

N° d'ordre : 65/VRPGRS/2023

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

**UNIVERSITÉ MOULOUD MAMMARI DE TIZI-OUZOU**  
**FACULTÉ DE GÉNIE ÉLECTRIQUE ET D'INFORMATIQUE**  
**DÉPARTEMENT D'ÉLECTRONIQUE**



**THÈSE DE DOCTORAT LMD**

Spécialité : Electronique

**SUJET**

**Traitement du Signal Electroencéphalographique (EEG) : Application à la  
détection et à la classification automatique des activités cérébrales par  
intelligence artificielle avec un noyau Riemannien**

Présentée par :

**FODIL Yacine**

Soutenu publiquement le 21 / 03 / 2024

Devant le jury composé de :

M <sup>f</sup> ACHOUR Hakim	Professeur	UMMTO	Président
M <sup>f</sup> HADDAB Salah	Professeur	UMMTO	Rapporteur
M <sup>f</sup> KACHENOURA Amar	HDR	Univ. Rennes 1	Co-rapporteur
M <sup>f</sup> HAMMOUCHE Kamal	Professeur	UMMTO	Examineur
M <sup>f</sup> KEMIH Karim	Professeur	Univ. Jijel	Examineur
M <sup>f</sup> LAGHROUCHE Mourad	Professeur	UMMTO	Examineur

# Remerciements

Ce travail de recherche a été fait au sein du laboratoire Analyse et Modélisation des Phénomènes Aléatoires (LAMPA) de l'université Mouloud Mammeri de Tizi-Ouzou (UMMTO), et au sein de l'équipe du Laboratoire Traitement du Signal et de l'Image (LTSI-UMR 1099) de l'université de Rennes 1 (France) dans le cadre de la bourse PROFAS B+. Le financement de cette dernière a été assuré par le ministère de l'enseignement supérieur et de la recherche scientifique, en partenariat avec Campus France que je tiens à remercier infiniment.

Je tiens à exprimer ma profonde gratitude à mon directeur de thèse, Professeur HADDAB Salah de l'université Mouloud Mammeri de Tizi-Ouzou (UMMTO), à qui j'adresse mes remerciements les plus profonds pour m'avoir confié ce travail, encadré et guidé. Son aide technique et scientifique, sa confiance et ses encouragements m'ont accompagné tout au long de ce travail de recherche.

Je remercie également mon co-directeur de thèse, Docteur KACHENOURA Amar, ingénieur de recherche au niveau du laboratoire LTSI-UMR 1099 de l'université de Rennes 1 (France), pour la confiance qu'il m'a prodigué en me permettant de réaliser la majeure partie de mes travaux de recherche au sein de son laboratoire, pour son co-encadrement, sa disponibilité, son expertise et ses conseils tout au long de ma mobilité. Cela m'a permis de m'enrichir autant sur le plan professionnel que personnel.

Je remercie également Docteur KARFOUL Ahmad pour sa disponibilité et sa contribution dans la réalisation de ce travail de recherche. Son expertise et ses commentaires ont été précieux pour appréhender cette thèse.

Je tiens à exprimer ma profonde gratitude envers le Professeur ACHOUR Hakim de l'université Mouloud Mammeri de Tizi-Ouzou, pour l'honneur qu'il m'a fait en acceptant de présider le jury de ma thèse de doctorat. Mes remerciements s'étendent également à tous les membres du jury, le Professeur KEMIH Karim de l'université de Jijel, le Professeur HAMMOUCHE Kamal, et le Professeur LAGHROUCHE Mourad de l'université Mouloud Mammeri de Tizi-Ouzou, pour avoir consacré leur temps à l'évaluation ce travail de recherche.

Je tiens à exprimer ma reconnaissance à Docteur MOUHEB Leatitia, à Monsieur KADI Massil et à Docteur BERRAUTE Paul, pour leur soutien, leur aide et leur contribution, ainsi qu'à Monsieur ZERROUKI Fodil pour son soutien et son orientation.

Je tiens également à remercier Docteur MOUHEB Lynda, maître de conférences B à l'université Mouloud Mammeri de Tizi-Ouzou (UMMTO), pour m'avoir permis d'avancer grâce à ses conseils précieux et son soutien indéfectible.

Mes derniers remerciements mais non les moindres vont à mes parents, à ma sœur et à mes amis, pour leur soutien et leurs encouragements pendant toutes ces années d'études. Je ne pourrai jamais les remercier assez.

# Table des matières

Remerciements.....	1
Liste des abréviations .....	6
Introduction générale.....	9
<b>Chapitre I : Interfaces cerveau-machine et électroencéphalographie</b>	
<b>1. Introduction .....</b>	<b>14</b>
<b>2. Les interfaces cerveau-machine .....</b>	<b>14</b>
<b>2.1. Définition d'une ICM .....</b>	<b>14</b>
<b>2.2. Historique de l'interface cerveau-machine : .....</b>	<b>15</b>
<b>2.3. Etude des ICMs .....</b>	<b>20</b>
<b>2.3.1. Configuration d'une ICM .....</b>	<b>20</b>
<b>2.3.2. Les potentiels exploités dans les ICMs.....</b>	<b>21</b>
<b>2.3.3. Les potentiels évoqués visuels (PEV) .....</b>	<b>21</b>
<b>2.3.4. Les potentiels évoqués auditifs (PEA).....</b>	<b>22</b>
<b>2.3.5. Les potentiels évoqués somesthésiques (PES).....</b>	<b>22</b>
<b>2.3.6. Les potentiels évoqués laser (PEL) .....</b>	<b>23</b>
<b>2.3.7. Les potentiels évoqués moteurs (PEM).....</b>	<b>23</b>
<b>2.3.8. Synchronisation et désynchronisation liée à l'événement (ERD/ERS).....</b>	<b>23</b>
<b>2.3.9. Principales catégories d'ICM.....</b>	<b>24</b>
<b>2.3.10. Brain Switch et Non Brain Switch .....</b>	<b>26</b>
<b>3. Anatomie et physiologie du système nerveux .....</b>	<b>27</b>
<b>3.1. Le système nerveux.....</b>	<b>27</b>
<b>3.1.1. Définition et fonctions du système nerveux .....</b>	<b>27</b>
<b>3.1.2. Les aires motrices cérébrales .....</b>	<b>32</b>
<b>3.1.3. La transmission nerveuse.....</b>	<b>34</b>
<b>3.2. L'activité cérébrale.....</b>	<b>35</b>
<b>3.2.1. Le rythme Alpha .....</b>	<b>35</b>
<b>3.2.2. Le rythme Bêta .....</b>	<b>35</b>
<b>3.2.3. Le rythme Gamma .....</b>	<b>35</b>
<b>3.2.4. Le rythme Delta.....</b>	<b>35</b>
<b>3.2.5. Le rythme Thêta.....</b>	<b>36</b>

3.2.6. Le rythme Mu.....	36
4. L'électroencéphalographie .....	36
4.1. Technique d'enregistrement .....	36
4.2. Propriétés de l'EEG .....	38
5. Conclusion .....	39

## Chapitre II : Outils applicatifs pour la classification des signaux d'imagerie motrice

1. Introduction .....	41
2. La géométrie Riemannienne .....	42
2.1. Principe de base.....	42
2.1.1. Cas à une dimension.....	42
2.1.2. Cas à deux dimensions .....	43
2.2. Le Riemannien dans la classification.....	46
2.3. Le filtrage géodésique.....	51
3. Technique de classification en Intelligence Artificielle.....	53
3.1. Apprentissage automatique (Machine Learning).....	54
3.1.1. Support Vector Machine.....	54
3.1.2. Réseaux de neurones artificiels.....	56
3.2. Apprentissage profond (Deep learning).....	57
3.2.1. Les réseaux de neurones profonds (DNN) .....	57
3.2.2. Les réseaux de neurones à convolution (CNN).....	58
3.2.3. Les réseaux de neurones récurrents (RNN).....	59
3.3. La validation croisée (Cross validation) .....	60
4. Conclusion .....	61

## Chapitre III : Approches de classification existantes

1. Introduction .....	64
2. Les méthodes de classification non Riemanniennes .....	65
2.1 Approche EEG-TCN <sub>ET</sub> .....	65
2.2 Approche Wavelet T-F Image CNN .....	67
2.3 Approche Sliding Window Common Spatial Pattern (SW-CSP).....	68
2.4 Approche Sinc-EEGNet .....	69
2.5 Approche MSAENet.....	71

2.6	Approche CS-GAN.....	72
2.7	Approche S-T Pattern .....	73
3.	Les méthodes de classification Riemanniennes .....	74
3.1	Approche MDM/FGDA.....	74
3.2	Approche TSLDA.....	75
3.3	Approche MFTL-TSK .....	76
3.4	Approche ARK-SVM .....	78
4.	Conclusion .....	78

#### Chapitre IV : Méthodes expérimentales de classification à base de Machine Learning

1.	Introduction .....	81
2.	La base de données .....	Erreur ! Signet non défini.
2.1.	Description de la base de données.....	64
2.2.	Exploitation de la base de données .....	82
3.	Classification des signaux.....	83
3.1.	RK-ANN .....	84
3.2.	RK-CNN .....	88
3.3.	ARK-ANN.....	88
3.4.	Filtrage des méthodes ARK-ANN et ARK-SVM .....	90
4.	Matériel utilisé.....	91
5.	Résultats.....	92
5.1.	Stratégie Intra-sujets.....	92
5.2.	Stratégie Inter-sujets .....	95
5.3.	Autres résultats.....	97
6.	Discussion .....	97
7.	Conclusion .....	98
	Conclusion générale.....	103
	Annexe.....	107
	Les équations du réseau de neurone .....	106
	Références .....	109
	Liste des tableaux .....	120
	Liste des figures .....	121

## Liste des abréviations

AE : Auto-Encoder

ANN : Artificial Neural Networks

ARK-ANN : Adaptive Riemannian Kernel based Artificial Neural Network

ARK-SVM : Adaptive Riemannian Kernel based Support Vector Machine

CNN: Convolutional Neural Network

CS-GAN : Common Spatial Generative Adversarial Network

CSP : Common Spacial Pattern

DARPA : Defense Advanced Research Projects Agency

DL : Deep Learning

DNN: Deep Neural Network

DP : Deux Pieds

EEG : Electroencéphalographie

ERD : Event Related Desynchronisation

ERP: Event-Related Potential

ERS : Event Related Synchronisation

FBCSP : Filter Bank Common Spatial Pattern

FE : Fréquence d'Echantillonnage

FG-ARK-ANN : Fisher Geodesic Adaptive Riemannian Kernel based Artificial Neural Network

FG-ARK-SVM : Fisher Geodesic Adaptive Riemannian Kernel based Support Vector Machine

FGDA : Fisher Geodesic Discriminant Analysis

FLDA : Fisher Linear Discriminant Analysis

FN : False Negative

FP : False Positive

GAN : Generative Adversarial Network

IA : Intelligence Artificielle

ICM : Interface Cerveau Machine

ICMAs : Interfaces Cerveau-Machines Auditives

IM : Imagerie Motrice

IHM : Interface Homme-Machine

LA : Langue  
LCR : Liquide Céphalo-Rachidien  
LCR : Longest Consecutive Repetition  
LDA : Linear Discriminant Analysis  
LFF : Loss Function Fusion  
MD : Main Droite  
MDRM : Minimum Distance to Riemannian Mean  
MG : Main Gauche  
MI : Motor Imagery  
NIRS : Near InfraRed Spectroscopy  
PE : Potentiel Evoqué  
PEA : Potentiels Evoqués Auditifs  
PEL : Potentiels Evoqués Laser  
PEM : Potentiels Evoqués Moteurs  
PES : Potentiels Evoqués Somesthésiques  
PEV : Potentiels Evoqués Visuels  
RAM : Random Access Memory  
RBF : Radial Basis Function  
ReLU : Rectified Linear Unit  
RK-ANN : Riemannian Kernel based Artificial Neural Network  
RK-CNN : Riemannian Kernel based Convolutional Neural Network  
RNN: Recurrent Neural Network  
SCM : Sample Covariance Matrix  
SDP : Symétrique et Défini Positif  
SLA : Sclérose Latérale Amyotrophique  
SNC : Système Nerveux Central  
SNP : Système Nerveux Périphérique  
SNR : Signal to Noise Ratio  
SSVEP: Steady-State Visual Evoked Potentials  
SVM : Support Vector Machine  
SW-CSP: Sliding Window Common Spatial Pattern  
SW-LCR: Sliding Window Longest Consecutive Repetition  
TCN: Temporal Convolution Network  
TN : True Negative

TP : True Positive

TS-LDA : Tangent Space Linear Discriminant Analysis

---

# **Introduction générale**

---

Historiquement, les Interfaces Cerveau-Machine (ICMs) ont été utilisées dans le domaine médical pour assister, augmenter ou restaurer les activités cognitives ou sensorimotrices humaines endommagées. Elles ont également été exploitées pour permettre aux personnes paralysées d'utiliser leurs propres signaux cérébraux pour contrôler des prothèses d'assistance, telles que des ordinateurs ou des bras robotisés de façon suffisamment précise pour effectuer certaines activités de la vie quotidienne. De plus, bien que leur utilisation exige au début un effort conscient et implique un réseau de plusieurs zones cérébrales distinctes, la répétition de l'exercice rend le processus plus aisé, presque automatique et intuitif. Cette phase d'apprentissage est alors similaire à celle du vélo ou à celle d'effectuer un swing de golf [1].

Ainsi, avec pour objectif de révolutionner la manière dont nous interagissons avec la technologie [2], l'interface cerveau-machine est un domaine de recherche en plein essor qui s'élargit à d'autres secteurs, notamment celui des jeux vidéo et du divertissement [3,4]. En effet, l'ICM est un outil qui permet de capter l'activité cérébrale à l'aide de différentes sources telles que des signaux électroencéphalographiques ou électromyographiques, afin de contrôler des dispositifs externes ou des programmes informatiques [5]. Toutefois, en raison de la complexité inhérente aux signaux bruts enregistrés du fait de la présence d'artéfacts et de la dissimulation de l'information pertinente au sein de ce type de signal [6], un traitement informatique approprié est requis pour extraire l'information de commande qui servira au pilotage de l'appareil cible. Dans le contexte de nos objectifs, la classification revêt une importance significative, car elle sert à identifier et à attribuer des étiquettes aux différentes tâches d'activités cérébrales. Cette procédure, visant à catégoriser les schémas d'activité cérébrale, revient à une opération d'une complexité substantielle dans le cadre de notre quête pour améliorer l'interface cerveau-machine et faciliter la reconnaissance des différentes activités mentales.

Le noyau riemannien constitue, par ailleurs, un cadre mathématique sophistiqué qui nous confère la capacité d'appréhender plus finement la nature des signaux extraits en les convertissant sous le format de matrices de covariance. Cette méthode permet une intégration rigoureuse des propriétés inhérentes aux signaux étudiés, améliorant ainsi notre compréhension de ces derniers [7]. Elle a été utilisée avec succès dans diverses applications scientifiques et elle présente un potentiel considérable dans l'amélioration des performances des Interfaces Cerveau-Machine [8].

Ainsi, dans cette thèse de doctorat, nous étudierons d'abord l'Interface Cerveau-Machine dans ses différents aspects et l'électroencéphalographie : deux entités permettant de relier un signal électrique cérébral à la commande correspondante. Nous présenterons également les notions de

base d'anatomie et d'électrophysiologie du cerveau nécessaires à la compréhension du fonctionnement du concept étudié.

Dans le second chapitre, nous présenterons les principes mathématiques de la géométrie Riemannienne, qui seront essentiels pour l'utilisation des noyaux Riemanniens. Nous aborderons également les principes fondamentaux de l'intelligence artificielle, qui sont au cœur de la méthode développée dans la partie expérimentale.

Avant de présenter cette dernière, nous passerons en revue les différentes approches existantes pour la classification des signaux d'imagerie motrice (IM) avec noyau Riemannien, comme la méthode MDRM, TSLDA, et sans noyau Riemannien, comme la méthode EEG-TCN<sub>ET</sub> ou encore la méthode Wavelet T-F Image CNN.

Enfin, dans le dernier chapitre, nous nous intéresserons à notre contribution avec la partie expérimentale qui vise à mettre en pratique les concepts théoriques développés dans les chapitres précédents. En effet, notre objectif à travers ce travail de recherche est de développer une nouvelle méthode de classification de signaux d'imagerie motrice dans le cadre de l'ICM. Ceci nécessite une compréhension approfondie des principes théoriques sous-jacents. À cet effet, nous nous sommes appuyés sur les travaux préexistants de Vidal, Wolpaw, Berger et d'autres chercheurs, afin d'établir un cadre conceptuel solide pour notre démarche basée sur les travaux utilisant des méthodes à noyau Riemannien qui ont abouti à des résultats prometteurs dans la classification des signaux, l'utilisation de noyaux Riemanniens dans les ICMs étant un domaine qui connaît une croissance soutenue [9], cette thèse ambitionne de réaliser une étude approfondie de son utilisation conjointe avec un réseau de neurones adaptatif, afin d'en mesurer le potentiel et les limites.

Nous allons détailler la méthodologie utilisée pour mener nos travaux, avec une description de la base de données et la mise en place de nos algorithmes de machine Learning. Ainsi, deux méthodologies novatrices ont été étudiées. La première approche apporte une amélioration à une méthode éprouvée, développée par A. Barachant et ses collaborateurs, à savoir l'ARK-SVM [10]. Bien que celle-ci présente des performances remarquables, nous avons envisagé une optimisation à travers un filtrage géodésique. La seconde approche, quant à elle, exploite la puissance des réseaux de neurones tout en prenant en compte la nature des données EEG [11], à travers l'utilisation du noyau Riemannien.

Les résultats obtenus par nos approches seront présentés, discutés et comparés à ceux obtenus par d'autres méthodes existantes. Pour ce faire, une étude comparative sur l'utilisation des

noyaux Riemanniens pour la classification des signaux électroencéphalographiques dans les ICMs sera menée, tout en évaluant l'efficacité de nos approches dans le contexte de la classification intra-sujets et inter-sujets. Pour terminer, nous concluons cette thèse avec les limitations rencontrées lors de nos expérimentations et les perspectives possibles.

---

# CHAPITRE I

Interfaces cerveau-machine et électroencéphalographie

---

## **1. Introduction**

L'interface cerveau-machine (ICM) est une technologie de pointe qui permet d'établir une communication directe entre le cerveau et un ordinateur, une machine ou tout autre dispositif, qu'il soit électronique ou informatique [5]. Ceci est possible à travers l'enregistrement de l'activité électrique du cerveau qui peut être obtenue par l'utilisation de l'électroencéphalographie (EEG).

Ce chapitre est organisé de la manière suivante : Après avoir rappelé l'historique des différentes étapes ayant abouti au développement des ICMs, nous décrirons de manière approfondie le fonctionnement, les caractéristiques et les différents types d'ICM.

L'évolution des interfaces cerveau-machine étant intimement liée à celle de l'électroencéphalographie (EEG) nous proposerons une description de l'anatomie du système nerveux et terminerons par la définition du signal EEG, du système d'acquisition de ce signal et de ses principales caractéristiques.

## **2. Les interfaces cerveau-machine**

### **2.1. Définition d'une ICM**

Une interface homme-machine (IHM) est un outil de communication très répandu utilisant, par exemple, un clavier et/ou une souris comme interface pour communiquer avec un ordinateur [12]. Dans le cas des pathologies générant des troubles moteurs tels que la sclérose latérale amyotrophique (SLA), les accidents vasculaires cérébraux ou les lésions de la moelle épinière [13], la commande motrice étant altérée, les patients deviennent incapables de générer les mouvements nécessaires à l'exécution de certaines actions. Les IHMs standards sont alors inexploitable et les personnes souffrant de pathologies de même nature que celles citées précédemment, se retrouvent privées de ces interactions, ce qui constitue un handicap majeur, particulièrement dans l'ère de la numérisation [14].

Aussi, dans le but d'offrir une qualité de vie optimale à ces malades dans ses différents aspects [15], l'expansion des connaissances relatives au fonctionnement cérébral et la modernisation de la médecine, mettant l'accent sur la compréhension des besoins et des attentes des patients ont contribué au développement des technologies d'interfaces cerveau-machine. Cependant, il est important de préciser que les ICMs ne sont pas des dispositifs permettant de lire les pensées, mais plutôt des outils qui interprètent des signaux identifiés de certaines fonctions cérébrales créant ainsi un canal de communication direct entre le cerveau et un appareil en utilisant

uniquement les signaux électriques cérébraux pour le contrôler, sans recours au contrôle moteur [16]. C'est ainsi que des fauteuils roulants adaptés [17], des bras motorisés [18] ou encore des outils de communication vocaux comme le P300 speller [19] ont vu le jour. De plus, les objets connectés étant de plus en plus présents dans notre quotidien, ils fournissent une passerelle pour les ICMs permettant un contrôle de la domotique par des commandes générées par la pensée [20]. Il en est de même dans d'autres domaines où l'on observe l'émergence de cette technologie dans des secteurs tels que le divertissement, le jeu vidéo, la réalité virtuelle, mais également en chirurgie où les robots déployés peuvent être renforcés avec une sécurité supplémentaire basée sur la concentration du chirurgien lors d'une opération pointue [21].

## **2.2. Historique de l'interface cerveau-machine :**

L'interface cerveau-machine est une technologie dont les prémices sont apparues depuis près d'un siècle avec, pour point de départ, la découverte, en 1780, du lien électrique responsable des contractions musculaires et de la conduction nerveuse [22]. A partir de là, Caton a utilisé, en 1875, un galvanomètre pour observer les impulsions électriques à la surface du cerveau de lapins et de singes vivants [23]. En 1887, il constata l'augmentation de ces courants électriques durant la phase de sommeil qui était sans rapport avec le rythme cardiaque ou respiratoire, mais qui étaient, en revanche, vulnérables à l'anoxie et à l'anesthésie pour disparaître à la mort de l'animal. En plus de constater de fortes variations de courants à la projection d'une lumière sur les yeux, Caton a également découvert les changements d'activité cérébrale par une stimulation sensorielle [24].

En 1912, le physiologiste russe Vladimir Vladimirovitch Pravdich-Neminsky a enregistré le premier EEG réalisé sur un animal [25], avant que Cybulsky et Jelenska-Macieszyna aient photographié et publié, en 1914, les premiers enregistrements EEG de crises expérimentales induites [26]. Un peu plus d'une décennie plus tard, le neurologue Hans Berger a mené, en 1929, les premières expériences électroencéphalographiques sur des humains [27]. Ces dernières ont ouvert le champ à des analyses de l'activité cérébrale menées par Fisher et Lowenback qui ont relevé des pointes épileptiformes en 1934 [28]. En 1946, Grey Walter a décrit les réponses à la stimulation photique [29] et, deux années plus tard, en 1948, les premiers enregistrements EEG en profondeur ont été effectués [30,31].

Ces avancées ont permis, en 1957, de réaliser la première stimulation électrique directe du système auditif humain par André Djourno et Charles Eyriès [32]. Dans cette lancée, en 1965, le compositeur américain Alvin Lucier utilisa l'EEG pour composer une musique publiée dans

une œuvre nommée « *Music for the Solo Performer* » ; il s'agit de l'un des premiers exemples d'une interface cerveau-machine fonctionnelle [33]. Deux années plus tard, en 1967, le neurologue E.V. Evarts enregistre le signal intracrânien d'un singe émis lors des mouvements de poussée et de traction [34]. Ces données ont permis de démontrer le rapport existant entre la pensée et les ondes émises par le cerveau et ont engagé des recherches dans le domaine de l'assistance par le biais de la pensée.

En 1969, l'otologiste américain William House installe le premier implant cochléaire qui n'est pas rejeté par le système du patient [35]. Dans la même année, le chercheur Eberhard Fetz, de l'université de Washington à Seattle, montre qu'un singe peut apprendre à contrôler l'aiguille d'un compteur en utilisant uniquement ses pensées [36]. Suite à cela, la *Defense Advanced Research Projects Agency* (DARPA) des États-Unis lance, en 1970, un programme visant à explorer les communications cérébrales à l'aide de l'EEG [37]. En dépit de tous ces travaux, ce n'est qu'en 1973 que le terme interface cerveau-machine a été introduit pour la première fois par Jaques Vidal [38].

En 1976, le laboratoire UCLA spécialisé dans les ICMs prouve que les signaux cérébraux visuels d'un seul essai peuvent être utilisés comme canal de communication suffisamment efficace pour contrôler un curseur dans un labyrinthe bidimensionnel [39]. Ces travaux ont conduit, Phillip Kennedy, à réaliser, en 1987, une interface cerveau-ordinateur intra-corticale en implantant des électrodes à cône neurotrophique chez des singes [40]. D'autres travaux ont permis, en 1988, d'utiliser les signaux EEG pour contrôler un robot mobile [41].

Dans les années 90, les travaux se sont concentrés sur l'amélioration de l'exactitude et de la fiabilité des ICMs en utilisant des techniques avancées d'analyse de signaux, telles que la décomposition en ondelettes et les réseaux de neurones. En 1998, des chercheurs de l'université Emory à Atlanta ont installé un implant cérébral stimulant le mouvement chez une personne atteinte du « *syndrome d'enfermement* » [42]. En 1999, Yang Dan de l'université de Californie, décode les excitations neuronales pour reproduire les images vues par les chats [43]. A peine une année plus tard, en 2000, des chercheurs parviennent à réaliser une ICM capable de reproduire les mouvements d'un singe-hibou pendant que celui-ci manipule une manette ou cherche à s'alimenter [44]. Par la suite, en 2004, Matthew Nagle, tétraplégique, devient la première personne à contrôler un curseur numérique à l'aide d'une interface cerveau-machine dans le cadre du projet « *BrainGate* » de Cyberkinetics [45]. Peu de temps après, O'Doherty a appliqué une ICM avec retour sensoriel à des singes rhésus par stimulation intra-corticale

directe [46]. Et en 2013, un autre patient de « *BrainGate* » fait la démonstration du contrôle d'un membre prothétique robotisé [47].

C'est en 2016 que l'entrepreneur Bryan Johnson lance le projet « *Kernel73* » avec pour objectif, de concevoir des technologies permettant d'améliorer radicalement et de développer les capacités de la cognition humaine. Dans cette lancée, l'entreprise Neuralink a été fondée par Elon Musk pour développer des interfaces cerveau-machine à taille réduite, ne laissant qu'une fine cicatrice sur la peau, et ayant pour objectif de connecter les humains et les ordinateurs [48].

Un an plus tard, en 2017, l'agence américaine DARPA lance un programme visant à fabriquer des implants neuronaux capables d'enregistrer les signaux d'un million de neurones [49]. Durant cette même année, Facebook révèle ses travaux sur des interfaces portables permettant aux gens de saisir du texte en utilisant uniquement les signaux cérébraux.

En 2018, des chercheurs de l'université de Californie à Berkeley ont créé et implanté le plus petit stimulateur nerveux sans fil « *neural dust* » qui s'est avéré être le plus efficace au monde [50]. Puis, en 2019, des chercheurs de l'UCSF (Université de Californie à San Francisco) font la démonstration d'une ICM qui utilise des méthodes d'apprentissage profond pour synthétiser la locution de patients souffrant de troubles de la parole dus à des maladies neurologiques [51].

Durant toutes ces étapes, les chercheurs ont été confrontés à différentes contraintes représentées par les difficultés d'analyse, de développement, de compréhension de l'électrophysiologie cérébrale, de traitement des signaux ainsi que leur classification, de financement des équipements et des limitations des performances des ordinateurs.

L'ICM a donc longtemps constitué l'un des domaines les plus confus et les plus complexes des recherches électroniques et médicales. Néanmoins, l'avancée technologique dans le domaine informatique, particulièrement dans les microcomposants de calculs, a rendu possible une modernisation des outils dans les différents domaines de recherche permettant des analyses plus poussées, mais également une modernisation des équipements médicaux augmentant, ainsi, la capacité de compréhension et de diagnostic des pathologies neurologiques.

Tout ceci a conduit aux premiers systèmes ICMs utilisés pour pallier aux divers déficits responsables de troubles de la communication et d'une réduction de l'autonomie dans la réalisation des tâches de la vie quotidienne. Ces dispositifs ont également commencé à se généraliser à d'autres domaines tels que la rééducation des patients atteints de lésions cérébrales et la réalité virtuelle.

Le tableau ci-dessous reprend l'historique complet des différentes étapes ayant abouti au développement des interfaces cerveau-machine.

Tableau 1 : Historique de l'interface cerveau-machine.

Année	Événement
<b>1780</b>	Découverte du lien électrique lors d'une contraction musculaire.
<b>1875</b>	Observation d'impulsions électriques à la surface des cerveaux d'animaux par R.Caton.
<b>1887</b>	Constatation des variations électriques pendant le sommeil, l'anoxie, l'anesthésie, la stimulation visuelle et sensorielle et la mort de l'animal par R.Caton.
<b>1912</b>	Enregistrement du premier EEG sur l'animal par V P-N.Vladimir.
<b>1914</b>	Publication du premier enregistrement EEG d'une crise expérimentale induite par Cybulsky et Jelenska-Macieszyna.
<b>1929</b>	Premières expériences EEG sur des humains par H.Berger.
<b>1934</b>	Relevé de pointes épileptiformes par Fisher et Lowenback.
<b>1946</b>	Détection de réponses à la stimulation photique par Grey Walter.
<b>1948</b>	Premiers enregistrements EEG profonds.
<b>1957</b>	Réalisation de la première stimulation électrique directe du système auditif humain par André Djourno et Charles Eyriès.
<b>1965</b>	Composition d'une musique en exploitant l'activité cérébrale récupérée à travers un EEG par Alvin Lucier.
<b>1967</b>	Enregistrement du premier tracé EEG de mouvements de traction et de poussée sur un signe par E.V Evarts.
<b>1969</b>	Installation du premier implant cochléaire non rejeté par W. House. Contrôle d'un appareil par la pensée d'un signe réalisé par E. Fetz.
<b>1970</b>	Lancement d'un programme pour exploiter la communication cérébrale par la DARPA aux états unis.

