

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE
MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA RECHERCHE
SCIENTIFIQUE

ÉCOLE NATIONALE POLYTECHNIQUE



المدرسة الوطنية المتعددة التقنيات
Ecole Nationale Polytechnique

Département d'électronique

Projet de Fin d'études

Pour l'obtention du diplôme d'ingénieur d'état en Électronique

Traitement et classification du signal EEG pour des applications BCI
et Pathologique

Anes KRIBA & Nazim SEHAL

Sous la direction de :

Dr. Farid HARIZI CDTA

Dr. Nesrine BOUADJENEK ENP

Présenté et soutenu publiquement le (21/06/2023)

Composition du jury :

Président :	Pr.ADNANE Mourad	ENP
Promoteur :	Dr. HARIZI Farid	CDTA
Co-Promoteur :	Dr.BOUADJENEK Nesrine	ENP
Examineur :	Dr.BERRANI Sid-Ahmed	ENP

ENP 2023

10 Rue des Frères OUDEK, El Harrach 16200 Alger Algérie.

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE
MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA RECHERCHE
SCIENTIFIQUE

ÉCOLE NATIONALE POLYTECHNIQUE



المدرسة الوطنية المتعددة التقنيات
Ecole Nationale Polytechnique

Département d'électronique

Projet de Fin d'études

Pour l'obtention du diplôme d'ingénieur d'état en Électronique

Traitement et classification du signal EEG pour des applications BCI
et Pathologique

Anes KRIBA & Nazim SEHAL

Sous la direction de :

Dr. Farid HARIZI CDTA

Dr. Nesrine BOUADJENEK ENP

Présenté et soutenu publiquement le (21/06/2023)

Composition du jury :

Président :	Pr.ADNANE Mourad	ENP
Promoteur :	Dr. HARIZI Farid	CDTA
Co-Promoteur :	Dr.BOUADJENEK Nesrine	ENP
Examineur :	Dr.BERRANI Sid-Ahmed	ENP

ENP 2023

10 Rue des Frères OUDEK, El Harrach 16200 Alger Algérie.

ملخص

إن فهم سلوك الدماغ البشري له أهمية حاسمة في تطوير التقنيات العصبية. ومن الأدوات الأساسية في هذا المجال استخدام إشارات مخطط الدماغ ، والتي تحتل مكانة بارزة. يهدف مشروعنا إلى إنشاء نظام تشخيص لمرض انفصام الشخصية ، وهو مرض يُساء فهمه ووصمه إلى حد كبير. في الوقت نفسه ، نحن مهتمون أيضًا بتطبيقات واجهة الدماغ والحاسوب من أجل تطوير أنظمة تسمح للدماغ بالتواصل مع الكمبيوتر وإصدار الأوامر دون ارتباط مادي. في هذا السياق ، ستشمل دراستنا استكشاف أنواع مختلفة من المصنفات والمرور بعدة مراحل من المعالجة المسبقة واستخراج الميزات. أخيرًا ، نقوم بتطوير تحليل مقارنة مع العمل الحالي في هذا المجال.

كلمات مفتاحية : انفصام ، تخطيط كهربية الدماغ ، واجهة الدماغ والحاسوب ، التشوشات ، التصنيف

Abstract

Understanding human brain behaviour is of crucial importance in the development of neurological technologies. One of the essential tools in this field is the use of EEG signals, which play a key role. The aim of our project is to set up a diagnostic system for schizophrenia, a largely unknown and stigmatised illness. At the same time, we are also interested in brain-computer interface (BCI) applications, with a view to developing systems that enable the brain to communicate with the computer and issue commands without a physical link. In this context, our study will involve exploring different types of classifiers and going through several stages of pre-processing and feature extraction. Finally, we develop a comparative analysis with existing work in the field.

keywords : Schizophrenia, EEG, brain-computer interface, artefacts, classification.

Résumé

La compréhension du comportement cérébral humain revêt une importance cruciale dans le développement des technologies neurologiques. Parmi les outils incontournables dans ce domaine l'exploitation des signaux EEG, qui occupent une place prépondérante. Notre projet vise à mettre en place un système de diagnostic de la schizophrénie, une maladie largement méconnue et stigmatisée. Parallèlement, nous nous intéressons également aux applications de l'interface cerveau-ordinateur (BCI) afin de développer des systèmes qui permettent au cerveau de communiquer avec l'ordinateur et faire des commandes sans un lien physique. Dans ce contexte, notre étude comprendra l'exploration de différents types de classifieurs et passant par plusieurs étapes de prétraitement et de l'extraction des caractéristiques. Enfin nous élaborons une analyse comparative avec les travaux existants dans le domaine.

Mots clés : Schizophrénie, EEG, Brain-computer Interface, artefacts, classification.

Dédicaces

Je dédie ce travail à ma famille, qui m'a soutenu tout au long de ce parcours. Leur amour, leur encouragement, leurs sacrifices et leur soutien inconditionnel ont été les moteurs de ma réussite.

À ma grand-mère, Mima, qui n'a jamais cessé de m'aimer, m'encourager et prier pour que je réussisse. Je lui dédie ce travail avec une profonde gratitude et un amour éternel.

À Massyl, Riad et Samy, qui ne sont plus des amis, mais des frères à qui je souhaite un avenir plein de succès et de réussite.

*À Heather, l'amie qui était toujours une source d'inspiration, encouragement, et de motivation pour moi,
Thank you for everything.*

Je tiens à exprimer ma gratitude envers tous mes amis et toutes les personnes qui m'ont apporté leur aide, que ce soit par de petites attentions ou des mots qui m'ont rendu heureux. Je suis reconnaissant envers chaque personne qui m'a offert des expériences ou des leçons de vie, m'aidant ainsi à grandir en tant qu'individu.

Merci à tous.

Remerciement

Tout d'abord, nous voudrions profiter de l'occasion pour exprimer nos profondes gratitudee et nos remerciements à nos chères familles, d'avoir toujours été à nos côtés, pour leur soutiens, leurs sacrifices et leurs prières et sans qui nous ne serions pas là aujourd'hui.

Nous tenons à exprimer nos sincères remerciements à notre directeur de thèse **M.HARIZI Farid** chercheur au sein du Centre de Développement des Technologies Avancées (CDTA) pour ses conseils et son soutien constant et sa présence permanente et pour les connaissances qu'il partage toujours si abondamment.

Nous voudrions remercier grandement notre superviseur et professeur, **Mme. BOUADJENEK Nesrine** pour tout son aide, sa gentillesse, sa rigueur et disponibilité ainsi que leurs précieux conseils et apports pour améliorer notre mémoire.

Par la suite, Nous adressons nos sincères remerciements à **M.ADENANE Mourad** qui nous fait l'honneur de présider le jury et à **M.BERRANI Sid-Ahmed**, d'avoir accepté d'examiner ce mémoire.

Nous remercions particulières nos amis Maroua et Romeila qui nous ont aidé lors de ce travail, ainsi que les étudiants de la meilleure promotion qui est devenue une deuxième famille **ELN MATCH** pour Leurs encouragements, leur collaboration, leur soutien, et pour tous les souvenirs que nous avons pu créer ensemble.

Merci à tous.

Table des matières

Liste des tableaux

Table des figures

Introduction générale	11
1 Généralités et fondements théoriques	12
1.1 Introduction	13
1.2 Aspects biologiques du cerveau	13
1.3 La Schizophrénie	15
1.4 Brain Computer Interface (BCI)	16
1.4.1 Type de BCI	16
1.4.1.1 Invasif :	16
1.4.1.2 Semi-invasif :	16
1.4.1.3 Non-invasif :	16
1.4.2 Applications de BCI	17
1.5 l'Électroencéphalographie (EEG)	17
1.5.1 Définition	17
1.5.2 Placement des électrodes	18
1.5.3 Types de montage	19
1.5.3.1 Montage bipolaire	19
1.5.3.2 Montage de référence moyen	20
1.5.3.3 Montage référentiels	20
1.5.4 Caractéristiques et nature des signaux EEG	20
1.5.4.1 Onde Delta	21

1.5.4.2	Onde Thêta	21
1.5.4.3	Onde Alpha	21
1.5.4.4	Onde Bêta	21
1.5.4.5	Onde Gamma	21
1.6	L'EEG dans notre problématique	22
1.6.1	Schizophrénie	22
1.6.2	Brain Computer Interface	23
1.7	Architecture des systèmes du traitement et la classification	23
1.7.1	Prétraitement	24
1.7.2	Extraction des caractéristiques :	25
1.8	État de l'art	26
1.8.1	La détection de schizophrénie	26
1.8.2	Application BCI	27
1.9	Conclusion	27
2	Méthodologie d'analyse et de classification	28
2.1	Introduction	29
2.2	Prétraitement	29
2.2.1	Segmentation	29
2.2.2	Filtre coupe-bande	30
2.2.3	Lissage des signaux (Smoothing)	30
2.2.4	Filtre à réponse impulsionnelle finie	31
2.2.4.1	Fenêtre de Hamming	31
2.2.4.2	Fenêtre de Hanning	31
2.2.4.3	Fenêtre de Blackman	32
2.2.4.4	Fenêtre de Bartlett	32
2.2.5	L'Analyse en Composantes Indépendantes (ACI)	33
2.3	Extraction des caractéristiques	34
2.3.1	Caractéristiques statiques	34
2.3.2	Caractéristiques des fréquentielle	34
2.3.3	Caractéristiques dynamiques non linéaires	35

2.4	Outils de classification	38
2.4.1	Régression logistique	38
2.4.2	Machine à vecteurs de support	39
2.4.2.1	Linéairement séparables	39
2.4.2.2	Non linéairement séparables	40
2.4.3	Réseau de neurones artificiels	41
2.4.3.1	Architecture de L'ANN	42
2.4.3.2	Réseau neuronal convolutif	46
2.4.3.3	Bloc des couches d'extraction des caractéristiques	46
2.4.3.4	Bloc des couches de classification	48
2.5	Conclusion	49
3	Analyse et résultats expérimentaux	50
3.1	Introduction	51
3.2	Description de les bases de données	51
3.2.1	Schizophrénie	51
3.2.2	BCI	52
3.3	Logiciels et librairies	53
3.3.1	Python	53
3.3.2	MNE	53
3.3.3	Scikit-learn	54
3.3.4	TensorFlow	54
3.3.5	Google Colaboratory	54
3.4	Analyse des données et résultats	55
3.4.1	Pré-traitement de données	55
3.4.2	Résultats expérimentaux	57
3.4.2.1	La détection de la Schizophrénie	57
3.4.2.2	Application BCI	63
3.5	Conclusion	66
	Bibliographie	68

Liste des tableaux

1.1	Estimation volumétrique et fonctionnement des composantes du néocortex . . .	14
3.1	Description de la base de données de la schizophrénie	51
3.2	Évaluation des performances sans filtre FIR	58
3.3	Évaluation des performances à l'aide de la fenêtre Hamming	58
3.4	Évaluation des performances à l'aide de la fenêtre Hanning	58
3.5	Évaluation des performances à l'aide de la fenêtre Blackman	59
3.6	Évaluation des performances des caractéristiques statiques	62
3.7	Évaluation des performances des caractéristiques fréquentielle (Welch)	62
3.8	Évaluation des performances des caractéristiques fréquentielle (Multitaper) . . .	62
3.9	Évaluation des performances des caractéristiques dynamiques non linéaires . . .	62
3.10	Évaluation des performances des caractéristiques dynamiques non linéaires . . .	63
3.11	Évaluation des performances des caractéristiques dynamiques non linéaires pour l'application BCI	63
3.12	Évaluation des performances des caractéristiques statiques pour l'application BCI	63
3.13	Performances du modèle CNN entraîné sur 80 participants	65

Table des figures

1.1	Zones anatomique du cerveau	13
1.2	anatomie fonctionnelle d'un neurone	14
1.3	Différents emplacements des électrodes pour les types de BCI	17
1.4	Illustration des enregistrements EEG	18
1.5	Zones fonctionnelles du cerveau	18
1.6	Le système international de placement d'électrodes 10-20	19
1.7	Montage bipolaire	19
1.8	Montage moyen	20
1.9	Montage référentiels	20
1.10	Bandes de fréquence des signaux EEG	22
1.11	Architecture du système de traitement et classification des signaux EEG	24
2.1	Exemple sur la segmentation des données	30
2.2	lissage des signaux	31
2.3	Fenêtre de Hamming - matlab	31
2.4	Fenêtre de Hanning - matlab	32
2.5	Fenêtre de Blackman - matlab	32
2.6	Fenêtre de Bartlett - matlab	32
2.7	Analyse en Composantes Indépendantes	33
2.8	Représentation schématique des limites de décision hypothétiques pour deux classes dans l'espace prédicteur original (à gauche) et l'espace transformé (à droite). classes dans l'espace prédicteur original (à gauche) et l'espace caractéristique transformé (à droite)	39
2.9	Linéairement séparables	40
2.10	Un neurone humain	41
2.11	Un neurone artificiel	41

2.12	Réseau de neurone avec une couche cachée	42
2.13	Graphe de fonction d'activation à seuil	43
2.14	Graphe de fonction linéaire	44
2.15	Graphe de sigmoïde fonction	44
2.16	Graphe de tanh	45
2.17	Graphe de ReLU	45
2.18	Architecture standard d'un CNN	46
2.19	Couche de convolution	47
2.20	Opération de Pooling (avec le max-pooling et average-pooling)	48
2.21	Bloc de classification	49
3.1	Emplacement des électrodes pour la base de donnée de la schizophrénie	52
3.2	Paradigme temporel de l'ensemble des données	52
3.3	Emplacement des électrodes pour la base de donnée de BCI	53
3.4	Composantes indépendantes pour une personne saine(droite) et une personne schizophrène (gauche)	56
3.5	Réduction d'artefactes	57
3.6	Représentation DSP par différents types de fenêtres (Méthode Welch)	60
3.7	Représentation DSP par différents types de fenêtres (Méthode Classique)	60
3.8	Représentation DSP par différents types de fenêtres (Méthode Multitaper)	61
3.9	Représentation DSP par différents types de fenêtres (Méthode Classique)	61
3.10	Résumé sur la couche d'extraction caractéristiques du CNN utilisé	65
3.11	Graphe de l'exactitude entre l'imagerie motrice et sa correspondance en réel pour chaque patient	65

Introduction générale

L'électroencéphalogramme (EEG) est un outil puissant permettant de comprendre les activités électriques du cerveau, tant extracrâniennes qu'intracrâniennes. La classification automatique et précise de ces signaux EEG revêt une grande importance dans l'évaluation des épilepsies et détection des pathologies. En effet, les signaux EEG contiennent des informations caractéristiques sur les ondes cérébrales, ce qui en fait une source précieuse de données pour diagnostiquer et traiter les maladies neurologiques. La capacité à extraire et à classifier ces informations de manière fiable et efficace contribue à améliorer la précision et la compréhension de la pathologie, ouvrant ainsi de nouvelles perspectives dans son diagnostic et sa prise en charge.

Tout au long de notre thèse nous nous intéressons à deux domaines neurologiques où les signaux EEG jouent un rôle crucial. Le premier domaine est la détection des pathologies et plus précisément la schizophrénie qui est un trouble neurologique courant touchant environ 1% de la population mondiale, soit environ 28 millions de personnes. Notre choix est de s'intéresser à cette pathologie pour plusieurs raisons. Tout d'abord, il y a un manque d'attention et de prise en charge de la schizophrénie dans les pays sous-développés, y compris notre pays, l'Algérie. De plus, il existe un manque de vigilance et de connaissances concernant cette pathologie. Enfin, les causes de la schizophrénie restent largement inconnues, et sa structure complexe nécessite une approche approfondie pour améliorer sa compréhension et sa prise en charge.

Le deuxième domaine concerne les applications des interfaces cerveau-ordinateur (BCI) qui sont de nos jours vastes et en constante expansion. Elles révolutionnent différents domaines tels que la médecine, la réadaptation, les jeux vidéo et la réalité virtuelle. Les applications BCI sont utilisées en médecine pour le diagnostic et le traitement de troubles neurologiques, ainsi que pour la réadaptation des patients avec des lésions médullaires ou des membres amputés. Dans le domaine du divertissement, elles permettent une interaction immersive dans les jeux vidéo et la réalité virtuelle. Les applications BCI offrent ainsi de nouvelles possibilités pour améliorer la qualité de vie et repousser les limites technologiques.

Ce mémoire est structuré en trois chapitres de la manière suivante :

- **Chapitre I** : Ce chapitre présente le contexte médical en retraçant l'impact de la pathologie ainsi et des applications BCI sur les personnes et sur la société ainsi que les travaux effectués.
- **Chapitre II** : Ce chapitre fournit la théorie des méthodes de filtrage, les caractéristiques et les classifieurs employés.
- **Chapitre III** : Dans ce chapitre nous parlerons plus en détails du travail effectué dans notre projet à travers des ressources utilisées ainsi que du modèle et de l'architecture adoptée. Nous concluons par une discussion et une comparaison des résultats des tests effectués.

Chapitre 1

Généralités et fondements théoriques

1.1 Introduction

Dans ce chapitre nous allons introduire d'une manière détaillée les aspects biologiques du cerveau en relation avec la schizophrénie, ainsi que l'interface cerveau-ordinateur (BCI) et l'utilisation de l'électroencéphalographie (EEG) dans notre problématique. Nous commencerons par examiner la physiologie du cerveau et son lien avec la schizophrénie, en mettant l'accent sur les altérations neurologiques observées dans ce trouble mental. Nous explorerons ensuite le concept de BCI, qui permet une communication directe entre le cerveau et les dispositifs externes, offrant ainsi de nouvelles possibilités de diagnostic et de traitement. Nous nous pencherons également sur l'utilisation de l'EEG, une technique non invasive qui enregistre l'activité électrique du cerveau, dans notre domaine d'étude. Ensuite, nous aborderons l'architecture des systèmes de traitement et de classification des signaux EEG, en mettant en évidence les différentes étapes de prétraitement et d'extraction des caractéristiques nécessaires à l'analyse des données cérébrales. Enfin, nous examinerons l'état de l'art des travaux réalisés dans la littérature scientifique, afin de comprendre les avancées et les perspectives actuelles dans notre domaine de recherche.

1.2 Aspects biologiques du cerveau

Le cerveau occupe une position centrale dans notre système nerveux. Il joue le rôle de chef d'orchestre en recevant, traitant et transmettant les informations à notre corps. En plus de cela, il abrite divers processus cognitifs liés à la connaissance, tels que la mémoire, le langage, le raisonnement, l'intelligence, la résolution de problèmes, la perception et l'attention. Ces processus se distinguent des aspects émotionnels de la fonction mentale, pour cela nous présentons brièvement le cerveau des vertébrés, en particulier chez les humains, ainsi que le système nerveux central et ses composantes principales.

Le cerveau humain est une structure complexe composée de plusieurs parties qui travaillent en synergie pour réguler et soutenir les fonctions cognitives, émotionnelles et physiologiques. Les principales sous-parties du cerveau tel que le cortex cérébral, le cortex frontal, le cervelet et le tronc cérébral sont présentées dans la figure 1.1 [1].

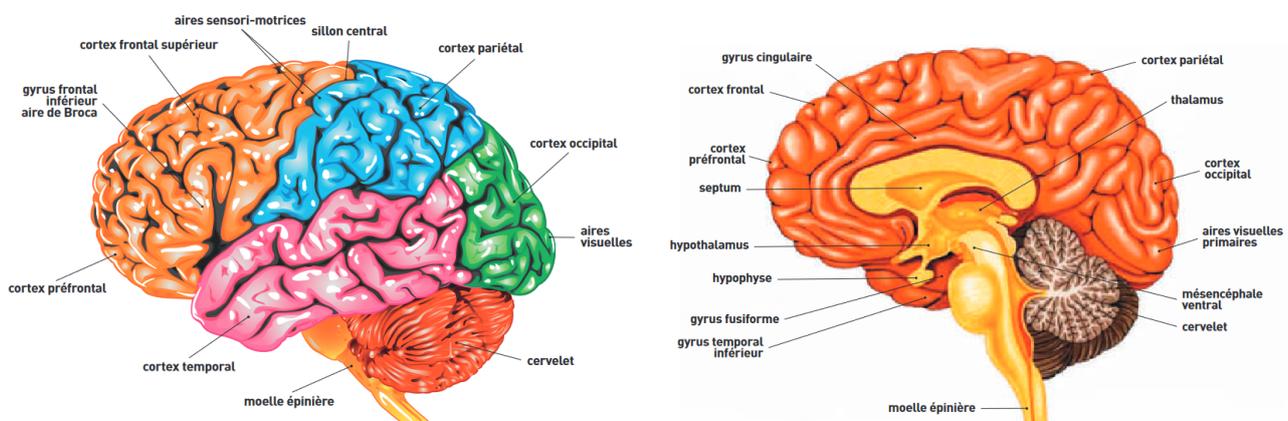


FIGURE 1.1 – Zones anatomique du cerveau

Le néocortex est une structure cérébrale qui se trouve dans la partie externe du cerveau, connue sous le nom de cortex cérébral. Ce dernier est impliqué dans de nombreuses

fonctions cognitives supérieures, tel que la perception sensorielle, la mémoire, le langage, la pensée abstraite et la prise de décision. Il joue également un rôle essentiel dans le traitement de l'information provenant des sens et dans la coordination des actions et des comportements complexes.

Le néocortex se compose essentiellement de neurones qui sont des cellules nerveuses jouant un rôle central dans la transmission de l'information dans le cerveau et qui sont responsables de la communication électrochimique en utilisant des signaux électriques et des neurotransmetteurs pour transmettre les informations entre les cellules. La figure 1.2 illustre l'anatomie fonctionnelle d'un neurone.

En se basant sur le travail de Bryan Kolb et de Ian Q Whishaw " Cerveau et comportement " [2] on peut estimer les volumes des composants essentiellement du néocortex et leur fonctionnement se résume dans le tableau 1.1.

