamentaux liés à l'apprentissage profond, notamment l'intelligence artificielle et l'apprentissage automatique, en mettant l'accent sur le rôle des réseaux de neurones convolutifs (CNN) dans le traitement des données à structure spatiale, telles que les images, ainsi que celui des réseaux de mémoire à long terme (LSTM) dans l'analyse des données temporelles comme les signaux EEG, renforçant ainsi l'efficacité de la classification des états émotionnels complexes.

Chapitre 3

Implémentation et résultats

3.1 Introduction

Dans ce chapitre, nous présentons la mise en œuvre pratique de notre système de classification des émotions à partir des signaux EEG. L'objectif est d'évaluer l'efficacité de deux modèles d'apprentissage profond — CNN 1D et LSTM — sur deux bases de données EEG différentes. Nous décrirons d'abord l'environnement de travail, les outils utilisés, puis les étapes de prétraitement des données. Ensuite, nous détaillerons l'architecture des modèles mis en œuvre, avant de présenter et analyser les résultats expérimentaux à l'aide de métriques de performance telles que la précision et la matrice de confusion.

3.2 Architecture globale

Le schéma suivant illustre l'ensemble des étapes du processus de classification des émotions à partir des signaux EEG. Il présente un enchaînement logique allant de l'acquisition des données jusqu'à la prédiction de l'émotion, en passant par le prétraitement et l'apprentissage via des modèles d'apprentissage profond.

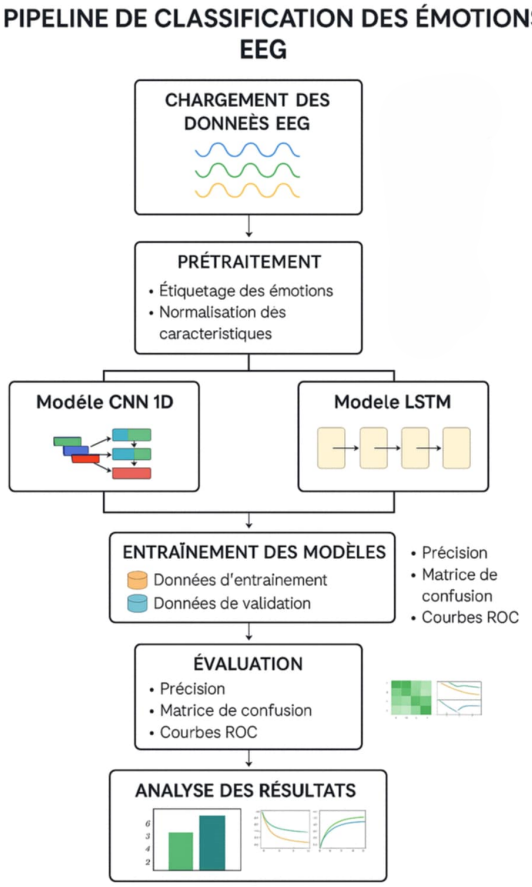

FIGURE 3.1 – Architecture globale du système

Cette architecture repose sur une approche séquentielle : les signaux EEG sont d'abord collectés à partir de bases de données spécifiques, puis prétraités afin de garantir la qualité des entrées. Par la suite, ils sont introduits dans des modèles CNN ou LSTM permettant d'extraire les caractéristiques pertinentes pour la tâche de classification. Le système aboutit finalement à la reconnaissance automatique des émotions à travers une sortie softmax représentant les différentes classes émotionnelles.

3.3 Environnement et Outils de Développement

3.3.1 Matériel Utilisé

Dans le cadre de ce travail, nous avons utilisé un ordinateur ayant les caractéristiques techniques suivantes :

Caractéristique	Spécification
Poste de travail	HP - Windows 11 Pro
Processeur	Intel Core i5-8350U @ 1.70GHz
RAM	8 Go
Type de système	Système 64 bits

TABLE 3.1 – Caractéristiques matérielles

3.3.2 Langage, Environnement et Bibliothèques Utilisés

- **Langage de programmation** :
  - Python : Le langage Python [48] est largement utilisé en apprentissage profond grâce à sa syntaxe simple, sa lisibilité et la richesse de ses bibliothèques comme TensorFlow et PyTorch, qui facilitent la conception et l'entraînement de modèles complexes.
- **Environnement** :
  - Google Colab :Google Colaboratory [49]est une plateforme gratuite basée sur les notebooks Jupyter, développée pour faciliter la recherche et l'apprentissage en machine learning. Elle permet d'exécuter du code et d'entraîner des modèles dans le cloud, sans nécessiter d'installation locale, ce qui en fait un outil accessible et pratique pour les chercheurs et étudiants.
- **Bibliothèques principales** :
- **TensorFlow** : Bibliothèque de référence développée par Google pour la conception et l'entraînement de modèles d'apprentissage profond. Elle permet la construction d'architectures complexes [50]via une approche orientée graphe.
- **NumPy** : Outil fondamental pour le calcul numérique [51], facilitant la manipulation efficace de tableaux multidimensionnels (matrices) et optimisant les opérations mathématiques de bas niveau.

- **Pandas** : Bibliothèque spécialisée dans la manipulation et l'analyse de données structurées [52]. Elle fournit des structures flexibles telles que les DataFrames, essentielles pour le nettoyage, la transformation et l'exploration des données.
- **Matplotlib / Seaborn** : Deux bibliothèques complémentaires dédiées à la visualisation de données [53] [54]. Tandis que Matplotlib permet une personnalisation fine des graphiques, Seaborn simplifie la création de visualisations statistiques informatives et esthétiques.
- **Scikit-learn** : Outil incontournable en machine learning [55], utilisé dans ce travail pour le prétraitement des données, la sélection de caractéristiques ainsi que l'évaluation des modèles. Elle offre une large gamme d'algorithmes supervisés et non supervisés via une interface simple et cohérente.

3.4 Système proposé

3.4.1 Ensembles de données

Dans cette étude, nous avons utilisé deux ensembles de données publiques contenant des signaux EEG associés à différents états émotionnels :

- **EEG Brainwave Dataset**[56] : Cette base contient des signaux EEG enregistrés via le casque *NeuroSky MindWave*. Elle comprend trois catégories émotionnelles principales : *Positive*, *Negative* et *Neutral*. Chaque échantillon représente un état émotionnel global, exprimé pendant une session donnée.