<b>1973</b>	Apparition du terme ICM pour la première fois introduit par J. VIDAL.
<b>1976</b>	Affirmation par le laboratoire UCLA de l'efficacité d'un seul canal de communication pour le contrôle d'une ICM.
<b>1987</b>	Construction de la première interface cerveau-ordinateur intra-corticale par P. Kennedy.
<b>1988</b>	Contrôle d'un robot mobile par EEG.
<b>1998</b>	Installation d'un implant cérébral chez une personne à mobilité réduite par des chercheurs de l'université Emory.
<b>1999</b>	Reproduction d'images vues par un chat par décodage d'excitations neuronales par Y. Dan.
<b>2000</b>	Reproduction des mouvements de manipulation d'un singe-hibou par une ICM.
<b>2004</b>	Premier contrôle d'une main robotique dans le cadre du projet <i>BrainGate</i> .  Mise en place d'une ICM avec retour sensoriel à des singes rhésus par stimulation intra-corticale directe par O'Doherty.
<b>2013</b>	Démonstration du contrôle d'un membre prothétique robotisé dans le cadre du projet <i>BrainGate</i> .
<b>2016</b>	Lancement du projet <i>Kernel73</i> visant à améliorer la cognition humaine par B. Johnson.  Fondation de l'entreprise Neuralink par E. Musk pour développer des ICMs plus performantes.
<b>2017</b>	Lancement d'un programme visant à développer des implants plus performants par la DARPA.  Début des recherches sur des ICMs portables par Facebook.
<b>2018</b>	Développement et implantation du plus petit et performant implant au monde par les chercheurs de l'université de Californie.
<b>2019</b>	Développement d'une ICM à apprentissage profond par les chercheurs de l'UCSF.

## **2.3. Etude des ICMs**

### **2.3.1. Configuration d'une ICM**

Le fonctionnement d'une ICM passe par quatre étapes [52] illustrées par la figure 1. Ces dernières sont représentées par :

- L'enregistrement de l'activité cérébrale au moyen d'électrodes situées sur le cuir chevelu (système non invasif) ou à l'aide d'une grille d'électrodes placées, en général, sur le cortex moteur (système invasif) [53]. Après avoir été transmis à un amplificateur et numérisé par le convertisseur analogique-numérique, le signal est envoyé au module de traitement du signal [54].
- Le prétraitement qui permet de préparer les données brutes pour la prochaine étape via des filtres (passe-bas, passe-haut, passe-bande ou Butterworth) qui éliminent les composantes et les caractéristiques indésirables du signal. Ceci est nécessaire pour améliorer le rapport signal/bruit (SNR) et pour atténuer les artefacts inhérents au dispositif d'acquisition, tels que les déplacements des électrodes, mais également ceux induits par le sujet tels que les mouvements oculaires, les activités musculaires et cardiaques [55].
- L'extraction des marqueurs qui sont des paramètres caractéristiques de l'activité cérébrale qui peuvent encoder les commandes de l'utilisateur, ou refléter les intentions de commande du sujet [56]. Ce processus consiste à extraire des informations clés d'un ensemble de données à l'aide d'algorithmes d'extraction de caractéristiques (transformée de Fourier rapide, transformée en ondelettes ou transformée en ondelettes discrètes). En d'autres termes, si les données à traiter sont trop volumineuses ou redondantes, elles peuvent être transformées en un ensemble réduit d'informations ou de vecteurs de caractéristiques d'informations.
- Après que les marqueurs aient été représentés sous forme de vecteurs, leur interprétation s'effectue par une méthode de classification (telle que le vecteur support machine SVM, le réseau de neurones convolutif CNN, la régression logistique ou l'arbre de décision) qui prédit la bonne classe des éléments d'entrées ce qui permettra de traduire les données en informations utiles telles que des commandes de sortie [52]. Une fois classées, ces dernières peuvent être utilisées par l'ICM dans le cas d'un jeu, d'un outil de rééducation ou d'un appareil de contrôle. Ces dispositifs peuvent fournir une rétroaction visuelle, auditive ou

tactile aux utilisateurs pour indiquer l'état de leur commande. Par exemple, un dispositif de feedback visuel peut afficher un message ou une icône pour indiquer que la commande a été reçue et exécutée avec succès.

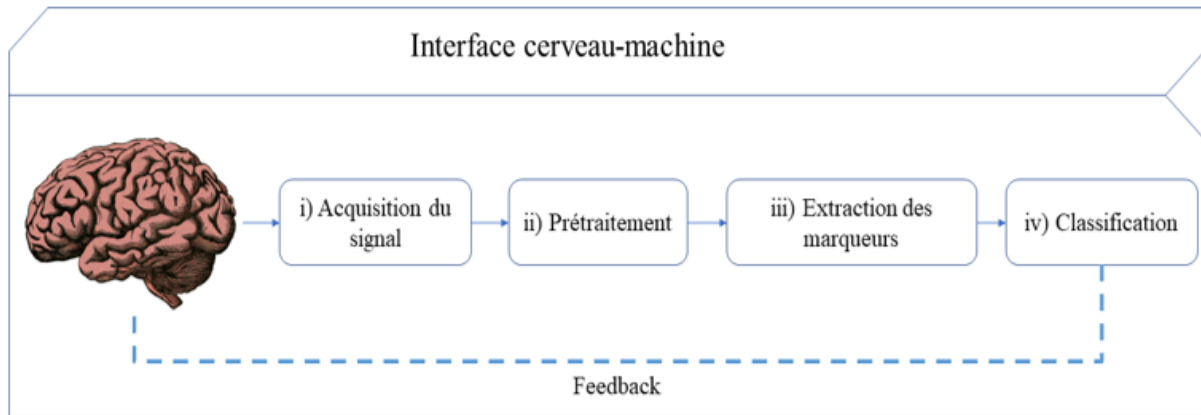


Figure 1 : Structure d'une interface cerveau-machine [57].

### 2.3.2. Les potentiels exploités dans les ICMs

En physiologie, on qualifie de potentiel une altération de l'activité électrique du système nerveux consécutive à la réaction à un stimulus externe, qu'il soit de nature auditive, visuelle, sensorielle ou motrice [58]. Son enregistrement fournit des informations sur le fonctionnement de la voie stimulée et il en existe plusieurs types :

### 2.3.3. Les potentiels évoqués visuels (PEV)

Les potentiels évoqués visuels représentent des variations de l'activité électrique enregistrée au niveau du cuir chevelu en réponse à des stimulations visuelles répétées à des fréquences données [59]. Ceux-ci sont recueillis soit à travers la fixation par le sujet d'un écran affichant une grille de carrés « en damiers » changeant périodiquement, soit par un système de flash lumineux sur les zones souhaitées [60]. Pour ce faire, des électrodes sont placées près des zones visuelles du cortex occipital et l'enregistrement de ces signaux permet d'observer des variations d'ondes, qui se présentent sous formes de pointes d'ondes avec une latence de 100 ms [61] ou 300 ms [62]. En plus de leur exploitation dans les ICMs comme biomarqueurs afin d'identifier, par exemple, l'objet souhaité par l'utilisateur parmi ceux présentés sur un écran, les PEVs permettent d'étudier le comportement des voies optiques [63], en particulier du nerf optique, et sont utiles pour diagnostiquer des pathologies oculomotrices.

On parle de Steady-State Visual Evoked Potentials (SSVEP) lorsqu'on obtient une réponse corticale visuelle qui se produit en réponse à des stimulations lumineuses répétitives, émanant d'une source lumineuse clignotante à des fréquences excédant 4 Hz. Le SSVEP peut être catégorisé en trois plages de fréquences distinctes : basse (jusqu'à 12 Hz), moyenne (12-30 Hz) et haute fréquence (> 30 Hz).

Les ICMs fondées sur le SSVEP se concentrent essentiellement sur les bandes de fréquences basses et moyennes, tandis que les initiatives relatives aux hautes fréquences demeurent rares. Cependant, il convient de noter que ces projets se limitent à l'évaluation de l'efficacité de diverses méthodes d'extraction du signal SSVEP [64].

#### **2.3.4. Les potentiels évoqués auditifs (PEA)**

Les potentiels évoqués auditifs sont générés par la réaction à un stimulus acoustique de manière synchronisée dans le temps (time-locked<sup>1</sup>). La réponse PEA présente un pic d'amplitude et une latence [65], exploités dans les interfaces cerveau-machines auditives (ICMAs) qui sont devenues un sujet émergent ces dernières années [66]. L'une des méthodologies utilisées se base sur la perception spatiale du son. Pour ce faire, différentes sources auditives sont placées autour du sujet où chacune représente une entrée unique pour une commande spécifique. L'utilisateur en focalisant son attention sur une seule source et en ignorant les autres, génère une réponse ERP [67]. Les PEAs ont initialement été employés pour diagnostiquer et localiser les pathologies affectant les voies du tronc cérébral. Ils ont également été amplement utilisés pour évaluer la fonction auditive et servent dans le cadre du dépistage auditif infantile comme outil de diagnostic efficace [68].

#### **2.3.5. Les potentiels évoqués somesthésiques<sup>2</sup> (PES)**

Les PESs se basent sur les informations sensorielles du corps comme la chaleur, la pression ou encore la douleur. Ils peuvent être utilisés pour étudier les interactions entre les nerfs et les muscles en utilisant une stimulation électrique non douloureuse qui permet de mesurer les réponses électriques de ces deux structures anatomiques, et ainsi, d'obtenir des informations sur le fonctionnement des voies corporelles sensibles [69].

---

<sup>1</sup> Time-locked : La réponse se produit à un moment fixe après le stimulus.

<sup>2</sup> Somesthésie : Ensemble des sensations qu'un être humain peut ressentir, comme les sensations de pression, de chaleur, de douleurs, etc.

### **2.3.6. Les potentiels évoqués laser (PEL)**

Les PELs sont obtenus en stimulant la peau avec un laser calorique, ce qui donne une sensation piquante et chaude, mais reste indolore en raison du nombre limité de stimulations. A travers ces signaux, on s'intéresse au fonctionnement des voies de la sensibilité thermique en mesurant la vitesse de conduction des signaux nerveux [70]. Cela permet d'identifier de potentiels problèmes liés à une atteinte des nerfs, et ainsi, diagnostiquer une douleur neuropathique à travers la détection des altérations de la transmission dans les voies thermo-algiques [69].

### **2.3.7. Les potentiels évoqués moteurs (PEM)**

Les potentiels évoqués moteurs sont obtenus en stimulant le cortex moteur frontal du cerveau, ce qui engendre une réponse musculaire enregistrée grâce à des électrodes qui permettent d'étudier le fonctionnement de la voie motrice. Ces ICMs basées sur le sensorimoteur sont très intéressantes pour les utilisateurs paralysés et sont utilisées dans le cadre de la rééducation afin d'accélérer la récupération des fonctions motrices [71]. L'exploitation de ce potentiel est une pratique couramment observée dans le contexte des ICMs, et notre travail de recherche s'articule autour de ces signaux.

### **2.3.8. Synchronisation et désynchronisation liée à l'événement (ERD/ERS)**

On distingue deux principes grandement utilisés dans les interfaces cerveau-machine : les Event Related Desynchronisation (ERD) et les Event Related Synchronisation (ERS) qui consistent à mesurer les changements de la fréquence des ondes cérébrales lorsqu'un individu effectue une tâche spécifique [72].

Il a été observé que certains événements tels que les stimuli sensoriels, l'activité motrice et les tâches de mémoire ont un impact direct sur les rythmes cérébraux [73]. Une augmentation de l'activité rythmique est appelée "synchronisation liée à un événement", tandis qu'une diminution est appelée "désynchronisation liée à un événement". Ces dernières peuvent être rencontrées quelques millisecondes avant, pendant ou après qu'une tâche soit effectuée. Par exemple, le fait d'imaginer un mouvement de la main déclenchera une désynchronisation liée à l'événement dans les rythmes mu et bêta du cortex moteur [73,74], un autre exemple d'ERD est la diminution du rythme alpha lors de l'ouverture des yeux.

L'ERD est basé sur l'hypothèse que certains signaux impliqués dans une tâche spécifique subissent une atténuation d'amplitude dans les bandes de fréquence appropriées lorsque

l'individu effectue une tâche [75]. On dit alors que ces réseaux neuronaux sont désactivés et désynchronisés [76]. Inversement, d'autres rythmes subissent une synchronisation liée aux événements ERS lorsqu'une région corticale est sollicitée, augmentant la puissance des rythmes associés. Par exemple, après une activation sensorimotrice, on peut détecter ce qu'on appelle un rebond bêta; ce qui peut être exploité pour envoyer des commandes à une ICM [75,77].

Enfin, ERD et ERS sont utilisés conjointement pour identifier les réseaux neuronaux cérébraux impliqués dans les tâches spécifiques afin d'améliorer la performance des ICMs.

### **2.3.9. Principales catégories d'ICM**

Avant d'explorer d'autres aspects des interfaces cerveau-machine, il est essentiel de souligner que cet outil se décline sous plusieurs types, en fonction de leur nature invasive, de leur dépendance vis-à-vis de l'utilisateur, de leur spontanéité, ou de leur synchronicité. Cette diversité permet d'appréhender l'étendue des possibilités offertes par ces interfaces, ouvrant la voie à des applications variées et adaptées à des contextes spécifiques.

#### **2.3.9.1. ICM invasive et non invasive**

Au sens strict, il existe une différence évidente entre les interfaces invasives, c'est-à-dire implantées sur le cortex, et celles non invasives, qui se trouvent à la surface de la peau. Cependant, toute source extérieure qui agresse ou nuit à l'intégrité corporelle, qu'il s'agisse d'outils ou même de photons ou de champs magnétiques, est considérée comme invasive dans la mesure où elle affecte directement la structure interne du corps. Ainsi, les technologies telles que la spectroscopie dans le proche infrarouge, l'imagerie par résonance magnétique et la tomographie par émission de positrons, sont toutes invasives, car les mécanismes mêmes par lesquels elles fonctionnent impliquent que le tissu visé soit perturbé intérieurement. Fort heureusement, pour la plupart d'entre elles, les effets sur le corps sont bien connus. Néanmoins, les effets de l'énergie absorbée sur le tissu cérébral avec le Near InfraRed Spectroscopy (NIRS) n'ont pas été étudiés sur le long terme, ce qui exige une utilisation prudente à ce stade [38].

#### **2.3.9.2. ICM dépendante et indépendante**

Une ICM dépendante utilise les mêmes canaux neuromusculaires que le cerveau pour transmettre et recevoir des informations. Dans certains cas, l'utilisateur doit être capable de fixer son regard sur un objet clignotant affiché sur un écran d'ordinateur pour que l'ICM détermine son objet cible parmi un ensemble fini [38]. Une ICM indépendante, quant à elle, n'utilise pas ces canaux neuromusculaires, mais exploite la capacité de l'individu à se concentrer

mentalement et à prendre des décisions, contournant ainsi la "dépendance" d'une voie naturelle qui pourrait être endommagée. Un exemple d'ICM dépendante pourrait être celle qui utilise la "direction du regard" pour déterminer la lettre sur laquelle l'utilisateur se concentre, utilisant ainsi les informations des mouvements des yeux. Une ICM indépendante utiliserait un potentiel évoqué (PE) qui dépendrait uniquement de la capacité à se concentrer sur une tâche mentale [78].

### **2.3.9.3. ICM spontanée et non spontanée**

Une ICM spontanée exploite les signaux cérébraux exogènes qui ne sont pas déclenchés par un stimulus extérieur spécifique. Ils sont produits par le cerveau de manière naturelle, sans intervention extérieure. A titre d'exemple, on peut citer le signal associé aux intentions de mouvement générées dans le cortex sensori-moteur sans qu'aucun stimulus spécifique ne soit requis [38].

Une ICM non spontanée, quant à elle, peut exploiter :

- Les potentiels évoqués qui sont des réponses cérébrales observables suite à un stimulus extérieur tel qu'une lettre clignotante, un son, une odeur ou un goût, que l'utilisateur y prête attention ou non. Ces potentiels sont synchronisés par rapport au stimulus, dans le sens où, si un utilisateur concentre son regard sur un caractère clignotant sur un écran, cette fréquence de clignotement sera observable dans les signaux du cortex visuel [38].
- Les potentiels liés à un événement est le terme général qui englobe les signaux précédents. Ils sont liés aux potentiels évoqués mais comprennent également des réponses cérébrales qui ne sont pas directement déclenchées par un stimulus, c'est-à-dire qu'ils peuvent inclure des pensées spontanées ou délibérées telles que le calcul mental, mais ils disposent d'une fenêtre temporelle bien contrôlée dans laquelle les signaux cérébraux sont surveillés, qu'ils soient spontanés ou consécutifs à un stimulus spécifique. Le terme potentiel lié à un événement est actuellement considéré comme plus précis pour tous les protocoles de stimulation [79].

### **2.3.9.4. ICM synchronisée et non synchronisée**

Les ICMs synchrones limitent l'interaction de l'utilisateur car il ne peut communiquer une intention ou une commande à la machine que lorsque celle-ci l'autorise [80]. Le signal surveillé peut être une réponse à un stimulus défini par l'ordinateur, ou une tâche mentale effectuée uniquement lorsque l'ICM est en attente d'une entrée, généralement au moyen d'un signal

sonore ou d'un signal lumineux. L'utilisateur a donc le contrôle de ce qu'il doit transmettre à la machine, mais pas du moment où il le fait. Cette approche courante consiste à faire savoir à ce dernier quand exécuter une tâche mentale, comme imaginer des mouvements, en donnant un indicateur visuel ou auditif. Après quelques secondes, l'individu interrompt la tâche et l'ordinateur exploite ces données pour déterminer son état mental. Dans une autre approche synchronisée courante, les utilisateurs choisissent parmi une série de lettres clignotantes [81]. Dans ce cas, l'interprétation des signaux par l'ordinateur ne peut se faire que pendant le clignotement de l'objet pour associer les caractéristiques des données à l'objet souhaité [38].

D'un autre côté, les ICMs asynchrones se basent sur les signaux cérébraux produits par l'utilisateur à tout moment, que ce soit en réponse à un stimulus contrôlé par l'ordinateur ou de manière spontanée [82]. Cette approche rend la reconnaissance des intentions de l'utilisateur plus complexe, car la machine doit tout d'abord déterminer si un signal lié à une intention a été intentionnellement produit, ce qui peut poser des problèmes pour la détection du début, et ensuite identifier quelle intention a été exprimée [38].

Un exemple d'utilisation d'ICM dans ce contexte est la mesure d'un état mental à travers un système permettant de quantifier le niveau de concentration et de relaxation de l'individu qui peut être déduit à l'aide de ratios ou de combinaisons des rythmes alpha, bêta et thêta, ou bien à travers une technique d'apprentissage automatique pour classer ces états mentaux [73]. Un autre exemple exploitant le potentiel évoqué est le SSVEP qui a été utilisé pour le contrôle de la navigation ou de jeux [83].

### **2.3.10. Brain Switch et Non Brain Switch**

Il existe deux principales catégories d'interfaces cerveau-machine : les ICMs à commutation cerveau (Brain Switch) et les ICMs sans commutation cerveau (Non-Brain Switch). Il est important de comprendre la différence entre ces deux concepts pour mieux appréhender les avancées et les limites de cette technologie.

Les ICMs Brain Switch sont des systèmes conçus pour détecter un seul état cérébral en utilisant des signaux ERP pour activer ou désactiver un événement. Ceci permet à l'utilisateur de contrôler directement un dispositif externe, comme l'ouverture d'une porte ou le démarrage d'un moteur. En d'autres termes, l'ICM ne doit produire aucune sortie lorsque l'utilisateur n'a pas l'intention de communiquer [84].

Les ICMs non-Brain Switch, au contraire, sont des systèmes dont la finalité est d'obtenir plusieurs signaux de sorties et ne se limitent pas à une utilisation en mode commutation. Elles sont exploitées pour un contrôle avancé direct d'un dispositif externe. Ces systèmes peuvent utiliser des techniques de réalité virtuelle ou de biofeedback pour aider l'utilisateur à améliorer son attention, sa mémoire ou sa coordination motrice.

Enfin, il est important de souligner que les avancées dans les ICMs sont encore limitées par les difficultés de l'interprétation des signaux cérébraux. Les approches non-Brain Switch sont souvent restreintes par la précision des signaux enregistrés et par la difficulté à interpréter les signaux cérébraux à cause des différents artefacts.

### **3. Anatomie et physiologie du système nerveux**

Après avoir exploré le fonctionnement des interfaces cerveau-machine, il est important de comprendre la biologie sous-jacente du système nerveux, notamment sa structure, son fonctionnement et son organisation complexe. Cette connaissance est primordiale pour la maîtrise des principes de l'exploitation des signaux cérébraux dans une interface cerveau-machine, ceux-ci étant générés par le système nerveux. Dans cette section, nous allons donc nous intéresser à ce dernier à travers son anatomie et sa physiologie pour ensuite aborder ses principales fonctions, les principes de la transmission nerveuse et les modalités de recueil des signaux électroencéphalographiques pour, ainsi, établir le lien entre ces derniers et les ICMs.

#### **3.1. Le système nerveux**

##### **3.1.1. Définition et fonctions du système nerveux**

Le système nerveux est un système biologique complexe qui coordonne les fonctions de l'organisme et permet à celui-ci de percevoir, de traiter et de répondre aux stimuli de l'environnement interne et externe [85]. Il est constitué d'un réseau de plus de 100 milliards de cellules nerveuses appelées neurones, qui représentent l'élément constitutif de base du système nerveux et qui communiquent entre elles grâce à des signaux électriques et chimiques [86]. D'un point de vue anatomique, le système nerveux se divise en deux parties : le système nerveux périphérique et le système nerveux central.

### 3.1.1.1. Système nerveux central

Le système nerveux central (SNC) est constitué de l'encéphale et de la moelle épinière qui sont logés dans la boîte crânienne et le canal rachidien, respectivement. L'encéphale est lui-même composé de trois structures anatomiques principales : le cerveau comprenant le télencéphale et le diencephale, le tronc cérébral constitué par le mésencéphale, le pont et le bulbe rachidien et enfin le cervelet. L'ensemble de ces éléments est protégé par le liquide céphalo-rachidien (LCR) et par trois enveloppes appelées « méninges ». Ces dernières sont constituées de l'extérieur vers l'intérieur de la dure-mère, de l'arachnoïde et de la pie-mère [87]. La moelle épinière, quant à elle, est un cordon nerveux qui s'étend du bulbe rachidien situé au niveau du tronc cérébral et se termine avec le cône médullaire au niveau de la région lombaire, à l'intérieur de la colonne vertébrale. Elle sert de voie de communication entre le cerveau et le reste du corps, transmettant les signaux nerveux de et vers les nerfs périphériques pour permettre la motricité, la sensibilité et les réflexes [88].

Cette architecture complexe confère au système nerveux plusieurs fonctions essentielles. En effet, le SNC, illustré sur la figure 2, représente le centre de l'intégration, du traitement des informations sensorielles, du contrôle, de la coordination et de la régulation des fonctions physiologiques et comportementales telles que la respiration, la digestion, la circulation sanguine et la température corporelle. Il permet ainsi l'adaptation et l'interaction de l'organisme avec son environnement et le maintien d'un état d'équilibre interne. De plus, il est également impliqué dans des fonctions cognitives telles que la mémoire, l'apprentissage, l'attention et le raisonnement [89]. Dans le cadre de notre travail de recherche, nous allons nous intéresser principalement au cerveau, à ses particularités et à ses fonctions.




Figure 2 : Constituants du système nerveux central [90].

- Le cerveau

Situé à l'intérieur de la boîte crânienne avec un poids de 1.3 kg, le cerveau présente à sa surface de nombreux sillons qui forment une couche externe de matière grise appelée cortex cérébral [91]. Cette substance grise est constituée de corps cellulaires et de dendrites, ainsi que de nombreuses cellules gliales qui recouvrent une masse de matière blanche plus épaisse, composée de faisceaux d'axones myélinisés et dont la couleur est due à la présence de graisses de myéline. En profondeur de cette substance blanche se trouve une autre région de matière grise appelée noyaux gris centraux.

D'un point de vue fonctionnel, la substance grise représente le carrefour où s'établissent les connexions entre les neurones et c'est à ce niveau que sont reçues, analysées, traitées et intégrées les informations. La substance blanche quant à elle, est responsable de la conduction de l'influx nerveux. On peut donc considérer la matière grise comme étant les ordinateurs du système nerveux central, tandis que la matière blanche constitue les câbles qui les relient [92].

Enfin, d'un point de vue organisationnel, le cerveau est divisé en deux hémisphères ayant une structure similaire : l'hémisphère gauche et l'hémisphère droit réunis par le corps calleux. Chaque hémisphère cérébral est composé de six lobes illustrés sur la figure 3 :

- Le lobe frontal : il se situe à l'avant du cerveau, sous l'os frontal et est particulièrement impliqué dans les fonctions cognitives telles que la parole, les mouvements, le raisonnement et les autres fonctions exécutives [89].
- Le lobe temporal : il se situe au niveau de l'os temporal, sur la partie latérale et inférieure du cerveau. Il est dédié aux diverses fonctions sensorielles comme la perception auditive, le goût, l'ouïe, une partie du langage mais également la mémoire et les émotions [93].
- Le lobe pariétal : il se situe au niveau de l'os pariétal, au-dessus des lobes temporal et occipital, et à l'arrière du lobe frontal. Il est impliqué dans les processus somato-sensitifs de la conscience visuo-spatiale et est chargé de fusionner plusieurs sources d'informations en une représentation cohérente de la manière dont notre corps est lié à l'environnement dans l'espace [89]. Ainsi, les tâches nécessitant des mouvements des yeux ou des mains et la coordination œil-main, seraient impossibles sans le cortex pariétal, qui traite, stocke et récupère également la forme, la taille et l'orientation des objets à saisir [93].

- Le lobe occipital : il se situe sur l'os occipital, à l'arrière de la tête, à côté du lobe pariétal et du lobe temporal. Il est impliqué principalement dans l'analyse et le traitement visuel [93].
- L'insula : elle représente la seule partie du cortex cérébral invisible à la surface du cerveau. Elle se charge d'intégrer les informations sensibles et végétatives reçues et est impliquée dans les sensations thermiques et algiques. Elle joue également un rôle dans le goût et dans certaines fonctions du langage [94].
- Le lobe limbique : il correspond à une zone en forme de C sur le bord le plus interne de chaque hémisphère cérébral. Il est formé par un ensemble de structures cérébrales qui jouent un rôle important dans la régulation des émotions comme l'agressivité, la peur, le plaisir, des comportements sociaux, de la motivation ainsi que dans la formation, la consolidation et la récupération de la mémoire émotionnelle. De plus, il est impliqué dans la régulation de la réponse de l'organisme aux récompenses, ainsi que dans la prise de décisions et exerce une influence sur le système endocrinien [95].




Figure 3 : Principaux lobes du cerveau [96].

Enfin, si nous décrivons chaque élément séparément dans le but de faciliter la compréhension de l'anatomie cérébrale et de la neurophysiologie, il est important de noter que l'ensemble de ces structures sont largement interconnectées et travaillent ensemble pour permettre à l'organisme de fonctionner de manière harmonieuse et coordonnée.

### **3.1.1.2. Système nerveux périphérique**

Le SNP, en parfaite continuité avec le SNC, est formé de ganglions et de nerfs périphériques. Ces derniers sont au nombre de 43 et sont divisés en 12 paires crâniennes et 31 paires rachidiennes et permettent de connecter le SNC aux différentes parties du corps, dont les organes, les muscles et les tissus à travers l'acheminement des informations sensibles vers le SNC et des ordres du SNC vers les effecteurs périphériques. Certains de ces nerfs, appelés nerfs moteurs, sont responsables de l'activation des muscles pour réaliser des mouvements comme la marche. D'autres sont des nerfs sensibles permettant de ressentir des sensations telles que le chaud, le froid ou la douleur. Le SNP est divisé en deux sous-systèmes : le système nerveux somatique et le système nerveux autonome.

Ce dernier, qui régule les fonctions corporelles de façon involontaire est divisé en deux parties qui travaillent en opposition : le système nerveux sympathique et le système nerveux parasympathique comme illustré dans la figure 4 [97]. Ce dernier intervient lors des situations calmes, de repos et de digestion. Il a pour fonction de ralentir le rythme cardiaque, de contracter<sup>3</sup> la pupille et de baisser la tension artérielle. Il a donc un effet calmant et ralentit le métabolisme pour économiser de l'énergie [98].

Le système nerveux sympathique, quant à lui, prépare le corps à faire face à des situations qui demandent de la force, de la vigilance ou qui évoquent des émotions comme la peur, la colère, l'excitation ou la gêne. Cette réponse est appelée réaction de lutte ou de fuite. Il a pour fonction d'augmenter la fréquence cardiaque, d'accélérer la respiration, de dilater les pupilles et de stimuler le métabolisme [97].

---

<sup>3</sup> Action de resserrer circulairement le diamètre




Figure 4 : Composantes et fonctions du système nerveux autonome [97].

### 3.1.2. Les aires motrices cérébrales

Les aires motrices cérébrales sont des régions spécifiques du cerveau qui sont responsables de la planification, de la coordination et de l'exécution des mouvements volontaires du corps. Ces aires jouent un rôle essentiel dans la commande des mouvements musculaires et sont souvent associées à la motricité fine comme les mouvements des doigts et à la motricité globale comme la marche ou la course [99]. L'étude des aires motrices cérébrales est donc cruciale pour comprendre le fonctionnement du système moteur. Etant donné que chaque région du corps se projette dans le cortex et occupe une surface variable selon la résolution sensori-motrice, les ICMs utilisent ces données en choisissant des actions dont l'activité corticale est spatialement bien différenciée.