TABLE 1.1 – Estimation volumétrique et fonctionnement des composantes du néocortex

Composant	Proportion Volumique	Fonctionnement
Axones	37%	transmission des signaux électriques des cellules nerveuses vers d'autres cellules
Dendrites	22%	transmission des signaux vers le corps cellulaire
Boutons	13%	transmission des signaux électriques entre les neurones
Épines	5%	traitement et stockage de l'information dans le cerveau
Glie	12%	maintien de l'équilibre chimique, protection des neurones et la régulation de l'environnement neuronal
Autres	12%	Synapses, Récepteurs, Canaux ioniques

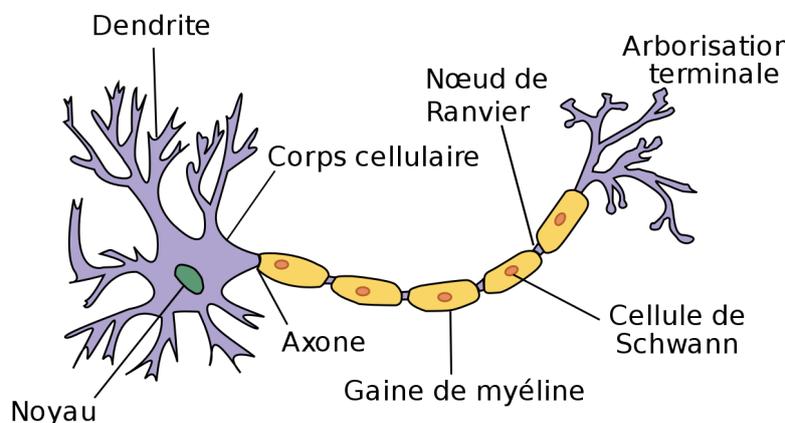


FIGURE 1.2 – anatomie fonctionnelle d'un neurone

L'axone, de forme cylindrique est responsable de la transmission des impulsions élec-

triques. Les dendrites sont connectées aux axones ou aux dendrites des autres cellules et reçoivent les impulsions électriques provenant d'autres cellules nerveuses, comme illustré dans la figure 1.1. Chaque nerf humain est généralement connecté à environ 10000 autres nerfs. L'activité électrique du système nerveux est principalement due aux courants circulant entre les extrémités des dendrites, les axones et les dendrites des cellules. Ces signaux ont une amplitude dans la gamme des μV et des fréquences inférieures à 100 Hz et sont connues sous le nom de signaux EEG [3].

1.3 La Schizophrénie

La schizophrénie est un trouble mental grave caractérisé par une perte de contact avec la réalité. Les symptômes comprennent des hallucinations, des délires, des pensées désorganisées et des difficultés relationnelles. [4]

Elle impacte profondément la vie quotidienne des personnes concernées, entravant leur fonctionnement professionnel, éducatif et social. Les symptômes sont variables et peuvent survenir de manière épisodique, avec des périodes de décompensation suivies de rémissions partielles. Cependant, certains individus peuvent présenter des symptômes constants. Les symptômes se regroupent en trois catégories distinctes.

1. Symptômes positifs :

- Hallucinations : perception de choses qui n'existent pas dans la réalité, le plus souvent auditives sous la forme de voix entendues.
- Délires : croyances fausses et irrationnelles, souvent paranoïaques ou grandioses.
- Pensée désorganisée : difficulté à organiser les idées, discours déstructurés.
- Comportements moteurs agités ou catatoniques : agitation excessive ou absence de mouvement et de réactivité.

2. Symptômes négatifs :

- Affect plat : diminution de l'expression émotionnelle, paraissant indifférent ou sans réaction émotionnelle appropriée.
- Avolition : perte de motivation ou incapacité à se fixer des objectifs.
- Alogie : diminution de la quantité de parole, des réponses verbales ou de la fluidité du discours.
- Retrait social : retrait progressif des activités sociales et diminution de l'intérêt pour les interactions sociales.

3. Symptômes cognitifs :

- Difficultés de concentration et de mémoire : diminution de l'attention, de la concentration et de la capacité à se souvenir des informations.
- Difficultés d'apprentissage : troubles de l'apprentissage de nouvelles informations et de l'organisation des idées.
- Difficultés d'exécution des tâches : difficulté à planifier et à exécuter des tâches complexes.

La schizophrénie touche environ 24 millions de personnes, soit une sur 300 (0,32 %), dans le monde. Ce taux est de 1 personne sur 222 (0,45 %) parmi les adultes [5]. Elle n'est pas aussi courante que beaucoup d'autres troubles mentaux. La schizophrénie débute le plus souvent à la fin de l'adolescence et entre 20 et 30 ans, et généralement plus tôt chez les hommes que chez les femmes.

1.4 Brain Computer Interface (BCI)

L'interface cerveau-ordinateur - *en anglais Brain Computer Interface* - est une méthode de communication basée sur l'activité neuronale générée par le cerveau et indépendante des voies de sortie normales des nerfs périphériques et des muscles. L'activité neuronale utilisée dans l'ICB (ou BCI) peut être enregistrée à l'aide de techniques invasives ou non invasives. L'objectif de la BCI n'est pas de déterminer l'intention d'une personne en écoutant l'activité cérébrale, mais plutôt de fournir un nouveau canal de sortie pour le cerveau qui nécessite un contrôle adaptatif volontaire de la part de l'utilisateur.

1.4.1 Type de BCI

Il y a différents types de BCI qui dépendent de l'emplacement de l'électrode au niveau de la tête, la figure 1.3 montre la différence entre les emplacements de chaque type.[6] [7]

1.4.1.1 Invasif :

Les types invasifs de BCI sont implantés directement dans le cerveau au cours d'une intervention neurochirurgicale. Il existe des BCI à unité unique, qui détectent le signal d'une seule zone de cellules cérébrales, et des BCI à unités multiples, qui détectent le signal de plusieurs zones. La qualité du signal est maximale, mais la procédure pose plusieurs problèmes, comme le risque de formation de tissus cicatriciels. Le corps réagit au corps étranger et forme une cicatrice autour des électrodes, ce qui entraîne une détérioration du signal. Comme la neurochirurgie peut être un processus risqué et coûteux, la cible de BCI invasif est principalement constituée de patients aveugles et paralysés.

1.4.1.2 Semi-invasif :

Dans cette méthode, les électrodes sont placées à l'intérieur du crâne sur la surface exposée du cerveau. En termes de science du cerveau, ces dernières sont placées soit à l'extérieur de la dure-mère (épidurale), soit sous la dure-mère (sous-durale).

De nombreuses électrodes sont présentes dans la bande et la grille d'électrodes, ce qui nous permet de couvrir de grandes zones du cerveau. L'ECOG est la principale technique utilisée dans cette méthode.

La résolution spatiale de l'ECOG qui est de l'ordre du dixième de millimètre est de l'ordre du centimètre pour l'EEG, est beaucoup plus élevée pour la raison le signal n'a pas besoin de voyager pour atteindre le cuir chevelu. Les électrodes ECOG ne sont placées sur le cerveau que lors d'une intervention chirurgicale nécessaire.

1.4.1.3 Non-invasif :

Il mesure les signaux cérébraux en plaçant les électrodes sur le cuir chevelu, la partie la plus externe du cerveau. Il existe plusieurs techniques non invasives utilisées pour étudier le cerveau. L'EEG est la méthode la plus courante et la plus rentable. D'autres technologies appliquant cette méthode non invasive sont le MEG, le PET et l'IRM, etc.

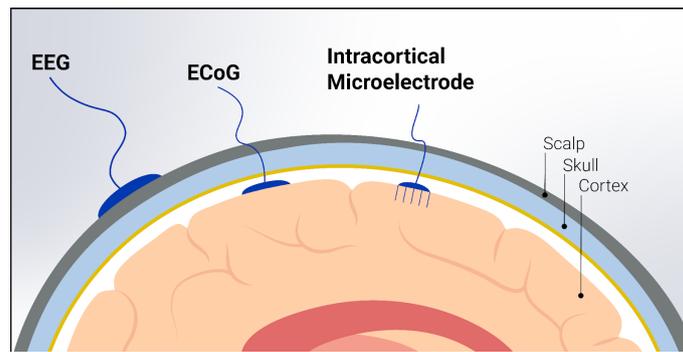


FIGURE 1.3 – Différents emplacements des électrodes pour les types de BCI

1.4.2 Applications de BCI

Les BCI couvrent plusieurs applications dans différents domaines et ne se limitent pas seulement sur le domaine médical. Les applications comprennent la neuroergonomie, la médecine, l'éducation et l'autorégulation, l'environnement intelligent, et les divertissements et les jeux, etc.

Dans le seul domaine des soins de santé, l'interface cerveau-machine peut être utilisée pour prévenir, détecter et diagnostiquer, et réhabiliter et restaurer une maladie.

L'interface cerveau-machine permet également une excellente coopération entre l'internet des objets et les technologies de l'Interface Machine-Cerveau, créant ainsi des environnements intelligents tels que des maisons, des transports ou des lieux de travail intelligents.

Le domaine du marketing a également montré un grand intérêt pour les technologies d'imagerie cérébrale. L'interface cerveau-machine permet de mesurer l'attention générée après avoir regardé une publicité à la télévision ou sur tout autre canal de marketing. D'autre part, les chercheurs s'intéressent également à l'estimation de la mémorisation des publicités à l'aide d'une interface cerveau-machine.

De même, l'interface cerveau-machine utilise les signaux électriques du cerveau pour déterminer le degré de clarté des informations étudiées, dans le domaine de l'éducation. La biométrie cognitive dans le domaine de la sécurité et de l'authentification est une application de la technologie IMC qui permet de surmonter les vulnérabilités rencontrées dans ce domaine.

1.5 L'Électroencéphalographie (EEG)

1.5.1 Définition

L'électroencéphalographie (EEG) est une mesure des potentiels qui reflète l'activité électrique du cerveau humain et représente l'un des outils les plus importants pour le diagnostic des maladies neurologiques telles que l'épilepsie, les tumeurs cérébrales, les traumatismes crâniens, les troubles du sommeil et la démence.[8]

Le premier appareil d'enregistrement EEG a été présenté au monde par Hans Berger en 1929. Berger, neuropsychiatre de l'université d'Iéna en Allemagne, qui a utilisé le terme allemand "elektrenkephalogramm" pour décrire les représentations graphiques des courants électriques générés dans le cerveau. Il a suggéré que les courants cérébraux changeaient en fonction

de l'état fonctionnel du cerveau, comme le sommeil, l'anesthésie et l'épilepsie. Cette idée a contribué à la création d'une nouvelle branche de la science médicale appelée neurophysiologie. [9]

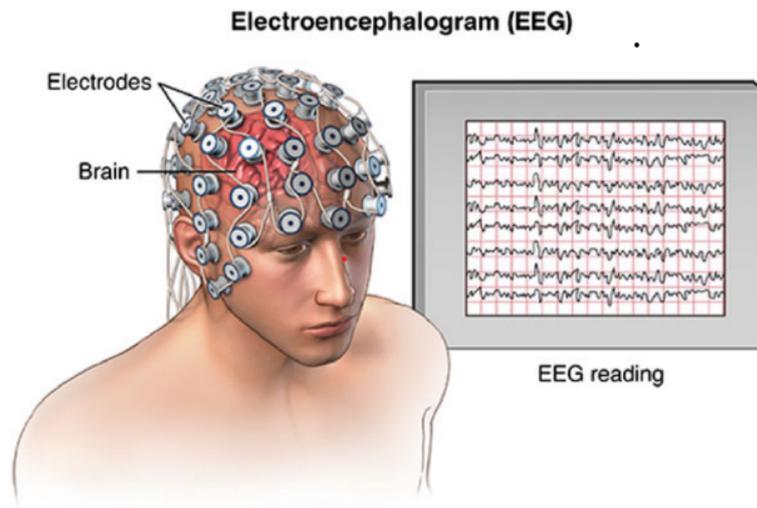


FIGURE 1.4 – Illustration des enregistrements EEG

Lors d'un test EEG, des électrodes sont placées sur le cuir chevelu à l'aide de colles temporaires, qui captent les signaux électriques du cerveau, ensuite amplifiés et affichés sous forme de lignes ondulées sur un écran d'ordinateur comme présenté dans la figure 1.4. Les charges électriques détectées résultent de l'activité des cellules cérébrales. Les enregistrements EEG peuvent comporter de 1 à 256 électrodes représentant différents canaux.

1.5.2 Placement des électrodes

les différents lobes du cortex cérébral traitent différentes activités du cerveau ce qui rend l'emplacement des électrodes important. La méthode standard pour localiser les électrodes du cuir chevelu est le système international d'électrodes 10-20 (Jasper 1958) comme démontré dans la figure 1.6, qui utilise des distances de 10 ou 20% entre les électrodes voisines. Les positions sont déterminées par les points **nasion** et **inion**. Chaque emplacement est identifié par une lettre pour le lobe et un chiffre pour l'emplacement de l'hémisphère. Les lettres F, T, C, P et O correspondent aux lobes frontal, temporal, central, pariétal et occipital figure 1.5.

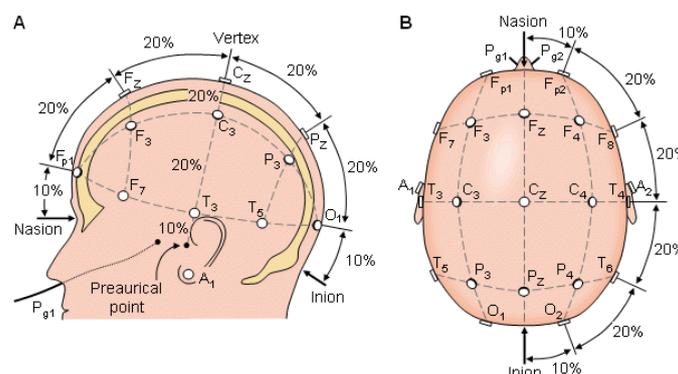


FIGURE 1.5 – Zones fonctionnelles du cerveau

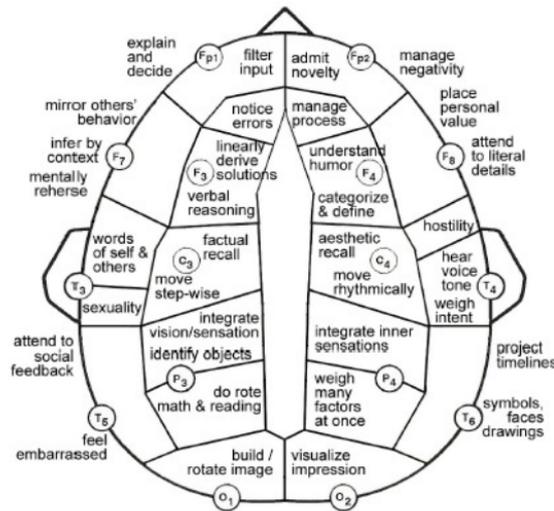


FIGURE 1.6 – Le système international de placement d'électrodes 10-20

1.5.3 Types de montage

Les montages EEG peuvent être classés en fonction de leur disposition électro-anatomique, tels que les montages non appariés, à canaux appariés et groupes appariés. Les montages non appariés minimisent les distorsions de tension, mais ne mettent pas en évidence l'asymétrie. Les montages à canaux appariés montrent bien l'asymétrie mais présentent une distorsion de tension importante par contre les montages à groupes appariés offrent un compromis en représentant bien l'asymétrie sans distorsion majeure de la tension. Les canaux peuvent également être organisés selon leur orientation spatiale, en montages longitudinaux (d'avant en arrière) et transversaux (de gauche à droite ou de droite à gauche).[8], le montage peut être **Bipolaire**, **Référentiel**, à **moyenne commune** ou **Laplacien** [10]

1.5.3.1 Montage bipolaire

Le montage bipolaire utilise deux électrodes pour mesurer la différence de potentiel. Il permet une mesure précise de l'activité électrique et la localisation des sources cérébrales, réduisant les artefacts. Cependant, il présente des limites comme la distorsion des signaux, compliquant l'interprétation pour les débutants.

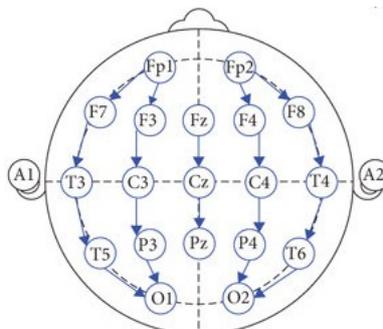


FIGURE 1.7 – Montage bipolaire

1.5.3.2 Montage de référence moyen

Le montage de moyenne analyse l'activité EEG moyenne pendant des événements spécifiques, réduisant le bruit de fond et isole l'activité électrique associée à ces événements. Il est utilisé dans le domaine de la recherche pour étudier les processus cognitifs, tels que la perception, l'attention ou la mémoire.

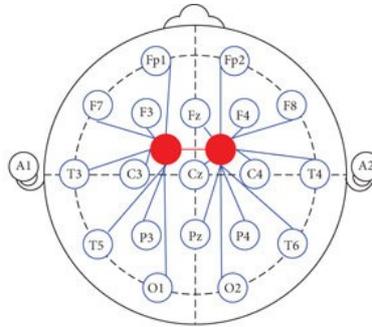


FIGURE 1.8 – Montage moyen

1.5.3.3 Montage référentiels

Il utilise une électrode de référence fixée sur le cuir chevelu, tandis que d'autres électrodes mesurent la différence de potentiel par rapport à cette référence. Ce montage est efficace pour détecter des anomalies EEG étendues, telles que les modifications globales de l'activité cérébrale, en observant les différences de potentiel entre toutes les électrodes et la référence.

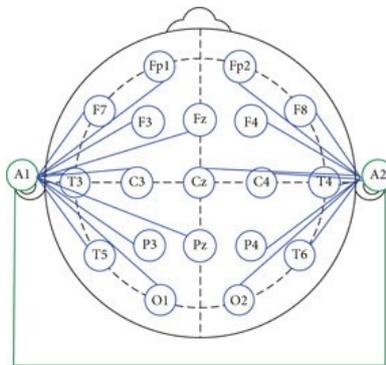


FIGURE 1.9 – Montage référentiels

1.5.4 Caractéristiques et nature des signaux EEG

Les caractéristiques des électrodes sur le cuir chevelu, comme la fréquence, l'amplitude et la forme des ondes, permettent de classer les rythmes EEG tels que Alpha, Bêta, Gamma, Thêta et Delta associés à différents comportements et états mentaux. [11]. Les ondes sont démontrées dans la figure. 1.10

1.5.4.1 Onde Delta

Les ondes Delta, avec une grande amplitude et une lenteur significative, sont associées à la matière grise du cerveau. Elles sont principalement enregistrées lors des stades 3 et 4 du sommeil, mais sont également présentes, chez les nourrissons et chez les adultes éveillés, peuvent indiquer une fréquence plus élevée et sont liées à l'hormone de croissance.

1.5.4.2 Onde Thêta

Les ondes thêta, entre 4 et 8 Hz, sont associées à l'activité subconsciente et observées lors de la relaxation profonde ou de la méditation. Elles peuvent influencer la spiritualité et les capacités extrasensorielles. Les enfants de moins de 13 ans présentent plus fréquemment ces ondes, qui impactent la production d'hormones pour l'apprentissage, la mémoire et la relaxation contre la douleur.

1.5.4.3 Onde Alpha

Les ondes alpha, avec une fréquence entre 8 et 13 Hz, sont observées chez les adultes détendus avec les yeux fermés. Elles se manifestent principalement dans les régions occipitales et pariétales du cerveau, avec une amplitude légèrement plus élevée du côté non dominant. Elles sont considérées comme le lien entre la conscience et les parties conscientes et subconscientes du cerveau.

1.5.4.4 Onde Bêta

Les ondes bêta, avec une fréquence entre 13 et 30 Hz, sont liées aux comportements, aux actions et aux cinq sens. Elles peuvent être observées dans les lobes frontaux et pariétaux du cerveau et sont associées à la production de cortisol, à l'apprentissage, à la mémoire, à la pleine conscience et à la réflexion et reflètent la capacité de penser et de réagir.

1.5.4.5 Onde Gamma

Les ondes gamma se situent entre 30 et 70 Hz et concernent l'observation et la conscience. Ces ondes ont une capacité innée et constituent un mélange équilibré de sources d'information tactiles. Les sens et la mémoire sont parfaitement consolidés par les ondes Gamma.

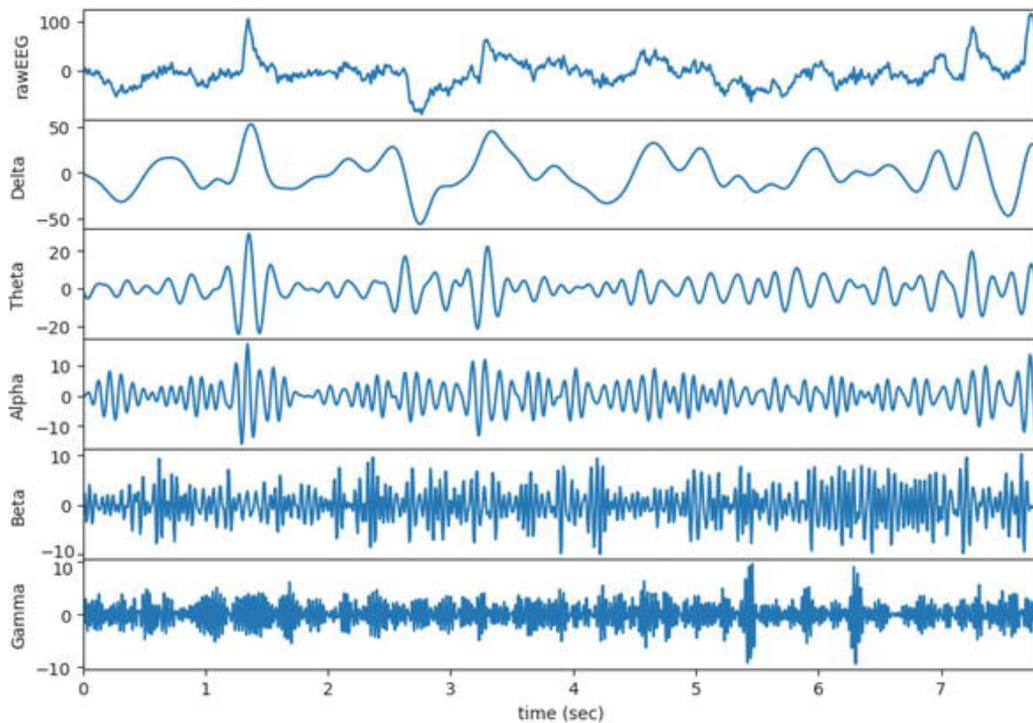


FIGURE 1.10 – Bandes de fréquence des signaux EEG

1.6 L'EEG dans notre problématique

1.6.1 Schizophrénie

Dans la schizophrénie, un EEG peut révéler des anomalies dans les oscillations cérébrales, qui sont des changements dans l'activité électrique du cerveau qui se produisent à différentes fréquences. Ces anomalies affectent la synchronie et la connectivité des régions cérébrales impliquées dans les processus cognitifs et émotionnels, entraînant des symptômes tels que des hallucinations, des délires et des troubles de la pensée et du comportement.