TABLE 3.2 – Caractéristiques du EEG Brainwave Dataset

Caractéristique	**Valeur**
Type de données	Signaux EEG bruts
Émotions représentées	3 classes (Positive, Negative, Neutral)
Format	CSV
Nombre d'échantillons	Plus de 13 000
Capteur EEG	NeuroSky MindWave (1 canal)

- **eeg-dataset-emotions** [57] : Cette base est structurée selon sept émotions fondamentales : *Happy*, *Sad*, *Angry*, *Fear*, *Disgust*, *Neutral*, et *Surprise*. Les données sont enregistrées sous forme de fichiers CSV représentant les variations des signaux EEG dans le temps.

TABLE 3.3 – Caractéristiques du eeg-dataset-emotions

Caractéristique	**Valeur**
Type de données	Séries temporelles EEG
Émotions représentées	7 classes (Happy, Sad, Angry, Fear, Disgust, Neutral, Surprise)
Format	CSV
Nombre d'échantillons	Environ 2 000
Capteurs EEG	De 1 à 14 selon l'enregistrement

3.4.2 Prétraitement des Données EEG

Dans notre travail, nous considérons le prétraitement des signaux EEG comme une étape cruciale avant l'entraînement des modèles d'apprentissage profond. Cette étape nous permet de garantir la qualité, la cohérence et la compatibilité des données avec les réseaux neuronaux utilisés.

- **Nettoyage** : Nous considérons le prétraitement des signaux EEG comme une étape cruciale avant l'entraînement des modèles d'apprentissage profond. Cette étape nous permet de garantir la qualité, la cohérence et la compatibilité des données avec les réseaux neuronaux utilisés.

```
                                        df =
df[df['label'].map(df['label'].value_cou
    nts()) >= 2].reset_index(drop=True)
```

- **Encodage des étiquettes** Nous avons converti les étiquettes des classes (émotions) en valeurs entières afin qu'elles puissent être interprétées correctement par les modèles d'apprentissage.
  — Dataset 1 :Transformation des labels textuel en entiers

```
    from sklearn.preprocessing import
                          LabelEncoder
              ()encoder = LabelEncoder
y_encoded = encoder.fit_transform(y)
```

— Dataset 2 :

Conversion des labels en entiers

Transformation en vecteurs one-hot

- **Normalisation des caractéristiques EEG** Les signaux EEG bruts présentent des amplitudes variables d'un canal à l'autre. Pour éviter que certaines caractéristiques ne dominent les autres lors de l'entraînement, nous avons appliqué une normalisation par centrage-réduction à l'aide de la méthode StandardScaler.

```
from sklearn.preprocessing import
                    StandardScaler
          ()scaler = StandardScaler
X_scaled = scaler.fit_transform(X)
```

- **Reshape des donnée**

Nous avons opté pour des modèles CNN et LSTM unidimensionnels, qui nécessitent des entrées tridimensionnelles afin de traiter efficacement les séquences de signaux EEG et d'en extraire des caractéristiques temporelles et spatiales pertinentes.

Pour CNN 1D :

```
                                X_cnn =
X_scaled.reshape(X_scaled.shape[0],
                 X_scaled.shape[1], 1)
```

Pour LSTM :

```
                                X_lstm =
X_scaled.reshape(X_scaled.shape[0], 1,
                    X_scaled.shape[1])
```

- **Découpage des ensombles**

Les données sont divisées en ensembles d'entraînement et de test, tout en conservant la répartition des classes à l'aide du paramètre stratify=y-qencoded, afin d'éviter tout déséquilibre entre les classes lors de l'apprentissage.

Dataset 1 :

— Entraînement : 80 % des données

— Test : 20 %

```
X_train, X_test, y_train, y_test =
                )train_test_split
          X_scaled, y_encoded,
    test_size=0.2, random_state=42,
              (stratify=y_encoded
```

Dataset 2 :

— Répartition des données :70 %

— Entraînement : 15 %

— Validation : 15 %

```
X_train, X_temp, y_train, y_temp =
train_test_split(X, y_categorical,
   test_size=0.3, random_state=42)
    X_val, X_test, y_val, y_test =
  train_test_split(X_temp, y_temp,
   test_size=0.5, random_state=42)
```

Afin de mieux comparer les étapes de prétraitement appliquées aux deux ensembles de données EEG, nous les avons synthétisées dans le tableau ci-dessous.

Étape	**emotions.csv**	**eeg_dataset_emotions.csv**
Type de données	Signaux EEG multi-caractéristiques	Données simplifiées (Attention, Méditation, Clignements)
Nettoyage	Suppression des classes peu fréquentes	Données relativement propres
Encodage des étiquettes	`LabelEncoder`	`LabelEncoder` + `to_categorical`
Normalisation	`StandardScaler`	`StandardScaler`
Reshape des données	$(n, f, 1)$ pour CNN $(n, 1, f)$pour LSTM	$(n, 3, 1)$ pour CNN $(n, 1, 3)$ pour LSTM
Division des données	80% apprentissage 20% test	70% apprentissage 15% validation 15% test

TABLE 3.4 – Comparaison des étapes de prétraitement pour les deux jeux de données EEG

3.4.3 Classification par modèles profonds

Nous avons utilisé deux types de modèles d'apprentissage profond pour la classification des émotions à partir des signaux EEG :

CNN 1D et LSTM. Ces modèles ont été choisis en raison de leur efficacité dans le traitement des données séquentielles et multidimensionnelles comme les signaux EEG.

3.4.3.1 Réseau de neurones convolutif 1D (CNN 1D)

Construction du modèle CNN 1D Nous avons également développé un modèle basé sur les **réseaux de neurones convolutifs unidimensionnels (CNN 1D)** pour la classification des émotions à partir des signaux EEG. Ce type de réseau est particulièrement adapté à l'analyse de données séquentielles telles que les séries temporelles ou les signaux EEG.

Le modèle reçoit en entrée un tenseur de forme (nombre d'échantillons, nombre de caractéristiques, 1). La première couche utilisée est une couche **Conv1D** avec 64 filtres, une taille de noyau de 3, et une fonction d'activation **ReLU**, permettant d'extraire des

motifs locaux dans les signaux.