Les principales aires motrices cérébrales illustrées sur la figure 5 sont les suivantes :

- Le cortex moteur primaire : il est localisé à l'arrière du lobe frontal et en avant du sillon central. Il est responsable du contrôle des mouvements volontaires en provoquant la

contraction des muscles squelettiques. Il est important de savoir que les voies motrices qui se développent à partir du cortex moteur de l'hémisphère gauche dirigent les neurones moteurs afférents vers les muscles squelettiques du côté droit du corps. Par conséquent, si une connexion dans le cortex moteur gauche est altérée, cela peut entraîner une paralysie de la moitié droite du corps, et vice versa [100].

- Le cortex moteur secondaire (ou cortex prémoteur) : il est également situé dans la partie frontale du cerveau. Cette région est impliquée dans la planification des mouvements complexes comme la coordination des mouvements des différentes parties du corps [101].
- L'aire de Broca : elle est le centre du langage dans le cerveau. Elle est responsable de la coordination des mouvements nécessaires à la production de la parole, en particulier les mouvements du larynx et de la bouche qui permettent l'expression des mots [102].

Ces aires motrices cérébrales travaillent en étroite collaboration avec d'autres régions du cerveau, telles que le cervelet et le tronc cérébral, pour permettre un contrôle précis et coordonné des mouvements corporels [103].




Figure 5 : Les aires fonctionnelles du cerveau [104].

### 3.1.3. La transmission nerveuse

La transmission nerveuse est un processus essentiel dans le système nerveux qui permet la communication entre les cellules nerveuses afin de coordonner et de réguler de nombreuses fonctions du corps.

Un neurone est une cellule nerveuse qui représente le pilier de la transmission nerveuse à travers la transmission des informations sensorielles telles que le goût, le toucher, la vue, l'audition et l'odorat, ainsi que dans la commande des muscles via les neurones moteurs [105]. Il se compose de trois parties principales comme illustré dans la figure 6 : le corps cellulaire, les dendrites qui s'étendent depuis le corps cellulaire et l'axone qui est un long prolongement unique se terminant par une arborisation terminale [91].




Figure 6 : Structure d'un neurone [106].

Dans le cerveau, les informations sont transmises sous forme d'influx nerveux qui se propage de neurone en neurone. Les dendrites recueillent les informations sensorielles qui sont transmises au corps cellulaire pour être traitées. Ces dernières se déplacent le long de l'axone jusqu'à la synapse, zone de contact entre deux cellules nerveuses permettant la transmission des informations de l'une à l'autre, où elles sont échangées sous forme de messages chimiques. Les neurones sont reliés entre eux par des milliers de connexions synaptiques et plus de cent neurotransmetteurs différents ont été identifiés [107].

De plus, la gaine de myéline entourant l'axone étant une membrane biologique formée par des oligodendrocytes, elle sert à isoler et à protéger les fibres nerveuses du fait de sa forte teneur en lipides et à la structure compacte de la myéline mais aussi à accélérer la vitesse de propagation

de l'influx nerveux transportant l'information le long des neurones. Ceci permet une transmission de l'information 100 fois plus rapide que celle des axones non myélinisés [108].

## **3.2.L'activité cérébrale**

L'activité cérébrale désigne l'ensemble des processus électriques et chimiques qui se produisent dans le cerveau en réponse à divers stimuli internes et externes et est générée par l'interconnexion de milliards de neurones [109]. Cette activité se traduit par différents rythmes cérébraux qui peuvent être mesurés à l'aide de l'électroencéphalographie. Ces derniers sont définis par leur fréquence et peuvent fournir des informations sur un état mental et être parfois volontairement contrôlés.

Les principaux rythmes cérébraux sont les suivants :

### **3.2.1. Le rythme Alpha**

Avec une fréquence de 7-12 Hz, le rythme alpha apparaît dans l'EEG de presque tous les individus normaux en état de veille ou au repos les yeux fermés, pour disparaître complètement pendant le sommeil. Il caractérise un état de conscience apaisé que l'on retrouve particulièrement lors d'une méditation légère ou d'une séance de relaxation [110].

### **3.2.2. Le rythme Bêta**

Avec une fréquence de 13-30 Hz, le rythme bêta peut être détecté lorsque l'on est éveillé et conscient [111]. Il apparaît généralement lorsque le système nerveux est actif et est donc associé à la stimulation sensorielle et à l'activité mentale. Il est particulièrement présent en période d'activité intense, de concentration ou d'anxiété.

### **3.2.3. Le rythme Gamma**

Avec une fréquence supérieure à 30 Hz, le rythme Gamma reflète la concentration attentive selon certains chercheurs et sert de fréquence porteuse pour faciliter l'échange de données entre les régions du cerveau [112]. D'autres associent ce rythme à des mouvements oculaires rapides, appelés micro-saccades, qui sont considérés comme faisant partie intégrante du traitement sensoriel et de l'assimilation des informations [113].

### **3.2.4. Le rythme Delta**

Avec une fréquence de 1-4 Hz, les ondes du rythme Delta sont examinées pour évaluer la profondeur du sommeil. Plus le rythme Delta est fort, plus le sommeil est profond. On a

également constaté que l'augmentation de la puissance Delta était associée à une plus grande concentration dans les tâches de mémoire de travail interne [114].

### **3.2.5. Le rythme Thêta**

Avec une fréquence de 4-7 Hz, le rythme Thêta est associé à un large éventail de processus cognitifs tels que l'encodage et la récupération de la mémoire, ainsi qu'à la charge de travail cognitive [115]. Ainsi, lorsque nous sommes confrontés à des tâches complexes, les ondes Thêta deviennent proéminentes. Elles sont également associées à des niveaux de fatigue plus élevés [116].

### **3.2.6. Le rythme Mu**

Avec une fréquence de 8-12 Hz, le rythme Mu est associé aux mouvements du corps, soit en déplaçant réellement une partie de son corps, soit en pensant à le faire, et n'apparaît que lorsque le corps est complètement détendu, c'est ce qui est désigné par l'appellation « imagerie motrice » [117]. Dans notre travail, nous avons axé nos méthodes sur ces signaux qui seront extraits d'une base de données reconnue dans le domaine des ICM disponible publiquement.

## **4. L'électroencéphalographie**

L'électroencéphalographie (EEG) est une technique non invasive de conversion des courants électriques de la zone périphérique du cerveau en signaux électriques exploitables reflétant l'activité cérébrale. L'exploitation et le traitement de ces signaux nous offrent la possibilité d'explorer les modèles d'activité électrique associés à des tâches spécifiques du cerveau ainsi que les processus neuronaux sous-jacents à diverses fonctions cognitives et comportementales [118].

### **4.1. Technique d'enregistrement**

L'enregistrement de l'activité électrique cérébrale se fait à travers des électrodes placées sur le cuir chevelu en utilisant un casque à lanières en caoutchouc ou des bonnets à électrodes intégrées [119]. La mise en place des électrodes se fait généralement avec le système international 10-20, qui consiste à placer chez les adultes, 21 électrodes symétriquement pour couvrir toute la tête, en incluant la référence et la terre (Fp1, Fp2, F3, F4, F7, F8, T3, T4, T5, T6, C3, C4, P3, P4, O1, O2, Fz, Cz, Pz). Ce système permet de fixer la position de chaque électrode proportionnellement par rapport aux repères osseux [120] comme illustré sur la figure 7. Pour améliorer le contact entre l'électrode et le cuir chevelu, une pâte adhésive et conductrice

doit être appliquée sous chaque électrode. Ces électrodes sont ensuite connectées à des fils qui les relient à l'appareil d'enregistrement permettant ainsi d'obtenir des signaux en temps réel de l'activité cérébrale.




Figure 7 : Configuration du système international 10-20 [120].

L'électroencéphalographie à ses débuts, se présentait sous forme analogique, le signal de l'activité cérébrale étant retranscrit sur une feuille de papier à travers des aiguilles à ancre. Ce système ancien ne permettait pas le traitement du signal ou l'extraction de caractéristiques autres que visuelles, représentées par l'évolution de l'amplitude à travers le temps mais était déjà suffisant pour relever certaines informations par les neurologues. C'est avec l'arrivée des EEG numériques que de nouvelles perspectives ont vu le jour [121].

Ainsi, le système EEG moderne repose sur des dispositifs d'acquisition de données qui permettent de transformer les signaux analogiques provenant du patient en une forme numérique. Pour cela, le signal de faible amplitude est récupéré à travers des électrodes pour ensuite être injecté dans un amplificateur différentiel qui se présente sous la forme d'un boîtier [122]. Cet amplificateur représenté sur la figure 8 contient généralement un filtre réjecteur de 50 Hz permettant d'éliminer le courant électrique du secteur. En plus des électrodes, il n'est pas rare d'avoir une caméra vidéo comme support supplémentaire afin d'observer le patient lors de l'examen EEG. Ceci est synchronisé de manière étroite avec les informations électriques lors d'un examen médical ou alors lors d'une application d'ICM, afin d'obtenir un enregistrement continu du patient pendant la phase d'enregistrement du signal [121].

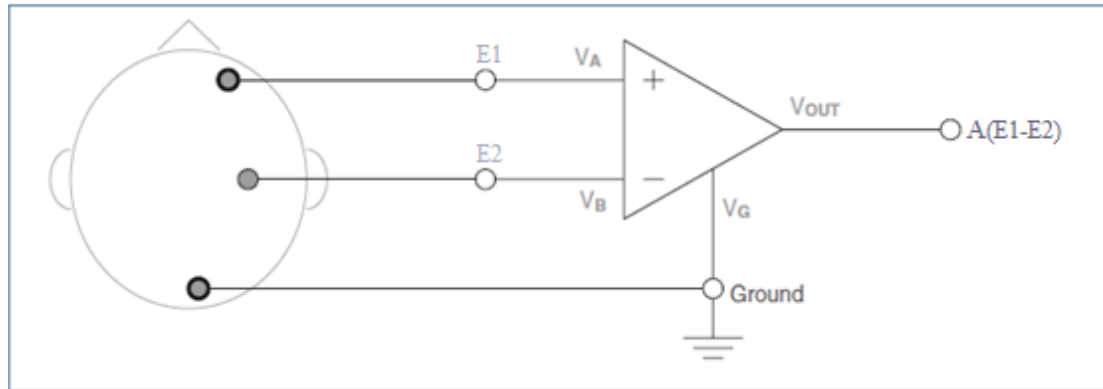


Figure 8 : Montage électronique de l'amplificateur différentiel [121].

Une fois amplifié, le signal passe par un processus qui convertit le signal analogique en une séquence de nombres numériques qui peuvent être traités et stockés dans un ordinateur. Le signal est ensuite échantillonné, l'écart entre deux échantillons successifs représentant la période d'échantillonnage qui doit respecter le théorème de Shannon afin de ne pas perdre d'information par rapport au signal d'origine analogique [123,124]. Tous les systèmes d'échantillonnage filtrent le signal analogique au moins à la moitié de la fréquence d'échantillonnage. Ce filtre, communément appelé filtre anti-repliement ou anti-aliasing, doit son nom au phénomène de repliement fréquentiel, résultant d'une erreur typique qui peut survenir si l'échantillonnage n'est pas effectué de manière rigoureuse et adéquate. Il se produit lorsque des fréquences supérieures à la moitié de la fréquence d'échantillonnage sont présentes dans le signal analogique d'entrée et se replient alors en dessous de la fréquence de Nyquist devenant indiscernables des fréquences inférieures [125]. Ce filtre est donc un élément clé, placé généralement en amont du convertisseur analogique-numérique.

Enfin, le processus de quantification permet de définir la précision de la mesure. Dans un système numérique, elle est déterminée par le nombre de bits utilisés pour la quantification du signal. Plus le nombre de bits utilisés est élevé, plus la résolution est meilleure, mieux le signal est représenté [126].

## 4.2. Propriétés de l'EEG

Du fait de sa disponibilité, de son faible coût, de ses enregistrements en temps réel, de sa facilité d'utilisation et de l'absence d'émission d'ondes [127], l'EEG est un outil stratégique pour une utilisation grand public mais aussi dans la recherche sur les processus cognitifs, le neurofeedback, le diagnostic des troubles mentaux, la neurochirurgie ou encore les interfaces cerveau-machine [128]. Ainsi, les données EEG recueillies peuvent être analysées pour détecter

des caractéristiques spécifiques telles que les fréquences d'ondes cérébrales, les potentiels évoqués et les synchronisations entre différentes régions cérébrales [129].

Cependant, l'EEG comporte également des inconvénients à prendre en considération comme sa faible résolution spatiale limitant la mesure de l'activité électrique à la surface du crâne. Il ne peut donc pas fournir d'informations sur les structures profondes du cerveau et est également sensible aux mouvements et aux artefacts [129].

Dans ce travail de recherche, le recours à l'EEG a été privilégié au vu de ses nombreux avantages cités précédemment, et ceci dans l'optique de permettre un meilleur déploiement et une meilleure accessibilité à cette technologie.

## **5. Conclusion**

Bien que la neuroanatomie et la physiologie du système nerveux soient des domaines complexes, les recherches scientifiques menées ont abouti à des avancées majeures dans le monde de la neuroscience notamment grâce à l'avènement de l'EEG et des techniques d'analyse des signaux électroencéphalographiques. Malgré le fait que cette technologie soit ancienne, l'EEG est encore largement utilisé notamment par rapport à son faible coût et à la simplicité de son utilisation [127] et demeure un outil incontournable pour de nombreuses applications, dont les interfaces cerveau-machine. Ces dernières représentent une technologie en développement rapide et continu qui offre des perspectives passionnantes pour la compréhension et la résolution de nombreuses problématiques médicales et sociétales. Elles exploitent les signaux émis par le cerveau comme les potentiels évoqués somesthésiques et les potentiels évoqués moteurs, pour établir une communication directe entre le cerveau et les dispositifs technologiques en reflétant les activités cognitives. De plus, les interfaces cerveau-machine ont déjà montré leur utilité dans les domaines de la réadaptation fonctionnelle, de la prévention de la déficience cognitive, de la robotique et de la palliation de la paralysie [13].

---

# **CHAPITRE II**

Outils applicatifs pour la classification des signaux  
d'imagerie motrice

---

## **1. Introduction**

L'analyse des signaux biomédicaux est devenue un outil crucial pour extraire des données cliniques substantielles. En effet, ces signaux renferment des informations cachées dans leur structure qui ne peuvent être directement observées et présentent des propriétés qui peuvent aider à identifier diverses conditions pathologiques [130].

Dans le contexte des ICMs, le signal utilisé est le signal électroencéphalographique, qui provient de l'électroencéphalographie, une méthode visant à refléter l'activité cérébrale d'une zone périphérique du cerveau en convertissant les courants électriques en signaux exploitables à travers une méthode non invasive. Ce signal est ensuite traité avec pour objectif de traduire les activités cérébrales en commandes informatiques qui seront utilisées pour piloter des dispositifs externes. Ce signal EEG est numérisé et subit un prétraitement permettant de supprimer les bruits indésirables et d'extraire les caractéristiques pertinentes des signaux cérébraux. Les caractéristiques extraites peuvent inclure des informations sur les ondes cérébrales, les potentiels évoqués et les signaux de synchronisation. Ce signal est ensuite traité dans le but de traduire les activités cérébrales en commandes informatiques qui seront utilisées pour piloter des dispositifs externes. Notre objectif consiste alors à extraire des informations exploitables qui pourront être utilisées pour contrôler divers dispositifs, notamment des prothèses ou des ordinateurs.

Dans ce chapitre, nous aborderons l'utilisation de la géométrie Riemannienne qui fait partie d'une branche des mathématiques qui est la géométrie différentielle et qui permet de prendre en compte la nature complexe des signaux en utilisant des outils tels que la cartographie logarithmique et l'espace tangent.

Par la suite, nous nous intéresserons à deux méthodes d'apprentissage automatique robustes utilisées en intelligence artificielle, à savoir le Support Vector Machine (SVM) et l'Artificial Neural Network (ANN). Ces techniques permettent de traiter de grandes quantités de données et d'extraire des informations significatives à partir des signaux électrophysiologiques, offrant ainsi une approche prometteuse pour la classification des signaux d'imagerie motrice.

## **2. La géométrie Riemannienne**

Une fois que les caractéristiques des signaux d'imagerie motrice sont extraites des données, il est primordial de mettre en place une stratégie de classification appropriée. La connaissance de la nature des données traitées permet d'optimiser les méthodes de classification utilisées. Dans le cadre de cette recherche, les caractéristiques étudiées appartiennent à une variété différentielle, qui nécessite une approche spécifique de la géométrie Riemannienne. De ce fait, nous procéderons à une introduction progressive de cette méthode mathématique dans cette section.

### **2.1.Principe de base**

Pour introduire la géométrie Riemannienne, nous allons nous intéresser à quelques notions élémentaires qui permettent de définir le principe général de cette théorie.

#### **2.1.1.Cas à une dimension**

Commençons par supposer l'existence d'un espace à une dimension, qui est représenté par une ligne. D'un point de vue topologique, rien ne nous empêche de déformer cette ligne, ou plutôt de fléchir cette dimension [131]. Si cette dimension est représentée par une ligne comme montré dans la figure 9.a, celle-ci n'est techniquement pas bornée de chaque côté ; elle est donc infinie. Si on la fléchit à plusieurs endroits, on obtient une boucle et ceci nous permet d'aboutir à la notion d'espace à une dimension finie, représentée par la figure 9.b [132].

De ce fait, si nous voulons peupler ces deux espaces à une dimension, nous aurons un point qui pourra se déplacer sur les deux sens de l'axe. La différence est que sur le deuxième espace, si le point bouge dans une direction, au bout d'un moment, il finira par repasser par le même endroit.




Figure 9 : Notion de passage de dimension infinie (a) à dimension finie (b) [132].

### 2.1.2. Cas à deux dimensions

Considérons maintenant l'opération équivalente appliquée au cas d'un espace à deux dimensions correspondant à un plan  $(x,y)$ . Si on applique une courbure à cet espace, nous obtiendrons un plan perçu courbé, mais qui restera toujours plat [133]. Bien que pour illustrer cette courbure, nous avons recours à un subterfuge de perspective qui laisse entrevoir une 3<sup>e</sup> dimension, mais comme pour l'exemple précédent, la notion de troisième axe apportant une troisième dimension pour les objets de l'espace ne peut être appliquée ; c'est une surface plate, et l'objet ne peut évoluer que sur les axes  $x$  et  $y$ . Ainsi, si nous voulions peupler cet espace, on pourrait y mettre un carré et pour l'observer, il suffirait de mesurer la longueur sur les axes  $x$  et  $y$  à l'aide d'une règle. Cependant, avec des outils cartésiens, l'exercice paraît plus intuitif sur l'espace non incurvé. Si nous avons une règle rigide, nous ne pourrions pas mesurer correctement la longueur du carré dans l'espace courbé.

Comme pour l'exemple à une dimension, cet espace à deux dimensions est, de base, infini. Si nous appliquons, là aussi, la notion de courbure de l'espace, nous prenons deux extrémités d'un seul axe et courbons le plan de façon à ce qu'elles se touchent comme illustré dans la figure 10.




Figure 10 : Transformation topologique de l'espace sur un seul axe [134].

Nous obtiendrons alors un espace ayant la forme d'un cylindre avec un axe fini sur l'axe courbé, mais infini sur l'axe restant [134]. De nouveau, si nous appliquons une courbure sur le deuxième axe, nous obtiendrons un tore qui, d'un point de vue topologique, est toujours le même type d'objet car cet espace est toujours bijectif et continu sur  $f$  et sur  $f^{-1}$ . Ce dernier est illustré sur la figure 11.




Figure 11 : Transformation topologique du cylindre pour l'obtention d'un tore [135].

Si ce tore est peuplé par un objet, celui-ci verrait toujours un espace plat lors de son déplacement, qui s'effectue toujours sur l'axe  $x$  et  $y$  seulement. Si nous souhaitons mesurer cet objet, la longueur du côté d'un carré par exemple, la tâche devient bien complexe à l'aide des outils classiques en raison de la déformation de l'objet sous l'effet de la courbure du plan initial. Il existe, toutefois, une solution qui consiste, plutôt que de recourir à des équations mathématiques élaborées sur cette surface courbée, à opter pour des calculs plus simples sur une surface plane et ensuite interpréter les résultats sur la surface courbée grâce à des facteurs de correction [135].

Prenons un autre exemple, la sphère, qui nous permet de faire une approche plus simple et plus proche de notre travail. Ces deux entités sont toutes deux des variétés, à savoir des espaces localement euclidiens qui peuvent être décrits mathématiquement en utilisant des cartes locales. Nous faisons donc appel à la notion de variété qui est une généralisation des espaces vectoriels, car celle-ci permet de mieux décrire les espaces courbés. De cette notion, nous pouvons tenter d'apporter une réponse à travers le principe de propriété localement vraie. On dit qu'une propriété est localement vraie en un point  $P$ , s'il existe un petit voisinage où cette propriété est vérifiée, c'est dire que ce voisinage soit un espace topologique. De façon intuitive, prenons l'exemple à une dimension et supposons que cet espace soit fini, si nous prenons un point situé dans la partie médiane et que nous effectuons un agrandissement sur ce point, nous aurons à son voisinage l'impression que nous sommes sur  $\mathbb{R}$  car il n'y a pas de bords, nous pouvons dire alors que ce voisinage est un ouvert de  $\mathbb{R}$ . Par contre, si nous prenons un point au bord de la ligne, malgré l'application d'un agrandissement, au voisinage de ce point, nous verrons toujours un bord. De ce fait, au voisinage de ce point, l'espace n'est pas homéomorphe à  $\mathbb{R}$ , la propriété n'est pas retrouvée et cet espace n'est donc pas localement vrai, comme illustré sur la figure 12.

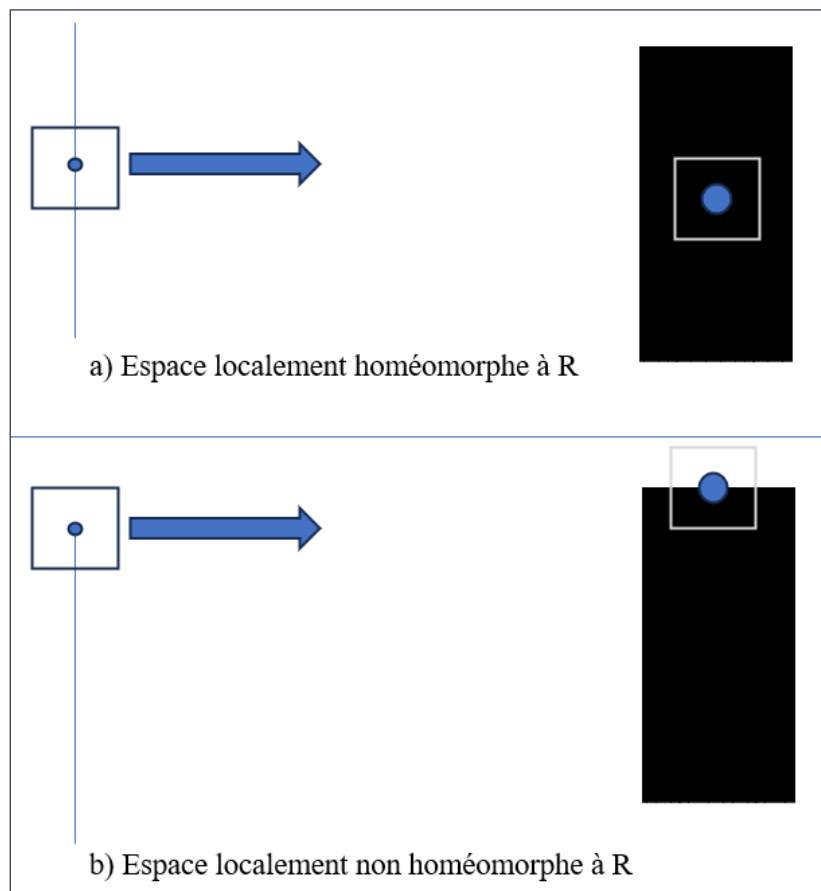


Figure 12 : Représentation de la propriété localement vraie en « a » et localement non homéomorphe « b » [136].

Nous pouvons appliquer le même raisonnement sur notre sphère. Si nous prenons un point sur une portion de la sphère qui forme une coupole, et appliquons un agrandissement, nous verrons toujours une forme représentative de l'espace  $S^2$ . Par contre, si nous ajoutons une extension comme un trait sur la partie où se trouve le point, au voisinage de celui-ci, la propriété n'est plus vraie. Si ce voisinage existe, alors nous pouvons dire que c'est un ouvert de l'espace dans lequel il se trouve.

Il existe ensuite plusieurs façons d'appréhender les déplacements sur ces espaces, notamment par difféomorphisme, et pour résoudre la problématique de calcul de distance et pouvoir ainsi faire une mesure de la distance entre deux voisinages, nous pouvons recourir au calcul de la projection des distances. C'est là que la géométrie Riemannienne vient apporter une solution avec des outils adaptés prenant compte des courbures de la variété.

## **2.2. Le Riemannien dans la classification**

La géométrie Riemannienne est un domaine de la géométrie différentielle qui étudie les espaces de courbure non nulle. Elle permet de décrire les propriétés géométriques locales d'une variété, comme la courbure ou la distance. En plus d'être utilisée pour projeter les signaux sur un espace de dimension inférieure tout en conservant certaines propriétés géométriques, la géométrie Riemannienne a permis l'utilisation de nouvelles approches de classification avec l'idée de cartographier les données directement dans un espace géométrique doté d'une métrique appropriée, comme c'est le cas des données EEG, avec l'utilisation des matrices de covariance des données. Le principe de cette cartographie repose sur l'hypothèse que la puissance et la distribution spatiale des sources EEG peuvent être considérées comme fixes pour un état mental donné et que ces informations peuvent être codées par une matrice de covariance [137].

De plus, la géométrie Riemannienne étudie les espaces courbés lisses qui peuvent être localement et linéairement approximés. Cette théorie énonce que lorsque chaque point a un voisinage homéomorphe au sous-ensemble ouvert, c'est-à-dire, lorsqu'un espace tangent est défini en chaque point de l'espace courbé,  $M$  est appelé manifold différentiel [138]. On peut alors y définir une géodésique qui est la courbe lisse la plus courte entre deux points,  $P_1$  et  $P_2$ . L'espace tangent  $T_P$  au point  $P$  est l'espace vectoriel couvert par les vecteurs tangents de toutes les géodésiques sur  $M$  passant par  $P_M$ . Cet espace tangent est alors un concept clé qui permet de décrire les propriétés géométriques d'un espace de manière locale, et peut également être considéré comme l'ensemble des vecteurs qui peuvent être utilisés pour décrire les variations de la courbe ou de la surface à proximité de ce point.

Le plan tangent peut être caractérisé par un produit scalaire qui permet de définir une métrique et donc d'établir une mesure de distance. On peut le considérer comme étant composé de tous les vecteurs tangents au point P, se dirigeant dans toutes les directions, nous avons [7]:

$$\|S\|_P = \sqrt{\langle S, S \rangle_P} \quad (1)$$

L'espace tangent  $T_P$  est un espace euclidien, constitué par les vecteurs  $S_i$  au point donné P de l'espace Riemannien comme illustré sur la figure 13. La métrique plane de cet espace est localement homéomorphe à la variété. Ceci signifie que, dans des régions locales de cet espace, les propriétés topologiques et géométriques peuvent être mappées de manière continue, c'est-à-dire, de manière graduelle et sans sauts brusques, et de façon inversible sur une variété, permettant une transformation de l'état A à l'état B, tout en garantissant que le retour de B à A est toujours réalisable, facilitant l'application d'outils arithmétiques et de classificateurs classiques adaptés à des formes géométriques plus familières [139].




Figure 13 : Représentation de l'espace tangent  $T_P$  [139].

Pour pouvoir appliquer les outils euclidiens aux informations situées sur la variété Riemannienne<sup>4</sup>, il faut passer un outil de cartographie qui permet d'effectuer une

---

<sup>4</sup> Il s'agit d'une variété différentielle munie d'une métrique riemannienne, qui est une fonction qui attribue à chaque point de la variété un produit scalaire sur son espace tangent

correspondance entre cette dernière et l'espace tangent euclidien. Pour une variété différentiable donnée, la correspondance exponentielle permet de faire correspondre à chaque point de l'espace tangent, un point de la variété. Ceci revient à projeter les points de la variété vers l'espace tangent à travers une fonction appelée opérateur logarithmique défini comme suit :

$$\text{Log}_P(P_i) = P^{\frac{1}{2}} \text{Log} \left( P^{-\frac{1}{2}} P_i P^{-\frac{1}{2}} \right) P^{\frac{1}{2}} \quad (2)$$

L'opérateur exponentiel de Riemann permet de retourner dans l'espace original des matrices symétriques et définies positives (SDP) avec une correspondance biunivoque, c'est-à-dire, une correspondance exacte entre les points de l'espace tangent et les points de l'espace original. Chaque point de l'espace (SDP) a, alors, une correspondance unique dans l'espace original, et vice versa.

$$\text{Exp}_P(S_i) = P^{\frac{1}{2}} \text{Exp} \left( P^{-\frac{1}{2}} S_i P^{-\frac{1}{2}} \right) P^{\frac{1}{2}} \quad (3)$$

Considérons maintenant, une courbe sur la variété paramétrée par le réel  $t$  appartenant à l'intervalle  $[0,1]$ , notée  $\alpha$ . Pour chaque point  $\alpha(t)$  de la variété, il existe un vecteur tangent  $\dot{\alpha}(t)$  dont la norme est  $\|\dot{\alpha}(t)\|_{\alpha(t)}$ . La longueur de la courbe reliant  $\alpha(0)$  à  $\alpha(1)$  est alors définie à partir de l'intégrale suivante [7] :

$$L(\alpha) = \int_0^1 \|\dot{\alpha}(t)\|_{\alpha(t)} dt \quad (4)$$

La longueur minimale de la courbe est alors appelée géodésique.