Plusieurs études ont montré que l'EEG peut être utilisé comme outil de diagnostic de la schizophrénie. A titre d'exemple, une étude a montré que la force des oscillations alpha (8 à 13 Hz) dans les régions frontales du cerveau était significativement réduite chez les patients atteints de schizophrénie par rapport aux témoins sains. Une autre a montré que les personnes atteintes de schizophrénie présentaient des anomalies dans les oscillations gamma (entre 30 et 80 Hz), qui sont importantes pour le traitement des informations sensorielles et la perception. Il est utilisé aussi pour évaluer l'efficacité du traitement de la schizophrénie. Une étude a montré qu'un EEG pouvait être utilisé pour prédire la réponse à la clozapine, un médicament antipsychotique, chez les patients atteints de schizophrénie. Les patients qui ont répondu au traitement avaient plus d'oscillations gamma synchronisées avant le traitement, tandis que les patients qui n'ont pas répondu avaient moins d'oscillations gamma synchronisées [12].

L'EEG a une autre application importante dans la schizophrénie est d'étudier les mécanismes sous-jacents à la schizophrénie, notamment en ce qui concerne les processus cognitifs et les émotions. l'EEG peut être utilisé pour étudier les oscillations thêta (entre 4 et 7 Hz), qui sont importantes pour la mémoire et l'attention. Les patients atteints de schizophrénie présentent souvent des oscillations thêta anormales, qui peuvent contribuer à leurs difficultés cognitives [13].

1.6.2 Brain Computer Interface

L'imagerie motrice - *En anglais Motor Imagery MI* - est une expérience dynamique au cours de laquelle l'utilisateur imagine mentalement un mouvement moteur sans activation d'un muscle ou d'un nerf périphérique. Une interface cerveau-ordinateur pour l'imagerie motrice (MI-BCI) est un système qui convertit les signaux cérébraux générés au cours de cette imagination en une séquence actionnable. Ils utilisent principalement l'électroencéphalogramme (EEG) pour mesurer l'activité cérébrale. L'EEG offre une résolution temporelle élevée, peut être transporté, est relativement peu coûteux et représente les signaux électriques synchrones produits par le cerveau.

L'EEG autant qu'une méthode non invasive qui permet de mesurer les signaux électriques synchrones produits par le cerveau. Il offre une résolution temporelle élevée, ce qui signifie qu'il peut détecter les variations rapides de l'activité cérébrale. De plus, il est relativement portable et peu coûteux par rapport à d'autres techniques d'imagerie cérébrale, telles que l'imagerie par résonance magnétique fonctionnelle (IRMf).

Lors de l'imagination d'un mouvement du corps vers la gauche ou vers la droite, les bandes de fréquences alpha (8-13 Hz) et bêta (13-30 Hz) des signaux EEG sont généralement impliquées. Ces bandes de fréquences ont été observées comme étant associées à l'imagerie motrice, mais il convient de noter que les caractéristiques exactes peuvent varier d'une personne à une autre.

1.7 Architecture des systèmes du traitement et la classification

La compréhension de l'impact de l'EEG dans la schizophrénie et les interfaces cerveau-ordinateur (BCI) constitue une avancée majeure dans le domaine de la neuroscience. Il est essentiel de souligner que pour obtenir des résultats optimaux, prendre en compte l'architecture des systèmes de traitement et de classification des signaux EEG. En effet, cette architecture doit être adaptée en fonction de la tâche spécifique à accomplir, que ce soit pour diagnostiquer la schizophrénie ou pour développer des applications BCI permettant aux patients de contrôler des dispositifs externes. Une conception réfléchie et personnalisée est nécessaire. Cela implique de choisir les bonnes caractéristiques à extraire des signaux EEG, d'appliquer des algorithmes de classification ou de décodage appropriés, et de valider rigoureusement le système. De plus, il est important de tenir compte des variations individuelles et des possibles interférences afin de garantir la fiabilité et la robustesse des résultats. En somme, la réussite de ces systèmes repose sur une architecture adaptée à la tâche spécifique, permettant ainsi d'exploiter au mieux les informations fournies par les signaux EEG.

La figure 1.11 Représente l'architecture utilisée pour le traitement et classification des signaux EEG.



FIGURE 1.11 – Architecture du système de traitement et classification des signaux EEG

1.7.1 Prétraitement

L'étape de prétraitement des signaux est cruciale dans le diagnostic des maladies et la reconnaissance des commandes cérébrales. Elle consiste à transformer les signaux bruts collectés par les capteurs EEG en un ensemble de données clair et prêt pour la prochaine étape. En premier lieu les expériences mal prises sont d'abord écartées, puis les signaux restants sont soumis à des filtres pour éliminer les bruits et les artefacts enregistrés lors de la collection des données EEG.

Types de bruit

Clignements des yeux :

Les clignements des yeux sont l'un des artefacts les plus courants et se caractérisent par des formes d'ondes négatives de très grande amplitude dans les régions frontales. Généralement on trouve ces types de Bruit lors d'enregistrement EEG [14]

Mouvements des yeux :

Les mouvements latéraux des yeux sont marqués par des polarités opposées dans les dérivations F7 et F8, qui sont dû, une fois encore, à la charge positive de la cornée et à la charge négative de la rétine. Lorsque vous regardez à droite, la cornée droite se rapproche de l'électrode F8 et reçoit une charge positive, la rétine gauche se rapproche de l'électrode F7 reçoit donc une charge négative

ECG artefact :

Les artefacts ECG sont marqués par des formes d'ondes qui sont synchronisées avec le complexe QRS sur le tracé ECG. Ils ont tendance à être présents d'avantage ou entièrement du côté gauche avec une faible amplitude.

Myogène artefacts :

L'artefact myogénique provient des mouvements musculaires et se trouve le plus souvent dans les régions frontales ou temporales latérales. Il se caractérise par une activité de haute fréquence, souvent de faible amplitude, qui se superpose aux rythmes cérébraux normaux, et plus important à l'état d'éveil.

Artefact électrique (Alimentation électrique) :

L'artefact électrique provient le plus souvent d'une interférence avec l'activité électrique de 60 Hz (aux États-Unis ; 50 Hz en Europe et ailleurs), il provient soit d'un appareil électrique, à la recharge ou d'un téléphone portable, bien que la plupart des équipements EEG modernes parviennent assez bien à le minimiser.

1.7.2 Extraction des caractéristiques :

L'extraction des caractéristiques des signaux EEG est une étape essentielle dans la robustesse et la qualité de la classification, elle est extraite des informations pertinentes qui seront utilisées pour identifier des motifs significatifs dans les signaux EEG qui peuvent être associés à des événements spécifiques ou à des états de l'activité cérébrale.

Il y a deux catégories de méthode d'extraction des caractéristiques :

- classiques
- automatique basées sur l'apprentissage automatique

Méthodes classiques :

Les méthodes classiques se réfèrent à l'extraction manuelle des caractéristiques, cela implique la sélection et le calcul manuel des mesures spécifiques en utilisant différentes approches mathématiques. Ces caractéristiques peuvent inclure des mesures dans plusieurs domaines tels que le temporel, fréquentiel et temps-fréquence, etc..

Les avantages de l'extraction manuelle des caractéristiques résident dans le contrôle total exercé par l'expert, qui peut incorporer des connaissances spécifiques du domaine dans le processus d'extraction, et peuvent être facilement interprétées et assimilées.

Méthodes à base d'apprentissage automatique :

Les dernières études ont montré qu'à l'aide du réseau de neurone convolutif, la possibilité d'extraire et de sélectionner automatiquement les caractéristiques pertinentes à partir des données brutes.

L'extraction automatique de caractéristiques offre des avantages significatifs en termes de gain de temps, d'adaptabilité, de capacité à capturer des caractéristiques complexes et d'adaptation aux données d'entraînement. Ces avantages ont conduit à une approche privilégiée dans de nombreux problèmes de l'apprentissage automatique.

1.8 État de l'art

1.8.1 La détection de schizophrénie

Plusieurs études récentes ont montré que l'apprentissage automatique peut également être un outil très utile pour classer la schizophrénie. En analysant le travail de Han Shaoqiang, Wang Yifeng cité sous le nom "The distinguishing intrinsic brain circuitry in treatment-naïve first-episode schizophrenia : Ensemble learning classification" [15] on retrouve un ensemble de méthode combinant le signal processing et le biomédical ainsi que des neuroanatomical extrait de donnée IRM qui sont utilisées cela a permet d'atteindre une précision de 84.7%. Ces données IRM ont été également utilisé en [16] pour obtenir une précision de classification de 87%.

Une précision de 85% a été atteinte dans la classification des patients atteints de schizophrénie et d'autisme en utilisant KNN et les caractéristiques corticales extraites des données IRM en [17]. Un classifieur SVM basé sur plusieurs caractéristiques structurales de l'IRM a permis à Zhu et al. d'atteindre une précision de 76% dans la classification de la schizophrénie à un stade clinique précoce [18]. Le SVM a également été utilisé pour classer la schizophrénie avec une précision de 85% en utilisant des caractéristiques de connectivité fonctionnelle au niveau du cerveau à partir de données d'IRM [19],[20] ces dernières ont proposé un autoencodeur clair profond à corrélation canonique pour classer les patients atteints de schizophrénie parmi les témoins sains. Leur méthode a été appliquée à la fois aux polymorphismes d'un seul nucléotide et à l'IRMf. Une précision de 95,65% a été obtenue avec les données génomiques, tandis que la précision était de 80,53% avec l'IRMf. Des données textuelles ont également été utilisées pour classer la schizophrénie.

Les techniques d'apprentissage automatique ont été largement utilisées pour classer la schizophrénie à partir des données EEG. Ces méthodes peuvent être regroupées en fonction de l'algorithme d'apprentissage automatique utilisés pour caractériser l'algorithme, ainsi que de la façon dont les données EEG ont été obtenues. Un résumé des méthodes les plus récentes est présenté, notamment l'algorithme de forêt aléatoire développé par Zhang [21], qui a permis de différencier la schizophrénie des sujets témoins sains en utilisant les caractéristiques N1 et P3 extraites lors de tâches sensorielles de base. Dans cette étude, la précision de classification maximale obtenue était de 81%.

Les auteurs de [22] Ont obtenu une précision de 71% dans la classification de la schizophrénie en utilisant le classificateur de la forêt aléatoire basé sur des caractéristiques de puissance extraites de plusieurs bandes de fréquence. Douze caractéristiques statistiques sur cinq bandes extraites du signal EEG au repos de 5 minutes ont été utilisées dans un modèle SVM permettant à Tikka et al. d'obtenir une précision de 79% dans la classification des patients schizophrènes par rapport aux témoins sains [23].

Mesures non linéaires telles que l'entropie, le plus grand exposant de Lyapunov, l'exposant de Hurst et l'analyse de la quantification de la récurrence ont été employées dans les algorithmes SVM, avec une précision d'environ 92% dans la classification des patients [24] [25]. Enfin, Sun et al. [26] ont mis au point une méthode qui, à partir de données EEG au repos, construit une image RVB de laquelle une caractéristique basée sur la FFT a été extraite. Cette caractéristique a été utilisée dans un modèle hybride basé sur des réseaux neuronaux convolutifs et des réseaux de mémoire à long et court terme pour obtenir des données sur la santé. réseaux de mémoire à long et court terme pour obtenir un classificateur de schizophrénie avec une précision élevée de 96.34 %

1.8.2 Application BCI

Les signaux d'imagerie motrice (MI), ainsi que les potentiels liés à l'événement (ERP) sont les seuls signaux dont l'efficacité a été prouvée dans les tâches des applications BCI (interface cerveau interface cerveau-ordinateur) [27]. Dans l'étude de Zhang et al. [28], une comparaison a été réalisée entre un algorithme combinant la transformation en ondelettes de Morlet (MWT) et des réseaux neuronaux convolutif, en utilisant l'ensemble de données III du concours BCI. Cet ensemble de données comprenait 280 essais lors de la tâche d'imagerie motrice (IM) des mains droite et gauche. Les résultats ont conduit à la conclusion que l'efficacité de calcul du MWT est limitée, tandis que le CNN a montré de meilleures performances.

Dans leur étude [29], Jun Yang et ses collaborateurs ont combiné le CNN (réseau neuronal convolutif), la transformation en ondelettes discrètes (DWT) et le RNN (réseau neuronal récurrent) afin de découvrir les modèles dans différentes tâches EEG. Ils ont utilisé les enregistrements EEG de six sujets pour classer les MI (imagerie motrice) de la main gauche et du pied droit, ainsi que les enregistrements de sept sujets pour classer les MI de l'infarctus du myocarde de la main gauche et de la main droite. De plus, ils ont également classé les échantillons des tâches d'IM impliquant l'imagination de la main gauche et de la langue, avec la participation de douze sujets. Leurs conclusions mettent en évidence que le RNN combiné à DWT et CNN, constitue un classificateur relativement plus précis que le CNN seul, et plus apte à gérer l'indépendance du sujet dans les applications BCI multitâches.

En explorant le travail de Kumar et ses collaborateurs en [30], ainsi que l'ensemble de données IVA du concours BCI, qui comprenait des enregistrements de cinq sujets effectuant des tâches d'imagerie motrice avec leurs mains gauche et droite (140 essais pour chaque main), nous constatant que ces derniers ont utilisé des auto-encodeurs pour révéler les modèles dans les données, tout en veillant à conserver l'efficacité de calcul du réseau. Pour ce faire, ils ont combiné la machine de Boltzmann restreinte (RBM) avec le CSP (commun pattern subtraction) afin de minimiser l'erreur maximale.

Dans leur étude [31], Zhang et al. ont utilisé la STFT pour convertir les signaux d'imagerie motrice en images sur une période de dix secondes. Ils ont ensuite comparé les performances des fonctions d'activation dans un modèle CNN à sept couches. SELU s'est avéré être la fonction d'activation la plus performante par rapport à ELU et RELU. Cependant, cette amélioration était plus significative lorsque SELU était utilisée en combinaison avec la STFT comme méthode de prétraitement, mais aucune preuve n'a démontré qu'elle dépasse RELU lorsque la STFT n'était pas utilisée.

1.9 Conclusion

A travers ce chapitre, nous avons essayé d'assurer la compréhension du contexte clinique de la schizophrénie, des principes fondamentaux des interfaces cerveau-ordinateur, ainsi que des méthodes d'acquisition et de traitement des signaux EEG. De plus, nous avons dressé un résumé de l'état de l'art, mettant en évidence l'essor de l'apprentissage profond tout en soulignant l'importance persistante des approches classiques qui offrent des performances solides. Ainsi, l'objectif central de notre travail consiste à analyser les performances de ces deux approches en examinant diverses caractéristiques temporelles et fréquentielles. Dans le prochain chapitre, nous présenterons en détail les caractéristiques sélectionnées, ainsi que les classificateurs étudiés.

Chapitre 2

Méthodologie d'analyse et de classification

2.1 Introduction

Dans ce chapitre, nous fournirons une vue détaillée des principaux blocs, mentionnés précédemment, d'un système de traitement et de classification des signaux EEG, comme. Nous présenterons les étapes clés du prétraitement des données EEG et accorderons une attention particulière à l'extraction des caractéristiques statiques, fréquentielles et dynamiques des signaux EEG, ainsi que les fondements et à la théorie mathématique qui suit ces derniers. Enfin, nous aborderons les différents algorithmes de classification utilisés dans notre étude.

Cette partie constitue le fondement de notre approche d'analyse et de classification, visant à garantir des signaux de qualité, à séparer les sources indépendantes et à explorer les différentes propriétés des données EEG.

2.2 Prétraitement

2.2.1 Segmentation

Les signaux EEG sont divisés en segments de longueur W avec un chevauchement, si c'est essentiel, pour éviter les pertes d'information. Le choix de ces paramètres est crucial pour la représentativité des données. Les fenêtres plus petites conviennent à la détection rapide avec peu de ressources, tandis que les plus grandes sont utilisées pour des activités complexes avec plus de ressources. Cependant, des segments trop longs sont chronophages et manquent le début des événements, tandis qu'une fenêtre trop petite peut limiter les décisions éclairées. Le réglage précis des paramètres est préférable à l'ajustement des hyperparamètres, qui est coûteux en ressources et en temps.

Voici quelques méthodes couramment utilisées pour segmenter les signaux EEG :

1. **Segmentation temporelle fixe** : Dans cette approche, le signal EEG est divisé en segments de durée fixe, par exemple, un signal de 10 minutes peut être divisé en 1 000 segments de 1 seconde chacun. Cette méthode est souvent utilisée pour l'analyse spectrale afin d'étudier les différentes fréquences présentes dans le signal.
2. **Segmentation basée sur des événements** : Dans cette approche, le signal EEG est segmenté en fonction d'événements spécifiques tels que des stimuli externes présentés à un sujet ou des réponses cérébrales spécifiques. Par exemple, pour étudier les réponses à des stimuli visuels, le signal EEG peut être segmenté en fonction du moment où les stimuli sont présentés, créant ainsi des segments distincts pour chaque stimulus.
3. **Segmentation basée sur des algorithmes d'apprentissage automatique** : Des techniques d'apprentissage automatique peuvent être utilisées pour détecter automatiquement des motifs ou des changements significatifs dans le signal EEG, permettant ainsi de le segmenter en conséquence. Par exemple, des algorithmes de détection de points de rupture peuvent être utilisés pour identifier les transitions entre différentes activités cérébrales.
4. **Segmentation adaptative** : Cette approche vise à segmenter le signal EEG en fonction des propriétés intrinsèques du signal lui-même. Par exemple, des méthodes basées sur des caractéristiques du signal telles que l'amplitude, la fréquence ou la cohérence peuvent être utilisées pour diviser le signal en segments correspondant à des régions homogènes du cerveau.

Il est important de noter que la segmentation des signaux EEG peut varier en fonction de l'objectif de l'étude ou de l'analyse spécifique. Différentes méthodes peuvent être combinées ou adaptées en fonction des besoins. De plus, l'interprétation des résultats de la segmentation nécessite souvent une expertise en neurosciences et en traitement du signal pour une analyse approfondie.

la figure 2.1 représente un exemple sur la segmentation des signaux.

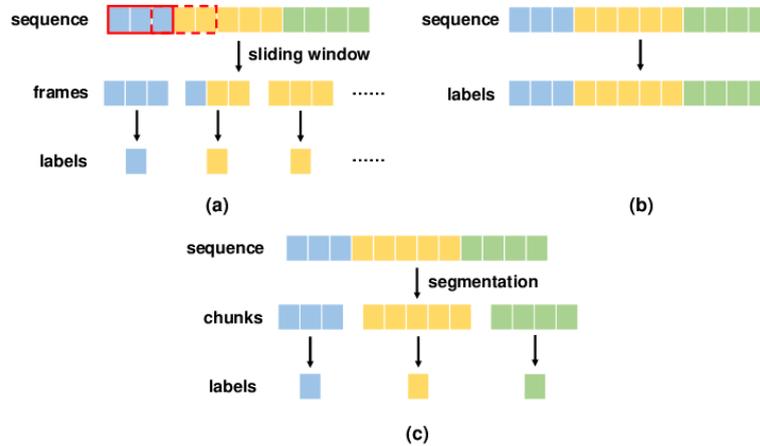


FIGURE 2.1 – Exemple sur la segmentation des données

2.2.2 Filtre coupe-bande

Le filtre coupe-bande - *en anglais notch* - également connu sous le nom de filtre de rejet de fréquence, est un type de filtre utilisé en électroencéphalographie (EEG) pour éliminer une fréquence spécifique indésirable du signal EEG. Son importance réside dans le fait qu'il permet de supprimer les interférences provenant de sources externes, telles que le bruit électrique de l'environnement ou les interférences électromagnétiques, qui pourraient perturber la qualité des enregistrements EEG [32].

2.2.3 Lissage des signaux (Smoothing)

Le lissage des signaux EEG consiste à appliquer des algorithmes mathématiques pour réduire la variabilité et le bruit présents dans les enregistrements EEG. En réduisant les fluctuations aléatoires et les artefacts indésirables, les techniques de lissage aident à révéler les motifs sous-jacents et les tendances de l'activité électrique du cerveau, rendant les signaux plus fiables et plus faciles à interpréter figure 2.2.

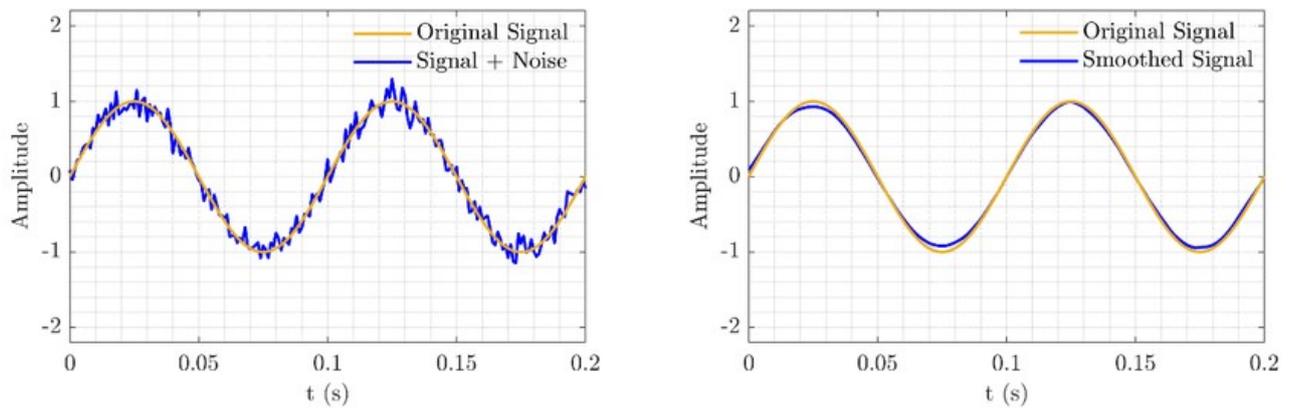


FIGURE 2.2 – lissage des signaux

2.2.4 Filtre à réponse impulsionnelle finie

Les filtres FIR sont des filtres numériques dont la réponse impulsionnelle est finie dans le temps. Ils permettent de supprimer ou atténuer certaines fréquences indésirables dans le signal EEG, tout en préservant les fréquences d'intérêt.

Un autre aspect de la conception des filtres FIR est la direction du signal utilisé comme entrée. Les filtres qui ne comprennent que des informations passées et présentes sont appelés filtres causaux, tandis que les filtres qui dépendent de l'entrée passée et future sont appelés filtres acausaux ou non causaux [33].