Elle est suivie d'une couche **MaxPooling1D** avec une taille de filtre de 2, afin de réduire la dimensionnalité des données et de conserver les caractéristiques les plus importantes. Une deuxième couche **Conv1D**, cette fois avec 128 filtres, est ensuite ajoutée pour capturer des motifs plus complexes, suivie d'une seconde couche de **MaxPooling1D**.

Les sorties de ces couches convolutives sont ensuite aplaties à l'aide d'une couche **Flatten**, puis transmises à une couche **Dense** composée de 128 neurones avec activation **ReLU**. Une couche **Dropout** de 50% est appliquée pour réduire le risque de surapprentissage.

Enfin, la couche de sortie contient un nombre de neurones égal au nombre de classes, avec une fonction d'activation **Softmax**, permettant de prédire la probabilité d'appartenance à chaque classe émotionnelle.

La figure suivante illustre l'architecture typique d'un réseau de couches **CNN 1D** .

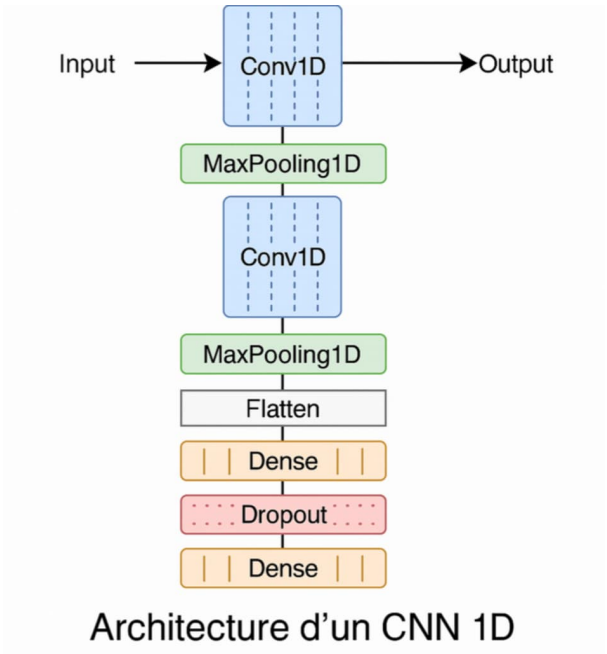

FIGURE 3.2 – Architecture CNN 1D

Formule de convolution :

$$y(t) = \sigma\left(\sum_{i=0}^{k-1} x(t+i) \cdot w_i + b\right) \tag{3.1}$$

où :

— $x(t)$ est l'entrée au temps t

— w_i représente les poids du filtre

— b est le biais

— σ est la fonction d'activation (ReLU)

Avantages de CNN 1D :

— Capacité à extraire des motifs locaux dans les signaux EEG

— Moins de paramètres que LSTM, donc apprentissage plus rapide

— Performant pour les signaux structurés et simples

3.4.3.2 Réseau LSTM (Long Short-Term Memory)

Construction du modèle LSTM Nous avons construit un modèle **LSTM** dans le but de classer les émotions à partir des signaux EEG, en tirant parti de sa capacité à traiter les données séquentielles et temporelles. Les données d'entrée ont d'abord été remodelées en un tenseur tridimensionnel de forme `(nombre_d'échantillons, 1, nombre_de_caractéristiques)` afin de répondre aux exigences des couches LSTM. Le modèle commence par une première couche `LSTM` composée de 128 unités, avec l'option `return_sequences=True` activée, permettant de transmettre la séquence complète à la couche suivante. Immédiatement après, une couche `Dropout` de 30% est appliquée pour éviter le surapprentissage. Ensuite, une deuxième couche `LSTM` est ajoutée, comportant 64 unités et ne retournant que la dernière sortie temporelle (`return_sequences=False`). Elle est suivie d'une autre couche `Dropout` avec le même taux.

Une couche `Dense` cachée de 64 neurones avec une fonction d'activation `ReLU` est ensuite insérée pour transformer les caractéristiques extraites en un espace plus compact. Une troisième couche `Dropout` est ajoutée afin d'améliorer la généralisation du modèle.

Enfin, la couche de sortie est composée d'un nombre de neurones égal au nombre de classes d'émotions, avec une fonction d'activation `Softmax`, permettant une classification multi-classes à partir des signaux EEG traités.

La figure suivante illustre l'architecture typique d'un réseau constitué de couches LSTM.

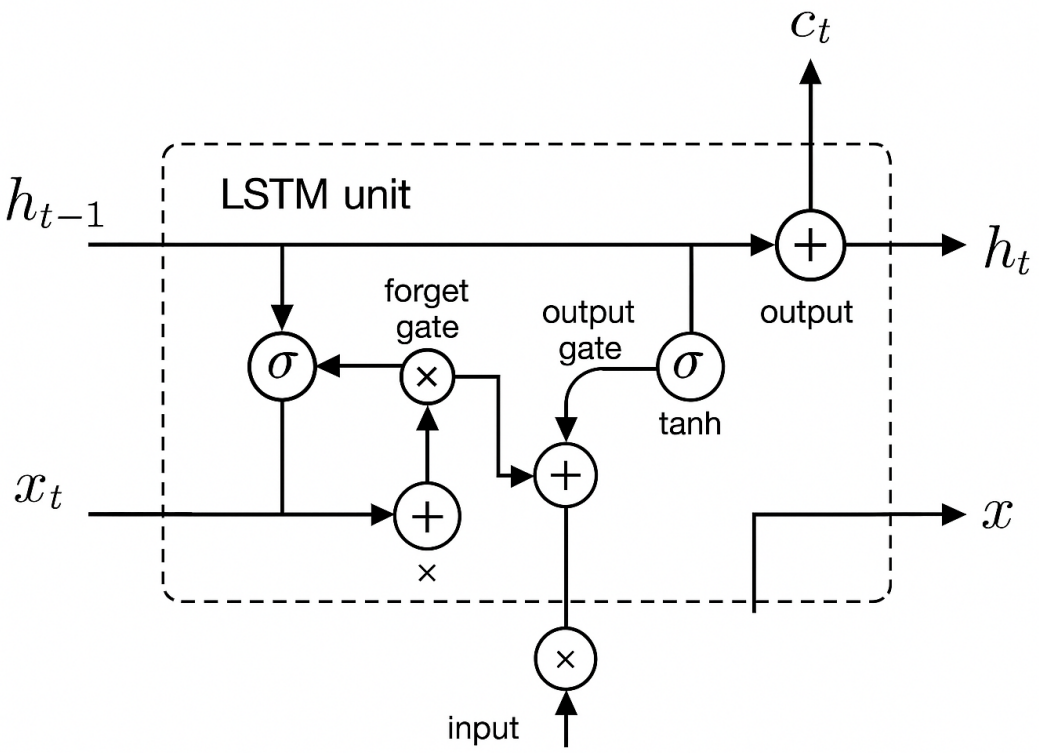

FIGURE 3.3 – Architecture de LSTM.