Pour calculer la longueur  $\ell$  entre deux points de la variété différentielle,  $P_1$  et  $P_2$ , paramétrée par  $t$  tel que  $\ell(0) = P_1$  et  $\ell(1) = P_2$  avec  $\ell(t)$  un point de cette géodésique, nous utilisons l'équation suivante :

$$\delta_R(P_1, P_2) = L(\ell) = \int_0^1 \|\dot{\ell}(t)\|_{\ell(t)} dt \quad (5)$$

Cette notion de géodésique est illustrée sur la figure 14 suivante :




Figure 14 : Longueur minimale  $l$  entre  $P_1$  et  $P_2$  [140].

La longueur  $\ell(t)$  est donnée par :

$$L(\ell) = \int_0^1 \|\dot{\ell}(t)\|_{\ell(t)} dt = \int_0^1 \sqrt{\text{Tr}(\dot{\ell}(t)\ell^{-1}(t)\dot{\ell}(t)\ell^{-1}(t))} dt \quad (6)$$

Dans le cadre de l'étude des ICMs, nous considérons des segments à court terme du signal EEG, sous la forme d'une matrice  $X_i$  qui correspond au  $i$ -ième essai du signal d'imagerie motrice. Nous supposons que chaque mesure par une électrode a été préalablement centrée. Pour le  $i$ -ième essai, la matrice de covariance spatiale peut être calculée par différents estimateurs, mais nous utiliserons le Sample Covariance Matrix (SCM). Pour calculer la matrice de covariance de notre signal EEG, supposons  $X_i \in \mathbb{R}^{E \times T}$ , un essai d'imagerie motrice, où  $E$  représente le nombre d'électrodes et  $T$  le nombre d'échantillons :

$$P_i = \frac{1}{N-1} X_i \cdot X_i^T \quad (7)$$

$P_i$  étant calculée pour chaque essai, nous obtenons des matrices appartenant à l'espace symétrique et défini positif (SDP) comme défini par F. Yagger et al [140]. Cette estimation est rapide et simple à calculer, cependant, lorsque  $E \approx T$ , le SCM n'est pas un bon estimateur de la vraie covariance. Dans le cas  $E > T$ , le SCM n'est même pas de plein rang [141].

Avec suffisamment d'échantillons, une matrice de covariance estimée avec le SCM est symétrique et définie positive (SDP), ce qui signifie que toutes ses valeurs propres sont

strictement positives. Les matrices ayant cette propriété forment une variété  $M$  comme introduit précédemment.

Soit  $P_1$  et  $P_2$  deux matrices de covariance de la variété Riemannienne, le calcul de la distance entre ces deux matrices est défini par [142] :

$$\delta_R(P_1, P_2) = \|\log(P_1^{-1}P_2)\|_F = \left[ \sum \log^2 \lambda_i \right]^{\frac{1}{2}} \quad (8)$$

Où  $\lambda_c, c = 1, \dots, C$  les valeurs propres de  $P_1^{-1}P_2$ .

Les principales propriétés de la distance géodésique Riemannienne sont les suivantes :

- $\delta_R(P_2, P_1) = \delta_R(P_1, P_2)$
- $\delta_R(P_1^{-1}P_2^{-1}) = \delta_R(P_1, P_2)$
- $\delta_R(W^T P_1 W, W^T P_2 W) = \delta_R(P_1, P_2) \forall W \in Gl(n)$

La troisième propriété est très importante, car elle implique que l'espace des matrices SDP est invariant par projection [139].

Pour un ensemble  $P$  de matrices de covariance, il est possible de calculer la moyenne géométrique de cet ensemble en faisant une analogie avec la moyenne euclidienne et en utilisant la distance Riemannienne. Cette moyenne, que l'on peut également appeler Barycentre de Frechet [7] de  $N$  points  $P_n$  sur la variété,  $n = 1; \dots; N$ , peut être définie comme le point qui minimise la somme des distances au carré à tous les  $P_i$  et définie comme suite [8]:

$$\mu(\Sigma_1, \dots, \Sigma_n) = \arg \min \sum_{i=1}^N \delta^2(\Sigma_i, \Sigma) \quad (9)$$

Cette moyenne n'a pas de forme fermée et peut être calculée de manière itérative. Pour ce faire, il existe plusieurs manières de procéder comme expliqué dans [141]. Cependant, nous allons nous concentrer sur la méthode qui utilise le fait que le plan tangent est un homéomorphisme local de la variété. Comme il est euclidien, on peut y calculer une moyenne euclidienne et la projeter sur la variété. On procède par itérations successives en projetant l'ensemble des matrices dans le plan tangent, en estimant la moyenne arithmétique des vecteurs du plan tangent, puis en projetant cette moyenne dans la variété et en recommençant la procédure avec la nouvelle moyenne comme point de passage vers le plan tangent [7]. Le processus s'arrête en définissant une limite d'itération ou une distance minimale entre deux barycentres où le changement est suffisamment minime pour être ignoré.

### 2.3. Le filtrage géodésique

Les signaux électroencéphalographiques, en particulier dans le contexte des signaux d'imagerie motrice, sont sujets à diverses sources de perturbations, notamment les interférences électromagnétiques, les mouvements musculaires involontaires et les artefacts liés à l'appareil de mesure. Afin d'obtenir des données d'imagerie motrice fiables et précises, il est impératif de filtrer ces signaux pour éliminer ou réduire l'impact de ces perturbations. En plus de l'élimination des artefacts, il est également possible d'appliquer un autre type de filtrage visant à améliorer la qualité des signaux. Ce type de filtrage est conçu pour réduire la dimension des données et améliorer la séparation des catégories de signaux, préparant ainsi les données pour une classification plus efficace.

Sur les variétés Riemanniennes, on peut recourir au filtrage géodésique sur l'espace tangent. En d'autres termes, le but de ce filtrage est de trouver les géodésiques supportant les informations liées à la classe, afin d'effectuer un filtrage qui élimine les informations non pertinentes dans l'espace Riemannien [52].

Notre objectif dans le cadre de cette approche consiste à accroître la séparation spatiale des données présentes dans les matrices de covariance sur l'espace tangent afin d'optimiser les procédures de classification. La mise en œuvre de ce filtre exige, en premier lieu, l'évaluation de la séparabilité entre les différentes classes, par le calcul de la distance entre les moyennes des classes, désignée par  $S_B$  « variance entre-classes ».

Pour calculer la variance entre les classes ou la matrice entre les classes  $S_B$ , supposons  $X = \{x_1, x_2, x_3, \dots, x_n\}$  où  $x_i$  représente l'échantillon  $i$  et  $N$  le nombre total d'échantillons. Chaque échantillon est représenté par  $M$  caractéristiques, en d'autres termes, chaque échantillon est représenté comme un point dans un espace à  $M$  dimension. Pour calculer  $S_B$  comme dans notre cas dans à deux classes. Il faut trouver la distance de séparation entre ces classes désignées par:

$$(m_i - m)^2 = (W^T u_i - W^T u)^2 = W^T (u_i - u)(u_i - u)^T W \quad (10)$$

$m_i$  représente la projection de la moyenne de l'échantillon.

La classe  $i$  est calculée comme suit :

$$m_i = W^T u_i \quad (11)$$

Où  $m$  est la projection de la moyenne totale de toutes les classes  $m = W^T u$  et  $W$  représente la matrice de transformation de la LDA.

$(u_i - u)(u_i - u)^T$  représente variance entre classe SB on peut donc noter :

$$(m_i - m)^2 = W^T S_{B_i} W \quad (12)$$

La variance totale entre les classes est calculée comme décrit dans [143] :

$$\left( S_B = \sum_{i=1}^c n_i S_{B_i} \right) \quad (13)$$

Par la suite, la variance de chaque classe  $S_w$ , nommée "variance intra-classe", doit être calculée.

Enfin, la matrice de transformation  $W$  est calculée par :

$$S_W W = \lambda S_B \quad (14)$$

avec  $\lambda$  les valeurs propres de la matrice de transformation.

Ce problème est résolu en calculant les valeurs propres et les vecteurs propres si  $S_w$  est non-singulière.

En d'autres termes, si la matrice de variance intra-classe est inversible, la matrice de transformation peut être calculée en résolvant une équation linéaire. Les valeurs propres et les vecteurs propres sont des mesures importantes pour caractériser les transformations linéaires et sont utilisées pour calculer les composantes principales d'un ensemble de données. Dans ce contexte, la matrice de transformation  $W$  permet de projeter les données dans un nouvel espace de variables, où celles-ci sont ordonnées en fonction de leur importance pour séparer les classes [52].

Ensuite, nous allons utiliser un filtre linéaire, ce qui signifie que l'opération de filtrage sera réalisée de la manière suivante :

$$\tilde{S}_i = W S_i \quad (15)$$

Avec  $W = [w_1 \dots w_j]$

$S \in \mathbb{R}^{J \times m}$ , une matrice formée par la concaténation des  $J < m$  filtres de  $m$  coefficients. Les filtres  $w_j$  peuvent être obtenus de différentes manières, en fonction des caractéristiques du filtrage souhaité. Le filtrage effectué par l'équation ci-dessus permet de réduire la dimension de l'espace de représentation, en plus d'effectuer un changement de base, ce qui empêche en retour l'utilisation de la carte exponentielle pour renvoyer les données dans la variété. Pour pallier ce problème, on utilisera comme projecteur la matrice  $\widehat{W} \in \mathbb{R}^{m \times m}$  qui renvoie les données filtrées dans leur base originelle. Ce projecteur est donné par l'équation suivante :

$$\widehat{W} = W^T (W W^T)^{-1} W \quad (16)$$

Alors

$$\widehat{S}_i = \widehat{W} S_i \quad (17)$$

Chaque filtre  $w_j$  correspond à une direction dans l'espace tangent. Le filtrage projette les données sur un hyperplan défini par  $J$  droites de l'espace tangent. Le passage dans la variété projette ensuite les données sur une sous-variété définie par  $J$  géodésiques. Cette opération de filtrage est appelée "filtrage géodésique" [7].

### **3. Technique de classification en Intelligence Artificielle**

Nous avons montré, lors de l'étude de l'aspect mathématique de la géométrie Riemannienne, que la projection des données sur un espace tangent permet d'appliquer les méthodes de classification classiques sur un espace vectoriel euclidien. Dans cette section, nous allons ainsi nous intéresser aux techniques de classification utilisées en intelligence artificielle et nous nous intéresserons, plus précisément, aux méthodes d'apprentissage automatique qui jouent un rôle central dans la traduction des états mentaux, tels que les intentions de mouvement, en commandes exploitables pour les dispositifs externes.

L'intelligence artificielle (IA) est un domaine en constante évolution qui vise à créer des machines capables de simuler l'intelligence humaine, telles que la reconnaissance de formes, la compréhension du langage naturel et la prise de décision [144,145]. Il existe de nombreuses techniques pour atteindre cet objectif, mais l'une des plus populaires est le Machine Learning. Il s'agit d'un outil qui permet aux machines d'apprendre à partir de données, avec leur propre modèle.

Le Machine Learning se divise en deux grandes catégories : l'apprentissage supervisé et l'apprentissage non supervisé. Le premier est utilisé pour résoudre des tâches de classification et de régression, en apprenant à partir d'un ensemble de données étiquetées, avec l'objectif de prédire les sorties pour de nouvelles données [146]. L'apprentissage non supervisé, quant à lui, est utilisé pour résoudre des tâches d'analyse de données, en déterminant des structures ou des modèles dans les données sans étiquettes préalables [147]. On peut citer aussi le Deep Learning (DL) qui est une sous-catégorie du Machine Learning s'appuie sur des réseaux de neurones profonds pour résoudre des tâches de classification complexes [148], telles que la reconnaissance d'images, la reconnaissance de la parole et bien d'autres tâches liées aux données à grande dimension. Cette approche utilise à la fois des modèles supervisés et non supervisés, tout comme dans le Machine Learning [149].

Ainsi, l'intelligence artificielle est devenue un domaine de recherche et d'application clé pour de nombreuses industries, telles que la finance, la santé, la robotique, la reconnaissance vocale et faciale, le médical, la sécurité et bien d'autres domaines encore. Ce champ de recherche est en constante évolution, et de nouvelles techniques et avancées sont en cours de développement pour relever les défis de l'apprentissage automatique illustré parfaitement par le récent chatbot « chatgpt ». Pour rester compétitif dans ce domaine, il est donc primordial de se tenir informé des dernières innovations et développements en intelligence artificielle, afin de pouvoir tirer parti des avancées les plus récentes dans les applications professionnelles.

### **3.1.Apprentissage automatique (Machine Learning)**

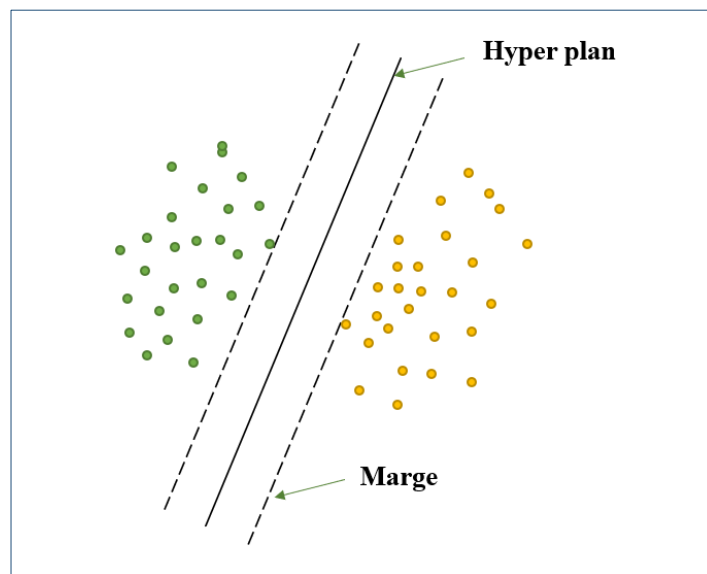
Dans le cadre du Machine Learning, deux méthodes populaires sont largement utilisées pour la classification de données, dans le cadre des ICMs : les Support Vector Machine (SVM) et les réseaux de neurones artificiels (ANN).

#### **3.1.1.Support Vector Machine**

Les SVM se présentent sous la forme d'un algorithme de classification supervisé basé sur des méthodes d'optimisation de la théorie des noyaux qui vise à séparer les différentes classes de données en utilisant des hyperplans et en minimisant la distance entre les points de données et les plans séparateurs. Il est particulièrement efficace pour les tâches de classification binaire ou multi-classes, telles que la détection de fraude dans les transactions financières [150], les interfaces cerveau-machine [151] ou la détection de tumeurs dans les images médicales [152].

Les SVM permettent également de résoudre des problèmes de discrimination et de régression mathématique. Elles ont été conceptualisées dans les années 1990 à partir de la théorie de Vapnik-Chervonenkis, développée par les informaticiens russes Vladimir Vapnik et Alexey Chervonenkis. Les SVM sont largement utilisées en raison de leur capacité à traiter des données de grandes dimensions, de leurs garanties théoriques et de leurs performances pratiques.

Le principe des SVM consiste à trouver un hyperplan séparateur qui maximise la marge entre deux classes comme illustré sur la figure 15. La marge est définie comme la distance entre l'hyperplan séparateur et le plus proche point de chaque classe, appelé vecteur de support. Les vecteurs de support sont les points les plus proches de l'hyperplan qui déterminent sa position.



*Figure 15 : Représentation du principe de classification par SVM [153].*

Les SVM utilisent également des fonctions mathématiques appelées « noyaux » pour transformer les données d'entrée dans un espace de caractéristiques de dimension plus élevée où l'hyperplan séparateur peut être plus facilement trouvé. Les fonctions de noyau les plus couramment utilisées sont les suivantes :

- Noyau Linéaire : ce noyau effectue une séparation linéaire des données dans l'espace de caractéristiques.
- Noyau Polynomiale : ce noyau permet une séparation non linéaire des données en utilisant des polynômes de degré supérieur.

- Noyau Gaussien ou Radial Basis Function (RBF) : ce noyau est largement utilisé pour sa capacité à gérer des données non linéaires. Il utilise une fonction gaussienne pour projeter les données dans l'espace des caractéristiques.
- Noyau Sigmoidale : ce noyau permet également une séparation non linéaire des données.

Un des principaux avantages des SVM est sa capacité à gérer efficacement les données à grande dimension avec une faible complexité de calcul. Il est également robuste aux données bruyantes et peut gérer des cas où les données sont sous-échantillonnées. Il a tendance à avoir un risque de surapprentissage plus faible que certains autres modèles de Machine Learning, en particulier lorsqu'un petit nombre d'échantillons d'entraînement est disponible. Cependant, il peut être sensible aux choix des paramètres et peut avoir des difficultés à gérer des données non linéairement séparables notamment avec un mauvais choix de noyau. Il peut également être mis en difficulté face à des ensembles de données trop volumineux [154].

### **3.1.2. Réseaux de neurones artificiels**

Les réseaux de neurones artificiels ou artificial neural network (ANN) représentent un type d'algorithme d'apprentissage automatique inspiré par le fonctionnement du cerveau humain. Ils peuvent traiter des données de manière non linéaire, ce qui les rend particulièrement efficaces pour les tâches de classification multi-classes. Ils sont constitués de couches de neurones connectés les uns aux autres, chacun ayant des poids qui sont mis à jour lors de l'entraînement pour améliorer la précision de la sortie. Ils ont récemment connu un regain d'intérêt avec le développement de l'apprentissage profond (Deep Learning), qui a permis des avancées significatives dans des domaines tels que la reconnaissance d'images, la reconnaissance de la parole, et la traduction automatique. Ils sont également utilisés pour résoudre des problèmes de reconnaissance de formes, de classification et de prédiction.

Il existe plusieurs types d'ANN selon leur principe de fonctionnement.

- Les réseaux de neurones à propagation avant : également appelés feedforward, ils ont des couches de neurones connectées de manière unidirectionnelle sans boucles de rétroaction entre les couches, c'est-à-dire, les neurones d'une couche sont connectés à tous les neurones de la couche suivante, mais pas à ceux de la couche précédente.
- Les réseaux de neurones récurrents : ils peuvent traiter des données séquentielles avec des connexions rétropropagées qui permettent aux informations de circuler dans les couches

plusieurs fois, leur conférant une notion de mémoire, ce qui est particulièrement utile pour la compréhension et la prédiction de données telles que du texte, des signaux audios ou des séries temporelles.

- Les réseaux de neurones à convolution : ils sont utilisés pour la reconnaissance d'images et les traitements des signaux.

### **3.2.Apprentissage profond (Deep learning)**

Le machine learning et le deep learning représentent deux approches distinctes dans le domaine de l'intelligence artificielle. Alors que l'apprentissage automatique englobe une variété de techniques, incluant les machines à vecteurs de support et les arbres de décision, le deep learning se distingue par l'utilisation de réseaux de neurones profonds. La principale différence réside dans l'architecture des modèles : Dans le cas du deep learning, les réseaux de neurones classiques sont remplacés par des réseaux de neurones profonds qui se distinguent par leur capacité à résoudre des tâches complexes et à apprendre des niveaux d'abstraction plus élevés des données, contrairement aux réseaux de neurones classiques qui ne peuvent apprendre qu'une représentation de bas niveau des données. Cela signifie que le Deep Learning peut apprendre des caractéristiques de plus en plus complexes à partir des données brutes, ce qui lui permet de résoudre des tâches plus complexes avec une plus grande précision et une meilleure généralisation.

#### **3.2.1. Les réseaux de neurones profonds (DNN)**

Les réseaux de neurones profonds (DNN, pour deep neural networks) sont des architectures de réseaux de neurones qui comportent un nombre de couches cachées supérieur à celui des réseaux classiques. Ces couches supplémentaires permettent aux DNNs d'apprendre des représentations plus abstraites et plus riches des données d'entrée, ce qui les rend plus efficaces pour la résolution de tâches telles que la reconnaissance d'images, la reconnaissance de la parole et la traduction automatique.

Ainsi, les DNNs permettent de créer des modèles très performants et ont également la capacité d'apprendre à partir de données non structurées, comme des signaux EEG dans les ICMs, des images ou des vidéos, et de les utiliser pour effectuer des tâches telles que la conduite autonome. Pour ce faire, ils sont généralement entraînés à l'aide de grandes quantités de données, avec des techniques d'optimisation telle que la descente de gradient stochastique. Ces techniques permettent aux DNNs d'apprendre les poids des connexions entre les neurones de manière à

minimiser une fonction de coût, qui mesure la différence entre les sorties prévues et les sorties réelles pour un ensemble de données d'entraînement. De plus, les DNNs ont permis d'obtenir des résultats très performants dans de nombreuses tâches d'apprentissage automatique, et ont également été utilisés avec succès dans des domaines tels que la reconnaissance de la parole, la synthèse de la parole et la génération de texte.

Il existe plusieurs architectures de DNNs, les plus utilisées dans le domaine des ICMs étant les réseaux de neurones à convolution (CNN) et les réseaux de neurones récurrents (RNN) [151,155].

### **3.2.2. Les réseaux de neurones à convolution (CNN)**

Les CNNs sont conçus pour traiter des données à deux dimensions comme des images. Dans le domaine des ICMs, ils ont été utilisés pour traiter les signaux électriques produits par le cerveau pour détecter des motifs spécifiques dans les EEG qui sont associés à des commandes de mouvement ou à des états mentaux. Il y a quelques années, des études ont montré que les CNNs ont une performance élevée pour la classification des commandes de mouvement dans les signaux EEG [156]. Ils ont également été utilisés pour la reconnaissance des mouvements oculaires, pour la détection d'événements cérébraux spécifiques et pour la classification de l'état mental d'un individu [157].

Les CNNs se composent de plusieurs couches de neurones, chacune ayant des fonctions spécifiques. La première couche, appelée couche d'entrée, prend en entrée l'image ou la matrice de données de l'ICM à traiter. Les couches suivantes sont appelées couches de convolution et sont utilisées pour extraire des caractéristiques de l'image et se composent généralement de plusieurs filtres qui sont utilisés pour détecter des motifs spécifiques dans l'image, tels que des bords, des textures ou des formes. Ces couches sont généralement suivies d'une couche de mise en commun, appelée couche de pooling, qui est utilisée pour réduire la dimension de l'image tout en conservant les caractéristiques importantes. Cela permet de réduire le nombre de neurones nécessaires pour traiter l'image, ce qui accélère le processus de reconnaissance.

La dernière couche de neurones, appelée couche de sortie, est utilisée pour classer l'image en fonction des caractéristiques extraites par les couches cachées. Les neurones de cette couche sont connectés aux neurones de la couche cachée précédente après avoir subi une transformation de vectorisation appelée « Flattening » et peuvent utiliser les caractéristiques détectées pour effectuer une classification. La figure 16 illustre les différentes couches du CNN abordées.

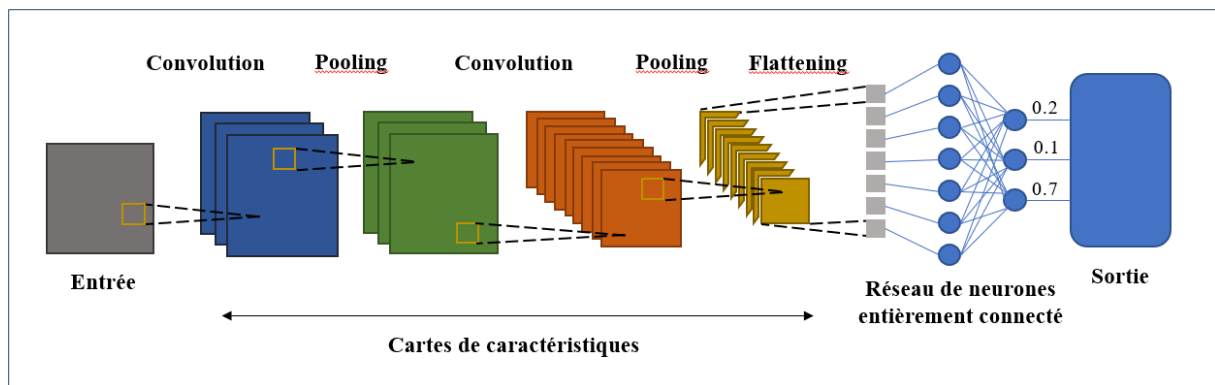


Figure 16 : Représentation d'un réseau de neurones convolutif [158].

### 3.2.3. Les réseaux de neurones récurrents (RNN)

Les réseaux de neurones récurrents, également appelés réseaux dynamiques ou à rétroaction, se distinguent des réseaux de neurones classiques, dits acycliques (à propagation avant) par l'existence de connexions en boucle comme illustré sur la figure 17. Cette caractéristique leur confère la capacité de modéliser des systèmes dotés d'une mémoire interne, ainsi que des systèmes sujets à des variations temporelles. Grâce à leur mémoire adaptable, ces réseaux sont capables de mettre en œuvre directement des systèmes dynamiques.

Lorsque l'on représente ces réseaux récurrents sous forme de graphes, on observe la présence de cycles, ce qui introduit une dimension temporelle dans leur comportement [159,160].

Les réseaux de neurones récurrents (RNN), en vertu de leur aptitude à traiter des séquences de données exploitant les boucles de leur architecture, se révèlent aptes à la manipulation d'entrées telles que la parole ou le texte ce qui s'avère crucial pour la compréhension des séquences temporelles.

Au final, il est important de noter que le Deep Learning est un domaine en constante évolution, et de nouvelles architectures et techniques d'optimisation sont constamment développées. Les recherches récentes dans ce domaine incluent notamment l'apprentissage en profondeur à partir de données de petite taille, l'apprentissage en profondeur avec des données non étiquetées et l'apprentissage en profondeur distribué.

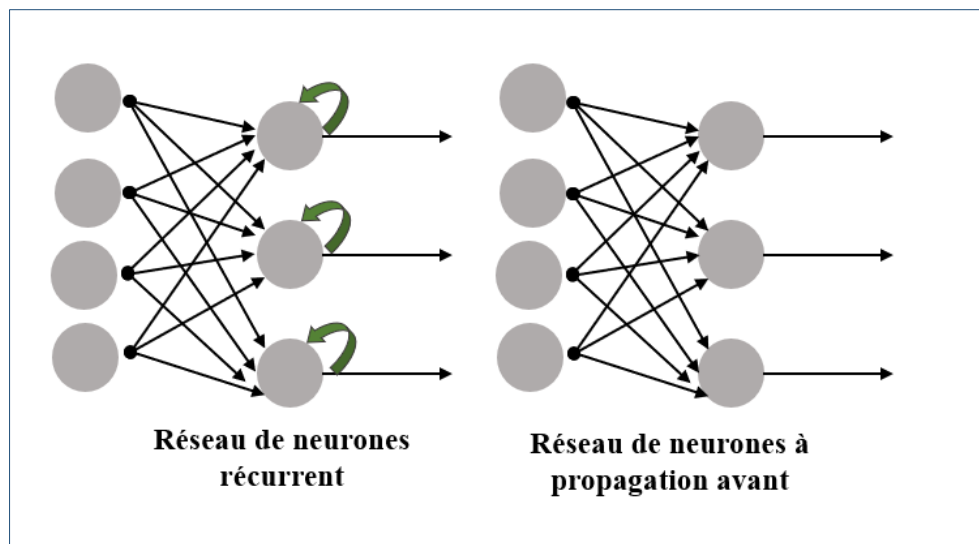


Figure 17 : Différence entre un réseau de neurones récurrent et un réseau de neurones à propagation avant [159,160].

### 3.3.La validation croisée (Cross validation)

La validation croisée k-fold est une méthode d'évaluation de la performance d'un modèle d'apprentissage automatique en utilisant une série d'itérations de séparation des données en groupes d'entraînement et de test. Le nombre de groupes, ou "k", est généralement défini par l'utilisateur. Elle consiste à diviser les données d'apprentissage en k sous-ensembles de tailles égales. Ensuite, on utilise k-1 sous-ensembles pour entraîner le modèle et le sous-ensemble restant pour tester le modèle. Cette procédure est répétée k fois et chaque sous-ensemble est utilisé une fois pour la validation. Les résultats sont ensuite moyennés pour donner une estimation plus fiable de la performance du modèle.

Au début de chaque itération, les données sont aléatoirement réparties en k groupes égaux. Le modèle est alors entraîné sur k-1 groupes et testé sur le groupe restant. Cette procédure est répétée k fois, en utilisant un groupe différent comme groupe de test à chaque fois. La performance du modèle est ensuite évaluée en utilisant les résultats de ces k itérations. La figure 18 illustre ce principe.




Figure 18 : Représentation de la 10 cross fold validation [161].

Ainsi, la validation croisée k-fold est utile pour obtenir une estimation plus précise de la performance générale d'un modèle, car elle permet de prendre en compte l'ensemble des données disponibles pour l'entraînement et le test. Elle est également utile pour éviter les biais de sélection de données qui peuvent survenir lorsque celles-ci sont séparées de manière aléatoire.

Enfin, il est important de noter que cette méthode nécessite suffisamment de données pour que chaque groupe de test ait une taille significative. Si les données sont limitées, une validation croisée à deux groupes (two-fold cross-validation) peut être utilisée à la place.

#### 4. Conclusion

Nous avons abordé, dans ce chapitre, deux catégories de méthodes de classification basées sur les techniques d'intelligence artificielle d'une part, et la géométrie Riemannienne d'autre part. Les réseaux de neurones jouissent également d'une notoriété grandissante et ont émergé comme des instruments essentiels dans le domaine de l'intelligence artificielle. Les réseaux de neurones feedforward, récurrents et convolutifs sont des exemples de réseaux qui ont été largement utilisés dans diverses applications, allant de la reconnaissance de la parole à la détection d'objets dans les images et bien sûr la reconnaissance des signaux d'ICM. Chacun de ces réseaux possède ses propres avantages et inconvénients selon la nature du problème à résoudre. Les réseaux de neurones profonds ont permis de régler des problématiques qui semblaient insurmontables auparavant, telles que la reconnaissance faciale et la traduction automatique.

Cependant, la conception et la formation de ces réseaux sont des tâches complexes qui nécessitent une expertise en mathématique et en informatique.