Les filtres FIR sont conçus en utilisant différentes méthodes de fenêtrage, qui déterminent la forme de la réponse en fréquence du filtre. Nous citerons quelques fenêtres.

2.2.4.1 Fenêtre de Hamming

Cette méthode attribue des poids décroissants aux points du filtre, ce qui permet d'obtenir une réponse en fréquence plus lisse et une meilleure atténuation des fréquences adjacentes.

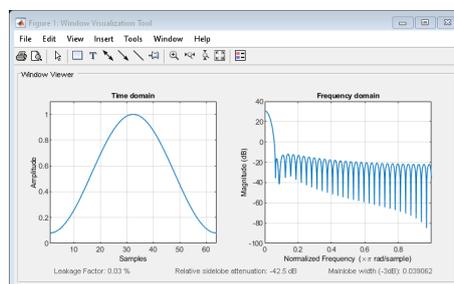


FIGURE 2.3 – Fenêtre de Hamming - matlab

2.2.4.2 Fenêtre de Hanning

Similaire à la fenêtre de Hamming, cette méthode attribue également des poids décroissants aux points du filtre. Elle offre une meilleure atténuation des fréquences adjacentes et une meilleure réjection des lobes latéraux.

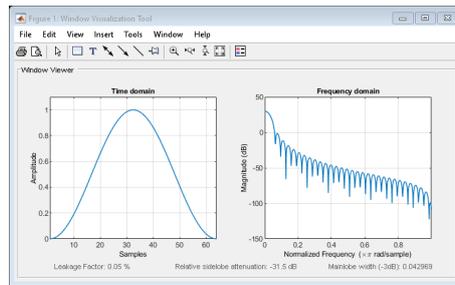


FIGURE 2.4 – Fenêtre de Hanning - matlab

2.2.4.3 Fenêtre de Blackman

Cette méthode utilise des poids plus complexes pour offrir une meilleure atténuation des fréquences adjacentes et une réjection plus élevée des lobes latéraux.

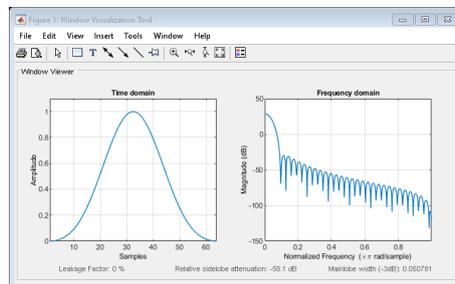


FIGURE 2.5 – Fenêtre de Blackman - matlab

2.2.4.4 Fenêtre de Bartlett

Cette méthode attribue un poids de valeur constante à chaque point du filtre, ce qui donne une réponse en fréquence plate dans la bande passante du filtre. Cependant, cela peut entraîner une réponse indésirable aux fréquences adjacentes.

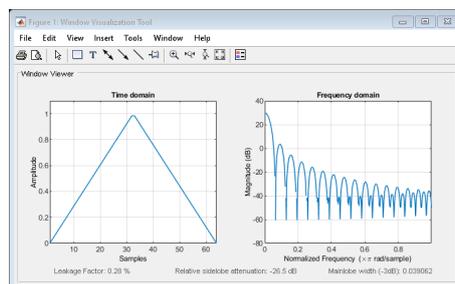


FIGURE 2.6 – Fenêtre de Bartlett - matlab

Chaque méthode de fenêtrage a ses avantages et ses limitations en termes de caractéristiques de filtrage. Le choix de la méthode dépend des spécificités du signal l'EEG et des objectifs de prétraitement du signal.

2.2.5 L'Analyse en Composantes Indépendantes (ACI)

L'Analyse en Composantes Indépendantes (ACI) est une méthode statistique utilisée pour différencier les signaux multivariés en sous-composantes supplémentaires. Elle permet de démêler les contributions de différentes sources à un ensemble de données observées, même lorsque ces sources sont mélangées de manière complexe [34].

L'ICA est largement utilisée dans divers domaines tels que le traitement du signal, la neuroimagerie, la reconnaissance de formes et l'apprentissage automatique. Son principe repose sur l'idée que les signaux observés peuvent être considérés comme une combinaison linéaire de signaux sources indépendants figure 2.7.

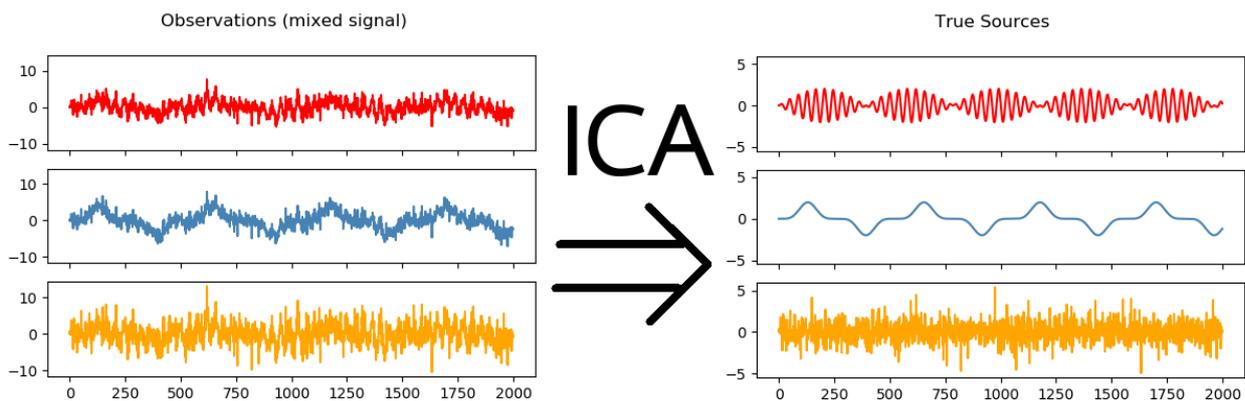


FIGURE 2.7 – Analyse en Composantes Indépendantes

L'ICA peut être résolue de différentes manières, telles que l'algorithme de maximisation de la négentropie (INFOMAX) ou l'algorithme de gradient stochastique. Ces méthodes itératives ajustent les paramètres de W pour maximiser la non-gaussienneté des signaux sources. Nous donnerons l'exemple de l'algorithme **INFOMAX**

$$\begin{aligned} X &= AS \\ S &= WX \end{aligned} \quad (2.1)$$

X : signaux observés

S : signaux sources

W : matrice de démixage

La clé de l'ICA réside dans la recherche de W qui maximise la non-gaussienneté des signaux sources. Selon les travaux de recherche de Dominic Langlois, Sylvain Chartier, and Dominique Gosselin "An Introduction to Independent Component Analysis : InfoMax and FastICA algorithms" [35] on peut résumer le fonctionnement de l'ACI par les étapes suivantes

On commence par initialiser la matrice de démixage W avec des valeurs aléatoires ou avec une matrice identité.

Après on Calcule de la sortie estimée en Multipliez la matrice de démixage W par les signaux observés X pour obtenir une estimation des signaux sources S estimés.

On applique une fonction non-linéaire à chaque élément de la matrice des signaux sources

estimés S . Une fonction couramment utilisée est la fonction sigmoïde $g(s)$ et on met à jour la matrice de démixage.

$$g(s) = \frac{1}{1 + e^{-s}} \tag{2.2}$$

$$W = \alpha(1 - 2g(W\dot{X}))\dot{X}^T + \beta\dot{W}$$

α, β : coefficients d'apprentissage

On répète les itération jusqu'à ce que la convergence soit atteinte. La convergence peut être vérifiée en calculant la variation de la négentropie ($NegEnt(s) = -E[g(s)]$) à chaque itération et en s'assurant qu'elle atteint un seuil prédéfini.

2.3 Extraction des caractéristiques

2.3.1 Caractéristiques statiques

Les caractéristiques statistiques représentent un modèle de distribution important des données des signaux EEG, ces caractéristiques se réfèrent à des mesures quantitatives qui capturent des informations spécifiques sur les signaux EEG à un moment donné, sans tenir compte de l'évolution temporelle du signal. Ces caractéristiques sont souvent calculées à partir de segments de signal EEG, tels que des fenêtres temporelles ou des segments de fréquence [36].

Les caractéristiques statique utilisées pour la détection de la schizophrénie et l'activité BCI sont résumées dans le tableau suivant.

Statistical characteristics	Formula
Moyenne	$\mu = \frac{1}{n} \sum_{i=1}^n x_i$
Écart-type	$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2}$
Maxima	Max = $\max(x(t))$
Minima	Min = $\min(x(t))$
Plage	ptp = $\max(x(t)) - \min(x(t))$
Variance	Var = $\frac{1}{N} \sum_{i=1}^n (x_i(t) - \mu)^2$
Valeur quadratique moyenne	RMS = $\frac{1}{n} \sum_{i=1}^n (x_i)^2$
Différence absolue	abs = $\sum_{i=1}^n x_i - \mu $
Skewness (asymétrie)	Skewness = $\frac{1}{n\sigma^3} \sum_{i=1}^n (x_i(t) - \mu)^3$
Kurtosis (aplatissement)	Kurtosis = $\frac{1}{n\sigma^4} \sum_{i=1}^n (x_i(t) - \mu)^4$

2.3.2 Caractéristiques des fréquentielle

Les caractéristiques de fréquence fournissent des informations précieuses sur la répartition de l'énergie des différentes bandes de fréquences dans le signal EEG. Ces bandes de fréquences reflètent différentes activités neuronales et peuvent être utilisées pour caractériser les états mentaux et les dysfonctionnements associés à la schizophrénie.

Rapport de puissance de bande

Le rapport de puissance de bande est une mesure utilisée pour évaluer la distribution de l'énergie dans différentes bandes de fréquences d'un signal EEG. Il permet de quantifier la proportion d'énergie contenue dans une bande de fréquences spécifique par rapport à une autre bande de fréquences.

a formule générale du rapport de puissance de bande peut être exprimée comme suit :

$$\text{Rapport de puissance de bande} = \frac{\text{Puissance de la bande cible}}{\text{Puissance totale}} \quad (2.3)$$

Entropie spectrale

L'entropie spectrale est une mesure utilisée pour quantifier le niveau de complexité ou d'irrégularité d'un signal EEG dans le domaine fréquentiel. Elle permet d'évaluer la distribution des amplitudes de fréquence dans le spectre du signal.

$$\text{SpEn} = - \sum_{i=1}^n p_i \log(p_i) \quad (2.4)$$

n : représente le nombre de bandes de fréquences dans le spectre du signal.

p_i = probabilité d'occurrence de la bande de fréquences dans le spectre du signal.

L'utilisation de l'entropie spectrale dans l'analyse de l'EEG permet de détecter des altérations spécifiques dans la complexité du signal associées à des conditions pathologiques ou à des états mentaux particuliers. Elle peut être utilisée pour caractériser les différences entre les sujets sains et les patients atteints de schizophrénie, ainsi que pour développer des modèles diagnostiques ou des outils de surveillance de l'état mental.

2.3.3 Caractéristiques dynamiques non linéaires

Les caractéristiques dynamiques non linéaires sont basées sur l'hypothèse que le cerveau est un système dynamique complexe et que les altérations observées dans les signaux EEG des patients atteints de schizophrénie peuvent être reflétées dans des mesures non linéaires. Ces caractéristiques visent à quantifier les propriétés telles que la régularité, la complexité, la récurrence ou l'instabilité du signal EEG, qui peuvent différer entre les sujets sains et les patients atteints de schizophrénie.

En utilisant les caractéristiques dynamiques non linéaires du signal EEG, les systèmes BCI peuvent détecter des modèles ou des changements subtils dans l'activité cérébrale qui sont difficiles à percevoir à travers les caractéristiques traditionnelles. Cela permet d'améliorer la précision et la fiabilité de la détection des intentions de l'utilisateur, et donc d'optimiser les performances globales du système BCI.

Entropie

L'entropie est une mesure du caractère aléatoire et de l'incertitude d'un signal. Une entropie plus élevée indique un système plus complexe et plus chaotique [37].

Elles fournissent des informations précieuses sur la distribution des amplitudes ou des fréquences du signal EEG, permettant ainsi de caractériser différentes propriétés du cerveau et de détecter des altérations spécifiques associées à des conditions pathologiques telles que la schizophrénie.

Entropie de permutation

L'entropie de permutation est une mesure utilisée pour évaluer la complexité ou le degré d'organisation d'une séquence de valeurs. Elle est souvent utilisée dans l'analyse de séries temporelles, de signaux ou de données séquentielles.

$$PE(r, m, n) = -\frac{1}{n-m} \sum_{i=1}^{n-m} \log_2 \left(\frac{\text{nombre de motifs de permutation similaires à } X_i}{n-m} \right) \quad (2.5)$$

Entropie approximative

L'entropie approximative est une mesure utilisée pour estimer ou quantifier le niveau d'incertitude ou de désordre dans un ensemble de données ou dans un système. Elle est souvent utilisée lorsque les calculs exacts de l'entropie sont difficiles ou impossibles, ou lorsque l'objectif est d'obtenir une estimation rapide et suffisamment précise de l'entropie [38].

$$\text{ApEn}(m, r, N) \simeq -\frac{1}{N-m} \sum_{i=1}^{N-m} \log \frac{\sum_{j=1}^{N-m} [\text{number of times that } d[|x_{m+1}(j) - x_{m+1}(i)|] < r]}{\sum_{j=1}^{N-m} [\text{number of times that } d[|x_m(j) - x_m(i)|] < r]} \quad (2.6)$$

m : la dimension d'intégration et est la longueur du modèle (longueur de la fenêtre des différentes comparaisons vectorielles).

r : le paramètre pour lequel une superposition de bruits beaucoup plus petits n'affecte pas le calcul de l'entropie.

Entropie d'échantillon

L'entropie d'échantillon est une mesure de l'incertitude ou de l'information contenue dans un échantillon de données. Elle est utilisée pour estimer l'entropie d'une distribution de probabilité à partir d'un échantillon fini de données observées.

Lorsque nous avons un échantillon de données, l'entropie d'échantillon est calculée en estimant les fréquences relatives des différentes valeurs ou catégories présentes dans l'échantillon. Plus précisément, l'entropie d'échantillon est calculée à partir de la formule suivante :

$$\text{SaEn}(m, r, N) = -\log \frac{\sum_{i=1}^{N-m} \sum_{j=1, j \neq i}^{N-m} [\text{number of times that } d[|x_{m+1}(j) - x_{m+1}(i)|] < r]}{\sum_{i=1}^{N-m} \sum_{j=1, j \neq i}^{N-m} [\text{number of times that } d[|x_m(j) - x_m(i)|] < r]} \quad (2.7)$$

Fuzzy entropy

L'entropie floue, également connue sous le nom d'entropie incertaine ou d'entropie floue, est une mesure utilisée pour quantifier le niveau d'incertitude dans un ensemble de données ou un système flou. Elle est utilisée pour évaluer le degré de désordre, de variabilité ou de complexité dans des données ou des systèmes présentant une certaine imprécision ou incertitude.

$$\begin{aligned} \mathbf{X}_m(i) &= [x(i), x(i+1), \dots, x(i+m-1)] - x(i) \\ D_{ij,m} &= \mu(d_{ij,m}, r) = \exp(-(d_{ij,m})^n / r) \\ \phi_m(n, r) &= \frac{1}{N-m} \sum_{i=1}^{N-m} \left(\frac{1}{N-m-1} \sum_{j=1, j \neq i}^{N-m} D_{ij,m} \right) \quad (2.8) \\ F_{uzzyEn}(m, n, r, N) &= \ln \phi_m(n, r) - \ln \phi_{m+1}(n, r) \end{aligned}$$

Mobilité et complexité de Hjorth

La mobilité de Hjorth et la complexité de Hjorth sont des mesures utilisées pour évaluer les caractéristiques temporelles d'un signal, en particulier dans le domaine de l'électroencéphalographie (EEG). Elles ont été proposées par Bjørn Hjorth pour quantifier la mobilité et la complexité d'un signal EEG [39].

La mobilité de Hjorth mesure la quantité de changement ou de variation présente dans un signal. Elle est calculée en comparant la variance du signal de dérivation première (c'est-à-dire la première dérivée du signal) à la variance du signal d'origine. Une mobilité élevée indique une plus grande variabilité du signal et une mobilité réduite indique une stabilité ou une régularité accrue du signal.

$$\text{Mobility} = \sqrt{\frac{\text{Var}\left(\frac{dx(t)}{dt}\right)}{\text{Var}(x)}} \quad (2.9)$$

La complexité de Hjorth, quant à elle, évalue la variation de la mobilité entre les dérivations de différents ordres. Elle est calculée en comparant la mobilité du signal de dérivation seconde (c'est-à-dire la seconde dérivée du signal) à la mobilité du signal de dérivation première. Une complexité élevée indique une variation importante de la mobilité entre les dérivations, ce qui peut refléter des transitions rapides ou des motifs complexes dans le signal.

$$\text{Complexity} = \frac{\text{Mobility}\left(\frac{dx(t)}{dt}\right)}{\text{Mobility}(x(t))} \quad (2.10)$$

Nombre de passages par zéro

Le nombre de passages par zéro (zero-crossings en anglais) est une mesure utilisée pour évaluer le nombre de fois qu'un signal traverse l'axe horizontal (zéro) au cours d'une période donnée.

$$\text{Nombre de passages par zéro} = \sum_{i=1}^n |\text{signe}(x_i) - \text{signe}(x_{i-1})| \quad (2.11)$$

Complexité de Lempel-Ziv

La complexité de Lempel-Ziv est une mesure utilisée pour évaluer la complexité d'une séquence de symboles. Elle est basée sur l'algorithme de compression sans perte de Lempel-Ziv, qui cherche les motifs récurrents dans une séquence et les remplace par des symboles plus courts. La complexité de Lempel-Ziv mesure la quantité d'information contenue dans la séquence originale en termes de répétitions et de motifs.

$$\text{Complexité de Lempel-Ziv} = \frac{\text{Nombre total de mots dans le dictionnaire}}{\text{Longueur de la séquence d'entrée}} \quad (2.12)$$

2.4 Outils de classification

2.4.1 Régression logistique

La régression logistique- *en anglais Logistic Regression (LR)* - est un algorithme d'apprentissage supervisé conçu pour la classification. Étant donné qu'il renvoie une valeur continue, il est nécessaire de définir un seuil. Ce seuil permet de convertir la probabilité prédite en une étiquette de classe. Une valeur supérieure à ce seuil indique une classe, tandis qu'une valeur inférieure indique l'autre classe.

La fonction logistique représente une sigmoïde suivant l'équation ci-dessous :

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (2.13)$$

avec z est la combinaison linéaire des variables prédictives pondérées par les coefficients :

$$z = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_m x_m \quad (2.14)$$

où $\beta_0, \beta_1, \beta_2, \dots, \beta_m$ sont les coefficients de régression correspondant à chaque variable prédictive x_1, x_2, \dots, x_m respectivement.

La probabilité de succès (ou l'occurrence de l'événement) est ensuite modélisée en utilisant la fonction logistique appliquée à z :

$$P(Y = 1 | x_1, x_2, \dots, x_m) = \sigma(z) \quad (2.15)$$

où $P(Y = 1 | x_1, x_2, \dots, x_m)$: probabilité conditionnelle de X sachant $Y = 1$

La probabilité que Y prenne la valeur 0 (échec) est donnée par :

$$P(Y = 0 | x_1, x_2, \dots, x_m) = 1 - P(Y = 1 | x_1, x_2, \dots, x_m) = 1 - \sigma(z) \quad (2.16)$$

la régression logistique est également très sensible aux données déséquilibrées, car elle tente d'ajuster la ligne en minimisant l'erreur (la distance entre la ligne et la valeur réelle).

La fonction de coût, également appelée perte, est donnée par l'équation suivante :

$$\text{cost}(P(x), y(\text{ actual })) = \begin{cases} -\log(P(x)) & \text{if } y = 1 \\ -\log(1 - P(x)) & \text{if } y = 0 \end{cases} \quad (2.17)$$

2.4.2 Machine à vecteurs de support

Le Machine à Vecteurs de Support - *en anglais Support Vector Machine (SVM)* - est un algorithme d'apprentissage automatique supervisé utilisé pour résoudre des problèmes de classification binaire, où l'objectif est de séparer les données en deux classes distinctes.

Le principe de base des SVM repose sur la recherche d'un hyperplan optimal dans un espace multidimensionnel pour séparer les données en différentes classes. Cet hyperplan est choisi de manière à maximiser la marge, c'est-à-dire la distance entre l'hyperplan et les exemples les plus proches de chaque classe appelés vecteurs de support.

La plupart des techniques de classification séparent les classes à l'aide d'hyperplans qui divisent les classes à l'aide d'un plan plat, dans l'espace du prédicteur. Malheureusement, dans de nombreux problèmes non triviaux, il n'existe pas de séparateur linéaire parfait. Les SVM étendent le concept de séparation par hyperplans aux données qui ne peuvent pas être séparées linéairement, en mappant les prédicteurs sur un nouveau plan plus élevé. Les données sont projetées dans un nouvel espace de dimension supérieure (appelé espace des caractéristiques) dans lequel ils peuvent être séparés linéairement (voir figure 10.2).

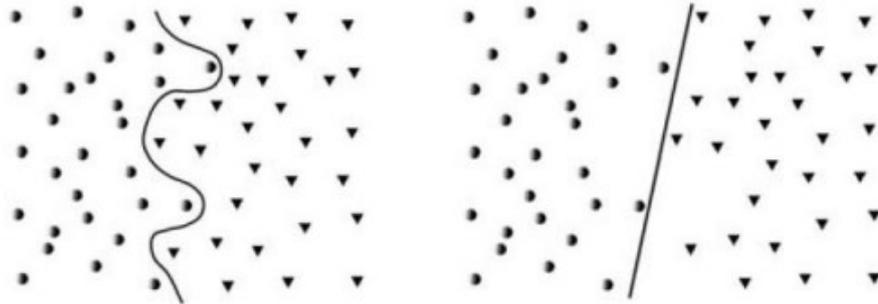


FIGURE 2.8 – Représentation schématique des limites de décision hypothétiques pour deux classes dans l'espace prédictif original (à gauche) et l'espace transformé (à droite). classes dans l'espace prédictif original (à gauche) et l'espace caractéristique transformé (à droite)

Dans ce diagramme, les deux classes ne peuvent être complètement séparées que par une courbe complexe dans l'espace original du prédicteur. Le meilleur séparateur linéaire ne peut pas séparer complètement les deux classes. Toutefois, si les valeurs originales du prédicteur peuvent être projetées dans un "espace des caractéristiques" plus approprié, il est possible de séparer complètement les classes à l'aide d'une frontière de décision linéaire. Par conséquent, le problème consiste à trouver la transformation appropriée. [40]

Les SVM peuvent être classés en deux types selon la distribution des données : linéairement séparables et non linéairement séparables.