3.4.4 Entraînement et évaluation

3.4.4.1 Entraînement

Pour entraîner les modèles de classification (CNN 1D et LSTM), un ensemble de paramètres a été défini afin d'optimiser la phase d'apprentissage.

Le tableau suivant présente les principales configurations adoptées durant l'entraînement des modèles.

Paramètre	**Valeur utilisée**	**Remarque**
Optimiseur	Adam	Efficace pour l'apprentissage profond
Fonction de perte	`sparse_categorical_crossentropy` ou `categorical_crossentropy`	Selon le format des labels (entiers ou one-hot)
Nombre d'époques	30 à 50	Dépend de la convergence et stabilité du modèle
Taille de batch	32	Bon compromis entre rapidité et stabilité
Fonction d'activation	ReLU (cachée), Softmax (sortie)	ReLU pour l'apprentissage, Softmax pour la classification
Dropout	0.3 à 0.5	Réduction du surapprentissage
Callback utilisé	ModelCheckpoint	Sauvegarde automatique du meilleur modèle
Validation croisée	Séparation `train/test` avec `stratify`	Équilibrage des classes dans les ensembles

TABLE 3.5 – Paramètres d'entraînement des modèles

3.4.4.2 évaluation

L'évaluation des performances des modèles CNN et LSTM a été réalisée en se basant sur plusieurs métriques standards dans les problèmes de classification, à savoir : la précision (accuracy), la matrice de confusion, les courbes ROC, ainsi que les scores de rappel (recall), de précision (precision) et F1-score.

Les résultats expérimentaux montrent que les deux modèles atteignent des performances élevées, avec une précision globale dépassant 96 %. Le modèle CNN s'est distingué par une convergence plus rapide et une meilleure stabilité sur les données EEG tabulaires, tandis que le modèle LSTM a présenté des résultats compétitifs, notamment grâce à sa capacité à capturer les dynamiques temporelles des signaux EEG.

L'analyse des matrices de confusion a permis d'identifier les émotions les mieux reconnues par les modèles (telles que *joie* et *neutre*), ainsi que celles qui ont été sujettes à confusion (comme *peur* et *colère*). Cela met en évidence l'impact du chevauchement des signaux cérébraux entre certaines émotions.

De plus, les courbes ROC générées pour chaque classe révèlent un bon pouvoir discriminant des modèles, avec des surfaces AUC proches de 1, ce qui confirme la fiabilité globale du système de classification proposé.

Enfin, le taux d'erreur observé sur les données de test reste faible, et l'écart de performance entre les données d'apprentissage et de test est limité. Cela indique que les modèles généralisent bien et qu'ils ne souffrent pas de surapprentissage significatif.

3.5 Analyse des résultats

Pour évaluer la performance d'apprentissage de nos modèles CNN et LSTM, nous avons analysé les courbes d'entraînement et de validation (accuracy et loss) générées pour chaque base de données. Ces courbes permettent de visualiser la manière dont le modèle apprend au fil des époques et d'identifier d'éventuels problèmes de surapprentissage ou de sous-apprentissage.

3.5.1 Analyse des courbes ROC

Les quatre graphiques présentés illustrent les courbes ROC des performances de nos deux modèles (CNN et LSTM) sur deux ensembles de données distincts (DATA 1 et DATA 2).

Remarque générale : plus la courbe ROC se rapproche du coin supérieur gauche, meilleure est la capacité du modèle à distinguer entre les différentes classes.

Pour CNN et LSTM sur DATA 1, nous observons que les deux modèles atteignent d'excellentes performances, avec des aires sous la courbe (AUC) proches de la valeur idéale (1), ce qui traduit une forte capacité de discrimination.

Pour CNN et LSTM sur DATA 2, les performances restent globalement satisfaisantes, bien que nous remarquions une légère baisse de l'AUC par rapport à DATA 1. Cela suggère que le deuxième jeu de données est plus complexe ou contient des signaux moins distincts, rendant la séparation entre les classes plus difficile.