La géométrie Riemannienne offre une alternative aux méthodes classiques de classification en utilisant les propriétés géométriques des signaux d'ICM et en respectant la nature des données appartenant à la variété riemannienne, permettant, de ce fait une optimisation des performances des algorithmes. Nous pouvons, ainsi, mieux caractériser la structure complexe des signaux d'ICM et améliorer l'exactitude de la classification des signaux d'électroencéphalographie afin de mieux distinguer les différentes activités cérébrales telles que les mouvements volontaires ou les activités cognitives. Cette approche connaît une utilisation croissante significative depuis quelques années, et plusieurs méthodes de classification l'ont exploitée dans le domaine de l'intelligence artificielle, tant en Machine Learning à ses débuts, qu'en Deep Learning plus récemment.

La géométrie Riemannienne a été utilisée avec succès dans des applications de contrôle de mouvement, de reconnaissance faciale et de commande de dispositifs électroniques. Son utilisation dans les interfaces cerveau-machine représente un domaine de recherche en pleine croissance, bien qu'elle ne soit pas encore utilisée de façon systématique, et nécessite des développements pour optimiser les méthodes de calcul de la courbure et de la distance, ainsi que pour adapter cette approche aux signaux cérébraux individuels. Les perspectives pour l'application de la géométrie Riemannienne dans les ICMs restent prometteuses et suscitent un grand intérêt dans la communauté scientifique. Les résultats obtenus avec ces méthodes sont comparés à ceux issus des autres méthodes classiques qui sont plutôt compétitifs.

---

# **CHAPITRE III**

Approches de classification existantes

---

## **1. Introduction**

Après avoir développé une connaissance approfondie des outils fondamentaux requis pour établir une méthode de classification robuste des signaux d'imagerie motrice, nous allons compléter notre thèse en examinant les différentes approches existantes dans la littérature scientifique qui visent à atteindre le même objectif que celui de notre travail de recherche. En effet, les méthodes de classification étant des outils indispensables dans les interfaces cerveau-machine, elles sont utilisées pour analyser, déduire et attribuer la classe la plus appropriée aux données d'entrées en fonction des caractéristiques extraites à partir des signaux électrophysiologiques du cerveau, représentatives de l'activité neuronale associée à des tâches spécifiques telles que la pensée, l'imagerie motrice ou l'identification de cible. Ces techniques de classification étant souvent basées sur l'apprentissage automatique, elles peuvent être appliquées à divers types de signaux, tels que l'EEG, l'EMG et l'IRMf et sont essentielles pour les interfaces cerveau-machine car elles permettent de traduire les signaux électrophysiologiques du cerveau en commandes pour contrôler des dispositifs tels que des prothèses, des robots ou un personnage de jeu vidéo. De plus, au sein même des ICMs s'appuyant sur l'imagerie motrice, un grand nombre d'études ont été entreprises pour améliorer la reconnaissance des différentes classes de mouvements. Cette tâche complexe a suscité l'intérêt de la communauté scientifique qui a mené de nombreuses recherches dans le but d'optimiser l'exactitude des algorithmes de classification.

Dans ce chapitre, nous allons donc faire état des méthodes aussi bien Riemanniennes que non Riemanniennes utilisées dans le cadre des ICMs à base d'EEG non invasif qui serviront de comparatif par rapport aux méthodes que nous avons développées dans le cadre de notre travail de recherche en termes d'exactitude et de pertinence. Les valeurs d'exactitude présentées dans les différents tableaux sont extraites des sources originales de chaque méthode, telles qu'elles sont rapportées dans les articles respectifs.

## **2. La base de données**

### **2.1. Description de la base de données**

Dans le cadre de notre travail de recherche, et des méthodes qui seront présentées dans ce chapitre, la base de données publique de la compétition BCI IV ensemble IIa [174] a été exploitée. Ce choix est justifié par plusieurs raisons : d'abord, elle est largement reconnue et a été fréquemment utilisée dans le domaine des interfaces cerveau-machine. Ensuite, en plus de

contenir des signaux d'imagerie motrice, cette base de données est celle sur laquelle repose la méthode ARK-SVM, approche qui sera présentée à la fin de ce chapitre, et sur laquelle cette thèse de doctorat s'est initialement basée.

La base de données BCI IV ensemble IIa est disponible sur <https://www.bbci.de/competition/iv/>. Elle a été instaurée lors de l'organisation d'une compétition axée sur la classification de signaux d'imagerie motrice. Elle est constituée d'enregistrements de quatre tâches d'imagerie motrice différentes, issues de l'imagination de quatre mouvements différents qui constitueront les classes cibles. Au total, la base est composée de 72 essais pour chacune des classes suivantes : main droite (MD), main gauche (MG), langue (LA) et les deux pieds (DP), enregistrées sur 9 sujets lors de deux sessions. 144 essais par classe ont été enregistrés sur ces deux sessions, pour un total de 576 essais pour toutes les classes incluses. Pour ce faire, 22 électrodes ont été utilisées avec le système international 10-20 sur des sujets assis face à un écran sur lequel une croix était affichée et un signal auditif était émis au démarrage de l'essai. Après deux secondes, un indice sous la forme d'une flèche était affiché pendant 1,25 secondes pour indiquer la tâche à effectuer. Les sujets devaient continuer l'exécution de la tâche mentale jusqu'à la disparition de la croix de fixation, c'est-à-dire 6 secondes après le début de l'essai et aucune rétroaction (feedback) n'a été fournie.

Les signaux électroencéphalographiques ont été recueillis durant toute la durée des épreuves de façon monopolaire, avec une référence à la mastoïde gauche et une mise à la terre sur la mastoïde droite. Enfin, un filtre de 50 Hz a été appliqué pour éliminer l'artefact du secteur et les signaux ont été échantillonnés à 250 Hz.

### **3. Les méthodes de classification non Riemanniennes**

#### **3.1 Approche EEG-TCNET**

La méthode EEG-TCNET résulte d'une collaboration inter-universitaire dirigée par Thorir Mar Ingolfsson et impliquant deux pays : la Suisse et le Japon [162]. Cette approche fait appel à un nouveau réseau de convolution temporelle (TCN) combiné avec l'EEGNet qui en plus de parvenir à atteindre de bons niveaux d'exactitude tout en nécessitant peu de paramètres entraînaux, présente une empreinte mémoire et une complexité de calcul réduite.

Les résultats obtenus sont illustrés dans le tableau 2.

Dans cette méthode, les auteurs de l'article exploitent les points forts d'EEGNet et les combinent avec des réseaux de neurones convolutifs temporels appelés « TCN » pour créer EEG-TCNet.

EEGNet est une architecture d'apprentissage profond spécifiquement conçue et adaptée pour l'analyse des données d'électroencéphalographie, en capturant les caractéristiques uniques de ces signaux. Elle sert de base au composant CNN du modèle, qui est responsable de l'extraction de caractéristiques des signaux EEG, dont la sortie est un ensemble de cartes de caractéristiques qui capturent les propriétés spectrales pertinentes des signaux EEG. Le composant TCN, quant à lui, est responsable de la modélisation des dépendances temporelles dans les signaux EEG.

Tableau 2 : Exactitudes de classification (%) obtenues respectivement par les méthodes EGGNet, EEG-TCN<sub>ET</sub>, DFFN.

Sujets	EGGNet	EEG-TCN <sub>ET</sub>	DFFN	EEG-TCN <sub>ET</sub> Sujet-spécifique
<b>S01</b>	86.48	85.77	83.46	89.32
<b>S02</b>	61.84	65.02	69.30	72.44
<b>S03</b>	93.41	94.51	90.29	97.44
<b>S04</b>	73.25	64.91	71.07	75.87
<b>S05</b>	76.81	75.36	65.41	83.69
<b>S06</b>	59.07	61.40	69.45	70.69
<b>S07</b>	90.25	87.36	88.18	93.14
<b>S08</b>	87.45	83.76	86.76	86.71
<b>S09</b>	82.95	78.03	93.54	85.23
<b>Moyenne</b>	79.06	77.35	79.71	<b>83.84</b>

Enfin, la sortie du TCN est introduite dans une couche entièrement connectée pour la classification. La couche entièrement connectée mappe les caractéristiques apprises par le CNN et le TCN aux différentes tâches d'imagerie motrice. Le modèle est entraîné à l'aide d'une fonction de perte d'entropie croisée et optimisé à l'aide de l'optimiseur Adam.

L'analyse de ces résultats montre une optimisation des performances d'EEG-TCN<sub>ET</sub> pour chaque sujet atteignent une exactitude de classification de 83,84 %, soit une augmentation de 6,49 % par rapport à la méthode standard. Ce boost est obtenu en recherchant les hyperparamètres optimaux spécifiques à chaque sujet (par exemple, la taille du noyau, le nombre de filtres ou l'utilisation de la standardisation des données) ainsi que les hyperparamètres d'entraînement d'EEG-TCNET (par exemple, le taux de désactivation) en

utilisant une recherche en grille (grid search) en validation croisée sur l'ensemble d'entraînement pour chaque sujet. De plus, cette méthode surpasse les méthodes EEGNet et DFFN respectivement de 4,78 % et 4,13 % et surpasse également la plupart des réseaux de pointe actuels [162].

### 3.2 Approche Wavelet T-F Image CNN

Cette approche axée sur l'apprentissage profond à base de réseau de neurones convolutif a été élaborée par BAOGUO XU et al. [163] et est le fruit d'une collaboration de plusieurs universités chinoises. Cette méthode utilise comme entrée la résultante de la transformée en ondelettes qui combine les caractéristiques temps-fréquence du signal d'imagerie motrice avec l'information spatiale des électrodes C3, C4, Cz. Ensuite, un réseau neuronal convolutif à deux couches est construit comme classificateur et les noyaux de convolution de différentes tailles sont validés.

Enfin, le modèle final est entraîné sur un petit jeu de données de deux couches convolutives et de noyaux 2D et 1D afin d'éviter le surapprentissage et les résultats sont illustrés dans le tableau 3.

Tableau 3 : Performances d'exactitude du modèle 2D et 1D.

Sujets	Noyau 2D	Noyau 1D
	Meilleure exactitude (%)	Meilleure exactitude (%)
S01	85,71	82,14
S02	78,57	75,05
S03	92,15	90,10
S04	95,67	94,61
S05	89,20	92,30
S06	85,12	86,75
S07	79,23	76,60
S08	81,28	80,50
S09	80,67	79,55
<b>Moyenne</b>	<b>85,59</b>	<b>84,18</b>

Ces résultats montrent que la méthode utilisant un réseau neuronal convolutif à deux dimensions est plus performante que celle utilisant une seule dimension.

De plus, les auteurs font mention d'une différence de qualité du signal d'imagerie motrice émis par chacun des participants, conduisant à une grande différence dans l'exactitude de la prédiction du modèle.

### 3.3 Approche Sliding Window Common Spatial Pattern (SW-CSP)

Dans une étude menée par des chercheurs de l'université d'Ulster, deux méthodes basées sur des fenêtres coulissantes CSP ont été développées [164]. La première technique appelée SW-LCR (Sliding Window Longest Consecutive Repetition) calcule la plus longue répétition consécutive (LCR) de la séquence de prédictions de toutes les fenêtres coulissantes afin de lui en attribuer la classe. En revanche, dans la seconde technique appelée SW-Mode, le décompte du nombre d'occurrences de la classe 1 et de la classe 2 est effectué. La classe présentant le nombre de répétitions le plus élevé est attribuée à cet essai spécifique. Ainsi, le modèle spatial commun (CSP) est utilisé pour extraire les caractéristiques de chaque fenêtre glissante, suivi d'une analyse discriminante linéaire (LDA) utilisée pour la classification de chaque fenêtre temporelle. Enfin, on utilise l'une des méthodes proposées par les auteurs pour améliorer la prédiction finale. Ces méthodes ont été appliquées sur deux jeux de données différents, le premier étant le même que nous avons utilisé, c'est-à-dire BCI Competition IV set IIa, sur lequel nous allons uniquement nous intéresser. Enfin, les résultats des prédictions sur les classes main gauche (MG), main droite (MD), deux pieds (DP) et langue (LA) sont détaillés sur les tableaux 4 et 5.

Tableau 4 : Exactitude (%) de la méthode SW-LCR.

Sujets	MG/MD	MG/DP	MG/LA	MD/DP	MD/LA	DP/LA	Moyenne
S01	86,81	97,22	97,22	97,22	100	69,44	91,32
S02	64,58	63,89	65,97	80,56	66,67	73,61	69,21
S03	95,83	93,06	94,44	93,06	94,44	69,44	90,05
S04	67,36	82,64	88,19	89,58	86,81	62,5	79,51
S05	68,06	65,97	74,31	70,83	65,97	68,06	68,87
S06	67,36	70,83	72,22	64,58	71,53	70,14	69,44
S07	80,56	97,92	93,75	93,75	93,75	79,86	89,93
S08	97,22	84,72	92,36	88,19	89,58	78,47	88,43
S09	92,36	96,53	97,22	84,03	82,64	85,42	89,70
<b>Moyenne</b>	80,02	83,64	86,19	84,64	83,49	72,99	<b>81,83</b>

Tableau 5 : Exactitude (%) de la méthode SW-Mode.

Sujets	MG/MD	MG/DP	MG/LA	MD/DP	MD/LA	DP/LA	Moyenne
<b>S01</b>	86.11	96.53	96.53	97.22	100	70.83	91.20
<b>S02</b>	64.58	64.58	65.97	80.56	66.67	75	69.56
<b>S03</b>	95.83	93.06	94.44	93.06	95.14	70.14	90.28
<b>S04</b>	64.58	84.72	88.89	90.28	89.58	63.19	80.21
<b>S05</b>	68.06	65.28	75	72.22	66.67	67.36	69.10
<b>S06</b>	68.75	70.14	70.83	64.58	71.53	70.14	69.33
<b>S07</b>	81.94	97.92	93.06	93.75	93.75	79.86	90.05
<b>S08</b>	97.22	84.03	92.36	88.89	90.28	78.47	88.54
<b>S09</b>	90.97	97.22	97.22	84.72	82.64	85.42	89.70
<b>Moyenne</b>	79.78	83.72	86.03	85.03	84.03	73.38	<b>82</b>

L'analyse de ces résultats permet de constater que pour les tâches d'IM MG/MD et MG/LA, la SW-LCR a fourni une exactitude de classification moyenne meilleure de 80,02 % et 86,19 % respectivement par rapport à SW-Mode. D'autre part, SW-Mode a mieux performé de 83,72 %, 85,03 %, 84,03 % et 73,38 % sur les autres tâches par rapport à SW-LCR. De plus, lorsque nous examinons l'exactitude moyenne des deux méthodes, nous notons une performance relativement équivalente avec des résultats de 81,83 % et 82 % pour les méthodes SW-LCP et SW-Mode respectivement.

### 3.4 Approche Sinc-EEGNet

L'architecture de réseau de neurones convolutifs (CNN) en quatre couches appelée Sinc-EEGNet a été élaborée par Alessandro Bria et al. [165]. Celle-ci combine de manière novatrice les avantages de deux approches distinctes : la décomposition des bandes de fréquence de l'électroencéphalogramme issue de méthodes traditionnelles similaires au FBCSP (Filter Bank Common Spatial Patterns) et l'apprentissage automatique ainsi que l'extraction de caractéristiques à partir de modèles légers de CNN comme EEGNet. Plus précisément, la première couche de ce réseau est une convolution sur le signal EEG en entrée. Les filtres sinc sont des filtres passe-bande paramétrés qui sont explicitement conçus pour apprendre la décomposition optimale des bandes de fréquence pour la tâche de classification IM. La seconde couche de convolution est de type profond similairement à EEGNet. Elle est responsable de l'apprentissage des filtres spatiaux et de la combinaison des caractéristiques extraites des

différentes bandes de fréquence préalablement sélectionnées. Autrement dit, elle est utilisée pour apprendre des filtres spatiaux pour chaque carte de caractéristique en entrée. Cette étape, combinée à la première couche de décomposition optimale de bande, peut être considérée comme une version "apprenante" de l'approche bien connue FBCSP. Puis les sorties sont fusionnées à l'aide de convolutions "pointwise". Cela permet une combinaison optimale de l'information au sein de, et entre les cartes de caractéristiques (feature maps). La dernière couche est une couche entièrement connectée qui reçoit les caractéristiques aplaties de la couche précédente, ces caractéristiques sont ensuite utilisées pour la classification finale du modèle.

Ainsi, cette approche fusionne de manière ingénieuse la robustesse de l'analyse en bande de fréquence classique avec la capacité d'apprentissage automatique d'un réseau de neurones convolutif, offrant ainsi un potentiel significatif pour améliorer la classification des signaux EEG dans le contexte de l'imagerie motrice. Les performances de cette méthode sont illustrées dans le tableau 6.

Tableau 6 : Comparatif de la méthode Sinc-EEG aux méthodes de références de l'étude.

Méthode	Exactitude
<b>FBCSP</b>	68,0%
<b>Deep ConvNet</b>	70,9%
<b>Shallow ConvNet</b>	73,7%
<b>Sinc-EEGNet</b>	75,4%

L'analyse de ces résultats montre que Sinc-EEGNet se distingue par une performance supérieure à toutes les autres méthodes répertoriées avec une exactitude de 75,4 %, ce qui représente une amélioration significative de 7,4 % par rapport à FBCSP. En ce qui concerne les expériences menées à la fois au sein d'un même sujet et entre sujets, EEGNet a produit des taux moyens d'exactitude de 60,99 % et 58,75 % respectivement, tandis que Sinc-EEGNet a obtenu des résultats de 70,56 % et 58,98 % respectivement. Il est à noter que cette méthode a également affiché des performances supérieures, enregistrant une amélioration notable de près de 10 % d'exactitude dans le cadre de la classification intra-sujets.

### **3.5 Approche MSAENet**

Née de la collaboration de deux universités de Taiwan, cette approche développée par Yanqing Dong et al. [166] et ayant utilisé la méthode de validation croisée en laissant un sujet de côté (leave-one-out cross-validation), est un nouveau réseau neuronal intégrant un auto-encodeur (AE) avec des modèles d'apprentissage profond à multi-échelle pour apprendre les caractéristiques des signaux EEG sous plusieurs aspects. Celui-ci se compose de trois modules : la branche multi-échelle, la fusion des fonctions de perte (LFF) et la branche auto-encodeur (AE). Cette dernière se divise principalement en deux éléments : l'encodeur et le décodeur.

L'encodeur prend des données de grande dimension et les transforme en un vecteur latent unidimensionnel  $z$ , en utilisant des techniques telles que la convolution et le pooling. Cette transformation permet de préserver les caractéristiques robustes du signal EEG-MI tout en réduisant la dimension des données, ce qui équivaut à une réduction de la dimensionnalité.

Le décodeur quant à lui, a une structure symétrique à celle de l'encodeur. En premier lieu, il amplifie le vecteur latent  $z$  pour qu'il atteigne la taille appropriée à l'aide d'une couche dense. Ensuite, il décode ce vecteur unidimensionnel en une reconstruction de la même dimension que les données d'entrée en utilisant deux couches de convolution transposée. En effet, la convolution transposée est efficace pour extraire des caractéristiques pertinentes des données, supprimer les caractéristiques inutiles et faciliter la reconstruction des vecteurs latents.

Suite à cela, la branche multi-échelle emploie différentes sous-branches pour extraire des caractéristiques spatiales-spectrales à diverses granularités. Elle utilise trois noyaux de convolution distincts, de tailles  $3 \times 3$ ,  $5 \times 5$  et  $7 \times 7$ , afin d'extraire des caractéristiques locales à partir des données spatiales-spectrales. Ces noyaux de granularités différentes sont exploités pour capturer des caractéristiques locales variées, garantissant ainsi l'extraction de caractéristiques plus riches et plus représentatives. S'ensuit alors une opération de convolution réalisée à l'aide d'un noyau de dimension  $3 \times 3$ . À mesure que le réseau s'approfondit, les caractéristiques locales extraites deviennent de plus en plus riches, ce qui permet d'obtenir un champ réceptif plus étendu pour l'EEG.

Les résultats comparatifs avec d'autres méthodes sont illustrés dans le tableau 7.

Tableau 7 : Performances des méthodes de classification dans le cadre inter-sujets.

Méthode	Exactitude
EEGNet	64,26
Deep ConvNet	56,34
MIN2Net	60,03
SSCNN	66,05
MSAENet	<b>69,98</b>

Le MSAENet présente les meilleures performances par rapport aux quatre autres méthodes, la différence maximale en termes d'exactitude est d'environ 13 % avec le DeepConvNet qui est la méthode la moins performante. La méthode SSCNN bien que moins performante que MSAENet présente tout de même d'assez bons résultats.

### 3.6 Approche CS-GAN

Développée par l'équipe de recherche dirigée par Yonghao Song de l'Université de Chine [167], cette méthodologie repose sur un réseau antagoniste génératif (GAN) baptisé "Common Spatial Generative Adversarial Networks (CS-GAN)" et a pour objectif d'amplifier le volume de données EEG. Non seulement les signaux EEG sont générés avec une représentation temporelle de qualité, mais leurs caractéristiques spatiales sont préservées de manière satisfaisante, tout en renforçant la distinction entre les différentes catégories. Pour ce faire, le générateur est utilisé pour produire des données fictives similaires aux données réelles à partir de séries aléatoires en estimant la distribution des données d'origine, tandis que le discriminateur a pour fonction de déterminer si les données générées sont réelles ou fictives. Après plusieurs cycles d'entraînement antagoniste, les deux modules atteignent progressivement un équilibre, où le générateur est capable de créer des données extrêmement réalistes que le discriminateur ne peut distinguer. Ainsi, cette approche se traduit par une amélioration significative des performances de classification EEG ce qui, en fin de compte, contribue à réduire la durée nécessaire pour l'étalonnage des systèmes d'interface cerveau-machine. De plus, une architecture de réseau de convolution est employée en tant que référence pour la classification des intentions motrices à partir de signaux EEG projetés dans un nouvel espace, où la distinction spatiale est accentuée

et où les informations temporelles sont préservées. Enfin, cette méthode a été testée dans différentes situations d'augmentation de données et se caractérise par l'obtention de performances remarquables qui sont présentées dans le tableau 8 pour la classification intra-sujets.

Tableau 8 : Exactitude des classifications (%) dans le contexte intra-sujets.

	S01	S02	S03	S04	S05	S06	S07	S08	S09	PRECISION
<b>Multi-Branch 3D</b>	77,40	60,14	82,93	72,29	75,84	68,99	76,04	76,85	84,66	75,02
<b>TSSM+LDA</b>	81,80	62,50	88,80	63,70	62,90	58,50	86,60	85,10	90,00	75,50
<b>Envelop+CNN</b>	85,23	69,73	90,15	65,57	77,42	52,41	93,68	90,04	84,75	78,78
<b>Functional Brain Network</b>	82,80	65,50	87,90	77,60	72,40	<b>70,70</b>	82,80	87,90	89,70	79,70
<b>Discriminative Feature Learning</b>	<b>91,31</b>	71,62	<b>92,32</b>	78,38	<b>80,10</b>	61,62	92,63	<b>90,30</b>	78,38	81,85
<b>CS-Gan</b>	90,00	<b>75,00</b>	90,00	<b>85,00</b>	58,33	63,33	<b>95,00</b>	90,00	<b>100,00</b>	<b>82,96</b>

Dans le cadre de cette analyse intra-sujets, il est observé que la méthodologie présentée dans la référence [167] affiche la meilleure performance, bien qu'elle soit étroitement suivie par l'approche du "Discriminative Feature Learning".

### 3.7 Approche S-T Pattern

Cette approche statistique a été publiée par l'institut de recherche en info-communication de Singapour [168]. Elle se base sur l'information mutuelle entre les schémas spatiotemporels des signaux EEG et les activités neuronales correspondantes et vient ainsi combler les limites de la méthode FBCSP comme la sélection manuelle du segment temporel spécifique au sujet. Ainsi, cette méthode vise à optimiser la sélection des schémas spatiotemporels dans les signaux EEG en utilisant des méthodes statistiques avancées. Pour ce faire, la méthodologie proposée se compose de quatre étapes évolutives : d'abord, une filtration temporelle multicouche combinée à une bande de fréquence temporelle est réalisée. Ensuite, un filtrage spatial CSP est appliqué avant de passer à la troisième étape qui consiste en la sélection des caractéristiques en se basant sur l'information mutuelle. Enfin, une classification est mise en œuvre.

Les résultats obtenus sont illustrés dans le tableau 9 ci-dessous en fonction du paramètre  $k$  de l'algorithme de validation croisée qui représente le nombre des meilleures caractéristiques individuelles à sélectionner.

Tableau 9 : Résultats expérimentaux dans un cadre de validation croisée à 10x10-fold cross validation.

Sujets	$k = 1$	$k = 2$	$k = 3$	$k = 4$
S01	71,91	78,09	80,52	82,95
S02	56,49	60,42	62,33	62,85
S03	80,42	82,85	83,51	82,64
S04	56,88	58,16	59,24	60,42
S05	66,98	66,84	68,33	68,58
S06	46,70	46,77	47,78	48,40
S07	82,60	88,47	91,22	90,73
S08	82,12	83,09	84,69	86,22
S09	58,51	61,46	63,75	62,78
Moyenne	66,96	69,57	71,26	71,73

En observant l'exactitude moyenne, on constate une amélioration significative de l'exactitude de classification à mesure que la valeur de  $k$  augmente. Cela indique que l'inclusion de plus de caractéristiques améliore la performance globale du modèle de classification. On notera également que les performances varient d'un sujet à l'autre. Par exemple, le sujet 07 obtient une exactitude particulièrement élevée, tandis que le sujet 06 montre des performances inférieures.

## 4. Les méthodes de classification Riemanniennes

### 4.1 Approche MDM/FGDA

Cette approche correspond à la première méthode présentée par le chercheur Alexandre B. appelée Minimum Distance to Riemannian Mean (MDM ou MDRM) [7]. En fait, il s'agit d'un algorithme de classification utilisant la distance et la moyenne Riemannienne. En effet, lors de la phase d'entraînement, le barycentre de chaque classe est calculé par moyenne géométrique. Pour classer un essai, la distance entre chaque barycentre de chaque classe est calculée pour ensuite affecter la donnée à classer à la classe présentant la distance la plus courte. Bien que

cette méthode présente des similitudes avec les k plus proches voisins, la MDRM est plus légère en termes de calcul et d'occupation mémoire [7].

Ensuite, l'auteur propose une amélioration de cette méthode avec des opérations de filtrage des matrices SDP en utilisant l'analyse discriminante de Fisher (FGDA). Ceci consiste à projeter les données sur l'espace tangent à la variété Riemannienne, puis à appliquer l'analyse discriminante de Fisher pour trouver les vecteurs discriminants optimaux et ensuite à effectuer une opération de filtrage sur les données de test en utilisant les vecteurs discriminants trouvés précédemment. Enfin, les données sont renvoyées sur l'espace d'origine pour y appliquer l'algorithme de classification utilisant les distances Riemanniennes sur les données de test.

Les résultats de ces méthodes sont illustrés dans le tableau 10.

Tableau 10 : Performances de classification (%) des méthodes MDRM et FGMDM

Sujets	MDRM	FGMDM	CSP
S01	78,9	79,5	77,8
S02	48,3	50,1	44,4
S03	77,5	88,6	82,2
S04	58,3	62,5	58
S05	44,2	46	41
S06	47,0	57,7	49,2
S07	74,1	82,2	80,6
S08	75,7	84,5	71,2
S09	76,4	88,2	79,4
<b>Moyenne</b>	64,5	71	64,8

L'analyse de ces résultats montre que l'utilisation d'un filtrage dans l'espace tangent, couplée à une classification basée sur la variété se traduit par une amélioration significative des performances pour l'ensemble des utilisateurs. On remarque également qu'avec la méthode FGMDM, un pourcentage de classification de 71 % est obtenu marquant ainsi une amélioration de 6,5 % par rapport à la méthode MDRM et une amélioration de 6,2 % par rapport à la méthode CSP.

## 4.2 Approche TSLDA

Comme pour la méthode précédente dont le principe réside dans l'exploitation des matrices de covariance spatiales comme des descripteurs des signaux d'imagerie motrice, l'idée de cette méthode développée au sein des laboratoires français avec l'équipe d'Alexandre B. est de se fier à la géométrie Riemannienne pour classer directement ces matrices. Pour ce faire, les

matrices de covariance sont projetées sur l'espace tangent Riemannien où elles peuvent être vectorisées et traitées comme des objets euclidiens afin d'y appliquer une classification par LDA basée sur la méthode d'analyse discriminante linéaire de Fisher [139]. Cette dernière cherche à maximiser la distance entre les centres des deux classes tout en minimisant la dispersion des données après projection. Ensuite, les chercheurs ont comparé leur approche appelée Tangent Space Linear Discriminant Analysis (TSLDA) à une méthode de référence CSP et LDA qu'ils ont présenté sous un format simple et amélioré et où le nombre optimal de filtres a été sélectionné pour chaque sujet selon un critère FDR pondéré. La comparaison a également été faite avec la méthode MDRM et les résultats sont illustrés dans le tableau 11.

Tableau 11 : Exactitude s des classifications avec une validation croisée.

Sujets	CSP+LDA	CSP+LDA AMELIOREE	MDRM	TSLDA
S01	78,3	81,8	77,8	80,5
S02	44,7	45,1	44,1	51,3
S03	82,2	83,5	76,8	87,5
S04	59,1	59	54,9	59,3
S05	39,7	42,2	43,8	45
S06	50,1	43,3	47,1	55,3
S07	81	81,5	72	82,1
S08	68,5	69,6	75,2	84,8
S09	77,4	80	76,6	86,1
<b>Moyenne</b>	64,6	65,1	63,2	70,2

A travers ces résultats, il s'avère que la méthode MDRM est la moins performante de ce comparatif avec une exactitude moyenne de 63,2 %. Les méthodes CSP + LDA arrivent ensuite avec respectivement 64,6 % et 65,1 % d'exactitude. La méthode TSLDA quant à elle, présente les meilleures performances sur tous les sujets en termes d'exactitude moyenne. Enfin, on notera que les performances varient considérablement d'un sujet à l'autre avec une moins bonne exactitude pour les sujets 2, 4, 5 et 6.