2.4.2.1 Linéairement séparables

La classification à séparation linéaire sépare les données à haute dimension en deux groupes, $+1, -1$ sans chevauchement ni erreur de classification. L'objectif principal de la machine à vecteur de support est de maximiser la largeur de la marge afin de réduire l'erreur de classification. maximiser la largeur de la marge afin de réduire l'erreur de classification.

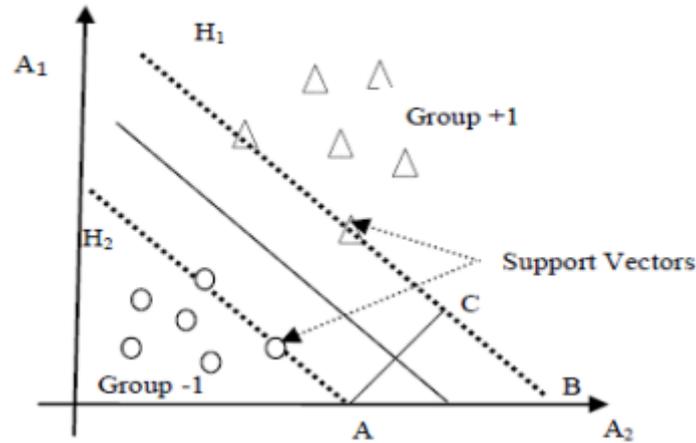


FIGURE 2.9 – Linéairement séparables

L'expression du classificateur linéaire est la suivante :

$$h_{w,b}(x) = y(w^T x + b)$$

avec $y \in \{-1, 1\}$, $w \in R^n$, $x \in R^n$ et b prend les valeurs $+1, 0, -1$ qui indique la distance entre les hyperplans et la ligne d'origine.

La largeur maximale de la marge est mesurée et est égale à :

$$AC_{\max} = \frac{2}{\sqrt{(w_1^2 + w_2^2)}} = \frac{2}{\|w\|}$$

ou w_1, w_2 sont les positions de l'hyperplan H1 et H2 respectivement, et x_1, x_2 sont des points de données. [41]

2.4.2.2 Non linéairement séparables

Le principal avantage des SVMS est qu'ils permettent un élargissement non linéaire de l'espace des caractéristiques, tout en conservant une efficacité de calcul significative, en utilisant un processus connu sous le nom de "kernel trick" (astuce du noyau). En particulier, un ensemble de caractéristiques p x_1, \dots, x_p peut être transformé en un ensemble de caractéristiques $2p$ $x_1, x_1^2, \dots, x_p, x_p^2$. Cela nous permet d'appliquer une technique linéaire à un ensemble de caractéristiques non linéaires. [42]

L'espace de dimension supérieure est appelé cartographie des caractéristiques et sa fonction de cartographie est désignée par $\phi(x_i)$. Les fonctions à noyau sont utilisées pour trouver la valeur de la fonction de mise en correspondance ϕ .

$$x_i^T x_j = k(x_i, x_j) = \phi(x_i)^T \phi(x_j)$$

La fonction Kernel est basée sur le produit intérieur de deux variantes x_i et x_j

Voici les fonctions noyaux les plus utilisées :

- Fonction de noyau radial (RBF)

$$K(x_i, x_j) = e^{-\frac{1}{2} \left(\frac{x_i - x_j}{\sigma} \right)^2}$$

- Fonction de noyau linéaire

$$K(x_i, x_j) = x_i^T x_j$$

- Fonction polynomiale du noyau

$$K(x_i, x_j) = \left[(x_i^T x_j) + 1 \right]^d$$

- Fonction gaussienne

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)$$

2.4.3 Réseau de neurones artificiels

Réseau de neurones artificiels est une méthode inspirée par la même manière que 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'intérieur du cerveau expliqué dans la première partie de notre rapport.

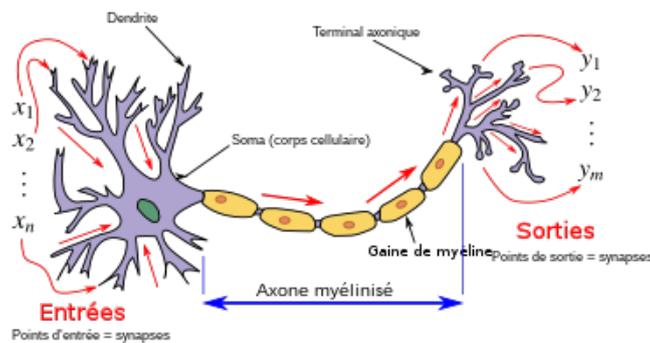


FIGURE 2.10 – Un neurone humain

Il en va de même pour le Réseau de neurones artificiels -en anglais *Artificial Neural Networks (ANN)*- , qui comporte des centaines d'unités de traitement, d'entrée et de sortie, interconnectées par des nœuds. Les unités d'entrée reçoivent les informations (sous forme de valeur) et, sur la base d'un système de pondération interne, elles apprennent à produire la sortie souhaitée. Le schéma suivant présente le modèle général du l'ANN inspiré d'un neurone biologique.

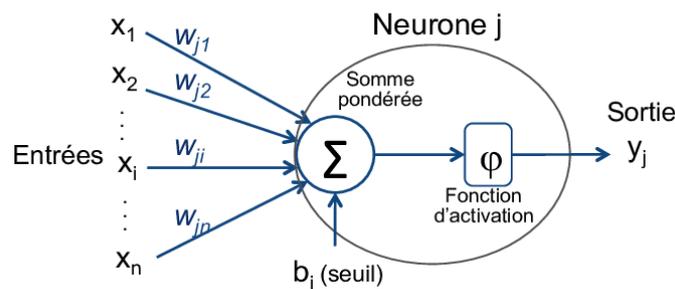


FIGURE 2.11 – Un neurone artificiel

Ce diagramme représente une seule couche avec un neurone. Les X_i sont les caractéristiques, les W_{ij} sont les poids et b est le biais. Chaque caractéristique x_i est multipliée par son poids de connexion, puis additionnée au biais et introduite dans la fonction d'activation pour obtenir à la fin la valeur de sortie.

2.4.3.1 Architecture de L'ANN

Les neurones :

Comme indiqué précédemment, les neurones sont les unités de traitement qui stockent le résultat de la couche précédente calculé par $\phi(w_0^k * x_0 + w_1^k * x_1 + w_2^k * x_2 + \dots + w_n^k * x_n + b^k)$. Un neurone simple avec un biais représenté dans la figure 9.5 a comme résultat : $y = f(w * x + b)$. Le nombre x est multiplié par w et additionné avec b et introduit dans la fonction de transfert f qui, à la fin, nous donne la sortie y .

Couches Cachées :

La couche cachée contient une quantité de neurones qui sont séparés entre eux et reliés à la couche suivante. En général, une couche cachée suffit à résoudre le problème. Plus le problème est complexe, plus on ajoute de couches. Par conséquent, le réseau neuronal se compose d'une couche d'entrée, suivie de couches cachées et d'une couche de sortie à la fin. Comme le montre la figure suivante :

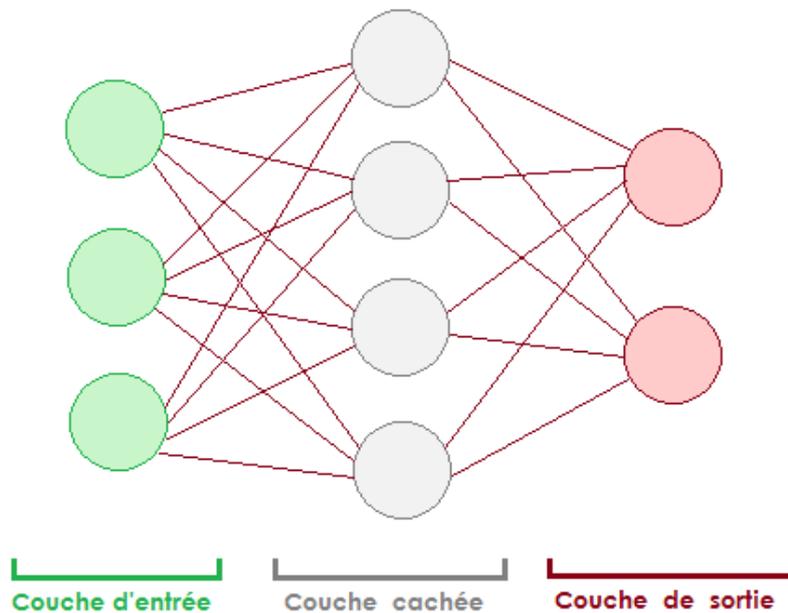


FIGURE 2.12 – Réseau de neurone avec une couche cachée

L'équation mathématique d'une couche cachée est la suivante : $y = f(w * x + b)$.

Où a, x, b sont des vecteurs et w est une matrice. Dans une autre représentation :

$$\begin{pmatrix} a_1 \\ a_2 \\ a_3 \\ a_4 \\ \vdots \\ a_n \end{pmatrix} = f \left\{ \begin{pmatrix} w_1 & w_2 & w_3 & w_4 & \cdots & w_n \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ \vdots \\ x_n \end{pmatrix} + \begin{pmatrix} b_1 \\ b_2 \\ b_3 \\ b_4 \\ \vdots \\ b_n \end{pmatrix} \right\}$$

Un réseau neuronal comportant plus d'une couche cachée est généralement appelé réseau neuronal profond-*en anglais Deep Neural Network (DNN)*-.

Fonction d'activation

Une fonction d'activation est une fonction mathématique utilisée dans les réseaux de neurones artificiels pour introduire de la non-linéarité dans le modèle. Elle est appliquée à la sortie d'un neurone afin de déterminer si ce neurone doit être activé ou non en fonction de la somme pondérée de ses entrées.

Il existe de nombreux types de fonctions d'activation, tels que :

1. Fonction d'activation à seuil :

-*en anglais Threshold activation function*- elle renvoie la valeur **un** si la valeur d'entrée est supérieure au seuil, et la valeur **zéro** dans le cas contraire.

Par exemple, $f(x) = \begin{cases} 1 & \text{si } x > 0 \\ 0 & \text{sinon} \end{cases}$



FIGURE 2.13 – Graphe de fonction d'activation à seuil

2. Fonction d'activation linéaire :

Elle multiplie l'entrée par un poids dans chaque neurone, et renvoie une sortie proportionnelle à l'entrée. elle est donnée par la formule suivante : $f = c * x$; où c est le poids et x est la caractéristique.

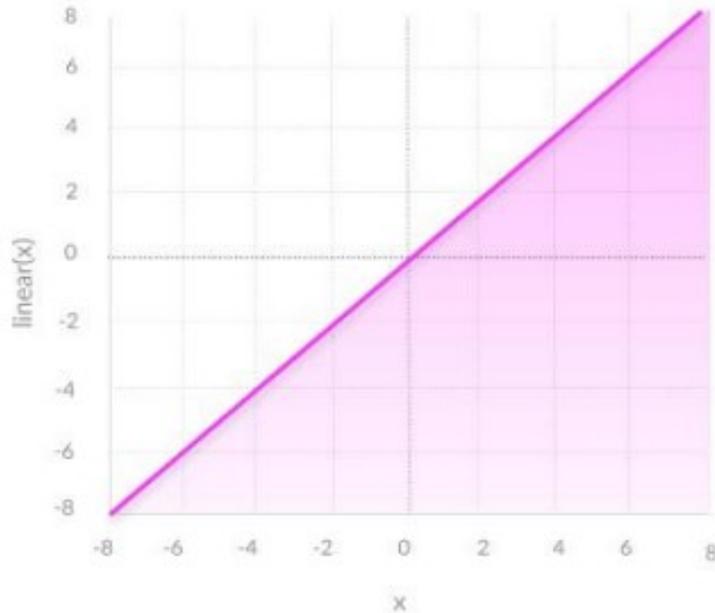


FIGURE 2.14 – Graphe de fonction linéaire

3. Fonction d'activation logistique / sigmoïde :

elle renvoie une valeur continue située entre zéro et un. elle est utilisé dans les probabilités en raison de l'intervalle de sortie. La fonction est donnée comme suite : $\sigma(z) = \frac{1}{1+e^{-z}}$

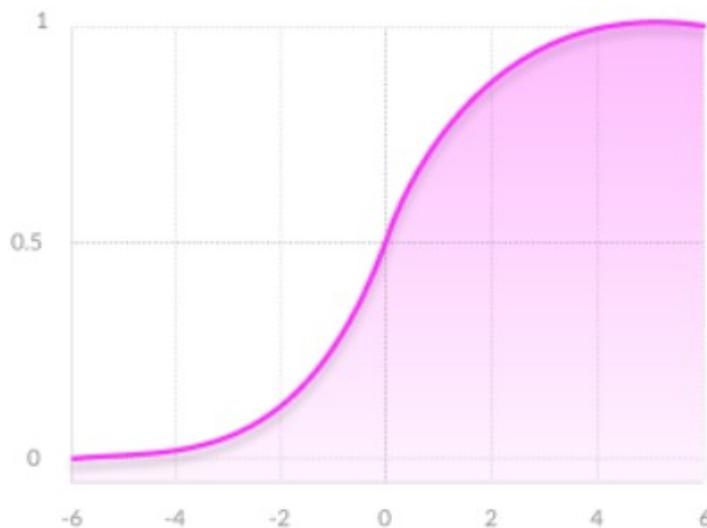


FIGURE 2.15 – Graphe de sigmoïde fonction

4. Fonction d'activation tangente hyperbolique :

Elle a le même principe que la fonction sigmoïde ; elles sont similaires dans l'intervalle

de sortie, par exemple de zéro à un. Cependant, elle est plus performante, elle s'adapte facilement aux entrées fortement négatives ou positives.

Elle est donnée par la formule suivante : $f(x) = \tanh(x) = \frac{2}{1+e^{-2x}} - 1$

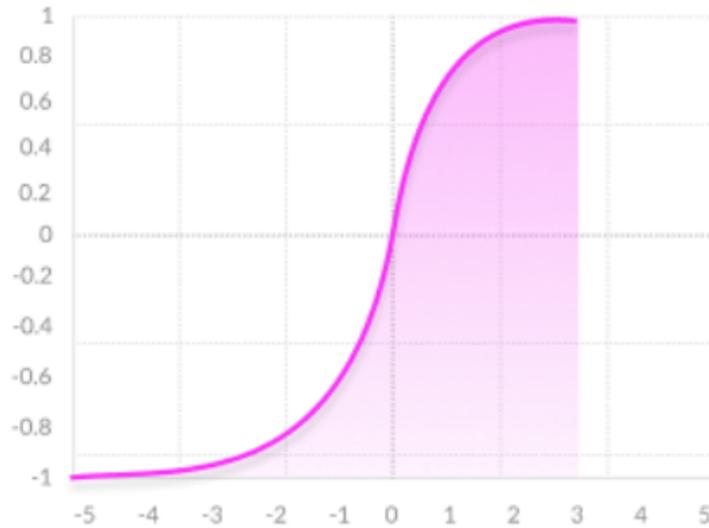


FIGURE 2.16 – Graphe de tanh

5. Unité linéaire rectifiée :

-En anglais *Rectified linear unit (ReLU)* - elle renvoie la valeur d'entrée lorsqu'elle est positive et zéro lorsqu'elle est négative. C'est la fonction d'activation la plus utilisée ; elle fait varier la sortie de zéro à l'infini.

Elle est donnée par la formule : $f(x) = \begin{cases} 0 & \text{si } x < 0 \\ x & \text{sinon} \end{cases}$

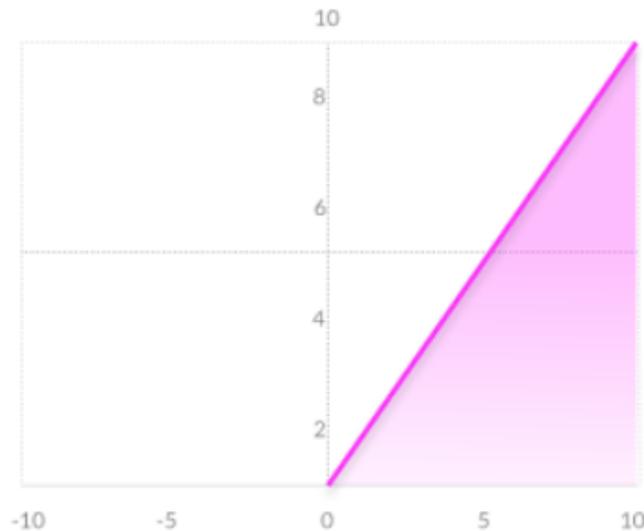


FIGURE 2.17 – Graphe de ReLU

2.4.3.2 Réseau neuronal convolutif

Les réseaux de neurones convolutifs - *en anglais Convolutional Neural Network (CNN)*- sont une classe de réseaux de neurones profonds spécialement conçus pour le traitement efficace des données structurées en grille, telles que des images. Ils sont largement utilisés dans le domaine de la vision par ordinateur et ont été à l'origine de nombreuses avancées majeures dans des tâches telles que la classification d'images, la détection d'objets, la segmentation sémantique, etc.

La principale caractéristique des CNN réside dans leur capacité à capturer des motifs locaux et hiérarchiques à différentes échelles spatiales. Ils utilisent des couches de convolution pour effectuer des opérations de filtrage sur les données d'entrée, en appliquant des noyaux de convolution qui glissent sur l'image pour extraire des caractéristiques locales. Ces caractéristiques sont ensuite combinées dans des couches ultérieures, telles que des couches de regroupement (pooling), pour agréger les informations spatiales et réduire la dimensionnalité.

Un aspect important des CNN est leur capacité à apprendre automatiquement des caractéristiques pertinentes à partir des données, sans nécessiter une ingénierie de caractéristiques manuelle. Cette capacité est rendue possible grâce à l'utilisation de couches de convolution avec des poids appris (ou filtres) qui sont ajustés pendant la phase d'apprentissage à l'aide de l'optimisation par rétropropagation du gradient.

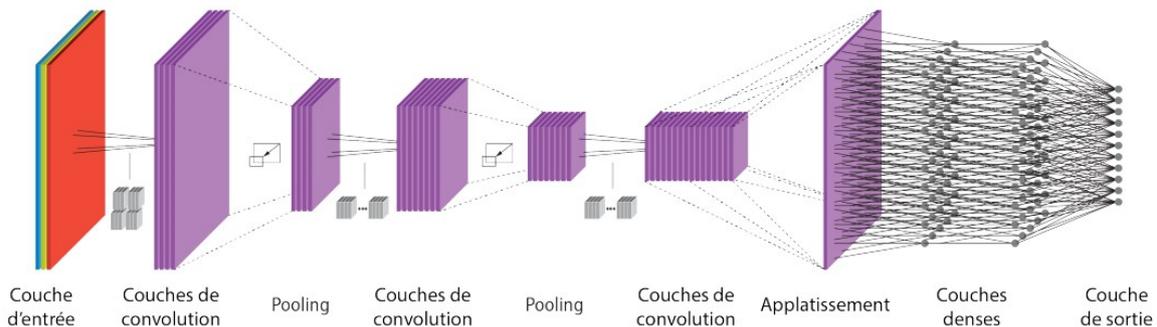


FIGURE 2.18 – Architecture standard d'un CNN

2.4.3.3 Bloc des couches d'extraction des caractéristiques

Le premier bloc de ce réseau se distingue par sa fonction d'extracteur de caractéristiques. La première couche de ce bloc applique plusieurs noyaux de convolution pour filtrer l'image, puis elle applique une fonction d'activation pour normaliser ou redimensionner les caractéristiques, ce qui crée une carte de caractéristiques. Ce processus peut être répété plusieurs fois. Les cartes de caractéristiques obtenues sont ensuite filtrées à l'aide de nouveaux noyaux, ce qui génère de nouvelles caractéristiques à normaliser et à filtrer à nouveau, et ainsi de suite. Enfin, les valeurs des dernières caractéristiques sont regroupées en un vecteur colonne [43]. Ce vecteur représente la sortie du premier bloc et sert d'entrée au second bloc.

Dans cette partie du réseau, il y a principalement deux types de couches : les couches convolutionnelles et les couches de Pooling.

Couches convolutionnelles

La couche de convolution joue un rôle essentiel dans les réseaux de neurones convolutifs

et constitue généralement leur première couche. Son objectif principal est de détecter la présence d'un ensemble de caractéristiques dans les images en entrée. Pour cela, elle effectue une opération de filtrage par convolution. Le principe est de faire glisser une fenêtre, par un nombre pas appelé *strides*, représentant la caractéristique souhaitée sur l'image et de calculer le produit de convolution entre la caractéristique et chaque portion de l'image balayée. Dans ce contexte, une caractéristique est considérée comme un filtre, les deux termes étant équivalents.

La couche de convolution reçoit plusieurs images en entrée et effectue la convolution de chaque image avec chaque filtre. Les filtres correspondent précisément aux caractéristiques que l'on souhaite détecter. Pour chaque paire (image, filtre), une carte d'activation ou carte des caractéristiques est obtenue. Cette carte indique où se trouvent les caractéristiques dans l'image : plus la valeur est élevée, plus la zone correspondante dans l'image ressemble aux caractéristiques.

Contrairement aux méthodes traditionnelles, les caractéristiques ne sont pas prédéfinies selon un formalisme spécifique, mais sont apprises au fur à mesure lors de la phase d'entraînement. Les noyaux des filtres représentent les poids de la couche de convolution. Ils sont initialisés puis ajustés grâce à la rétropropagation du gradient.

C'est là que réside la puissance des réseaux de neurones convolutifs : ils sont capables de déterminer automatiquement les éléments discriminants d'une image en s'adaptant au problème donné. Par exemple, si l'objectif est de distinguer les chats des chiens, les caractéristiques automatiquement apprises peuvent décrire la forme des oreilles ou des pattes.