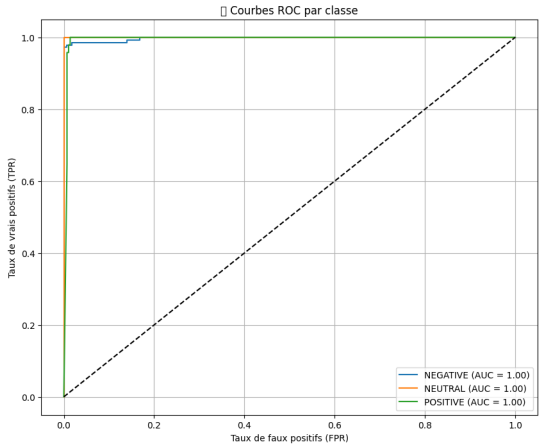

courbe ROC DATA 1 CNN

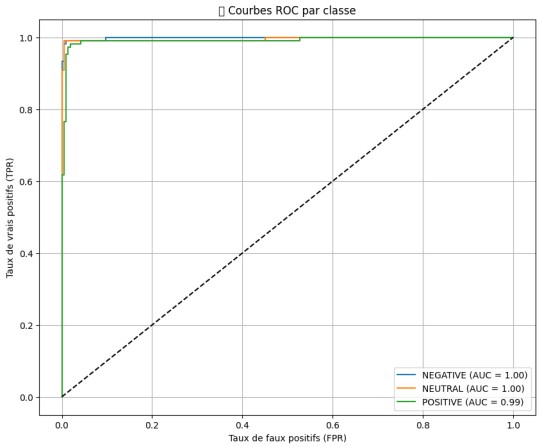

courbe ROC DATA 1 LSTM

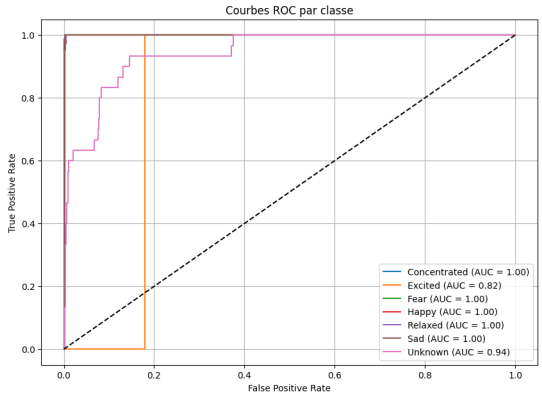

courbe ROC Data 2 CNN

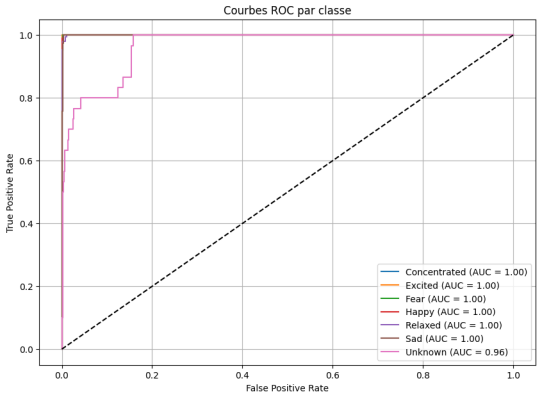

courbe ROC DATA 2 LSTM

FIGURE 3.4 – Matrice de confusion

3.5.2 Matrice de confusion

Les matrices de confusion permettent d'évaluer la performance des modéles de classification en détaillant les cas de bonne et mauvaise classification selon les étiquettes réelles et prédites

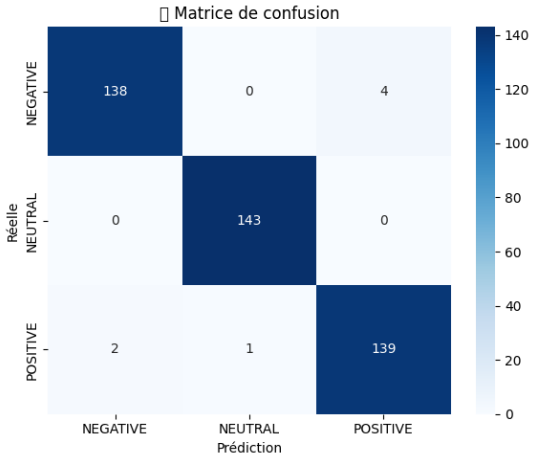

Matrice de confusion DATA 1 CNN

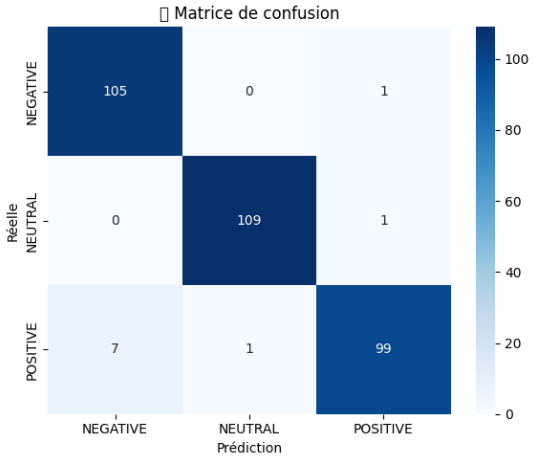

Matrice de confusion DATA 1 LSTM

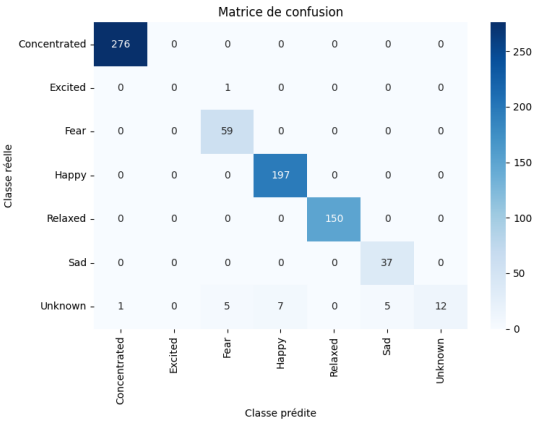

Matrice de confusion DATA 2 CNN

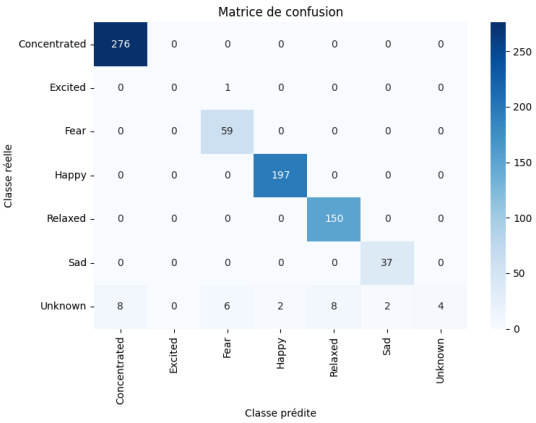

(Matrice de confusion DATA 2 LSTM

FIGURE 3.5 – Matrice de confusion

3.5.3 Courbes de Précision (Accuracy et Loss)

Nous constatons qu'il n'y a pas une grande différence entre la précision obtenue sur l'ensemble d'apprentissage et celle obtenue sur l'ensemble de test. Par ailleurs, le taux d'erreur sur les données de test demeure acceptable, ce qui indique que le modèle que nous avons conçu fonctionne correctement et ne présente pas un surapprentissage significatif.