### 4.3 Approche MFTL-TSK

Cette approche développée par l'équipe de Yong Liang de l'université de Shangai présente un algorithme qui repose sur un processus de calibration en deux étapes fondé sur le principe de l'apprentissage par transfert et agissant simultanément au niveau des individus et des caractéristiques [169]. Dans ce contexte, les matrices de covariance spatiale, qui sont représentées dans l'espace riemannien, sont utilisées pour décrire les signaux EEG recueillis à partir de multiples canaux. Les individus sources, dont les caractéristiques présentent une

similarité substantielle avec celles de l'utilisateur actuel, sont identifiés comme sources de transfert au moyen d'un algorithme d'alignement de géométrie Riemannienne. Ensuite, les caractéristiques extraites de ces individus sources dans l'espace tangent Riemannien ainsi que celles de l'utilisateur actuel sont fusionnées et sont soumises à une calibration par l'intermédiaire d'un algorithme d'adaptation de distribution équilibrée. Enfin, un modèle de classification est élaboré pour l'utilisateur actuel en utilisant un nombre limité de nouvelles données d'entraînement. Les résultats sont illustrés dans le tableau 12 ci-dessous.

Tableau 12 : Comparatif des exactitudes de classification (%) des méthodes étudiées.

Sujets	CSP-	MDRM	TS-	KPCA-	MFTL-	MFTL-	MFTL-
	LDA		SVM	SVM	LDA	SVM	TSK
S01	79,75	79,00	78,25	80,50	79,00	79,00	79,00
S02	46,00	48,25	43,75	50,50	53,50	53,50	52,00
S03	79.75	67.75	84.25	84.25	82.00	82.75	85.75
S04	60.25	61.75	53.50	56.50	55.00	54.25	58.75
S05	37.00	50.50	41.50	44.50	43.75	43.75	45.25
S06	45.25	45.25	45.25	44.50	48.25	50.50	49.00
S07	73.00	64.75	76.75	79.00	79.00	77.50	82.00
S08	73.00	70.75	77.50	78.25	83.50	82.00	82.00
S09	80.50	73.00	83.50	80.50	82.00	82.00	80.50
<b>Moyenne</b>	64.00	62.50	64.75	66.25	67.75	67.00	<b>68.50</b>

Les résultats expérimentaux montrent que la méthode proposée surpasse les autres méthodes. En outre, l'exactitude de la classification présente une amélioration pour les méthodes basées sur l'approche MFTL qui comparativement aux méthodes précédentes, comprend deux étapes d'apprentissage par transfert.

Au niveau des sujets, l'algorithme de sélection de la source pallie le manque de données d'entraînement pour le sujet cible. En effet, non seulement il identifie les sujets sources appropriés pour le sujet cible afin d'éviter le transfert négatif, mais il réduit également les différences entre les individus grâce à la calibration des matrices de covariance spatiales.

Au niveau des caractéristiques, la calibration dans l'espace tangent Riemannien améliore encore la séparabilité des classes. Ainsi, l'algorithme MFTL obtient de meilleurs résultats par rapport

aux autres algorithmes, en particulier lorsque la quantité de données d'entraînement de l'utilisateur actuel est faible.

#### 4.4 Approche ARK-SVM

Cette approche élaborée par des chercheurs français sous la direction d'Alexandre B. [10] vise à prendre en compte la variabilité connue dans les distributions des caractéristiques entre les sessions d'enregistrement. Ceci est possible à travers une adaptation pouvant être réalisée en mettant à jour le point de référence utilisé pour la cartographie de l'espace tangent afin de s'adapter aux nouvelles données. Pour ce faire, les caractéristiques des signaux d'imagerie motrice sont extraites et transformées en matrices SDP pour être ensuite projetées sur l'espace tangent et subir une vectorisation dans le but d'alimenter un classifieur SVM. Chaque matrice de covariance peut être projetée localement sur le plan tangent à l'aide des outils de géométrie Riemannienne utilisés dans les méthodes MDM/FGDA et TSLDA pour ensuite être manipulée dans cet espace. Cette approche a considérablement amélioré la méthode RK-SVM pour la classification des signaux d'imagerie motrice EEG [10] comme illustrés dans le tableau 13.

Tableau 13 : Exactitude (%) moyenne des méthodes de classification.

Classification	ARK-SVM	RK-SVM	SVM
<b>MG/MD</b>	82,7	79,9	73
<b>MG/DP</b>	89,5	87,3	78,2
<b>MG/LA</b>	88,7	86,9	81
<b>MD/DP</b>	87,3	85,9	77
<b>MD/LA</b>	88,3	86	77,5
<b>DP/LA</b>	79,5	77,2	68,5
<b>Moyenne</b>	86	83,9	75,9

Ces résultats montrent qu'en ignorant la structure particulière des matrices de covariances, le SVM linéaire obtient l'exactitude la plus basse. Les approches SVM basées sur le noyau Riemannien quant à elles, montrent une amélioration de l'exactitude et le noyau adaptatif obtient la meilleure exactitude moyenne avec un résultat de 86 %.

## 5. Conclusion

Après une brève revue de la littérature sur les principales méthodes de classification utilisées dans le cadre des interfaces cerveau-machine, il est incontestable que chacune des approches

présentées regorge de nombreux avantages mais aussi d'inconvénients. Bien que certaines d'entre elles comme les réseaux de neurones convolutifs (CNN) soient très populaires en raison de leur exactitude et de leur efficacité, d'autres approches alliant la géométrie Riemannienne aux méthodes classiques sont de plus en plus utilisées.

En définitive, la méthode ARK-SVM introduite par Alexandre B. et al. [10] a particulièrement retenu notre attention. En effet, en plus d'être la source d'inspiration des méthodes développées dans le cadre de notre travail de recherche, elle représente la méthode de référence pour l'évaluation de nos résultats.

---

# **CHAPITRE IV**

Méthodes expérimentales de classification à base de  
Machine Learning

---

## **1. Introduction**

Au commencement, ce travail de recherche a vu le jour suite à l'intérêt accordé aux interfaces cerveau-machine avec l'apport considérable que cela peut apporter dans différents domaines [3], puis à l'expansion de l'utilisation de la géométrie Riemannienne dans divers domaines de recherche [164]. En parallèle, comme expliqué dans les chapitres précédents, les réseaux de neurones artificiels ont connu un grand succès du fait de leur robustesse et de leur efficacité [170,171]. Ils ont donc naturellement constitué la base de notre recherche axée sur l'intégration des réseaux de neurones dans les interfaces cerveau-machine, qui n'étaient pas encore répondus dans ce domaine à la rédaction de cette thèse.

Ensuite, les signaux issus des essais d'imagerie motrice faisant partie du domaine de la variété différentielle, il est donc important de pouvoir prendre en compte cette propriété intrinsèque des données avec les outils adéquats dans la réalisation de ce travail.

L'idée novatrice de cette thèse est de proposer une approche qui exploite à la fois les réseaux de neurones et la géométrie Riemannienne [172,173]. Plus précisément, nous proposons une nouvelle méthode, nommée ARK-ANN (Adaptive Riemannian Kernel based Artificial Neural Network). De plus, quatre variantes de cette dernière ont aussi été mises en œuvre. Il s'agit de la méthode RK-ANN (Riemannian Kernel based Artificial Neural Network), Riemannian Kernel Convolutional Neural Network (RK-CNN), FG-ARK-ANN (Fisher's Geodesic Adaptive Riemannian Kernel based Artificial Neural Network) et FG-ARK-SVM (Fisher's Geodesic Adaptive Riemannian Kernel based Support Vector Machines). Il est crucial de noter que pour étudier la capacité de généralisation et de robustesse de nos modèles, les méthodes proposées ont été évaluées dans deux contextes expérimentaux distincts : analyse intra sujets (sujet dépendant) et analyse inter sujets (sujet indépendant). Les résultats préliminaires obtenus, montrent une amélioration des performances en termes de classification des signaux d'imagerie motrice dans le contexte des interfaces cerveau machine.

Dans cette section, nous allons donc retracer les différentes étapes nous ayant permis d'aboutir à l'élaboration de ces méthodes de classification en passant par l'analyse des résultats obtenus et leur discussion. Nous allons également discuter des limites de notre étude ainsi que des perspectives envisagées.

## **2. Exploitation de la base de données**

Pour exploiter cette base de données présentée dans le chapitre précédent, le point de départ correspond à l'importation et la préparation des données recueillies pour passer des signaux EEG brutes à des signaux caractéristiques des essais organisés sur les quatre classes citées précédemment et répartis par patient. Pour ce faire, la première étape consiste à récupérer la partie utile du signal, en éliminant les premières secondes afin de ne récupérer que la partie contenant l'activité d'imagerie motrice qui correspond à l'imagination d'un mouvement. Ceci a pour conséquence la production du rythme « mu » qui reflète cette activité cérébrale similaire à la réalisation d'un mouvement réel. Ensuite, un filtre Butterworth du 5ème ordre de 8 à 35 Hz a été appliqué avant de passer à l'extraction de chaque essai de tous les patients et leur répartition en quatre catégories correspondantes à la tâche d'imagerie motrice effectuée lors de l'essai, c'est-à-dire, l'imagination du mouvement de la main gauche, de la main droite, de la langue et des deux pieds [10].

Les signaux étant répartis de façon structurée, il est maintenant facile de récupérer ceux à utiliser. Au final, pour chaque patient ( $i$ ) (avec  $i=1$  à 9), les données des deux sessions sont réparties comme suit :

- Patient ( $i=1$ )
  - o 72 essais de la classe 1,
  - o 72 essais de la classe 2,
  - o 72 essais de la classe 3,
  - o 72 essais de la classe 4.
  
- Patient ( $i=2$ )
  - o ...

Maintenant que les données sont structurées, les matrices de covariance de chaque essai de chaque classe pour chaque patient a été calculées à l'aide de l'estimateur SCM défini dans le premier chapitre. Ceci permet de passer de signaux temporels de dimension  $22 \times 751$  comme illustré sur la figure 19(a) à des matrices de dimension  $22 \times 22$  qui caractérisent le signal comme illustré sur la figure 19(b). Ces matrices sont ensuite projetées par l'opérateur logarithmique sur l'espace tangent comme illustré sur la figure 19(c). Comme les matrices de covariances sont symétriques, on exploite uniquement leurs parties supérieures comme illustré sur la figure

19(d). Chaque matrice est alors vectorisée (voir figure 19(e)) en utilisant uniquement le triangle supérieur. Autrement dit, les signaux EEG bruts sont d'abord transformés en vecteurs de caractéristiques qui peuvent être utilisés comme entrée pour d'éventuels algorithmes de classification traditionnels.

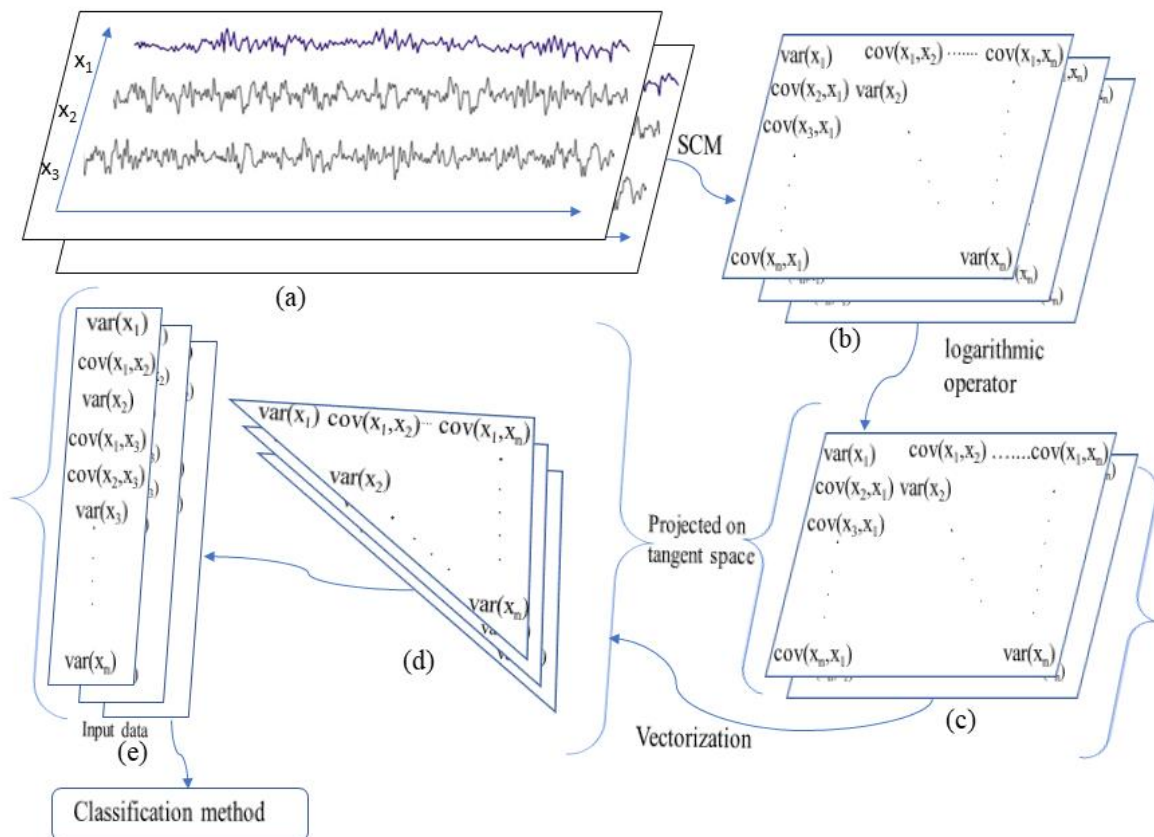


Figure 19 : Transformation de données : Les enregistrements de données de la figure (a) sont transformés en matrices de covariance par SCM comme indiqué dans la figure (b). La figure (c) représente la projection des données dans l'espace tangent par l'opérateur logarithmique. La matrice supérieure dans la figure (d) est vectorisée comme représentée dans la figure (e) pour adapter les données en tant qu'entrées pour les différentes méthodes.

### 3. Classification des signaux

Dans cette section, nous allons présenter les différentes approches que nous avons mis en place lors de ce travail. Plus précisément, nous proposons trois nouvelles méthodes en Machine Learning à noyau Riemannien : Riemannian Kernel Artificial Neural Network (RK-ANN), Riemannian Kernel Convolutional Neural Network (RK-CNN) et Adaptive Riemannian Kernel Artificial Neural Network (ARK-ANN). La méthode ARK SVM [10] ayant donné de bons

résultats dans la littérature, nous avons procédé à sa ré-implémentation et été la méthode référence pour le reste du travail.

Nous explorons également l'apport du filtrage géodésique sur la méthode ARK-ANN et la méthode de référence ARK-SVM [10]. Ces deux dernières méthodes sont nommées FG-ARK-ANN et FG-ARK-SVM, respectivement.

### 3.1.RK-ANN

Bien que les réseaux de neurones soient largement utilisés dans les problématiques de classification, notre travail de recherche ne vise pas à alimenter un réseau de neurones avec des données brutes ou des données filtrées dont les caractéristiques auraient été extraites, mais à innover dans cette approche par l'utilisation du noyau Riemannien dans le but d'optimiser l'apprentissage et la prédiction de notre modèle. Ainsi, dans cette approche Riemannienne, les essais projetés sur l'espace tangent à travers l'opérateur logarithmique défini précédemment, sont vectorisés et injectés comme entrée pour notre modèle de réseau de neurones, comme illustré sur la figure 20.

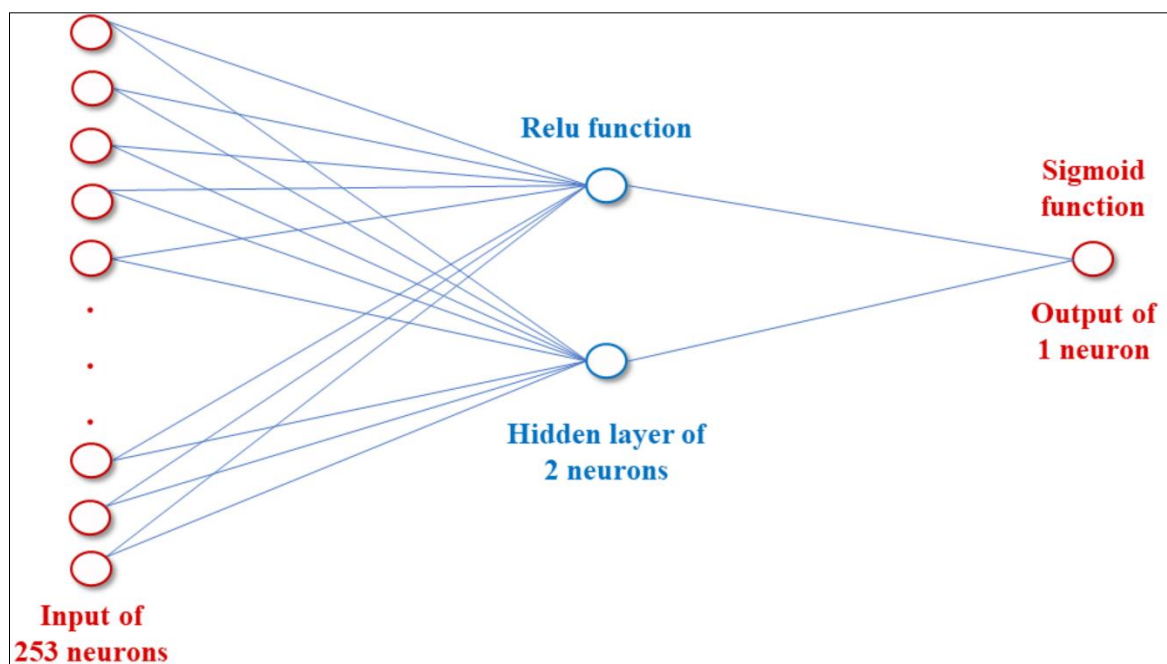


Figure 20 : Perceptron multicouche utilisé dans notre étude.

Notre modèle n'est autre qu'un perceptron multicouche, c'est-à-dire, un réseau de neurones à propagation avant, doté d'une couche d'entrée à 253 neurones de façon à correspondre à la dimension des données d'entrée. Bien que le perceptron multicouche à son apparition ne fût

composé que d'une seule couche cachée par limitation technique, il est actuellement possible d'en avoir plusieurs.

Cependant, dans notre modèle, notre choix s'est porté sur l'utilisation d'une unique couche cachée non pas par limitation de ressources, mais plutôt pour des raisons d'optimisation. En effet, étant donné que la quantité de données disponibles est limitée en termes de volume, un modèle complexe avec plusieurs couches cachées peut conduire à des résultats contreproductifs en raison du surapprentissage. Ceci a également été confirmé à travers des séries d'expérimentations comprenant diverses configurations à l'issue desquelles nous avons identifié le modèle optimal. Ce dernier est caractérisé par une unique couche cachée comprenant deux neurones, qui utilise la fonction d'activation Rectified Linear Unit (ReLU) et qui a démontré des performances supérieures. De plus, notre perceptron possède à son dernier niveau une couche de sortie à un seul neurone à sortie binaire indiquant la classe des données testées, le choix de cette sortie étant le modèle le plus adapté à une classification binaire. Cette couche utilise la Binary crossentropy comme fonction de coût. En plus d'être couramment utilisée dans les tâches de classification binaire, cette dernière mesure la différence entre les prédictions du modèle et les vraies étiquettes (classes) des données d'entraînement. Ainsi, notre objectif consiste à minimiser cette fonction afin d'obtenir les meilleures performances possibles sur la tâche de classification binaire.

Ensuite, afin de minimiser le biais de surapprentissage et d'améliorer la généralisation de nos modèles, la descente de gradient stochastique "Adam" est utilisée avec une taille de lot de 35 et 300 époques. En effet, l'algorithme d'optimisation Adam est un optimiseur de gradient stochastique largement utilisé dans les réseaux de neurones profonds en raison de sa capacité à maintenir une estimation adaptative permettant une convergence plus rapide et une meilleure généralisation sur les données de test. La taille de lot quant à elle, détermine le nombre d'échantillons d'entraînement utilisés dans une itération, ce qui peut affecter la vitesse de convergence et la qualité de l'apprentissage.

Par ailleurs, l'utilisation d'une taille de lot et du nombre d'époques dans un réseau de neurones artificiels permet d'optimiser l'apprentissage du modèle. En effet, en plus de déterminer le nombre d'échantillons de données utilisés pour effectuer une seule mise à jour des poids du réseau neuronal, la taille de lot sert à accélérer l'entraînement de l'ANN en effectuant des mises à jour de poids moins fréquemment, en présentant plusieurs échantillons d'apprentissage à la fois. De plus, son utilisation peut permettre d'améliorer la stabilité de l'entraînement de l'ANN, car lorsque les exemples d'apprentissage sont présentés un à un à cette dernière, la mise à jour

des poids peut être très bruitée et instable. En revanche, en utilisant un batch size, les gradients calculés sur plusieurs exemples d'apprentissage sont plus représentatifs de l'ensemble des données et peuvent donc conduire à une mise à jour de poids plus stable.

Le nombre d'époques quant à lui, définit le nombre de fois que l'ensemble des données sera utilisé pour entraîner le modèle. De ce fait, le calcul des gradients et la mise à jour des poids peuvent être effectués en une seule fois, ce qui réduit le temps d'exécution de l'algorithme d'optimisation. De plus, le choix du nombre d'époques dépend de la complexité du modèle et de la quantité de données d'entraînement. Ainsi, trop peu d'époques peut conduire à un sous-apprentissage du modèle, tandis qu'un trop grand nombre d'époques peut conduire à un surapprentissage où le modèle ajuste de façon exagérée les données d'entraînement et réduit sa capacité à généraliser sur de nouvelles données. Par conséquent, en utilisant un batch size et un nombre d'époques appropriés, nous pouvons trouver un compromis entre la vitesse de l'apprentissage et l'exactitude du modèle. C'est ainsi que dans cette étude, nous avons pu atteindre cet équilibre en établissant une taille de lot de 35 et un nombre d'époques de 300. De plus, notre modèle comprend une étape de validation croisée à 10 éléments lors de son entraînement avec la fonction « grid search » qui divise automatiquement les données. En effet, la validation croisée « k-fold » est une technique d'évaluation des performances des modèles qui permet de diviser les données en k ensembles de tailles égales. Le modèle est ensuite entraîné sur k-1 ensembles et évalué sur le dernier ensemble. Ce processus est répété k fois, de sorte que chaque ensemble soit utilisé une fois pour l'évaluation. Cela permet de réduire le risque de surapprentissage et d'obtenir une estimation plus fiable de la performance du modèle sur de nouvelles données. En définitive, les choix de la structure, des paramètres et des hyperparamètres du réseau de neurones mis en place dans notre travail ont été établis après plusieurs tests, et le réseau neuronal offrant les meilleures performances a été sélectionné. Plus précisément, chaque itération d'entraînement de réseaux de neurones, effectuée avec les mêmes données d'entrée et les mêmes paramètres, génère des performances variables. Ceci est attribuable à une caractéristique intrinsèque des réseaux de neurones, à savoir leur capacité à s'auto-ajuster tout au long du processus d'entraînement. À chaque étape de l'entraînement, les poids de chaque neurone sont adaptés de manière autonome en réponse à l'évaluation de la fonction de coût. En conséquence, le modèle évolue de manière unique, engendrant des résultats distincts à chaque itération. Pour cette raison, et afin de trouver le modèle le plus optimal, les processus d'apprentissage et de prédiction sont conçus pour être itérés 60 fois pour chaque test consécutivement. Cela signifie que le processus d'apprentissage et de prédiction est répété 60

fois pour chaque sujet, avant de passer au sujet suivant. Cela a été réalisé pour chaque paire de classification. Le code simplifié de notre modèle ANN est donné en Annexe.

Les différentes étapes de la méthode RK-ANN sont détaillées comme suit :

- L'**Algorithm 1** montre comment les données sont préparées en calculant des matrices de covariance des EEG brutes. Ces dernières sont projetées sur l'espace tangent à travers l'opérateur logarithmique défini précédemment. Enfin, elles sont vectorisées pour être injectées comme entrée pour notre modèle de réseau de neurones.
- L'**Algorithm 2** sert à entraîner notre modèle ANN sur des données d'entraînement.
- L'**Algorithm 3** décrit la phase de classification de la méthode RK-ANN sur le sujet test.

---

**Algorithm 1** Calcul des matrices SDP vectorisées

---

Input:  $\Omega$  a set of training covariance matrices  $P_i$

Output:  $\tilde{\mathcal{S}}$  set of all vectorized covariance matrices

1:  $P_{\Omega}^I = \frac{1}{n} \sum_{i=1}^n (P_i)$  { Computation of the mean of all training covariance matrices }

2:do

a:  $P_m = \frac{1}{n} \sum_{i=1}^n \text{Log}_{P_{\Omega}^I} (P_i)$  { Arithmetic mean of the projected covariance matrices }

b:  $P_{\Omega}^f = P_{\Omega}^{(t+1)} = \text{Exp}_{P_{\Omega}^I} (P_m)$  { The riemannian mean of the training set }

3:while  $\|P_m\|_F < \epsilon$

4: $S = \text{Log}_{P_{\Omega}^f}(\Omega)$  { projection of the two class covariance matrices }

5: $\tilde{\mathcal{S}} = \text{vect}(S)$  { Vectorization of the covariance matrices }

Return  $\tilde{\mathcal{S}}$

---



---

**Algorithm 2** Training the RK-ANN

---

Input:  $\Omega$  a set of training covariance matrices  $P_i$

Input:  $X_i$  a new covariance matrix to classify

Input:  $X$  a set of testing covariance matrices

Output: ANNModel

1: Compute  $\tilde{\mathcal{S}}_e$  (Applying Algorithm 1) { Compute the vectorized training set }

2: ANNModel = fit( $\tilde{\mathcal{S}}_e, y_i$ ) { Training the model }

---

---

**Algorithm 3** Test prediction of the RK-ANN

---

Input: ANNModel

Input:  $X$  a set of testing covariance matrices and  $X_i$  a new covariance matrix to classify.

Output:  $\hat{y}_{T_i}$  is the estimated class of the test covariance matrix

1:  $S_T = \text{Log}_{\text{PDF}}(X)$  { projection of the test set }

2:  $\tilde{S}_T = \text{vect}(S_T)$  { Vectorization the test set }

3:  $s_{T_{y_i}} = \text{predict}(\text{ANNModel}, \tilde{S}_T)$  { Predicting the class of the testing set }

return  $\hat{y}_{T_i}$

---

### 3.2.RK-CNN

L'utilisation d'un réseau de neurones plus complexe comme le CNN était une continuité de notre paradigme. Ici, nous avons voulu explorer l'apport de ce type de réseau de neurones avec un noyau Riemannien. Pour ce faire, nous avons élaboré un réseau de neurones basique, avec différentes configurations. La structure globale de ce dernier est la suivante : une couche d'entrée, un filtre convolutif muni d'une fonction d'activation Relu, un max pooling 2D avant de passer à la couche « Flatten » qui permet de transformer une sortie de couche de convolution en un vecteur 1D pour que cette sortie puisse être utilisée comme entrée dans une couche dense « fully-connected » qui suit la couche de convolution. Les informations spatiales contenues dans la sortie de la couche de convolution sont rangées dans un vecteur qui peut être absorbé par une couche dense. L'étape Flatten est importante car elle permet de conserver les caractéristiques de hautes dimensions tout en permettant une classification par un réseau de neurones.

Néanmoins, en dépit de nos tentatives visant à incorporer les principes de la géométrie Riemannienne dans l'architecture de notre réseau de neurones convolutif, les performances en matière de classification ne se sont pas révélées significatives. Il est plausible que notre configuration du réseau n'ait pas été optimale et par conséquent, ces données n'ont pas été retenues dans le cadre de ce travail de recherche.

### 3.3.ARK-ANN

L'apprentissage basé sur un réseau de neurones à noyau Riemannien adaptatif représente une approche novatrice et prometteuse qui n'a pas encore été explorée dans le domaine de la classification de données par le biais de modèles à réseau de neurones. De plus, cette approche

permet de mieux prendre en compte la structure intrinsèque des données, en exploitant la géométrie de l'espace Riemannien, qui ouvre de nouvelles perspectives pour les interfaces cerveau-machine et pour la classification de données issues de variétés différentielles. Dans cette optique, l'innovation apportée par cette troisième méthode est la prise en compte de la notion de biais entre les différentes sessions d'enregistrement en utilisant l'adaptation des données de tests injectées dans notre modèle RK-ANN. Cette notion d'adaptation a présenté des performances d'optimisation prometteuses, notamment pour la méthode SVM étudiée dans [10].

Ainsi, de même que la méthode RK-ANN, dans l'ARK-ANN nous avons tout d'abord procédé au calcul des matrices de covariance pour l'ensemble de données d'entraînement. Pour ce faire, nous avons fait usage de la boîte à outils Riemannienne mise à disposition par Alexandre B. et al [10], pour ensuite projeter les données sur l'espace tangent de cette base pour pouvoir entraîner notre modèle. Cette étape reste identique à celle réalisée dans la méthode précédente.

La différence avec la méthode RK-ANN réside dans la partie test des données. En effet, pour la classification d'un essai de test, il est nécessaire de recalculer une nouvelle moyenne géométrique. Cette dernière doit être établie à partir de toutes les matrices de covariance de test pour déduire un nouveau point de projection adapté spécifiquement à la nouvelle session d'enregistrement. L'ensemble de test a ensuite été projeté dans le plan tangent où la moyenne arithmétique est calculée et projetée à nouveau à travers la projection exponentielle sur l'espace Riemannien. Cette nouvelle matrice moyenne est utilisée comme nouveau point de projection pour les essais de test et un paramètre seuil a été établi pour stopper le calcul de la moyenne géométrique. Celui-ci peut être considéré comme la distance minimale qui sépare les deux matrices moyennes les plus récentes, marquant le moment où la distance est devenue si infime qu'elle est considérée comme négligeable. Un deuxième seuil peut également être fixé comme le nombre maximum d'itérations de ce calcul. La moyenne géométrique sera alors la dernière matrice moyenne calculée, comme indiqué dans les étapes de l'algorithme 1 de l'étape 1 à 3. Une fois que les matrices de test sont sur l'espace tangent, elles sont vectorisées à l'aide de la formule expliquée dans la section 2.2 et sont prêtes à être utilisées pour le modèle de classification proposé, représenté par l'étape 2 de l'algorithme 4.