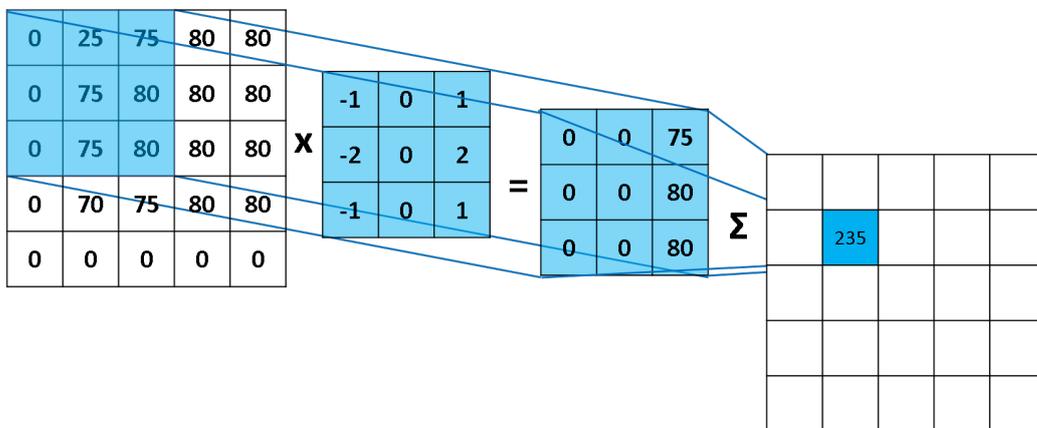


FIGURE 2.19 – Couche de convolution

Couches de Pooling

La couche de pooling réalise une opération de sous-échantillonnage de l'image en utilisant uniquement les dimensions spatiales de la largeur et de la hauteur. L'image d'entrée est divisée en carrés non superposés. Cette couche est souvent placée entre deux couches de convolution consécutives dans une architecture CNN afin de réduire le nombre de paramètres et la puissance de calcul requise, tout en préservant les caractéristiques les plus importantes. Dans la pratique, l'image est divisée en petites cellules carrées adjacentes, espacées d'un certain pas pour éviter une perte excessive d'informations. Le nombre d'images de sortie reste le même que celui d'entrée, mais chaque image possède moins de pixels [43].

Il existe deux types principaux de pooling : le max-pooling et l'average-pooling, le max-

pooling renvoie la valeur maximale de la partie de l'image couverte par le noyau, tandis que l'average-pooling renvoie la moyenne des valeurs de cette partie de l'image. En pratique, le max-pooling est le plus couramment utilisé et donne de meilleurs résultats que l'average-pooling. La figure 2.6 illustre un exemple d'opérations de max-pooling et d'average-pooling.

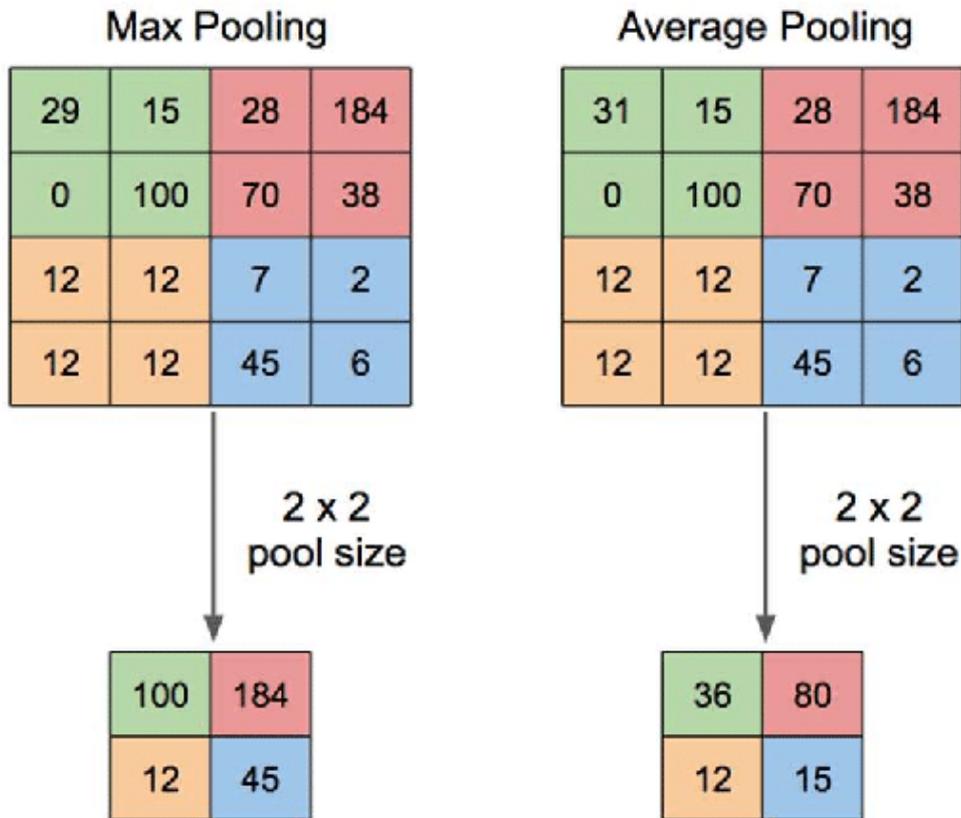


FIGURE 2.20 – Opération de Pooling (avec le max-pooling et average-pooling)

2.4.3.4 Bloc des couches de classification

Le bloc de classification est utilisé pour effectuer des tâches de classification sur les données d'entrée. Il est situé à la fin du réseau après les couches d'extraction de caractéristiques.

Le bloc de classification prend les caractéristiques extraites par les couches précédentes et les utilise pour prédire la classe ou la catégorie à laquelle appartient l'entrées.

La première étape du bloc de classification consiste souvent à aplatir les caractéristiques en un vecteur pour les préparer à la classification. Cela signifie que les caractéristiques sont réorganisées à partir de leur structure spatiale ou temporelle en une représentation linéaire.

Ensuite, des couches entièrement connectées sont utilisés pour effectuer la classification. Ces couches sont composées de neurones qui sont connectés à tous les neurones de la couche précédente. Chaque neurone de la couche de classification combine les caractéristiques d'entrée pondérées par des poids, puis applique une fonction d'activation pour produire une sortie comme on a expliqué dans les sections précédentes.

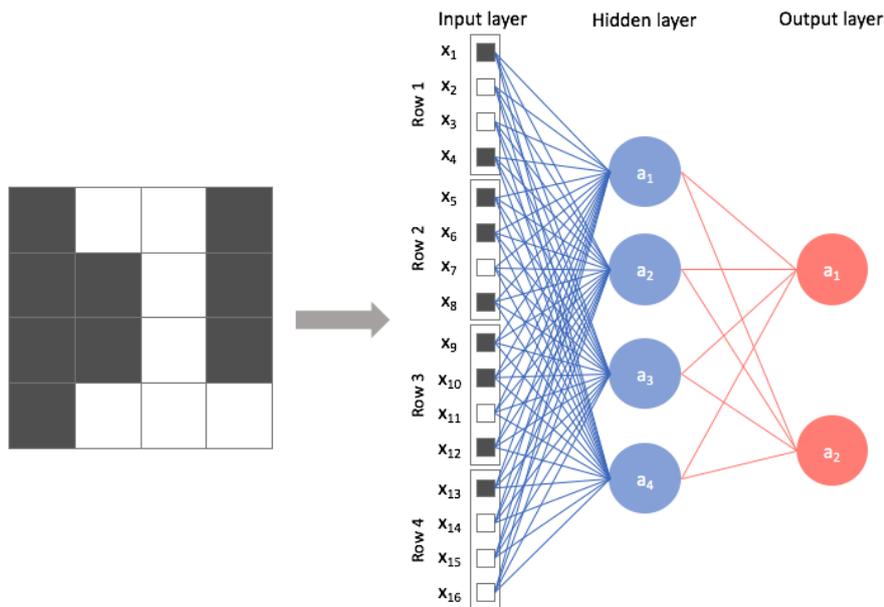


FIGURE 2.21 – Bloc de classification

2.5 Conclusion

Dans cette partie, nous avons acquis des connaissances approfondies sur les outils essentiels utilisés à chaque étape de notre projet. Nous avons exploré les filtres employés pour réduire les artefacts, ainsi que le concept des classifieurs et des caractéristiques nécessaires pour extraire les informations pertinentes en vue de la réalisation de l'application EEG souhaitée. Grâce à cette compréhension approfondie des différents éléments, nous sommes maintenant mieux préparés à mettre en œuvre notre application EEG de manière efficace et précise.

Dans le prochain chapitre nous présenterons l'architecture adoptée dans ce travail pour la détection de la schizophrénie et application BCI pour différents classifieurs, nous nous intéresserons aussi aux caractéristiques extraites, aux hyperparamètres et aux résultats expérimentaux obtenus.

Chapitre 3

Analyse et résultats expérimentaux

3.1 Introduction

Ce chapitre est consacré à la présentation des résultats expérimentaux obtenus en mettant en pratique la méthodologie de travail décrite précédemment. Nous avons mis en place un modèle de détection de la schizophrénie en utilisant différentes techniques de classification telles que la régression logistique, SVM, ANN, DNN et CNN. De plus, nous avons développé un modèle d'application BCI capable de détecter l'ouverture et la fermeture de la main gauche ou droite uniquement par l'imagination. Donc, nous commencerons par la description des bases de données ainsi que les l'ensemble de logiciels employés dans ce projet. Puis nous traiterons ces données en utilisant les méthodes expliquées précédemment pour extraire les informations pertinentes nécessaires à la classification. Nous effectuerons également une étude comparative sur l'impact des différentes fenêtres utilisées dans le prétraitement, ainsi que sur les différents types de caractéristiques utilisés. Par la suite, les résultats obtenus seront présentés et discutés en détail.

3.2 Description de les bases de données

3.2.1 Schizophrénie

L'étude de la schizophrénie a utilisé des données librement accessibles provenant d'un dépôt public créé par *Olejarczyk* et *Jernajczyk* [44]. La méthodologie de montage EEG 10/20 a été utilisée pour collecter les signaux EEG. Il s'agit des enregistrements EEG de 14 patients schizophrènes et de 14 sujets sains de l'Institut de psychiatrie et de neurologie de *Varsovie* (à l'exclusion des patients souffrant de troubles cérébraux). Les critères de sexe et d'âge ont été pris en compte pour le choix du groupe de contrôle. Les patients inclus dans cette étude étaient âgés de plus de 18 ans. Ces patients n'avaient consommé aucun médicament au moins sept jours avant l'enregistrement des données. Les patientes enceintes, les patients souffrant d'une pathologie cérébrale organique, les maladies neurologiques graves, la présence d'une affection médicale générale et les personnes âgées de moins de 18 ans ont été exclus de l'étude. En outre, les patients à un stade précoce de la maladie, comme ceux qui présentaient leur première crise, n'ont pas été inclus dans l'étude. Les enregistrements ont duré en moyenne 15 minutes, les yeux fermés et au repos. Les électrodes ont été placées selon le système 10/20. Les données ont été recueillies sur 19 canaux à une fréquence d'échantillonnage de 250 Hz.

TABLE 3.1 – Description de la base de données de la schizophrénie

Caractéristique	Value
Groupes	14 groupes schizophrènes, 14 groupes témoins
Genre	28 Patients (14 hommes , 14 femmes)
Âge moyen	27.9 ± 3.3 (7 hommes schizophrènes)
	28.3 ± 4.1 (7 femmes schizophrènes)
	26.8 ± 2.9 (7 hommes en bonne santé)
	28.7 ± 3.4(7 7 femmes en bonne santé)
Durée de chaque segment EEG	25 s(250 × 25 = 6250)

Les électrodes sont placés comme suite :

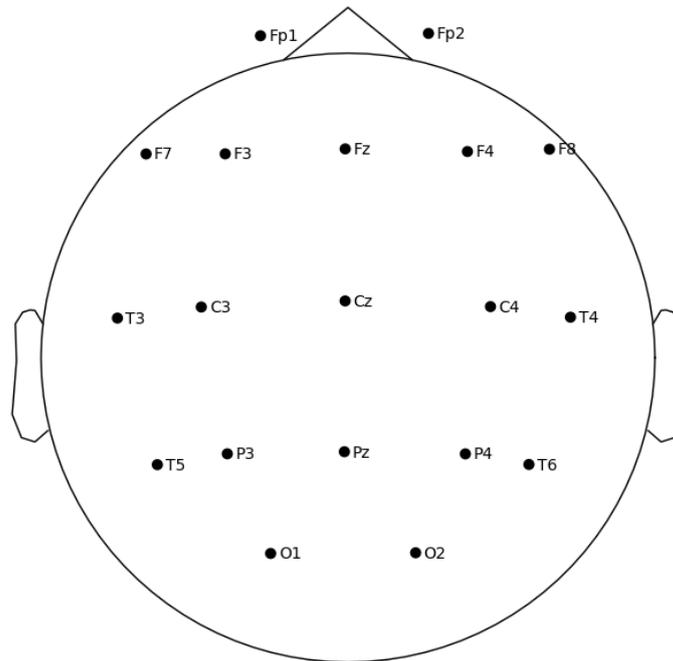


FIGURE 3.1 – Emplacement des électrodes pour la base de donnée de la schizophrénie

3.2.2 BCI

Nous avons utilisé les enregistrements EEG de 109 sujets effectuant quatre tâches motrices/imaginaires à l'aide d'un système BCI2000 à 64 canaux pour construire un système BCI polyvalent disponible dans la base de données PhysioNet [45]. Chaque participant a effectué 14 séries expérimentales comprenant deux séries de base (Baseline) et trois séries de deux minutes de tâches motrices réelles/imaginaires. Nous n'avons utilisé que les données correspondant aux tâches MI, car le BCI ne nécessite que des mouvements imaginaires pour la classification. Le calendrier de l'expérience est présenté à la figure 3.3. La configuration expérimentale était la suivante. Les deux premiers essais étaient les essais de base, l'un avec les yeux ouverts et l'autre avec les yeux fermés. Ensuite, le sujet a imaginé ouvrir/fermer le poing gauche/droit en fonction de l'indice affiché sur le côté gauche/droit de l'écran. Si le repère visuel apparaissait en haut de l'écran, le sujet devait imaginer qu'il fermait et ouvrait les deux poings. Si l'indice visuel se trouvait en bas de l'écran, le sujet devait imaginer qu'il ouvrait et fermait les deux pieds. Le sujet se détendait ensuite après chaque indice.

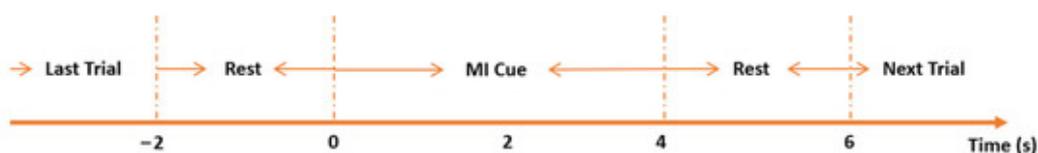


FIGURE 3.2 – Paradigme temporel de l'ensemble des données

L'emplacement des électrodes était comme suite :

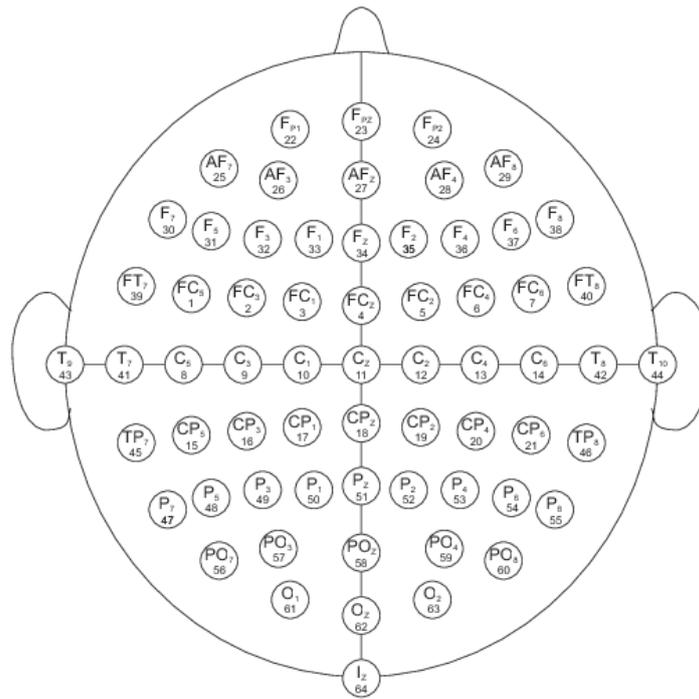
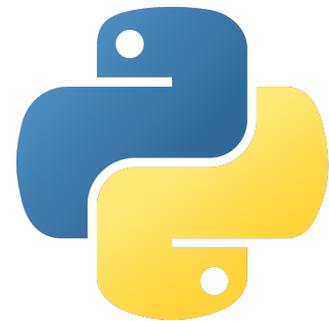


FIGURE 3.3 – Emplacement des électrodes pour la base de donnée de BCI

3.3 Logiciels et bibliothèques

3.3.1 Python

Python est un langage de programmation populaire, polyvalent et facile à apprendre. Il est largement utilisé dans différents domaines tels que le développement web, la science des données et l'intelligence artificielle. Python se distingue par sa syntaxe claire et lisible, sa bibliothèque standard étendue et sa communauté active. C'est un langage flexible qui supporte plusieurs paradigmes de programmation.



3.3.2 MNE

MNE est une bibliothèque Python largement utilisée dans le domaine de la neuroimagerie pour l'analyse des signaux électroencéphalographiques (EEG), magnétoencéphalographiques (MEG) et autres données de neuroimagerie. MNE est l'abréviation de "M/EEG and Neural Signal Processing".



MNE offre une gamme complète d'outils pour le prétraitement, la visualisation et l'analyse des données M/EEG. Elle permet de charger, manipuler et explorer les données brutes, de les filtrer, de détecter et supprimer les artefacts, d'effectuer des analyses statistiques et d'afficher les résultats.

3.3.3 Scikit-learn

scikit-learn (sklearn) est une bibliothèque Python populaire pour l'apprentissage automatique. Elle propose une API cohérente et intuitive, facilitant son utilisation. La bibliothèque offre des outils de prétraitement des données et prend en charge de nombreux algorithmes d'apprentissage supervisé et non supervisé. Elle permet également la sélection de modèles et l'évaluation des performances. Scikit-learn s'intègre bien avec d'autres bibliothèques Python telles que NumPy et pandas, et peut être étendu avec des fonctionnalités personnalisées.



3.3.4 TensorFlow

TensorFlow est un framework d'apprentissage automatique open-source apprécié pour son adaptabilité et sa fiabilité. Créé par Google, il constitue une plateforme influente pour le développement et le déploiement de divers modèles d'apprentissage automatique. TensorFlow utilise un graphe de flux de données, où les nœuds représentent les opérations mathématiques et les arêtes décrivent le mouvement des tenseurs entre ces opérations. Cette approche basée sur un graphe permet une exécution parallèle, ce qui rend TensorFlow adapté à la recherche et à la production.



TensorFlow utilise de nombreux outils et bibliothèques qui facilitent de nombreuses applications. Sa polyvalence et sa capacité à exploiter les accélérateurs matériels tels que les GPU et les TPU font de TensorFlow le choix privilégié pour l'apprentissage profond et les projets d'IA. Avec une communauté active et dynamique, TensorFlow continue de se développer, offrant aux développeurs un écosystème complet pour développer, entraîner et déployer des modèles d'apprentissage automatique à grande échelle.

3.3.5 Google Colaboratory

Google Colab est une plateforme cloud fournie par Google qui permet aux utilisateurs d'exécuter du code Python en utilisant des notebooks Jupyter. Cette plateforme offre un environnement virtuel puissant avec des ressources matérielles telles que des processeurs et des processeurs graphiques (GPU). Elle est principalement utilisée pour des tâches d'analyse de données, d'apprentissage automatique (machine learning) et de projets de codage collaboratifs.



Les utilisateurs peuvent créer des notebooks Jupyter interactifs contenant du code, des explications textuelles, des visualisations et des équations mathématiques. Colab fonctionne sur l'infrastructure cloud de Google, ce qui signifie que les utilisateurs peuvent bénéficier de la puissance de calcul des serveurs de Google sans avoir à installer de logiciels sur leur propre machine.

L'un des avantages de Google Colab est l'accès gratuit aux ressources GPU, ce qui permet d'accélérer les tâches d'apprentissage profond (deep learning) et de traiter des ensembles de

données volumineux de manière plus efficace.

3.4 Analyse des données et résultats

3.4.1 Pré-traitement de données

Segmentation des données pour la schizophrénie :

Pour les données de schizophrénie nous avons opté pour la segmentation temporelle fixe avec une fenêtre de 5 secondes avec un chevauchement de 1 seconde, et cela revient à la non-stationnarité des signaux EEG et donc il sera plus intéressant de les exploiter sur des segments de 5 secondes.

Le chevauchement de 1 seconde entre les segments est utilisé pour éviter les pertes d'informations causées par la discontinuité créée lors de l'application des fenêtres. Lorsque on applique une fenêtre à un signal, on crée une discontinuité aux bords de la fenêtre, ce qui peut introduire des artefacts indésirables. En utilisant un chevauchement, on peut assurer que les informations aux bords des segments sont partagées entre les segments adjacents, réduisant ainsi l'impact des discontinuités.

Cette approche de segmentation temporelle fixe avec chevauchement est utilisée pour analyser les signaux EEG dans le contexte de la schizophrénie. En découpant les signaux en segments de 5 secondes, il est possible d'observer les caractéristiques spécifiques de la schizophrénie à différentes échelles temporelles et d'extraire des informations pertinentes pour la détection ou la classification de cette pathologie.

Segmentation des données pour l'application BCI :

Pour l'application BCI, nous avons mis en œuvre la technique de segmentation qui repose sur des événements spécifiques. Pour ce faire, nous avons extrait des segments de 0,7 seconde à partir de chaque événement, où l'action de l'imagination est réalisée par le participant. Ces événements étaient liés à l'ouverture ou à la fermeture de la main gauche, ainsi qu'à l'ouverture ou à la fermeture de la main droite.

En utilisant cette approche de segmentation basée sur les événements, nous avons pu isoler et analyser des périodes spécifiques d'activité cérébrale liées à l'imagination des mouvements de la main. En focalisant notre attention sur des segments de durée fixe, nous avons pu obtenir des données plus précises et spécifiques sur les schémas d'activité cérébrale associés à chaque événement.

Cela nous a permis de mieux comprendre les modèles et les caractéristiques distincts des signaux cérébraux lors de l'imagination des mouvements de la main gauche ou de la main droite. En segmentant les données de cette manière, nous avons pu développer des algorithmes plus précis pour détecter et interpréter les intentions des participants, facilitant ainsi une communication plus efficace entre le cerveau et l'ordinateur.