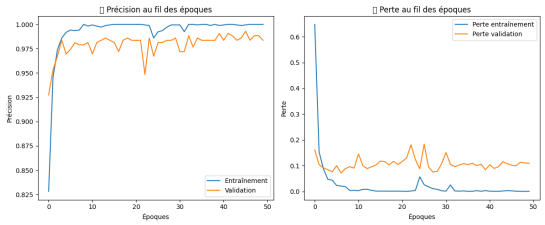

Précision et perte au fil des époques DATA 1 CNN

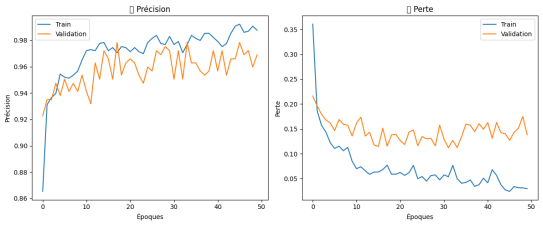

Précision et perte au fil des époques DATA1

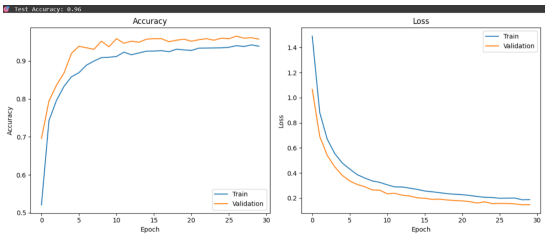

Précision et perte au fil des époquesdata Data 2 CNN

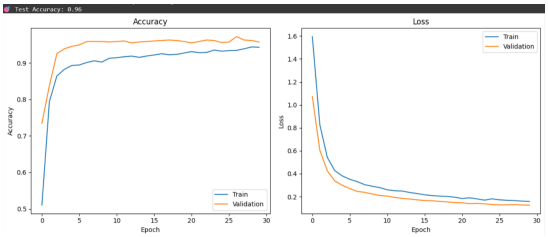

Précision et perte au fil des époques DATA 2 LSTM

FIGURE 3.6 – Matrice de confusion

3.5.4 Différences entre les résultats des modèles

Ce tableau présente les résultats obtenus pour les deux ensembles de données en utilisant le modèle CNN1D et LSTM.

Modèle	**emotions.csv**	**eeg-dataset-emotions**
CNN	98.30%	96.00%
LSTM	96.90%	96.00%

TABLE 3.6 – Précision comparative des modèles

Les deux modèles ont obtenu des résultats satisfaisants pour la classification des émotions EEG. Le CNN a atteint une précision élevée de 98,30 Le LSTM a montré de bonnes performances, surtout sur les données séquentielles. Ces résultats soulignent l'efficacité de l'apprentissage profond pour l'analyse des signaux EEG.

Remarque : Ensembles de données 01 est :

EEG Brainwave Dataset (emotions.csv),

Base de donnée 02 est : dataset-emotions,

Conclusion

Dans ce chapitre, nous avons conçu et développé un système basé sur des techniques d'apprentissage profond pour la classification des émotions humaines à partir de signaux EEG. Deux types de réseaux neuronaux profonds ont été utilisés : un réseau neuronal convolutif unidimensionnel (CNN) pour extraire les caractéristiques spatiales, et un réseau de mémoire à long terme (LSTM) pour capturer la dynamique temporelle des signaux cérébraux.

À l'aide de deux bases de données EEG distinctes et après plusieurs étapes de prétraitement, les modèles ont pu être entraînés efficacement, atteignant des précisions dépassant les 96% dans certains cas. Les résultats ont montré que le modèle CNN est plus performant en termes de rapidité et de précision sur des données statiques, tandis que le modèle LSTM présente un avantage lorsqu'il s'agit de traiter des séquences temporelles complexes.

Conclusion générale

Dans ce travail, nous avons étudié la classification des émotions humaines à partir des signaux EEG en utilisant des techniques d'apprentissage profond, notamment les réseaux CNN 1D et LSTM. Cette approche s'inscrit dans le cadre du développement d'outils intelligents permettant une meilleure compréhension des états émotionnels, avec des applications potentielles dans les domaines de la santé mentale, des neurosciences et des interfaces homme-machine (IHM).

Après avoir présenté les bases biologiques des signaux EEG ainsi que les fondements de l'apprentissage profond, nous avons appliqué deux modèles distincts sur deux jeux de données EEG : l'un complexe et multicanal (emotions.csv), et l'autre plus simple basé sur des indicateurs cognitifs (eeg dataset emotions.csv).

Les résultats obtenus sont prometteurs. Toutefois, certaines limitations ont été identifiées, telles que la taille réduite et la diversité restreinte des bases de données utilisées, ainsi que l'absence de validation en temps réel. L'application concrète de ces modèles nécessite également des ressources informatiques considérables et un ajustement précis des hyperparamètres.

En ce qui concerne les perspectives futures, nous proposons d'explorer des architectures hybrides telles que CNN-BiLSTM, d'intégrer des techniques comme le mécanisme d'attention (Attention Mechanism) et l'Intelligence Artificielle Explicable (Explainable AI), ainsi que de collecter des données EEG plus riches et plus variées. Ces améliorations permettront de renforcer la précision des modèles et leur applicabilité dans des contextes réels.

Références

[1] Parlons sciences. (2025) Lobes du télencéphale dans le cerveau humain. Image de Henry Vandyke Carter, domaine public, via Wikimedia Commons. Consulté le 9 mai 2025. [Online]. Available : https://parlonssciences.ca/ressources-pedagogiques/documents-dinformation/le-cerveau-humain

[2] Arizona State University School of Life Sciences, "Life sciences resources and research," https://libguides.asu.edu/lifesciences, 2025, consulté le 19 mai 2025.