Enfin, la phase d'adaptation consiste donc à trouver un nouvel espace tangent qui convient mieux à l'ensemble de test afin de projeter les matrices de covariance sur celui-ci. Nous avons utilisé les mêmes hyperparamètres que pour la méthode RK-ANN, et avons appliqué le même

principe de 60 itérations pour retenir le modèle ayant donné le meilleur résultat pour chaque sujet.

---

**Algorithm 4** Testing the ARK-ANN

---

Input: ANNModel

Input:  $\mathbf{X}$  a set of testing covariance matrices

Output:  $\hat{y}_{Ti}$  is the estimated class of the test covariance matrix

1: Compute  $\tilde{\mathbf{s}}_T$  (Applying Algorithm 1) { Compute the vectorized adaptive testing set on a new tangent space }

2:  $s_{Tyi} = \text{predict}(\text{ANNModel}, \tilde{\mathbf{s}}_T)$  { Predicting the class of the testing set }

return  $\hat{y}_{Ti}$

---

### 3.4. Filtrage des méthodes ARK-ANN et ARK-SVM

Dans cette section, nous présentons une variante de l'algorithme ARK-ANN, où une étape de filtrage géodésique (décrite dans la section II.3) sur l'ensemble d'entraînement a été ajoutée. Plus précisément, le filtrage est effectué avant de commencer l'entraînement du modèle ANN (voir **Algorithm 5**), où le filtre  $w$  est calculé à l'aide de la technique FGDA, appliquée à l'ensemble d'entraînement. Ensuite, la méthode ARK-ANN est appliquée. Ceci donne naissance à une nouvelle méthode, nommée FG-ARK-ANN, détaillée dans **Algorithm 6**.

---

**Algorithm 5** Fisher geodesic filtering on the training data

---

Input:  $\tilde{\mathbf{S}}$  set of all vectorized covariance matrices

Output:  $\tilde{\mathbf{S}}_e$  vectorized filtered train set

1: Compute  $\tilde{\mathbf{S}}$  the vectorization of the training set (Algorithm1)

2:  $\tilde{\mathbf{w}} = \text{LDA}(\tilde{\mathbf{S}})$  { Computation of the projection vectors using the FGDA }

3: Select the first  $K$  vectors  $\tilde{\mathbf{w}}_k$

4:  $\tilde{\mathbf{S}}_e = \tilde{\mathbf{w}} (\tilde{\mathbf{w}}^T \tilde{\mathbf{w}})^{-1} \tilde{\mathbf{w}}^T (\tilde{\mathbf{S}})$  {Filtering operation }

Return  $\tilde{\mathbf{S}}_e$

---

---

**Algorithm 6** FG-ARK-ANN

---

Input:  $\Omega$  a set of training covariance matrices  $P_i$

Input:  $X_i$  a new covariance matrix to classify

Input:  $X$  a set of testing covariance matrices

Output:  $\hat{y}_{Ti}$  is the estimated class of the test covariance matrix

1: Compute  $\tilde{\mathbf{s}}_{ef}$  (Applying Algorithm 5) { Compute the vectorized filtered training set }

2: Train the ANNModel { Training the model over the filtered data }

3: Compute  $\tilde{\mathbf{s}}_T$  ( Applying Algorithm 4) { Compute the vectorized adaptive testing set and predict the labels }

return  $\hat{y}_{Ti}$

---

Dans cette perspective, nous avons également estimé la méthode FG-ARK-SVM qui s'inscrit dans la continuité de l'approche méthodologique de la FG-ARK-ANN, présentée précédemment. Cette dernière, n'avait pas été proposée dans la littérature scientifique auparavant.

#### 4. Matériel utilisé

Pour réaliser ce travail de recherche, l'ensemble de nos expérimentations ont été menées sur un ordinateur portable équipé d'un processeur Intel(R) Core(TM) i5-8300H CPU à 2.30GHz, capable d'atteindre une fréquence turbo de 4Ghz, et disposant de 8 cœurs logiques. La machine était également équipée d'une carte graphique NVIDIA GeForce GTX 1050 Ti with Max-Q Design et de 16 Go de mémoire vive (RAM). Elle disposait de deux disques durs SSD, dont le principal était de type NVMe pour le stockage des données et fonctionnait sous le système d'exploitation Windows 10. En outre, de nombreux outils logiciels ont été utilisés, notamment pour la partie traitement du signal et la classification SVM pour lesquelles nous avons eu recours au logiciel MATLAB avec la boîte à outils d'Alexandre B. et al. pour la géométrie Riemannienne disponible sur <https://github.com/alexandrebarachant/covariancetoolbox> et la boîte à outils de traitement du signal et SVM de MATLAB. Pour la partie préparation et manipulation des données et développement de l'ANN, l'environnement était sous Python 3.6.9 et les bibliothèques suivantes ont été exploitées : scipy.io, numpy, keras.models, keras.layers, keras.wrappers.scikit\_learn, sklearn.model\_selection, sklearn.metrics et datetime.

Initialement, les expériences ont été menées dans l'IDE Spyder, mais ont été transférées ultérieurement à VSCode en raison de la limitation du premier en termes de support de parallélisme.

Enfin, il convient de souligner que ces informations sont fournies à titre indicatif. Toutefois, cette configuration peut être considérée comme le minimum requis, car l'utilisation d'une configuration inférieure peut entraîner des temps de traitement excessivement longs et n'est donc pas recommandée. L'utilisation du parallélisme est également primordiale pour optimiser la vitesse de traitement des données.

## **5. Résultats**

Les performances des différentes méthodes ont été évaluées en termes d'exactitude (Accuracy). Plus la valeur d'exactitude est grande, mieux est la méthode. Pour estimer cette dernière, il est nécessaire de calculer la proportion de résultats vrais positifs et vrais négatifs dans tous les cas analysés. Cette mesure peut être exprimée mathématiquement par la formule suivante :

$$Exactitude = \frac{TP + TN}{TP + TN + FP + FN} \quad (18)$$

Où TP désigne les résultats vrais positifs (true positives), TN les résultats vrais négatifs (true negatives), FP les faux positifs (false positives) et FN les faux négatifs (false negatives). Ce calcul permet ainsi d'évaluer l'efficacité d'un test et de déterminer s'il est capable de produire des résultats précis et fiables. Dans notre étude, les performances des méthodes sont évaluées à travers des processus de classification binaire. Ainsi, pour chaque exécution du script, le couple de classes à tester est récupéré. Par exemple, lors de la première exécution du script, la classification est réalisée entre la classe 1 qui représente les signaux de la main gauche et la classe 2 qui représente les signaux de la main droite. Il est important de noter que pour évaluer la capacité de généralisation des méthodes, notamment dans le cadre des ICMs, celles-ci ont été appliquées à la base de données suivant deux stratégies différentes, à savoir intra-sujets (patients spécifiques) et inter-sujets (non patients spécifiques).

### **5.1.Stratégie sujet-dépendant**

Ce premier cadre de travail consiste en une étude de généralisation intra-sujets, dans laquelle des modèles ont été entraînés à l'aide des données de la première session d'enregistrement d'un sujet, avant d'utiliser les données de la deuxième session comme ensemble de test pour une

généralisation sur toutes les classes chez le même sujet. Cette approche permet d'évaluer la capacité de généralisation d'un modèle sur les données du même sujet.

Les résultats obtenus sont synthétisés dans le tableau 14 qui évalue nos méthodes basées réseaux de neurones comparativement à l'approche ARK-SVM dont les résultats sont extraits de l'article de référence [10].

Tableau 14 : Comparatif entre méthode ANN et SVM dans le contexte intra-sujets.

<b>Classe</b>	<b>ARK-SVM</b>	<b>RK-ANN</b>	<b>ARK-ANN</b>
<b>MG/MD</b>	82,7%	81,9%	82,6%
<b>MG/DP</b>	89,5%	77,5%	90,2%
<b>MG/LA</b>	88,7%	80,0%	89,4%
<b>MD/DP</b>	87,3%	80,5%	90,3%
<b>MD/LA</b>	88,3%	78,2%	88,8%
<b>DP/LA</b>	79,5%	71,2%	82,8%
<b>Moyenne</b>	<b>86,0%</b>	<b>78,2%</b>	<b>87,4%</b>

On observe que la méthode RK-ANN, qui exploite le réseau neuronal de manière rudimentaire sur les matrices de covariance vectorisées, a obtenu une exactitude de 78,2 %, ce qui est moins pertinent que la méthode SVM. L'exactitude du réseau neuronal était inférieure sur toutes les classes par rapport aux autres méthodes. En revanche, la méthode ARK-ANN a montré une exactitude de 87,4 %, surpassant sensiblement la méthode ARK-SVM sur toutes les paires de classes, à l'exception de MG/MD, où la différence était minime. A titre informatif, le tableau 15, présente les résultats de notre méthode ARK-ANN, en termes d'exactitude, avec ceux obtenus par d'autres méthodes de la littérature (qui n'exploitent pas la géométrie Riemannienne), présentées précédemment.

Tableau 15 : Résultats d'exactitude (%) de notre approche avec les méthodes étudiées de l'état de l'art.

Méthode	Exactitude moyenne
EEG-TCN <sub>ET</sub>	83.8%
Wavelet T-F Image CNN	85,6%
Sinc-EEGNet	75,4%
SW-LCR	81,8%
SW-Mode	82,0%
CS-GAN	83,0%
<b>ARK-ANN</b>	<b>87,4%</b>

Ainsi, comparativement aux autres méthodes étudiées, notre approche ARK-ANN offre la meilleure performance avec 87,4% d'exactitude. L'approche Wavelet T-F Image CNN [163] arrive en seconde position avec 85,6% d'exactitude. Les méthodes EEG-TCNET [162], SW-Mode [164] et SW-LCR [164] offrent des résultats plutôt similaires avec respectivement 83,8 %, 82 % et 81,8 % d'exactitude. Enfin, la méthode ayant obtenu l'exactitude la moins performante est Sinc-EEGNet [165] avec 75,4 % d'exactitude.

Nous allons maintenant nous intéresser aux résultats obtenus avec l'application du filtrage géodésique sur les méthodes à base de SVM et d'ANN. Le tableau 16 reprend les méthodes ARK-ANN et ARK-SVM afin d'avoir un axe de comparaison pour les méthodes FG-ARK-ANN et FG-ARK-SVM où nous avons essayé différents noyaux SVM pour en sauvegarder celui qui offrait les meilleures performances.

Tableau 16 : Performance du filtrage géodésique sur les différentes méthodes.

Classe	ARK-SVM	FG-ARK-SVM	ARK-ANN	FG-ARK-ANN
<b>MG/MD</b>	82,7%	79,6%	82,6%	74,8
<b>MG/DP</b>	89,5%	89,7%	90,2%	82,7
<b>MG/LA</b>	88,7%	89,6%	89,4%	83.9
<b>MD/DP</b>	87,3%	89,0%	90,3%	81.8
<b>MD/LA</b>	88,3%	87,0%	88,8%	82.9
<b>DP/LA</b>	79,5%	82,3%	82,8%	77.2
<b>Moyenne</b>	86,0%	86,2%	87,4%	80,6%

Les résultats obtenus par FG-ARK-ANN sont significativement moins performants que la méthode sans filtrage ARK-ANN. On constate une baisse de performance de l'exactitude de 6,8%. Les performances de FG-ARK-SVM semblent légèrement surpasser celles de ARK-SVM, avec une moyenne de 86,2% par rapport à 86,0%. Cela suggère que l'ajout du filtrage peut apporter des améliorations discernables dans la capacité de classification des modèles SVM, mais cela nécessiterait d'explorer davantage cette approche avec des données plus fournies ou un noyau SVM plus optimisé.

## **5.2.Stratégie sujet-indépendant**

Dans cette deuxième expérience, nous évaluons la capacité de généralisation des différentes méthodes. Pour ce faire, une stratégie inter-sujets, où les données du sujet testé ne sont pas prises en compte dans la phase d'entraînement des modèles. Étant donné, que la base testée inclut un nombre limité de sujets, une procédure de validation croisée « tous sauf un » (Leave One Out, LOO) a été adoptée ici. Cela signifie que les enregistrements de la première session de tous les sujets ont été regroupés, à l'exception de celui d'un seul sujet qui sert de sujet de test. Pour éviter tout biais dans les résultats, les enregistrements de la première session de ce sujet n'ont pas été inclus dans la partie entraînement.

Ensuite, seulement les enregistrements de la deuxième session du sujet de test ont été utilisés comme ensemble de test. Cette procédure a été répétée pour l'ensemble des sujets et pour toutes les combinaisons de classification binaire. De cette manière, on peut évaluer la capacité de généralisation d'un modèle sur des sujets différents de ceux utilisés pour l'apprentissage. En d'autres mots, dans cette section, nous évaluons la capacité de nos modèles à apprendre sur un ensemble de données générées par un groupe de sujets afin de prédire la classe des essais d'un patient tiers. Le jeu de données est segmenté avec une procédure LOO. Par conséquent, les deux modèles, SVM et ANN, ont été entraînés en utilisant l'ensemble d'entraînement de huit sujets, et l'ensemble de données du dernier sujet a été utilisé comme ensemble de test. En répétant cette procédure, l'exactitude pu être calculée pour chaque sujet et les classifications binaires ont été choisies pour être identiques à celles de l'étude menée dans le cadre de la classification intra-sujets. Les résultats obtenus sont présentés dans le tableau 17 qui montre l'exactitude moyenne des six classifications possibles pour chaque cas. Par exemple, pour la classification P1, les données du sujet 2 au sujet 9 ont été utilisées comme base d'entraînement, et les données du sujet 1 ont été utilisées comme ensemble de test. Ensuite, comme dans le contexte intra-sujets,

six classifications ont été créées pour représenter toutes les combinaisons binaires possibles afin de maintenir la même logique de comparaison.

Tableau 17 : comparatif entre méthode ARK-ANN et ARK-SVM dans le contexte inter-sujets.

Sujet de test	ARK-SVM	ARK-ANN
P1	78,6%	89,3%
P2	55,8%	58,0%
P3	79,3%	85,9%
P4	65,5%	76,5%
P5	59,9%	67,1%
P6	63,9%	63,7%
P7	62,6%	82,5%
P8	79,5%	83,8%
P9	76,5%	89,0%
<b>Moyenne</b>	<b>69,1%</b>	<b>77,3%</b>

Ainsi, les résultats obtenus montrent clairement que la méthode proposée ARK-ANN offre de meilleures performances sur tous les tests sauf pour le sujet P6. Elle obtient une exactitude globale de 77,3% contre 69,1% pour la méthode ARK-SVM.

De plus, une analyse comparative de notre méthode avec les approches étudiées précédemment est proposée dans le tableau 18.

Tableau 18 : comparatif de notre approche avec les approches de la littérature dans un contexte inter-sujets.

Méthode	Exactitude moyenne
MSAENet	70,0%
S-T pattern	71,7%
MFTL-TSK	68,5%
<b>ARK-ANN</b>	<b>77,3%</b>

A travers ces données, nous constatons que la méthode ARK-ANN a produit les meilleurs résultats dans cette comparaison inter-sujets avec une exactitude de 77,3 %, suivie des méthodes S-T pattern et MSAENet avec respectivement 71.7% et 70% d'exactitude moyenne. La méthode MFTL-TSK quant à elle, a obtenu le niveau d'exactitude le plus faible. Néanmoins, il convient de noter que le jeu de données était peu volumineux, limitant la capacité d'utilisation de la puissance d'un réseau de neurones complexe.

### **5.3. Autres résultats**

Au cours de la phase expérimentale, nous avons examiné diverses configurations de notre réseau de neurones artificiels (ANN). À l'origine, notre modèle était bien plus complexe, avec plusieurs couches cachées contenant un grand nombre de neurones. Nous avons constaté que, quelle que soit la modification du nombre de neurones dans chaque couche cachée ou du nombre de couches cachées, les résultats obtenus étaient similaires. Toutefois, en réduisant la complexité de notre modèle, nous avons noté une nette amélioration des performances, jusqu'à ce que la configuration présentée dans cette thèse donne les meilleurs résultats.

## **6. Discussion**

Premièrement, concernant les données intra-sujets, nous avons comparé nos méthodes à base des réseaux de neurones RK-ANN et ARK-ANN à la méthode référence ARK-SVM. En termes de performance de classification, même si les résultats obtenus par la méthode RK-ANN sont intéressants (exactitude de 78,2 %), elle reste moins efficace que ARK-SVM (exactitude de 86 %). Ceci peut s'expliquer par la variation entre les sessions d'enregistrement créant ainsi un biais qui nécessiterait un réentraînement du modèle sur le nouvel ensemble de données de test. En effet, il est possible que le modèle apprenne à repérer les caractéristiques de chaque classe de façon à prendre en compte l'environnement de l'enregistrement et ne peut être efficace que sur des données d'une même session.

La méthode ARK-ANN quant à elle, s'est montrée plus robuste et a donné les meilleurs résultats avec une exactitude de 87,4% comparativement aux méthodes ARK-SVM et RK-ANN, mais aussi à toutes les autres méthodes basées sur les réseaux de neurones et qui n'exploitent pas la géométrie Riemannienne. Cette efficacité peut être expliquée par l'adaptabilité du noyau Riemannien qui permet, comme pour la méthode ARK-SVM, une meilleure discrimination du jeu de test à l'inverse de la méthode RK-ANN.

Plus particulièrement, il est aussi intéressant de souligner que notre méthode ARK-ANN, qui rappelons-le exploite la géométrie Riemannienne couplée avec un réseau de neurone très léger, reste plus performante que la méthode EEGTCNET qui présente une optimisation personnalisée plus poussée. En effet, cette dernière exploite un modèle entraîné spécifiquement sur chaque sujet avec des hyperparamètres réglés au cas par cas. En d'autres termes EEGTCNET apprend donc un modèle avec une architecture différente par sujet, alors que ARK-ANN est basée sur la même architecture. En définitive, la méthode ARK-ANN présente une approche intéressante dans le contexte des ICMs.

De plus, la taille des données ayant été relativement pauvre limitant ainsi la capacité à utiliser la puissance d'un réseau neuronal artificiel, il est complètement logique de s'attendre à de meilleurs résultats avec les méthodes à réseau de neurones, notamment l'ARK-ANN, avec un ensemble de données plus important.

Un autre point très intéressant de notre méthode est sa capacité de généralisation. En effet, dans le cadre des tests avec une stratégie inter-sujets, l'ARK-ANN, présente des performances très intéressantes (exactitude de 77,3 %), en surpassant la méthode ARK-SVM et les autres méthodes de la littérature pour la majorité des patients étudiés. De plus, dans ce cas plus difficile d'inter-sujets, ARK-ANN montre une amélioration des résultats très significative d'environ 7%.

Enfin, concernant l'application d'un filtre géodésique, nous avons constaté que ce prétraitement n'apporte pas d'amélioration que ce soit pour la méthode basée SVM ou celle basée ANN. Notre hypothèse porte dans ce cas sur la sensibilité des modèles SVM et ANN. En effet, le SVM linéaire est généralement sensible à la distribution des données et à la séparabilité linéaire, tandis que les réseaux de neurones peuvent être plus flexibles et capables de capturer des relations non linéaires. Or, le filtrage géodésique peut augmenter la séparabilité linéaire des données bénéficiant ainsi au SVM, mais il peut également supprimer des informations non linéaires utiles pour les réseaux de neurones. Il est également possible que l'application d'un tel filtrage nécessite une modification du modèle ANN afin de mieux répondre à l'application du filtre.

## **7. Conclusion**

Dans le cadre de la classification intra-sujets basée sur un réseau de neurones, il est important de souligner la contribution considérable apportée par l'adaptation des données de test, qui nous

a permis d'améliorer l'exactitude de 9,2%, en passant de 78,2% avec la méthode RK-ANN à 87,4% avec la méthode ARK-ANN, ce qui en fait la méthode la plus pertinente parmi les différents comparatifs menés lors de notre travail de recherche.

La deuxième conclusion est l'inefficacité du filtrage géodésique sur les méthodes basées sur les réseaux de neurones, bien que ce dernier apporte une très légère amélioration pour la méthode basée sur SVM.

Dans le contexte de la classification inter-sujets, le filtrage géodésique est moins efficace pour les méthodes basées sur SVM et les méthodes basées sur les réseaux de neurones. Ceci est compréhensible compte tenu de la différence marquée entre certains sujets qui ont pu avoir des difficultés avec la tâche et ont donc produit uniquement des signaux de MI avec des erreurs qui rendent leur classification impossible. Reproduire cette méthode avec une base de données plus riche et en sélectionnant soigneusement les patients qui ne fournissent que des signaux de MI forts serait intéressant. En revanche, l'adaptation des données de test pour la méthode basée sur les réseaux de neurones est également très pertinente, offrant une amélioration de l'exactitude de 8,2% entre les méthodes ARK-SVM et ARK-ANN. La méthode ARK-ANN est donc la méthode la plus efficace quel que soit le type de classification, démontrant ainsi l'efficacité de coupler les réseaux de neurones et la géométrie Riemannienne dans le domaine de la classification des signaux neurologiques.

Dans le contexte intra-sujets, une amélioration des résultats est observée par rapport à la méthode de référence. En revanche, il est également très probable qu'avec une base de données plus riche, ARK-ANN pourrait aussi apporter une amélioration de l'exactitude de la classification. Cela nécessitera sans aucun doute l'utilisation d'un réseau de neurones plus complexe, et il serait intéressant d'entreprendre cette expérience dans un travail futur avec des bases de données plus riches.

---

# **Conclusion générale**

---

Au cours de cette thèse, nous avons étudié les éléments nécessaires pour mettre en place une Interface Cerveau-Machine, en passant en revue l'EEG et la partie anatomique du cerveau, avant de passer à l'aspect technique en abordant les principes sur lesquels est fondée notre thèse, avant de présenter nos expérimentations. Notre travail s'est articulé autour de deux approches.

La première partie est basée sur l'utilisation d'un réseau de neurones artificiels à noyau riemannien adaptatif et non adaptatif, pour lesquels nous avons développé un modèle que nous avons entraîné de manière à l'optimiser pour la base de données exploitée BCI Competition ensemble IIa.

La deuxième partie a concerné l'optimisation de notre méthode principale, c'est-à-dire, l'ARK-ANN, ainsi que la méthode ARK-SVM proposée par Alexandre B. et al. en utilisant un filtrage géodésique. Les résultats ont été présentés dans deux contextes : le premier consistant à prédire les classes de l'ensemble de test émanant du même sujet, et le second consistant à généraliser notre modèle sur l'ensemble de test émis par d'autres sujets. Ceci a permis d'estimer l'exactitude de nos méthodes.

Les résultats obtenus avec l'ARK-ANN sont très encourageants et dépassent les autres méthodes de la littérature en obtenant 87,4 % d'exactitude dans le cadre intra-sujets avec une amélioration de 1,8% par rapport à la méthode la plus performante de la littérature la Wavelet T-F Image CNN. On retrouve également d'excellents résultats dans le contexte inter-sujet et de manière plus significative, avec écart de 5,6 % entre notre méthode ARK-ANN et la méthode de la plus performante de la littérature S-T pattern ayant obtenu respectivement 77,3% et 71,7%. Les résultats obtenus avec le filtrage géodésique sont également encourageants pour la méthode FG-ARK-SVM, car nous avons pu considérablement améliorer l'exactitude des prédictions lors de notre analyse avec la reproduction de la méthode ARK-SVM à noyau linéaire, sans toutefois parvenir à une nette amélioration significative comparativement aux résultats obtenus avec le noyau utilisé dans l'étude de référence. Cela suggère la possibilité que les résultats de FG-ARK-SVM pourraient être meilleurs avec un noyau SVM plus optimisé. Il en résulte également que l'application d'un filtrage géodésique aux méthodes basées sur les réseaux de neurones entraîne une détérioration significative des performances du modèle, conduisant à une réduction notable de son efficacité.

Durant cette thèse, nous avons été confrontés à plusieurs limites. La première découle du volume restreint de la base de données utilisée, ce qui s'avère restreignant pour mener une étude fondée sur des réseaux de neurones. En effet, les réseaux de neurones artificiels étant des

modèles d'apprentissage automatique créant leur logique autour des données injectées, ils nécessitent un volume suffisant de données pour pouvoir extraire des caractéristiques significatives et apprendre à généraliser. Ainsi, un jeu de données faible réduit le potentiel d'apprentissage du modèle et peut entraîner un surapprentissage (overfitting) de l'ANN, ce qui se produit lorsque l'ANN s'adapte trop bien aux données d'entraînement spécifiques, au point de ne plus pouvoir généraliser pour des données de test nouvelles et l'ANN peut apprendre des bruits et des particularités propres aux données d'entraînement qui ne se généralisent pas à des données de test, ce qui explique l'utilisation d'un modèle de perceptron basique avec un minimum de neurones et de couches cachées dans cette thèse. De même, un jeu de données faible peut engendrer l'effet inverse et entraîner un sous-apprentissage (underfitting) de l'ANN. Celui-ci se produit lorsque l'ANN ne parvient pas à capturer les caractéristiques importantes des données d'entrée, en raison d'une complexité insuffisante ou d'un manque d'exemples d'entraînement. Dans ce cas, l'ANN ne sera pas en mesure de généraliser correctement pour des données de test, car elle ne sera pas suffisamment informée sur les caractéristiques discriminantes des données d'entrée. Une autre limitation réside dans le fait que, certains sujets n'ayant pas été correctement formés, il a été constaté que ces derniers n'ont pas réussi à générer les signaux requis, ce qui a entraîné un mauvais apprentissage de l'algorithme. Cette limitation aurait pu moins affecter les résultats si la taille de l'ensemble de données avait été plus grande, ce qui aurait permis à l'intelligence artificielle d'être plus complexe et donc de mieux s'optimiser pour discerner les classes.

Bien que notre travail ait abouti à des résultats probants, il reste encore de nombreuses pistes à explorer. Nous recommandons, par exemple, l'utilisation de notre méthode ARK-ANN avec une base de données plus fournie en adaptant la complexité du réseau neuronal en conséquence, ceci soit par une base de données nativement plus volumineuse, soit en recourant à la méthode d'augmentation de base de données. Une autre possibilité serait d'avoir recours à une base de données contenant des signaux d'imagerie motrice dont les sujets seraient suffisamment entraînés, afin d'être capables de générer des signaux d'imagerie motrice plus robustes pour l'entraînement du modèle.

En s'inspirant des travaux de la littérature présentés dans le chapitre III, il serait intéressant d'étudier les performances de la méthode ARK-ANN en configurant les hyperparamètres du modèle de façon spécifique à un seul sujet comme présenté dans la méthode EEGTCN<sub>ET</sub>.

En ce qui concerne l'approche de filtrage géodésique, une piste de recherche pertinente serait d'explorer l'utilisation d'un noyau plus optimisé pour la méthode SVM, tel que celui utilisé dans

l'étude d'Alexandre B. et al. [10] qui a montré des résultats supérieurs à ceux du noyau linéaire disponible dans la boîte à outils MATLAB. En outre, une comparaison approfondie entre l'approche basée sur l'ANN et celle basée sur le SVM pourrait être entreprise pour évaluer leur robustesse en fonction des recommandations suggérées. Ces résultats pourraient à leur tour contribuer à une meilleure appréciation des méthodes efficaces dans le développement de futures interfaces cerveau-machine plus performantes.

---

# **Annexe**

---

## Les équations du réseau de neurone

Au niveau mathématique, un neurone est défini par une fonction d'activation qui prend en entrée des signaux provenant d'autres neurones et produit une sortie. La fonction d'activation la plus couramment utilisée est la fonction sigmoïde, mais d'autres fonctions telles que la fonction ReLU (Rectified Linear Unit) sont également utilisées. Les poids sont ajustés en utilisant des algorithmes d'optimisation tels que la descente de gradient pour minimiser l'erreur entre la sortie prévue et la sortie réelle.

Le gradient est utilisé pour déterminer la direction dans laquelle les paramètres du réseau doivent être ajustés pour minimiser l'erreur entre les sorties prédites et les sorties réelles. Plus précisément, le gradient de la fonction de coût du réseau par rapport à ses poids est calculé à chaque itération de l'optimisation du réseau, et cette valeur est utilisée pour ajuster les poids du réseau dans la direction qui minimise l'erreur. Cela permet au réseau d'apprendre à mieux effectuer sa tâche de classification ou de prédiction en minimisant l'erreur entre les sorties prédites et les sorties attendues. Le calcul du gradient est réalisé par rétropropagation, qui consiste à propager l'erreur à travers les couches du réseau en utilisant la règle de la chaîne de dérivées.

Un réseau de neurones quant à lui est défini par un ensemble de neurones interconnectés par des liens pondérés  $w_i$ , dans lesquels l'entrée de chaque neurone (à l'exception de ceux de la couche d'entrée) est définie par :

$$S_i = \sum x_i \cdot w_i \quad (19)$$

Chacun de ces neurones porte une fonction d'activation qui modifie le signal reçu à sa sortie  $y_i$ , par exemple :

- La fonction binaire :

$$f(x) = \begin{cases} 0 & \text{pour } x < 0 \\ 1 & \text{pour } x \geq 0 \end{cases} \quad (20)$$

- La fonction linéaire :

$$f(x) = x \quad (21)$$

- La fonction sigmoïde :

$$f(x) = \frac{1}{1 + e^{-x}} \quad (22)$$

Cette fonction est souvent utilisée pour les couches de sortie d'un réseau de neurones. Elle prend en entrée un nombre réel et renvoie une valeur entre 0 et 1.