Filtrage et réduction des artefacts

Afin de réduire au maximum les artefacts, on utilise un filtre qui sera adapté avec l'application, pour la schizophrénie le filtre passe bas utilisé est de **50 Hz**, et un filtre passe bande de **8-30 Hz** appliqué sur les données de la BCI où l'activité est plus intéressante dans cette bande. Puis on applique l'ACI pour décomposer le signal en plusieurs composantes indépendantes.

La figure 3.4 fournit une représentation graphique des composantes indépendantes extraites à partir de l'ACI pour une personne saine, ainsi que pour une personne atteinte de la schizophrénie.

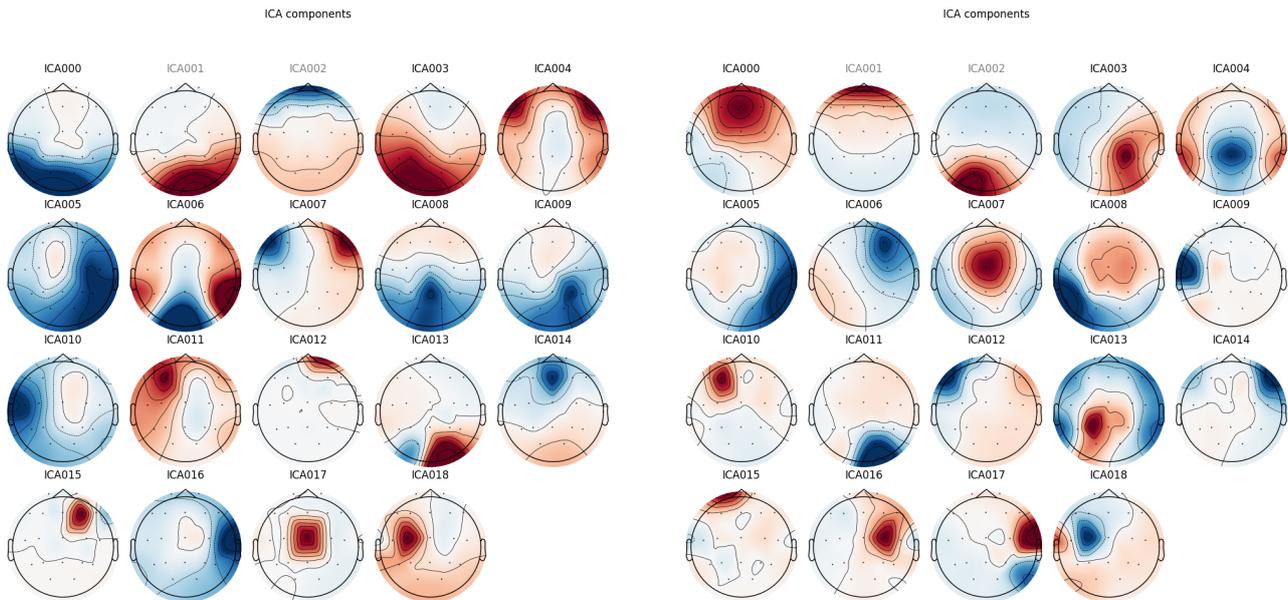


FIGURE 3.4 – Composantes indépendantes pour une personne saine(droite) et une personne schizophrène (gauche)

La différenciation des couleurs peut être utilisée pour indiquer des polarités différentes des composantes ICA. Les composantes affichées en rouge représentent des sources d'activité positive, tandis que celles affichées en bleu représentent des sources d'activité négative.

On constate que la schizophrénie est une maladie très complexe qui touche la majorité des zones du cerveau ne se limite pas à viser un seul canal.

La figure 3.5 permet de visualiser l'effet de l'ACI pour réduire les artefacts.

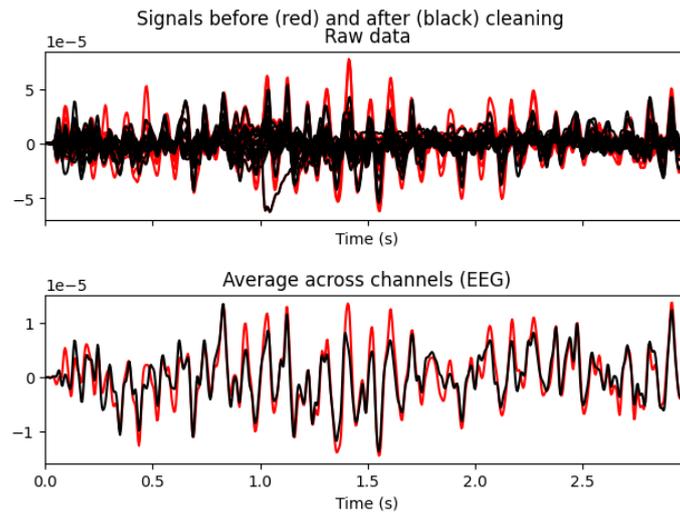


FIGURE 3.5 – Réduction d'artefactes

De plus on applique un filtre **Notch** sur les signaux afin d'éliminer les bruits causés par l'alimentation et pour enrichir notre étude comparative, nous appliquerons 3 différents types de filtre FIR afin de comparer leurs effet sur l'exactitude.

3.4.2 Résultats expérimentaux

Dans cette section, nous présentons les résultats de nos expériences visant à évaluer l'efficacité des modèles d'apprentissage automatique dans la détection de la schizophrénie et la reconnaissance des activités cérébrales par l'imagination, main gauche ou droite dans notre cas.

3.4.2.1 La détection de la Schizophrénie

Les résultats expérimentaux de notre étude ont le potentiel de contribuer à l'amélioration de la précision du diagnostic de la schizophrénie et de fournir des informations précieuses pour la prise en charge des patients. Ils pourraient également ouvrir la voie à de nouvelles approches de recherche et de traitement basées sur l'apprentissage automatique dans le domaine de la santé mentale.

Évaluation de l'effet du fenêtrage

Dans cette partie, nous évaluerons l'impact des différentes fenêtres utilisées pour le filtre FIR sur les performances individuelles de chaque classifieur, à savoir le SVM, la régression logistique, un réseau de neurones simple (ANN) et un réseau de neurones profond (DNN). Cette analyse nous aidera à déterminer la combinaison fenêtre-classifieur la plus optimale donnant les meilleures performances dans le contexte de notre problème de classification.

Nous effectuerons des expériences en utilisant différentes fenêtres couramment utilisées dans les filtres FIR, telles que la fenêtre de Hamming, la fenêtre de Hanning et la fenêtre de Blackman. Pour chaque fenêtre, nous appliquerons le filtre FIR aux données d'entrée avant de les utiliser comme caractéristiques pour chaque classifieur.

Pour ces expériences, voici les paramètres fixés pour chaque classifieurs :

- **SVM** : on a opté pour le noyaux **Rbf** avec les valeurs 10 et 0.01 pour les paramètres C et gamma respectivement.
- **LR** : Dans notre cas on a fixé le paramètre C à 1 en utilisant la régularisation **L2** et le solveur *liblinear* pour la résolution du problème d'optimisation de la régression logistique.
- **ANN** : Ce modèle est constitué d'une couche d'entrée de 32 neurones avec la fonction d'activation *RELU* et une couche de sortie basé sur la fonction d'activation *sigmoïde*.
- **DNN** : Ce modèle est constitué de trois couches cachés avec un nombre de neurones 64 , 32 et 16 respectivement, cela en utilisant la fonction d'activation *RELU*. En plus d'une couche de sortie utilisant la fonction *sigmoïde* pour une classification binaire.

Les résultats des expériences effectuées sont illustrés dans les tableaux 3.2, 3.3 , 3.4 ,3.5 ci-dessous :

TABLE 3.2 – Évaluation des performances sans filtre FIR

Sans Filtrage				
Classifieur	Exactitude (%)	F1-score (%)	Précision (%)	Recall (%)
LR	88.2	89	89.7	88
SVM	89	89	90	89
ANN	92.1	92	92	92
DNN	92.8	93	93	93

TABLE 3.3 – Évaluation des performances à l'aide de la fenêtre Hamming

Fenêtre Hamming				
Classifieur	Exactitude (%)	F1-score (%)	Précision (%)	Recall (%)
LR	89.9	91	92.7	88.6
SVM	89.5	90.5	90	91
ANN	93.3	93	93	93
DNN	93.7	94	93	94

TABLE 3.4 – Évaluation des performances à l'aide de la fenêtre Hanning

Fenêtre Hanning				
Classifieur	Exactitude (%)	F1-score (%)	Précision (%)	Recall (%)
LR	89.6	90.3	92.7	88.1
SVM	89.4	90.4	90	91
ANN	93	93	93	93
DNN	94.1	94	94	94

TABLE 3.5 – Évaluation des performances à l’aide de la fenêtre Blackman

Fenêtre Blackman				
Classifieur	Exactitude (%)	F1-score (%)	Précision (%)	Recall (%)
LR	89.3	90	92.2	88
SVM	89.5	90.6	89.8	91.4
ANN	92.4	92	92	92
DNN	93.9	94	94	94

En premier lieu, on constate que l’application des du filtre FIR a induit à une augmentation en terme d’exactitude comparant au premier cas sans filtrage, illustré dans le tableau 3.2. Cela revient à la suppression des fréquences indésirables.

En second lieu, après l’évaluation des différentes fenêtres associés au filtre FIR, les résultats des tableaux 3.3 3.4 3.5 montrent que les meilleures performances sont obtenues pour la fenêtre de **Hanning** avec le DNN en atteignant 94.1% d’exactitude.

Évaluation de l’effet des caractéristiques

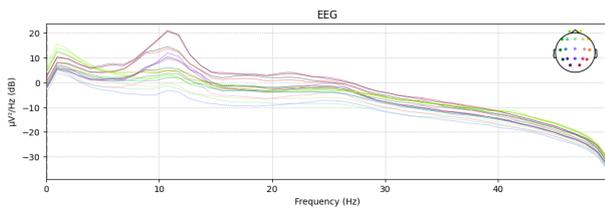
Dans cette partie nous évaluerons les différents effets des caractéristiques statiques, fréquentielle et les caractéristiques dynamiques non linéaires, qui ont été décrits précédemment, sur les performances des classifieurs. Les caractéristiques statiques et dynamiques non linéaires sont calculé suivant 8.2 et 8.4. Cependant, les caractéristiques fréquentielles demandent une étape de calcul supplémentaire qui consiste à choisir entre une des 2 méthodes de fenêtrage pour le calcul de la DSP. Ces méthodes seront décrites dans ce qui suit.

Méthode Welch :

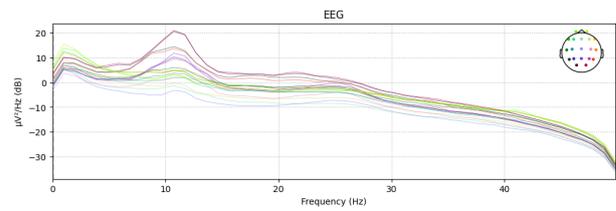
La méthode Welch est une technique utilisée pour estimer la densité spectrale de puissance (DSP) d’un signal. Elle combine des segments de données de manière non redondante afin de réduire les effets de la variance et d’améliorer la précision de l’estimation spectrale.

En utilisant la méthode Welch, on peut obtenir une estimation plus lisse et plus précise de la densité spectrale de puissance d’un signal, comparée à une simple FFT sur l’ensemble des données. Cette méthode est couramment utilisée dans des domaines tels que l’analyse de signaux, le traitement du son, la surveillance de la qualité du signal, et d’autres applications nécessitant une analyse spectrale précise.

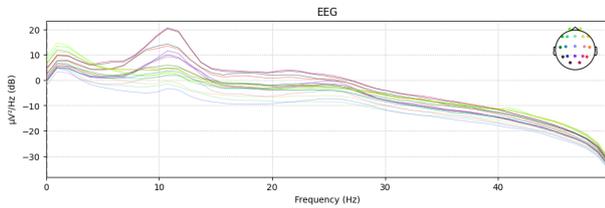
Les figures 3.6a 3.6b 3.6c 3.6d fournissent des représentation graphique de la DSP d’un individu de notre base de données calculé respectivement suivant les fenêtres : Hamming, Hanning, Blackman et Bartlett.



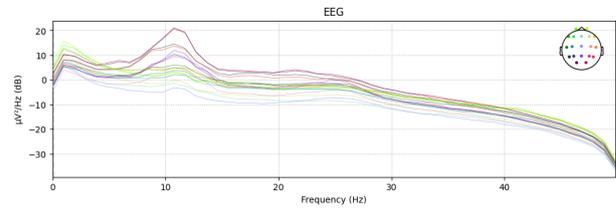
(a) Représentation DSP avec fenêtre hamming



(b) Représentation DSP avec fenêtre hanning



(c) Représentation DSP avec fenêtre blackman

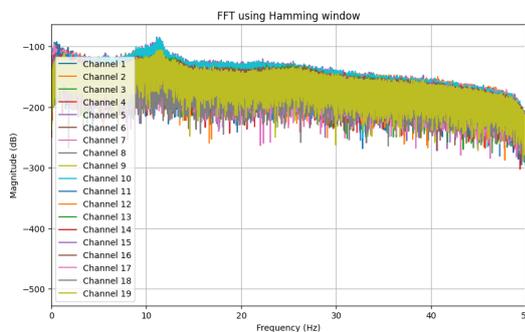


(d) Représentation DSP avec fenêtre bartlett

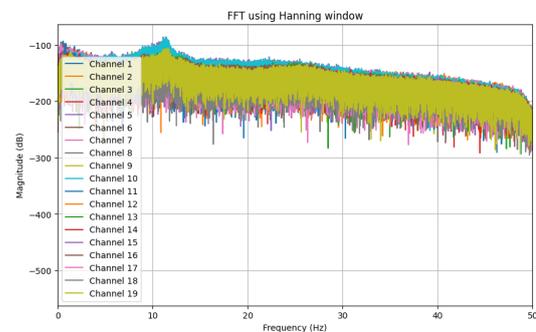
FIGURE 3.6 – Représentation DSP par différents types de fenêtres (Méthode Welch)

En comparant avec les figures 3.7a 3.7b 3.7c 3.7d qui illustrent la représentations de la DSP calculée par une méthode classique, on remarque la présence du phénomène de **fuite spectrale**.

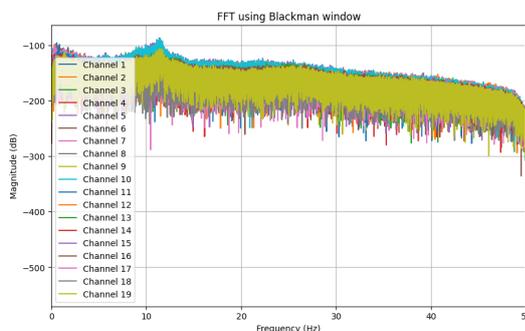
La fuite spectrale est un phénomène qui se produit lorsqu'un signal présente des composantes de fréquence qui ne sont pas parfaitement alignées avec les points de l'échantillonnage lors du calcul de la transformée de Fourier. Cela se traduit par une dispersion d'énergie du signal réel sur plusieurs fréquences adjacentes dans le spectre obtenu.



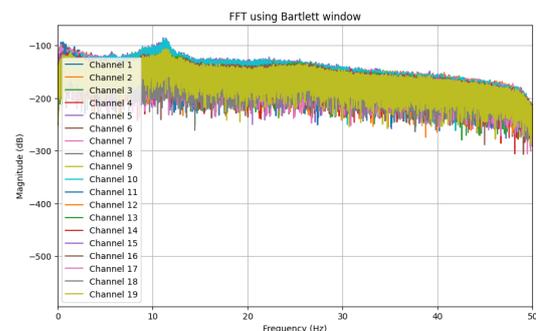
(a) Représentation DSP avec fenêtre hamming par méthode classique



(b) Représentation DSP avec fenêtre hanning par méthode classique



(c) Représentation DSP avec fenêtre blackman par méthode classique



(d) Représentation DSP avec fenêtre bartlett par méthode classique

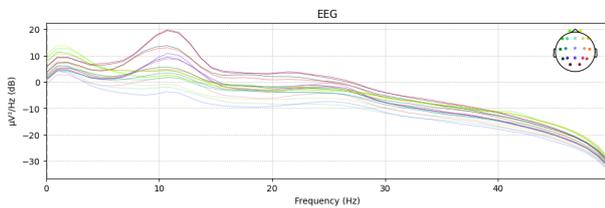
FIGURE 3.7 – Représentation DSP par différents types de fenêtres (Méthode Classique)

Méthode Multitaper

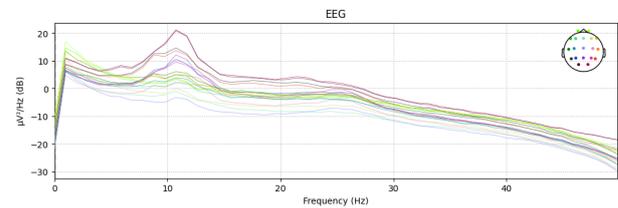
La méthode Multitaper est une technique d'analyse spectrale qui permet d'estimer la densité spectrale de puissance (DSP) d'un signal avec une meilleure résolution et une plus grande précision. Elle utilise plusieurs fenêtres, également appelées tapers, pour calculer l'estimation spectrale. Chaque fenêtre est appliquée au signal original, produisant ainsi plusieurs réalisations fenêtrées du signal. Ces réalisations sont ensuite transformées de Fourier pour obtenir les spectres correspondants.

Les avantages de la méthode Multitaper incluent une meilleure suppression du bruit et une réduction de la variance par rapport aux méthodes traditionnelles. Elle permet également une meilleure résolution en fréquence, ce qui est particulièrement utile pour détecter des composantes de fréquence étroites ou proches les unes des autres.

Les figures 3.8a 3.8b sont des représentations graphiques de la DSP d'un individu de notre base de données calculer respectivement suivant les fenêtres de Slepian et de Kaiser.

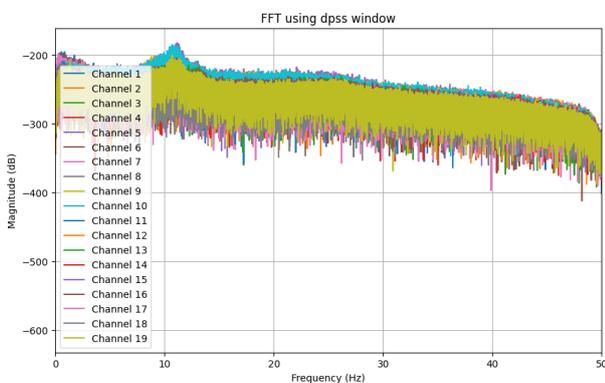


(a) Représentation DSP avec fenêtre Slepian

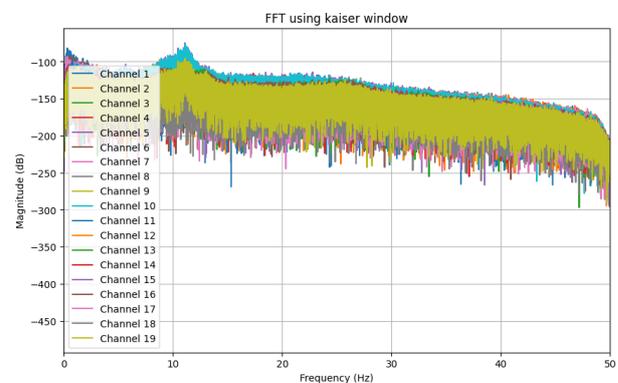


(b) Représentation DSP avec fenêtre Kaiser

FIGURE 3.8 – Représentation DSP par différents types de fenêtres (Méthode Multitaper)



(a) Représentation DSP avec fenêtre Slepian méthode classique



(b) Représentation DSP avec fenêtre kaiser méthode classique

FIGURE 3.9 – Représentation DSP par différents types de fenêtres (Méthode Classique)

Les tableaux 3.6 3.7 3.8 3.13 montrent les résultats retrouvés en utilisant les différents classifieurs. On voit bien qu'en changeant les types de caractéristiques, L'exactitude varie de 84.73% à 97.84%. Le pic d'exactitude de **97.84%** est atteint en utilisant les caractéristiques dynamiques non linéaires sous le classifieur SVM.

TABLE 3.6 – Évaluation des performances des caractéristiques statiques

Caractéristiques statiques				
Classifieur	Exactitude (%)	F1-score (%)	Précision (%)	Recall (%)
LR	89.9	91	92.7	88.6
SVM	89.5	90.5	90	91
ANN	93.3	93	93	93
DNN	93.7	94	93	94

TABLE 3.7 – Évaluation des performances des caractéristiques fréquentielle (Welch)

Caractéristiques fréquentielle (welch)				
Classifieur	Exactitude (%)	F1-score (%)	Précision (%)	Recall (%)
LR	84.73	85.87	87.56	84.25
SVM	92.36	93.03	93.51	92.56
ANN	93	93	93	93
DNN	94.51	95	95	95

TABLE 3.8 – Évaluation des performances des caractéristiques fréquentielle (Multitaper)

Caractéristiques fréquentielle (Multitaper)				
Classifieur	Exactitude (%)	F1-score (%)	Précision (%)	Recall (%)
LR	85.35	86.44	88.20	84.76
SVM	94.17	94.67	95.39	93.95
ANN	95.56	94	94	94
DNN	94.3	94	94	94

TABLE 3.9 – Évaluation des performances des caractéristiques dynamiques non linéaires

caractéristiques dynamiques non linéaires				
Classifieur	Exactitude (%)	F1-score (%)	Précision (%)	Recall (%)
LR	88.68	89.69	90	89.29
SVM	97.29	97	97	97
ANN	95.28	95	95	95
DNN	97.84	98.04	98.23	97.85

Le temps de calcul est un autre paramètres à considérer lors du calcul des caractéristiques. Le tableau 3.10 résume le temps de calcul nécessaire pour chaque caractéristique.

TABLE 3.10 – Évaluation des performances des caractéristiques dynamiques non linéaires

Temps de calcul caractéristiques	
Caractéristiques	Temps de calcul
Caractéristiques statiques	4 min
Caractéristiques fréquentielle (welch)	14 min
Caractéristiques fréquentielle (Multitaper)	29 min
Caractéristiques dynamiques non linéaires	2h 30 min

3.4.2.2 Application BCI

Dans cette partie, nous avons évalué les différents classifieurs utilisés dans la partie précédente pour une classification binaire cette fois-ci en visant à différencier l'imagination d'ouvrir et de fermer la main droite de celle de la main gauche. L'objectif était d'obtenir des résultats qui se rapprochent le plus possible des mouvements réels lorsqu'on imagine ces actions.