[3] Biologie101.fr. (2024) Message nerveux et sa transmission. Consulté le 30 mai 2025. [Online]. Available : https://www.biologie101.fr/terminale-svt/mouvement-systeme-nerveux-comportements/message-nerveux-et-sa-transmission

[4] eCampusOntario. (2025) Neuroscience 1 : Introduction to eeg and data analysis. Consulté le 9 mai 2025. [Online]. Available : https://ecampusontario.pressbooks.pub/rspnc/chapter/neuroscience-1/

[5] J. du Net. (2021) Les neurosciences ont inspiré l'intelligence artificielle : le modèle neuronal et les concepts. Consulté le 26 mai 2025. [Online]. Available : https://www.journaldunet.com/intelligence-artificielle/1494055-les-neurosciences-ont-inspire-l-intelligence-artificielle-le-modele-neuronal-et-les-conc

[6] Natural Solutions. (2022) Histoire du deep learning. Natural Solutions. Consulté le 26 mai 2025. [Online]. Available : https://www.natural-solutions.eu/blog/histoire-du-deep-learning

[7] MonCoachData. (2023) Comprendre les réseaux de neurones. Consulté le 4 juin 2025. [Online]. Available : https://moncoachdata.com/blog/

comprendre-les-reseaux-de-neurones/

[8] N. Pussadeniya. (2022) Introduction to cnn architecture. Consulté le 27 mai 2025. [Online]. Available : https://medium.com/@Nirodya_Pussadeniya/introduction-to-cnn-architecture-53f2f8e8705f

[9] D. Camp. (2023) Lstms : Long short-term memory networks explained. Accessed : 2025-06-06. [Online]. Available : https://databasecamp.de/en/ml/lstms

[10] G. Bloch and P. Vernier, "Le cerveau exploré," *Clefs CEA*, no. 62, 2014, consulté le 9 mai 2025. [Online]. Available : https://www.cea.fr/multimedia/Documents/publications/clefs-cea/Clefs62-cerveau-explore.pdf

[11] Nagwa. (2024) . 2 2025. [Online]. Available : https://www.nagwa.com/ar/explainers/492141307986/

[12] A. inconnu, *Réussir tout le semestre 1 IFSI*. Éditions Elsevier Masson, 2023, p. 118, consulté le 2 juin 2025. [Online]. Available : https://stm.cairn.info/reussir-tout-le-semestre-1-ifsi--9782311662405-page-118?lang=fr

[13] C. Brière and R. Lopez, "Introduction à l'électro-encéphalographie," PowerPoint slides, 2025, récupéré de http://www.med.univ-montp1.fr/enseignement/cycle_2/UE_systeme_neurosensoriel/Ressources_locales/ED_en_EEG.pdf.

[14] Société canadienne du cancer. (2025) Électroencéphalogramme (eeg). Société canadienne du cancer. Consulté le 9 mai 2025. [Online]. Available : https://cancer.ca/fr/treatments/tests-and-procedures/electroencephalogram-eeg

[15] Elsan. (2025) Électroencéphalogramme (eeg) : définition et indications - déroulement et résultats. Elsan, groupe hospitalier privé. Consulté le 9 mai 2025. [Online]. Available : https://www.elsan.care/fr/pathologie-et-traitement/maladies-neurologiques/electroencephalogramme-EEG-deroulement-resultat

[16] D. Sellam, "Électroencéphalographie," 2025, deuxième année médecine – Physiologie. Document PDF consulté le 9 mai 2025. [Online]. Available : https://facmed-univ-oran.dz/ressources/fichiers_produits/fichier_produit_2295.pdf

[17] The Decision Lab. (2025) L'émotion affecte-t-elle notre capa-

cité à prendre des décisions rationnelles ? Consulté le 9 mai 2025. [Online]. Available : https://thedecisionlab.com/fr/insights/health/emotion-affects-our-ability-rational-decisions

[18] P. Livet, "L'émotion et la prise de décision," *Revue française de gestion*, no. 2, pp. 33–47, 2008, consulté le 9 mai 2025. [Online]. Available : http://www.cairn.info/revue-francaise-de-gestion-2008-2-page-33.htm

[19] Université Laval - Aide en psychologie. Comprendre et réguler ses émotions. Consulté le 9 mai 2025. [Online]. Available : https://www.aide.ulaval.ca/psychologie/textes-et-outils/developpement-personnel/comprendre-et-reguler-ses-emotions/

[20] Le Labo des savoirs. (2025) Prise de décision : écoutons nos émotions. Consulté le 9 mai 2025. [Online]. Available : https://labodessavoirs.fr/prise-de-decision-ecoutons-nos-emotions/

[21] Psylio. Liste des émotions. Consulté le 9 mai 2025. [Online]. Available : https://jade.psylio.com/fr/blog/liste-emotions

[22] C. Audrin, "Le rôle de l'émotion dans la prise de décision intuitive," *ProQuest Dissertations Publishing*, 2012, consulté le 9 mai 2025. [Online]. Available : https://www.proquest.com/scholarly-journals/le-r%C3%B4le-de-l%C3%A9motion-dans-la-prise-d%C3%A9cision/docview/1021198706/se-2

[23] J.-F. Richard, "Intelligence émotionnelle et processus de décision," *Gestion 2000*, no. 3, pp. 67–83, 2011, consulté le 9 mai 2025. [Online]. Available : https://shs.cairn.info/revue-gestion-2000-2011-3-page-67?lang=fr

[24] La Psychologie Positive. Liste des émotions. Consulté le 9 mai 2025. [Online]. Available : https://www.lapsychologiepositive.fr/liste-des-emotions/

[25] École de la fonction publique du Canada. (2024) Explorer ses émotions (trn4-j45) - outil de travail pour la gestion des émotions. Consulté le 9 mai 2025. [Online]. Available : https://www.csps-efpc.gc.ca/tools/jobaids/managing-emotions-fra.aspx

[26] Emotion Compass. Primary and secondary emotions. Consulté le 9 mai 2025. [Online]. Available : https://emotioncompass.org/fr/information/primary-secondary-emotions/

[27] Enfant Encyclopédie. Les émotions - synthèse. Consulté le 9 mai 2025. [Online]. Available : https://www.enfant-encyclopedie.com/pdf/synthese/emotions

[28] Commission Nationale de l'Informatique et des Libertés (CNIL), "Intelligence artificielle, de quoi parle-t-on ?" https://www.cnil.fr/fr/intelligence-artificielle/intelligence-artificielle-de-quoi-parle-t-on, 2025, consulté le 10 mai 2025.