Les résultats sont illustrés dans les tableaux suivants :

TABLE 3.11 – Évaluation des performances des caractéristiques dynamiques non linéaires pour l'application BCI

Caractéristiques dynamiques non linéaires				
Classifieur	Exactitude (%)	F1-score (%)	Précision (%)	Recall (%)
LR	48.75	45.3	44.3	46
SVM	48	45.3	44.3	46.36
ANN	50	51	51	50
DNN	48	47	46	47

TABLE 3.12 – Évaluation des performances des caractéristiques statiques pour l'application BCI

caractéristiques dynamiques non linéaires				
Classifieur	Exactitude (%)	F1-score (%)	Précision (%)	Recall (%)
LR	53.75	51.10	49.5	52.7
SVM	58.33	61.24	53.37	71.8
ANN	51	51	50	51
DNN	55	54	54	54

Les résultats obtenus peuvent être attribués à la complexité de la base de données d'imagerie motrice, qui présente plusieurs aspects ajoutant de la difficulté à notre modèle lors de l'extraction des caractéristiques. Tout d'abord, la base de données contient des données provenant de plusieurs participants, ce qui signifie que les modèles doivent prendre en compte les variations individuelles et les différences interpersonnelles. Cela peut rendre l'analyse et l'apprentissage plus complexes, car il faut trouver un équilibre entre les caractéristiques générales et spécifiques à chaque participant.

De plus, l'imagerie motrice elle-même est un domaine complexe. Il s'agit de la représentation mentale des mouvements sans les exécuter physiquement, ce qui implique des processus cognitifs complexes. Les données d'imagerie motrice peuvent être influencées par des facteurs tels que la concentration, l'expérience préalable du participant, et même des aspects émotionnels ou motivationnels. Toutes ces variables ajoutent une autre couche de complexité à la tâche d'extrapoler des caractéristiques significatives à partir de la base de données.

Tenant compte de cette complexité, nous avons opté pour l'utilisation des réseaux de neurones convolutive (CNN) en raison de leur capacité à résoudre efficacement ce type de problème, en particulier grâce à leurs couches de convolution qui sont capables d'extraire les caractéristiques les plus pertinentes, même dans des situations complexes.

L'architecture du CNN proposée : Dans cette architecture, les données d'entrée sont d'abord réorganisées pour traiter les informations temporelles et spatiales qui seront extraites et classifiées en passant par les couches suivante :

1. Couche de convolution temporelle : elle est appliquée avec 40 filtres de taille (25,1) pour extraire les caractéristiques temporelles des données.
2. Couche de convolution spatiale : utilisée avec les mêmes 40 filtres, mais cette fois avec une taille de noyau de (1,64), pour capturer les caractéristiques spatiales dans les données.
3. Couche de normalisation par lot (*batch normalization*) : est appliquée afin de normaliser les activations des filtres.
4. Couche de non linéarité : qui applique la fonction non linéaire (*square*) aux activations résultantes pour introduire de la non-linéarité dans le modèle.
5. Couche de pooling maximale : utilisée pour réduire la dimensionnalité des caractéristiques extraites.
6. Couche de non linéarité : Une autre fonction non linéaire (*safe_log*) est appliquée aux activations après le pooling.
7. Couche de dropout : utilisée pour régulariser le modèle en désactivant aléatoirement certains neurones avec la probabilité de 0.5 dans notre cas.
8. Couche classification : C'est une couche de convolution utilisant 2 filtres de taille (1,1) qui vise à combiner et à pondérer les activations provenant des couches précédentes pour obtenir les scores de classification. Cette convolution est suivie par l'application de la fonction **softmax** pour l'extraction des probabilités de classe.

Cette architecture combine des opérations de convolution temporelle et spatiale, de normalisation, de non-linéarité et de pooling pour extraire des caractéristiques discriminantes des données d'entrée et effectuer la classification. La différence entre la convolution temporelle et spatiale est illustrés sur la figure 3.10 :

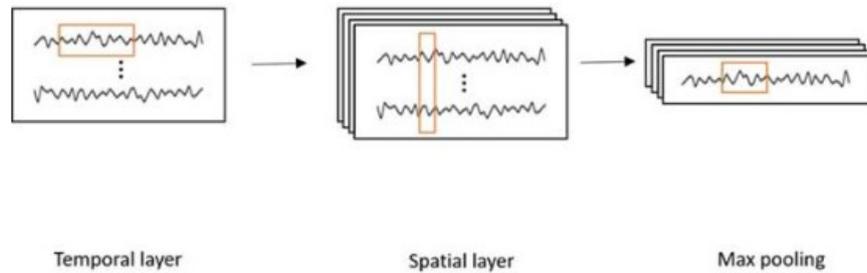


FIGURE 3.10 – Résumé sur la couche d'extraction caractéristique du CNN utilisé

Entraînement du modèle : Nous avons divisé notre base de données en plusieurs expériences pour évaluer notre modèle. Nous l'avons entraîné en utilisant deux expériences de chaque groupe de 80 participants qui vont imaginer l'ouverture et la fermeture leur main gauche ou droit selon l'action demandé.

TABLE 3.13 – Performances du modèle CNN entraîné sur 80 participants

Performances du modèle CNN		
Train (%)	Validation (%)	Test (%)
84.8	77.3	76.4

Évaluation : Lors de l'évaluation, nous allons évaluer les performances de notre modèle uniquement sur la troisième expérience fictive réalisée par les 25 premiers participants. Cette évaluation sera complétée par une expérience réelle où le mouvement sera effectivement réalisé.

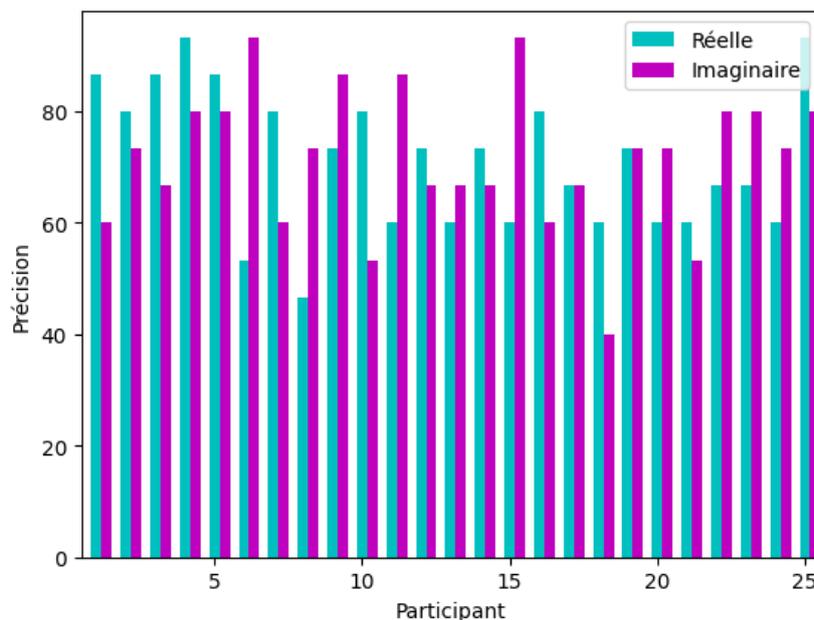


FIGURE 3.11 – Graphe de l'exactitude entre l'imagerie motrice et sa correspondance en réel pour chaque patient

La figure 3.11 montre les variations des performances du modèle pour chaque patient, résultant de la complexité et de l'unicité des signaux EEG.

Certains patients peuvent être plus réceptifs à l'imagerie motrice, ce qui leur permet de mieux reproduire les mouvements réels lorsqu'ils se concentrent sur l'imagerie. Ces patients peuvent être capables de créer une connexion étroite entre leur imagerie mentale et leurs capacités motrices, conduisant à des performances plus élevées lors de l'utilisation de l'imagerie motrice. D'autres patients peuvent avoir une meilleure capacité à effectuer les mouvements réels, ce qui se traduit par des performances plus élevées lors des tests impliquant les mouvements réels. Ces patients peuvent bénéficier d'une coordination motrice plus développée ou d'une expérience antérieure dans l'exécution des mouvements spécifiques évalués.

D'après la figure 3.11 nous remarquons que la différence d'exactitude entre l'imagerie motrice et l'action réelle varie de 53.3% à 93.3% pour une moyenne de 70% pour les actions réelle et 71.46% pour l'imagerie motrice par participant et cela revient aux raisons suivantes :

- **Différences individuelles** : Les résultats peuvent révéler des variations individuelles dans la capacité du modèle à prédire les mouvements réels à partir de l'imagerie motrice. Certains participants peuvent avoir des caractéristiques motrices ou des schémas de signaux plus difficiles à prédire, ce qui se traduit par une plus grande différence d'exactitude, tandis que d'autres peuvent présenter une concordance plus élevée entre l'imagerie motrice et les mouvements réels
- **Limitations du modèle** : La différence d'exactitude peut également souligner les limitations du modèle lui-même. Certains modèles d'imagerie motrice peuvent ne pas capturer pleinement la complexité des mouvements réels, entraînant ainsi une plus grande divergence entre l'imagerie motrice simulée et les actions réelles.
- **Adaptation du modèle** : Nous remarquons que la différence d'exactitude est importante pour certains participants, cela indique la nécessité d'adapter ou de recalibrer le modèle pour mieux s'aligner sur les mouvements réels. Cela implique des ajustements des paramètres du modèle, l'ajout de données d'entraînement supplémentaires ou l'utilisation de techniques d'apprentissage spécifiques pour réduire la différence d'exactitude entre l'imagerie motrice et l'action réelle.

3.5 Conclusion

Dans ce chapitre, nous avons abordé plusieurs aspects essentiels de notre projet. Tout d'abord, nous avons présenté les outils logiciels et matériels utilisés, notamment les bases de données nécessaires à notre étude. Nous avons également discuté des méthodes d'évaluation que nous avons employées pour mesurer les performances de nos différents modèles. Ensuite, nous avons effectué des tests multiples afin de détecter les zones et les caractéristiques clés de la pathologie étudiée. Cette analyse nous a permis de mieux comprendre le fonctionnement de la maladie et d'identifier les indicateurs pertinents pour la détection et le diagnostic. De plus, nous avons évalué les performances de nos modèles à travers des tests rigoureux, en comparant les résultats obtenus avec des références cliniques et des normes établies. Enfin, nous avons réalisé une comparaison entre les actions imaginaires et réelles dans le contexte de l'interface cerveau-ordinateur (BCI).

Conclusions générale

L'électroencéphalogramme (EEG) est une technologie polyvalente ayant de nombreuses applications, en particulier dans le domaine médical, elle est utile pour détecter plusieurs anomalies mentales comme en témoigne sa capacité à détecter la schizophrénie et son utilisation dans les interfaces cerveau-ordinateur (BCI) pour aider les personnes handicapées ou imputées. La diversité de ces applications nécessite donc une variété de méthodes de prétraitement, extractions des caractéristiques et de classification des signaux EEG, comme nous l'avons exploré au cours de ce projet.

Nous avons alors examiné l'effet de différents filtres et méthodes de réduction des artefacts tels que ICA, ainsi que l'utilisation de différents modèles de classification tel que : la regression logistique, SVM, ANN, DNN qui se sont révélés performants dans la détection de la schizophrénie.

Concernant la BCI nous avons adopté une approche conventionnelle pour l'extraction des caractéristiques en utilisant un réseau de neurones convolutif (CNN) afin de mieux appréhender la variété des performances pour chaque individu. Nous avons ainsi constaté que le signal EEG se caractérise par sa complexité et son individualité, pouvant varier d'une personne à l'autre.

Notre approche suivie par le modèle DNN donne les meilleurs résultats à ce jour sur cette base de données avoisinant les 98% de précision dans certaines configurations concernant la détection de la schizophrénie. Pour les applications BCI nous avons atteint une correspondance de 93% entre l'action imaginaire et l'action réel.

Ce travail a donc montré la puissance des caractéristiques choisis et l'extraction automatique des features pour le CNN qui a donné des résultats extrêmement encourageants.

Bibliographie

- [1] Gilles Bloch et Philippe Vernier. Le cerveau exploré. In *Clefs CEA N°62*, 2014.
- [2] B. Kolb, I.Q. Whishaw, G.C. Teskey, M.H. Canu, E. Dupont, M. Noulhiane, and N.N. Linares. *Cerveau et comportement*. NEUROSCIENCES & COGNITION. De Boeck supérieur, 2019.
- [3] Puloma Pramanick. Classification of electroencephalogram (eeg) signal based on fourier transform and neural network. 2013.
- [4] Schizophrénie — organisation mondiale de la santé. <https://www.who.int/fr/news-room/fact-sheets/detail/schizophrenia>.
- [5] Schizophrénie, organisation mondiale de la santé. <https://www.who.int/fr/news-room/fact-sheets/detail/schizophrenia>.
- [6] Waldert S. Invasive vs. non-invasive neuronal signals for brain-machine interfaces : Will one prevail. Jun 2016.
- [7] Eric C Leuthardt. A brain–computer interface using electrocorticographic signals in humans. *Neural Engineering*, 2004.
- [8] Automatic eeg analysis during long-term monitoring in the icu. *Electroencephalography and Clinical Neurophysiology*, 107(1) :44–58, 1998.
- [9] Electroencephalogram (eeg) and its background. ://link.springer.com/chapter/10.1007/978-3-319-47653-7_1.
- [10] Zhe Zhang, Yun Ren, Nabil Sabor, Jing Pan, Xiaona Luo, Yongfu Li, Yucai Chen, and Guoxing Wang. Dwt-net : Seizure detection system with structured eeg montage and multiple feature extractor in convolution neural network. *Journal of Sensors*, pages 1–13, 08 2020.
- [11] Schizophrénie — fact sheet. <https://www.treatmentadvocacycenter.org/evidence-and-research/learn-more-about/25-schizophrenia-fact-sheet>.
- [12] Zack Dvey-Aharon, Noa Fogelson, Avi Peled, and Nathan Intrator. Schizophrenia detection and classification by advanced analysis of eeg recordings using a single electrode approach. *PLOS ONE*, 10 :e0123033, 04 2015.
- [13] T Koenig, D Lehmann, N Saito, T Kuginuki, T Kinoshita, and M Koukkou. Decreased functional connectivity of eeg theta-frequency activity in first-episode, neuroleptic-naive patients with schizophrenia : preliminary results. *Schizophrenia Research*, 50(1) :55–60, 2001.
- [14] Learning eeg, artifacts. <://www.learningeeg.com/artifacts>.
- [15] Shaoqiang Han, Yifeng Wang, Wei Liao, Xujun Duan, Jing Guo, Yangyang Yu, Liangkai Ye, Jiao Li, Xiaogang Chen, and Huafu Chen. The distinguishing intrinsic brain circuitry in treatment-naïve first-episode schizophrenia : Ensemble learning classification. *Neurocomputing*, 365 :44–53, 2019.
- [16] Geetha Soujanya Chilla, Ling Yeow, Qian Hui Chew, Kang Sim, and Bhanu Prakash KN. Machine learning classification of schizophrenia patients and healthy controls using diverse neuroanatomical markers and ensemble methods. *Scientific Reports*, 12 :2755, 02 2022.

-
- [17] Walid Yassin, Hironori Nakatani, Yinghan Zhu, Masaki Kojima, Keiho Owada, Hitoshi Kuwabara, Wataru Gono, Yuta Aoki, Hidemasa Takao, Tatsunobu Natsubori, Norichika Iwashiro, Kiyoto Kasai, Yukiko Kano, Osamu Abe, Hidenori Yamasue, and Shinsuke Koike. Machine-learning classification using neuroimaging data in schizophrenia, autism, ultra-high risk and first-episode psychosis, 10 2020.
- [18] Yinghan Zhu, Hironori Nakatani, Walid Yassin, Norihide Maikusa, Naohiro Okada, Akira Kunimatsu, Osamu Abe, Hitoshi Kuwabara, Hidenori Yamasue, Kiyoto Kasai, Kazuo Okanoya, and Shinsuke Koike. Application of a machine learning algorithm for structural brain images in chronic schizophrenia to earlier clinical stages of psychosis and autism spectrum disorder : A multiprotocol imaging dataset study. *Schizophrenia Bulletin*, 48, 03 2022.
- [19] Lung-Hao Lee, Chang chen hao, Wan-Chen Chang, Po-Lei Lee, Kuo-Kai Shyu, Mu-Hong Chen, Ju-Wei Hsu, Ya Bai, Tzu Su, and Pei-Chi Tu. Evaluating the performance of machine learning models for automatic diagnosis of patients with schizophrenia based on a single site dataset of 440 participants. *European Psychiatry*, 65 :1–34, 01 2022.
- [20] Gang Li, Depeng Han, Chao Wang, Wenxing hu, Vince Calhoun, and Yu-Ping Wang. Application of deep canonically correlated sparse autoencoder for the classification of schizophrenia. *Computer Methods and Programs in Biomedicine*, 183 :105073, 09 2019.
- [21] Lei Zhang. Eeg signals classification using machine learning for the identification and diagnosis of schizophrenia. volume 2019, pages 4521–4524, 07 2019.
- [22] Ricardo Buettner, David Beil, Stefanie Scholtz, and Aadel Djemai. Development of a machine learning based algorithm to accurately detect schizophrenia based on one-minute eeg recordings. 01 2020.
- [23] Sai Krishna Tikka, BikeshKumar Singh, S Haque Nizamie, Shobit Garg, Sunandan Mandal, Kavita Thakur, and Lokesh Singh. Artificial intelligence-based classification of schizophrenia : A high density electroencephalographic and support vector machine study. *Indian Journal of Psychiatry*, 62 :273, 05 2020.
- [24] Jahmunah Vicnesh, Shu Lih Oh, Venkatesan Rajinikanth, Edward Ciaccio, Kang Hao Cheong, Arunkumar, and U Rajendra Acharya. Automated detection of schizophrenia using nonlinear signal processing methods. *Artificial Intelligence in Medicine*, 100, 07 2019.
- [25] Sunil Prabhakar, Harikumar Rajaguru, and Sun-Hee Kim. Schizophrenia eeg signal classification based on swarm intelligence computing. *Computational Intelligence and Neuroscience*, 2020 :1–14, 11 2020.
- [26] Jie Sun, Cao Rui, Mengni Zhou, Malik Hussain, Bin Wang, Jiayue Xue, and Jie Xiang. A hybrid deep neural network for classification of schizophrenia using eeg data. *Scientific Reports*, 11, 02 2021.
- [27] Nuri Korhan, Leyla Abilzade, Taner Ölmez, and Zümray Dokur Ölmez. Classification of left and right hand motor imagery eeg signals by using deep neural networks. *International Journal of Applied Mathematics Electronics and Computers*, 9(4) :85 – 90, 2021.
- [28] Nuri Korhan, Leyla Abilzade, Taner Ölmez, and Zümray Dokur Ölmez. Classification of left and right hand motor imagery eeg signals by using deep neural networks. *International Journal of Applied Mathematics Electronics and Computers*, 9(4) :85 – 90, 2021.
- [29] Nuri Korhan, Leyla Abilzade, Taner Ölmez, and Zümray Dokur Ölmez. Classification of left and right hand motor imagery eeg signals by using deep neural networks. *International Journal of Applied Mathematics Electronics and Computers*, 9(4) :85 – 90, 2021.
- [30] Shiu Kumar, Alok Sharma, Kabir Mamun, and Tatsuhiko Tsunoda. A deep learning approach for motor imagery eeg signal classification. pages 34–39, 12 2016.
- [31] Nijisha Shajil, Sasikala Mohan, Poonguzhali Srinivasan, Janani Arivudaiyanambi, and Arunngiri Murrugesan. Multiclass classification of spatially filtered motor imagery eeg signals using

- convolutional neural network for bci based applications. *Journal of Medical and Biological Engineering*, 40, 06 2020.
- [32] Sabine Leske and Sarang Dalal. Reducing power line noise in eeg and meg data via spectrum interpolation. *NeuroImage*, 189, 04 2019.
- [33] Pitfalls of filtering the eeg signal. <https://sapienlabs.org/lab-talk/pitfalls-of-filtering-the-eeg-signal/>.
- [34] Aapo Hyvärinen. Independent component analysis : Recent advances. *Philosophical transactions. Series A, Mathematical, physical, and engineering sciences*, 371 :20110534, 02 2013.
- [35] Dominic Langlois, Sylvain Chartier, and Dominique Gosselin. An introduction to independent component analysis : Infomax and fastica algorithms. *Tutorials in Quantitative Methods for Psychology*, 6, 03 2010.
- [36] Siuly Siuly, Smith Khare, Varun Bajaj, Hua Wang, and Yanchun Zhang. A computerized method for automatic detection of schizophrenia using eeg signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 1 :1, 09 2020.
- [37] Negar Ahmadi, Yulong Pei, Evelien Carrette, Albert Aldenkamp, and Mykola Pechenizkiy. Eeg-based classification of epilepsy and pnes : Eeg microstate and functional brain network features. *Brain informatics*, 7 :6, 05 2020.
- [38] Alfonso Delgado-Bonal and Alexander Marshak. Approximate entropy and sample entropy : A comprehensive tutorial. *Entropy*, 21(6), 2019.
- [39] Mohsen Kaboli, Armando T, Rich Walker, and Gordon Cheng. In-hand object recognition via texture properties with robotic hands, artificial skin, and novel tactile descriptors. pages 1155–1160, 11 2015.
- [40] ALAN H.Fielding. Cluster and classification techniques for the biosciences. *New York : Cambridge University Press*, 2007.
- [41] P. Bhuvaneshwari and J. Satheesh Kumar. Article : Support vector machine technique for eeg signals. *International Journal of Computer Applications*, 63(13) :1–5, February 2013. Full text available.
- [42] Michael halls-moore. (2014, sep.) quantstart. <https://www.quantstart.com/articles/Support-Vector-Machines-A-Guide-for-Beginners>.
- [43] A comprehensive guide to convolutional neural networks — the eli5 way | by sumit saha | towards data science. <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>.
- [44] Elzbieta Olejarczyk and Wojciech Jernajczyk. EEG in schizophrenia, 2017.
- [45] G. Schalk, D.J. McFarland, T. Hinterberger, N. Birbaumer, and J.R. Wolpaw. Bci2000 : a general-purpose brain-computer interface (bci) system. *IEEE Transactions on Biomedical Engineering*, 51(6) :1034–1043, 2004.