[29] P. européen. (2020) Intelligence artificielle : définition et utilisation. Consulté le 3 juin 2025. [Online]. Available : https://www.europarl.europa.eu/topics/fr/article/20200827STO85804/intelligence-artificielle-definition-et-utilisation

[30] I. A. School. (s.d.) Intelligence artificielle : définition, usages et enjeux de l'ia. Consulté le 3 juin 2025. [Online]. Available : https://www.intelligence-artificielle-school.com/ecole/technologies/intelligence-artificielle-definition-usages-et-enjeux-de-lia/

[31] DataScientest. (2024) Machine learning : tout savoir. Consulté le 3 juin 2025. [Online]. Available : https://datascientest.com/machine-learning-tout-savoir

[32] Commission Nationale de l'Informatique et des Libertés (CNIL), "Apprentissage profond (deep learning)," https://www.cnil.fr/fr/definition/apprentissage-profond-deep-learning, 2025, consulté le 10 mai 2025.

[33] DataScientest, "Deep learning : définition," https://datascientest.com/deep-learning-definition, 2025, consulté le 10 mai 2025.

[34] Cognizant, "Deep learning," https://www.cognizant.com/fr/fr/glossary/deep-learning, 2025, consulté le 11 mai 2025.

[35] EDC Paris Business School, "Deep learning : Définition, applications et avantages," https://www.edcparis.edu/fr/blog/deep-learning-definition-applications-et-advantages, 2025, consulté le 11 mai 2025.

[36] Queoval Formation, "Le deep learning, révolution de l'ia," https://www.queoval-formation.com/actualites/le-deep-learning-revolution-de-l-ia, 2025, consulté le 11 mai 2025.

[37] Amazon Web Services (AWS), "Qu'est-ce que le deep learning ?" https://aws.amazon.com/fr/what-is/deep-learning/, 2025, consulté le 11 mai 2025.

[38] Retengr, "Deep learning : définitions, applications, avantages et inconvénients," https://www.retengr.com/le-blog/deep-learning-definitions-applications-avantes-inconvenients, 2025, consulté le 11 mai 2025.

[39] R. Team. (2024) Deep learning : comprendre les réseaux de neurones artificiels (artificial neural networks). Consulté le 3 juin 2025. [Online]. Available : https://ryax.tech/fr/deep-learning-comprendre-les-reseaux-de-neurones-artificiels-artificial-neural-networks/

[40] OdevEn. (2023) Introduction aux réseaux de neurones informatiques. Consulté le 3 juin 2025. [Online]. Available : https://odeven.fr/introduction-aux-reseaux-de-neurones-informatiques/

[41] M. Nielsen, *Neural Networks and Deep Learning*. Determination Press, 2015, available online at http://neuralnetworksanddeeplearning.com.

[42] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.

[43] S. Ruder, "An overview of gradient descent optimization algorithms," *arXiv preprint arXiv :1609.04747*, 2016.

[44] I. Rakhmatulin, M.-S. Dao, A. Nassibi, and D. Mandic, "Exploring convolutional neural network architectures for eeg feature extraction," *Sensors (Basel)*, vol. 24, no. 3, p. 877, 2024, published : 2024-01-29. [Online]. Available : https://www.mdpi.com/1424-8220/24/3/877

[45] X. Wang, Y. Ren, Z. Luo, W. He, J. Hong, and Y. Huang, "Deep learning-based eeg emotion recognition : Current trends and future perspectives," *Journal of*

Neural Engineering, vol. 21, no. 3, p. 035012, 2024, consulté le 21 mai 2025. [Online]. Available : https://iopscience.iop.org/article/10.1088/1741-2552/ad1234

[46] B. Mouazen, A. Benali, N. T. Chebchoub *et al.*, "Enhancing eeg-based emotion detection with hybrid models : Insights from deap dataset applications," *Sensors*, vol. 25, no. 6, p. 1827, 2025, consulté le 21 mai 2025. [Online]. Available : https://www.mdpi.com/1424-8220/25/6/1827

[47] L. Zhang, W. Chen, and M. Zhao, "Eeg-based emotion recognition using graph convolutional neural network with dual attention mechanism," *Frontiers in Computational Neuroscience*, vol. 18, p. 1416494, 2024, consulté le 21 mai 2025. [Online]. Available : https://www.frontiersin.org/journals/computational-neuroscience/articles/10.3389/fncom.2024.1416494/full

[48] P. S. Foundation, "Tutoriel python 3.13," https://docs.python.org/fr/3.13/tutorial/index.html, 2025, [En ligne ; consulté le 6 juin 2025].

[49] Google, "Google colaboratory — plateforme gratuite de notebooks jupyter dans le cloud," https://colab.research.google.com/, 2025, [En ligne ; consulté le 6 juin 2025].

[50] M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean, M. Devin, S. Ghemawat, I. Goodfellow, A. Harp, G. Irving, M. Isard, Y. Jia, R. Jozefowicz, L. Kaiser, M. Kudlur, J. Levenberg, D. Mané, R. Monga, S. Moore, D. Murray, C. Olah, M. Schuster, J. Shlens, B. Steiner, I. Sutskever, K. Talwar, P. Tucker, V. Vanhoucke, V. Vasudevan, F. Viégas, O. Vinyals, P. Warden, M. Wattenberg, M. Wicke, Y. Yu, and X. Zheng, "Tensorflow : Large-scale machine learning on heterogeneous systems," https://www.tensorflow.org, 2015, software available from tensorflow.org.

[51] NumPy Developers, "NumPy : The fundamental package for scientific computing with Python," https://numpy.org/, 2024, [En ligne ; consulté le 6 juin 2025].

[52] M. Sarda, "Data analysis using pandas in python | k21academy, cloud training program," https://k21academy.com/datascienceblog/introduction-to-pandas, 2024, [En ligne ; consulté le 6 juin 2025].

[53] J. D. Hunter, “Matplotlib : A 2d graphics environment,” *IEEE*, 2007.

[54] M. Waskom, “seaborn : statistical data visualization,” *Journal of Open Source Software*, 2021.

[55] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay, “Scikit-learn : Machine learning in python,” *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.

[56] birdy654, “Eeg brainwave dataset : Feeling emotions,” https://www.kaggle.com/datasets/birdy654/eeg-brainwave-dataset-feeling-emotions, 2021, accessed : 2025-06-06.

[57] A. BV, “Eeg dataset - emotions,” https://www.kaggle.com/datasets/abhishekbv01/eeg-dataset-emotions, 2022, accessed : 2025-06-06.