- La fonction ReLU (Rectified Linear Unit) :

$$f(x) = \max(0, x) \quad (23)$$

Cette fonction est souvent utilisée pour les couches cachées d'un réseau de neurones. Elle prend en entrée un nombre réel et renvoie la valeur maximale entre 0 et l'entrée.

- La fonction tangente hyperbolique :

$$f(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \quad (24)$$

Cette fonction est similaire à la fonction sigmoïde, mais elle renvoie des valeurs comprises entre -1 et 1.

- La fonction Softmax :

$$\text{softmax}(z_i) = \frac{\exp(z_i)}{\sum_i \exp(z_i)} \quad (25)$$

Cette fonction est utilisée pour les couches de sortie d'un réseau de neurones pour des tâches de classification. Elle prend en entrée un vecteur de nombres réels et renvoie un vecteur de nombres réels compris entre 0 et 1 qui sont des probabilités.

Enfin, les ANN ont des avantages tels que la capacité à gérer des données non linéaires et à apprendre à partir de données non étiquetées. Cependant, ils peuvent rencontrer des difficultés à gérer des données bruyantes et peuvent être sujets au surapprentissage si les données d'entraînement ne sont pas suffisamment variées.

Dans ce travail de recherche, nous avons élaboré un perceptron multicouche dont la conception repose sur le code suivant. Ce dernier est spécifiquement destiné à la réalisation d'une tâche de classification complexe inhérente à notre domaine d'étude.

La fonction `build_classifier` prend en compte les spécifications essentielles telles que le nombre d'unités dans les couches cachées (`units1` et `units2`), la fonction d'activation à chaque couche (`activationFunction`), ainsi que l'optimiseur utilisé pour guider l'apprentissage (`optimizer`). Ce souci de modularité confère à notre perceptron multicouche une adaptabilité face aux exigences spécifiques de notre problématique de recherche.

La phase de compilation effectuée par le biais de la méthode `compile`, comporte l'optimiseur, le type de perte (`loss`), et les métriques de performance qui sont définis de manière précise. Par la suite, l'instanciation du modèle est réalisée à travers l'utilisation d'un objet `KerasClassifier`. Les paramètres de la grille de recherche (`grid_search`) témoignent d'une démarche systématique visant à explorer et optimiser les performances du modèle sur une gamme variée de configurations. Les éléments tels que la taille du lot (`batch_size`), le nombre d'époques (`epochs`), et d'autres paramètres clés sont minutieusement spécifiés pour garantir une évaluation exhaustive.

```
def build_classifier(units1, units2, activationFunction, optimizer):
    classifier = Sequential()
    classifier.add(Dense(units = units1, kernel_initializer = 'uniform',
activation = activationFunction, input_dim = 253))
classifier.add(Dense(units = units2, kernel_initializer = 'uniform',
activation = 'sigmoid'))
    classifier.compile(optimizer = optimizer,
                      loss = 'binary_crossentropy',
                      metrics = ['accuracy'])
    return classifier

classifier = KerasClassifier(build_fn=build_classifier)
parameters = {"units1": [2],
              "units2": [1],
              "activationFunction": ["relu"],
              "batch_size": [35],
              "epochs": [300],
              "optimizer": ["adam"]}
grid_search = GridSearchCV(estimator=classifier,
                           param_grid=parameters,
                           scoring="accuracy",
                           cv=10,
                           n_jobs=-1)
```

## Références

- [1] Wander J D, Blakely T, Miller K J, Weaver K E, Johnson L A, Olson J D, Fetz E E, Rao R P N and Ojemann J G 2013 Distributed cortical adaptation during learning of a brain–computer interface task *Proceedings of the National Academy of Sciences* **110** 10818–23
- [2] Nourmohammadi A, Jafari M and Zander T 2018 A Survey on Unmanned Aerial Vehicle Remote Control Using Brain–Computer Interface *IEEE Transactions on Human-Machine Systems* **PP** 1–12
- [3] Abiri R, Borhani S, Sellers E W, Jiang Y and Zhao X 2019 A comprehensive review of EEG-based brain–computer interface paradigms *J. Neural Eng.* **16** 011001
- [4] Takabi H, Bhalotiya A and Alohalay M 2016 Brain Computer Interface (BCI) Applications: Privacy Threats and Countermeasures 2016 *IEEE 2nd International Conference on Collaboration and Internet Computing (CIC)* 2016 IEEE 2nd International Conference on Collaboration and Internet Computing (CIC) (Pittsburgh, PA, USA: IEEE) pp 102–11
- [5] Chamola V, Vineet A, Nayyar A and Hossain E 2020 Brain-Computer Interface-Based Humanoid Control: A Review *Sensors* **20** 3620
- [6] Altaheri H, Muhammad G, Alsulaiman M, Amin S U, Altuwaijri G A, Abdul W, Bencherif M A and Faisal M 2021 Deep learning techniques for classification of electroencephalogram (EEG) motor imagery (MI) signals: a review *Neural Comput & Applic*
- [7] Barachant A 2012 Commande robuste d'un effecteur par une interface cerveau machine EEG asynchrone 190
- [8] Chevallier S, Kalunga E K, Barthélemy Q and Monacelli E 2021 Review of Riemannian Distances and Divergences, Applied to SSVEP-based BCI *Neuroinformatics* **19** 93–106
- [9] Yger F, Berar M and Lotte F 2017 Riemannian Approaches in Brain-Computer Interfaces: A Review *IEEE Trans. Neural Syst. Rehabil. Eng.* **25** 1753–62
- [10] Barachant A, Bonnet S, Congedo M and Jutten C 2013 Classification of covariance matrices using a Riemannian-based kernel for BCI applications *Neurocomputing* **112** 172–8
- [11] Dadebayev D, Goh W W and Tan E X 2022 EEG-based emotion recognition: Review of commercial EEG devices and machine learning techniques *Journal of King Saud University - Computer and Information Sciences* **34** 4385–401
- [12] Cannan J and Hu H Human-Machine Interaction (HMI): A Survey
- [13] Proesmans N Brain Computer Interfaces using Machine Learning: Reducing calibration time in Motor Imagery
- [14] Pinède N and Lespinet-Najib V 2019 Numérique et situations de handicap : le projet « Fractures corporelles, Fractures numériques » *Communication et organisation. Revue scientifique francophone en Communication organisationnelle* 139–48
- [15] Trad D, Al-Ani T and Jemni M 2012 *Thesis by Dalila TRAD*

- [16] Värbu K, Muhammad N and Muhammad Y 2022 Past, Present, and Future of EEG-Based BCI Applications *Sensors* **22** 3331
- [17] Voznenko T I, Chepin E V and Urvanov G A 2018 The Control System Based on Extended BCI for a Robotic Wheelchair *Procedia Computer Science* **123** 522–7
- [18] Katyal K D, Johannes M S, Kellis S, Aflalo T, Klaes C, McGee T G, Para M P, Shi Y, Lee B, Pejsa K, Liu C, Wester B A, Tenore F, Beaty J D, Ravitz A D, Andersen R A and McLoughlin M P 2014 A collaborative BCI approach to autonomous control of a prosthetic limb system *2014 IEEE International Conference on Systems, Man, and Cybernetics (SMC) 2014 IEEE International Conference on Systems, Man and Cybernetics - SMC (San Diego, CA, USA: IEEE)* pp 1479–82
- [19] Rakotomamonjy A and Guigue V 2008 BCI Competition III: Dataset II- Ensemble of SVMs for BCI P300 Speller *IEEE Trans. Biomed. Eng.* **55** 1147–54
- [20] Velasco-Álvarez F, Fernández-Rodríguez Á and Ron-Angevin R 2022 Brain-computer interface (BCI)-generated speech to control domotic devices *Neurocomputing* **509** 121–36
- [21] Olivieri E, Barresi G and Mattos L S 2015 BCI-based user training in surgical robotics *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* pp 4918–21
- [22] Dirksen R T, Eisner D A, Ríos E and Sipido K R 2022 Excitation–contraction coupling in cardiac, skeletal, and smooth muscle *Journal of General Physiology* Rockefeller University Press
- [23] Cohen 1959 Richard Caton (1842–1926) Pioneer Electrophysiologist *Proceedings of the Royal Society of Medicine* **52** 645–51
- [24] Haas L F 2003 Hans Berger (1873–1941), Richard Caton (1842–1926), and electroencephalography *Journal of Neurology, Neurosurgery & Psychiatry* **74** 9–9
- [25] Satyanarayana D P, Raju D R S, Manaswi C and Draivid P S 2015 A PILOT STUDY OF EEG PATTERN IN CONGENITAL BLIND CHILDREN **2**
- [26] Karbowski K 1995 [Electroencephalography and epileptology in the 20th century] *Praxis (Bern 1994)* **84** 1465–73
- [27] Herrmann C S, Strüber D, Helfrich R F and Engel A K 2016 EEG oscillations: From correlation to causality *International Journal of Psychophysiology* **103** 12–21
- [28] Prof. Christos P. Panteliadis\* 2021 Historical Overview of Electroencephalography: from Antiquity to the Beginning of the 21st Century
- [29] Walter W G, Dovey V J and Shipton H 1946 Analysis of the Electrical Response of the Human Cortex to Photic Stimulation *Nature* **158** 540–1
- [30] Barbara J-G 2018 Localiser les enregistrements et les stimulations électriques du cerveau par la stéréotaxie *Bulletin d'histoire et d'épistémologie des sciences de la vie* **Volume 25** 169
- [31] Kennedy J L and Travis R C 1948 Surface Electrodes for Recording Bioelectric Potentials *Science* **108** 183–183

- [32] Seitz P R 2002 French origins of the cochlear implant *Cochlear Implants International* **3** 77–86
- [33] Nijholt A, Jacob R J K, Andujar M, Yuksel B F and Leslie G 2018 Brain-Computer Interfaces for Artistic Expression *Extended Abstracts of the 2018 CHI Conference on Human Factors in Computing Systems* CHI '18: CHI Conference on Human Factors in Computing Systems (Montreal QC Canada: ACM) pp 1–7
- [34] Evarts E V 1968 A technique for recording activity of subcortical neurons in moving animals *Electroencephalography and Clinical Neurophysiology* **24** 83–6
- [35] Mudry A and Mills M 2013 The Early History of the Cochlear Implant: A Retrospective *JAMA Otolaryngology–Head & Neck Surgery* **139** 446–53
- [36] Carmena J M 2012 Becoming Bionic *IEEE Spectrum* **49** 24–9
- [37] Arafat I Brain Computer Interface: Past, Present & Future *International Islamic University Chittagong (IIUC) Chittagong, Bangladesh*
- [38] Barrera A 2011 *Advances in Robot Navigation* (BoD – Books on Demand)
- [39] Wolpaw J R, Birbaumer N, Heetderks W J, McFarland D J, Peckham P H, Schalk G, Donchin E, Quatrano L A, Robinson C J and Vaughan T M 2000 Brain-computer interface technology: a review of the first international meeting *IEEE Trans. Rehab. Eng.* **8** 164–73
- [40] Wang L, Li C and Wu J 2017 The Status of Research into Intention Recognition *Improving the Quality of Life for Dementia Patients through Progressive Detection, Treatment, and Care* 201–21
- [41] Bozinovski S, Sestakov M and Bozinovska L 1988 Using EEG alpha rhythm to control a mobile robot *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society* Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society pp 1515–6 vol.3
- [42] Kennedy P R and Bakay R a. E 1998 Restoration of neural output from a paralyzed patient by a direct brain connection *NeuroReport* **9** 1707
- [43] Stanley G B, Li F F and Dan Y 1999 Reconstruction of Natural Scenes from Ensemble Responses in the Lateral Geniculate Nucleus *J. Neurosci.* **19** 8036–42
- [44] Viswanath A, Swathi H and Saseendran A 2014 *A Novel Motor Imagery Classification for Brain Computer Interfacing*
- [45] Brower V 2005 When mind meets machine *EMBO Rep* **6** 108–10
- [46] O’Doherty J E, Lebedev M A, Ifft P J, Zhuang K Z, Shokur S, Bleuler H and Nicolelis M A L 2011 Active tactile exploration using a brain–machine–brain interface *Nature* **479** 228–31
- [47] Lee B, Liu C Y and Apuzzo M L J 2013 A Primer on Brain–Machine Interfaces, Concepts, and Technology: A Key Element in the Future of Functional Neurorestoration *World Neurosurgery* **79** 457–71
- [48] Kulshreshth A, Anand A and Lakanpal A 2019 Neuralink- An Elon Musk Start-up Achieve symbiosis with Artificial Intelligence *2019 International Conference on Computing,*

*Communication, and Intelligent Systems (ICCCIS) 2019 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS) pp 105–9*

- [49] Segado M 2017 Military Applications of Invasive Brain Stimulation [Industry Viewpoint] *IEEE Technology and Society Magazine* **36** 13–5
- [50] Martins H M G 2022 The Upper Limit: An Essay on Mental Integrity and Mental Enhancement *Medicine, Law & Society* **15**
- [51] Smalley E 2019 The business of brain–computer interfaces *Nature Biotechnology* **37** 978–82
- [52] Yacine F, Salah H, Amar K and Ahmad K 2022 A novel ANN adaptive Riemannian-based kernel classification for motor imagery *Biomed. Phys. Eng. Express* **9** 015010
- [53] Yuan H, Li Y, Yang J, Li H, Yang Q, Guo C, Zhu S and Shu X 2021 State of the Art of Non-Invasive Electrode Materials for Brain–Computer Interface *Micromachines* **12** 1521
- [54] Teplan M 2002 FUNDAMENTALS OF EEG MEASUREMENT *MEASUREMENT SCIENCE REVIEW* **2**
- [55] Komorowski D 2018 EGG DWPack: System for Multi-Channel Electrogastrographic Signals Recording and Analysis *J Med Syst* **42** 201
- [56] Hussien H R, El-Kenawy E-S M and El-Desouky A I 2021 EEG Channel Selection Using A Modified Grey Wolf Optimizer *European Journal of Electrical Engineering and Computer Science* **5** 17–24
- [57] Wang X, Yang R and Huang M 2022 An Unsupervised Deep-Transfer-Learning-Based Motor Imagery EEG Classification Scheme for Brain–Computer Interface *Sensors* **22** 2241
- [58] de Jaeger C and Cherin P 2009 Intérêt des potentiels évoqués cognitifs dans l'étude du vieillissement chez l'homme *Médecine & Longévité* **1** 44–55
- [59] Sandrini G and Rossi P 2010 The clinical neurophysiology of tension-type headache ScienceDirect-ELSEVIER Volume 97 pp 367-376
- [60] Kapeller C, Hintermuller C, Abu-Alqumsan M, Pruckl R, Peer A and Guger C 2013 A BCI using VEP for continuous control of a mobile robot *Annu Int Conf IEEE Eng Med Biol Soc* **2013** 5254–7
- [61] Kalaivaazhi R and Kumar D 2012 Feature extraction in P 100 detection for classification of pattern visual evoked potential (P-VEP) signals correlated with occlusion therapy for squint eyes *WSEAS Transactions on Information Science and Applications* **9** 210–9
- [62] Li M, Yang G, Liu Z, Gong M, Xu G and Lin F 2021 The Effect of SOA on An Asynchronous ERP and VEP-Based BCI *IEEE Access* **9** 9972–81
- [63] Odom J V, Bach M, Barber C, Brigell M, Marmor M F, Tormene A P and Holder G E Visual evoked potentials standard (2004)
- [64] Diez P F, Mut V A, Avila Perona E M and Laciár Leber E 2011 Asynchronous BCI control using high-frequency SSVEP *Journal of NeuroEngineering and Rehabilitation* **8** 39
- [65] Plourde G 2006 Auditory evoked potentials *Best Practice & Research Clinical Anaesthesiology* **20** 129–39

- [66] Islam M N, Sulaiman N, Bari B S, Rashid M and Mustafa M 2021 Auditory Evoked Potential (AEP) Based Brain-Computer Interface (BCI) Technology: A Short Review *Advances in Robotics, Automation and Data Analytics Advances in Intelligent Systems and Computing* ed J A Mat Jizat, I M Khairuddin, M A Mohd Razman, A F Ab. Nasir, M S Abdul Karim, A A Jaafar, L W Hong, A P P Abdul Majeed, P Liu, H Myung, H-L Choi and G-A Susto (Cham: Springer International Publishing) pp 272–84
- [67] Cai Z, Makino S and Rutkowski T M 2015 Brain Evoked Potential Latencies Optimization for Spatial Auditory Brain–Computer Interface *Cogn Comput* **7** 34–43
- [68] Boston J R 1981 Spectra of Auditory Brainstem Responses and Spontaneous EEG *IEEE Transactions on Biomedical Engineering BME-28* 334–41
- [69] Belwafi K 2017 *Conception d’une architecture embarquée adaptable pour le déploiement d’applications d’interface cerveau machine* phdthesis (Université de Cergy Pontoise ; Ecole Nationale d’Ingénieurs de Sousse (Tunisie))
- [70] Lorenz J and Garcia-Larrea L 2003 Contribution of attentional and cognitive factors to laser evoked brain potentials *Neurophysiologie Clinique/Clinical Neurophysiology* **33** 293–301
- [71] Ahn S, Kim K and Jun S C 2016 Steady-State Somatosensory Evoked Potential for Brain-Computer Interface—Present and Future *Frontiers in Human Neuroscience* **9**
- [72] Pfurtscheller G 1991 EEG Rhythms - Event-Related Desynchronization and Synchronization *Rhythms in Physiological Systems* Springer Series in Synergetics ed H Haken and H P Koepchen (Berlin, Heidelberg: Springer) pp 289–96
- [73] Mercier J 2015 *Contribution to the study of the use of brain-computer interfaces in virtual and augmented reality* phdthesis (INSA de Rennes)
- [74] Mariman J J, Bruna-Melo T, Gutierrez-Rodriguez R, Maldonado P E and Burgos P I 2023 Event-related (de)synchronization and potential in whole vs. part sensorimotor learning *Frontiers in Systems Neuroscience* **17**
- [75] Derambure P, Defebvre L, Bourriez J L, Cassim F and Guieu J D 1999 Désynchronisation et synchronisation liées à l’événement Étude de la réactivité des rythmes électrocorticaux en relation avec la planification et l’exécution du mouvement volontaire *Neurophysiologie Clinique/Clinical Neurophysiology* **29** 53–70
- [76] Pfurtscheller G, Neuper C and Mohl W 1994 Event-related desynchronization (ERD) during visual processing *International Journal of Psychophysiology* **16** 147–53
- [77] Pfurtscheller G and Neuper C 2001 Motor imagery and direct brain-computer communication *Proceedings of the IEEE* **89** 1123–34
- [78] Prashant P, Joshi A and Gandhi V 2015 Brain computer interface: A review 2015 5th Nirma University International Conference on Engineering (NUICONE) 2015 5th Nirma University International Conference on Engineering (NUICONE) pp 1–6
- [79] Luck S J 2012 Event-related potentials *APA handbook of research methods in psychology, Vol 1: Foundations, planning, measures, and psychometrics* APA handbooks in psychology® (Washington, DC, US: American Psychological Association) pp 523–46

- [80] Nooh A A, Yunus J and Mohd Daud S 2011 *A Review of Asynchronous Electroencephalogram-based Brain Computer Interface Systems*
- [81] Lu J, Speier W, Hu X and Pouratian N 2013 The effects of stimulus timing features on P300 speller performance *Clinical Neurophysiology* **124** 306–14
- [82] Barachant A 2012 *Robust control of an actuator by EEG based asynchronous BCI* phdthesis (Université de Grenoble)
- [83] Chen Y-J, Chen S-C, Zaeni I A E and Wu C-M 2016 Fuzzy Tracking and Control Algorithm for an SSVEP-Based BCI System *Applied Sciences* **6** 270
- [84] Pfurtscheller G, Allison B, Bauernfeind G, Brunner C, Solis Escalante T, Scherer R, Zander T, Mueller-Putz G, Neuper C and Birbaumer N 2010 The hybrid BCI *Frontiers in Neuroscience* **4**
- [85] Paillard J *Système nerveux et fonction d'organisation*
- [86] Math F, Kahn J-P and Vignal J-P 2008 Chapitre 6. Comportements cognitifs : apprentissage, mémoire, communication *Neurosciences cliniques Neurosciences & cognition* (Louvain-la-Neuve: De Boeck Supérieur) pp 305–65
- [87] Netter F H and CO J S & 2023 *Atlas Netter d'anatomie humaine* (Elsevier Health Sciences)
- [88] Levin M C 2021 *Moelle épinière - Troubles du cerveau, de la moelle épinière et des nerfs Manuels MSD pour le grand public*
- [89] Sherwood L 2015 *Physiologie humaine* (De Boeck Supérieur)
- [90] Ngor A, Steiner A J, Pakhdikian S, Okikawa D, Pizano D, Younan L, Cohen S and IsHak W W 2023 Bipolar and Related Disorders *Atlas of Psychiatry* ed W W IsHak (Cham: Springer International Publishing) pp 493–529
- [91] Amar M B and Léonard L 2002 *Les psychotropes: pharmacologie et toxicomanie* (PUM)
- [92] Sherwood L 2015 *Physiologie humaine* (De Boeck) *Sauramps Medical*
- [93] Flament-Durand J 1982 Le cerveau : morphologie et fonctions *Bulletins de l'Académie Royale de Belgique* **64** 143–57
- [94] Boucher O, Citherlet D, Ghaziri J, Hébert-Seropian B, Von Siebenthal Z and Nguyen D K 2017 *Insula : neuropsychologie du cinquième lobe du cerveau Revue de neuropsychologie* **9** 154–61
- [95] Pichon S and Vuilleumier P 2011 Neuro-imagerie et neuroscience des émotions: Imagerie et cognition (8) *Med Sci (Paris)* **27** 763–70
- [96] Mader S S, Dubois N and Pelletier N 2009 *Biologie humaine* (Chenelière éducation)
- [97] Coon E 2023 *Présentation du système nerveux autonome - Troubles du cerveau, de la moelle épinière et des nerfs Manuels MSD pour le grand public*
- [98] Lee S 2020 *Anatomie et physiologie du système nerveux Société canadienne du cancer*
- [99] Massion J 1997 *Cerveau et motricité: Fonctions sensori-motrices Presses Universitaires de France (Réédition Numérique Fenixx)*

- [100] Rigal R 2003 *Motricité humaine - Tome 2: Fondements et applications pédagogiques* (PUQ)
- [101] Quesada M C 2018 *L'effet antalgique de stimulations corticales non invasives par stimulation magnétique transcrânienne répétée (rTMS). Confirmation de l'intérêt antalgique de la stimulation du cortex moteur primaire et exploration du potentiel d'une nouvelle cible corticale : le cortex somatosensoriel secondaire* phdthesis (UNIVERSITE DE LYON (UJM Saint-Etienne))
- [102] Mathon B 2013 Les neurones miroirs : de l'anatomie aux implications physiopathologiques et thérapeutiques *Revue Neurologique* **169** 285–90
- [103] Clarac F and Ternaux J-P 2008 Chapitre 4. Le cerveau moteur : de l'observation aux fonctions *Encyclopédie historique des neurosciences Neurosciences & cognition* (Louvain-la-Neuve: De Boeck Supérieur) pp 123–73
- [104] Zeng C, Mu Z and Wang Q 2022 Classifying Driving Fatigue by Using EEG Signals *Computational Intelligence and Neuroscience* **2022** 1–13
- [105] Pavot-Lemoine C 2018 Chap 5. Le cerveau, les sens et l'apport des neurosciences *Des bébés et des crèches Petite enfance* (Paris: Dunod) pp 99–147
- [106] Tran H 2019 *Signatures extracellulaires des potentiels d'action neuronaux: modélisation et analyse*
- [107] Bacq Z M 1935 La Transmission chimique des Influx dans le Système nerveux autonome *Ergebnisse der Physiologie und exper. Pharmakologie* **37** 82–185
- [108] Prevost V 2018 *Validation du transfert d'aimantation inhomogène (ihMT) comme nouveau biomarqueur IRM de la myéline* These de doctorat (Aix-Marseille)
- [109] Clarac F and Ternaux J-P 2008 Chapitre 9. De l'activité électrique des assemblées de neurones à la création des neurosciences *Encyclopédie historique des neurosciences Neurosciences & cognition* (Louvain-la-Neuve: De Boeck Supérieur) pp 335–79
- [110] Klimesch W 2012 Alpha-band oscillations, attention, and controlled access to stored information *Trends Cogn Sci* **16** 606–17
- [111] Spitzer B and Haegens S 2017 Beyond the Status Quo: A Role for Beta Oscillations in Endogenous Content (Re)Activation *eNeuro* **4** ENEURO.0170-17.2017
- [112] Jia X and Kohn A 2011 Gamma Rhythms in the Brain *PLOS Biology* **9** e1001045
- [113] Yuval-Greenberg S, Tomer O, Keren A S, Nelken I and Deouell L Y 2008 Transient induced gamma-band response in EEG as a manifestation of miniature saccades *Neuron* **58** 429–41
- [114] Harmony T 2013 The functional significance of delta oscillations in cognitive processing *Front Integr Neurosci* **7** 83
- [115] Klimesch W 1999 EEG alpha and theta oscillations reflect cognitive and memory performance: a review and analysis *Brain Res Brain Res Rev* **29** 169–95
- [116] Craig A, Tran Y, Wijesuriya N and Nguyen H 2012 Regional brain wave activity changes associated with fatigue *Psychophysiology* **49** 574–82

- [117] Fu R, Tian Y, Bao T, Meng Z and Shi P 2019 Improvement Motor Imagery EEG Classification Based on Regularized Linear Discriminant Analysis *J Med Syst* **43** 169
- [118] Chanoine V and Badier J-M 2016 Chapitre 4. Techniques de neuro-imagerie *Traité de neurolinguistique* (De Boeck Supérieur) pp 45–63
- [119] Khouaja I Imagerie cérébrale: Traitement et Modélisation Embarqués
- [120] Wagner A, Ille S, Liesenhoff C, Aftahy K, Meyer B and Krieg S M 2022 Improved potential quality of intraoperative transcranial motor-evoked potentials by navigated electrode placement compared to the conventional ten-twenty system *Neurosurg Rev* **45** 585–93
- [121] Mecarelli O 2019 *Clinical Electroencephalography* (Cham: Springer International Publishing)
- [122] Lee C-J and Song J-I 2019 A Chopper Stabilized Current-Feedback Instrumentation Amplifier for EEG Acquisition Applications *IEEE Access* **7** 11565–9
- [123] Walden R H 1999 Analog-to-digital converter survey and analysis *IEEE Journal on Selected Areas in Communications* **17** 539–50
- [124] Hinrichs H 1987 EEG Data Acquisition *NPS* **17** 77–84
- [125] Rampil I J 1998 A Primer for EEG Signal Processing in Anesthesia *Anesthesiology* **89** 980–1002
- [126] Rebai C 2002 *Contribution à la Caractérisation des Convertisseurs Analogiques Numériques haute performances : Mise en œuvre de nouveaux systèmes de traitement du signal pour le test in-situ*. phdthesis (Université Bordeaux 1)
- [127] Vercueil L 2011 Apport de l'EEG en médecine d'urgence: principales indications et contribution au diagnostic et à la prise en charge *Annales françaises de médecine d'urgence* **1**
- [128] Blanc-Feraud L, Caruyer E, Jutten C and Liebgott H 2022 *Le corps en images. Nouvelles imageries pour la santé* (CNRS Editions)
- [129] Campagne A and Vercueil L 2013 Chapitre 1. Électroencéphalographie *Électrophysiologie de la cognition* Psycho Sup (Paris: Dunod) pp 17–55
- [130] Subasi A 2019 *Practical Guide for Biomedical Signals Analysis Using Machine Learning Techniques*
- [131] Jedrzejewski F 2017 Deleuze et la Géométrie Riemannienne: Une Topologie des Multiplicités *From Riemann to Differential Geometry and Relativity* pp 311–28
- [132] Colmez P Espaces vectoriels de dimension finie et représentations de de Rham
- [133] Labourie F 1994 Exemples de courbes pseudo-holomorphes en géométrie riemannienne *Holomorphic Curves in Symplectic Geometry* Progress in Mathematics ed M Audin and J Lafontaine (Basel: Birkhäuser) pp 251–69
- [134] Guillopé L Fonctions zêta de Selberg et surfaces de géométrie finie
- [135] Agrachev A A 2016 Topics in sub-Riemannian geometry *Russ. Math. Surv.* **71** 989–1019

- [136] Rajala K 2005 The local homeomorphism property of spatial quasiregular mappings with distortion close to one *GAFA, Geom. funct. anal.* **15** 1100–27
- [137] Lotte F, Bougrain L, Cichocki A, Clerc M, Congedo M, Rakotomamonjy A and Yger F 2018 A review of classification algorithms for EEG-based brain–computer interfaces: a 10 year update *J. Neural Eng.* **15** 031005
- [138] Jost J 2011 *Riemannian Geometry and Geometric Analysis* (Berlin, Heidelberg: Springer)
- [139] Barachant A, Bonnet S, Congedo M and Jutten C 2012 Multiclass Brain–Computer Interface Classification by Riemannian Geometry *IEEE Transactions on Biomedical Engineering* **59** 920–8
- [140] Yger F, Lotte F and Sugiyama M 2015 Averaging covariance matrices for EEG signal classification based on the CSP: An empirical study *2015 23rd European Signal Processing Conference (EUSIPCO) 2015 23rd European Signal Processing Conference (EUSIPCO)* pp 2721–5
- [141] Kalunga E, Chevallier S, Barthélemy Q, Djouani K, Monacelli E and Hamam Y 2016 Online SSVEP-based BCI using Riemannian geometry *Neurocomputing* **191** 55–68
- [142] Moakher M 2005 A Differential Geometric Approach to the Geometric Mean of Symmetric Positive-Definite Matrices *SIAM J. Matrix Anal. Appl.* **26** 735–47
- [143] Tharwat A, Gaber T, Ibrahim A and Hassanien A E 2017 Linear discriminant analysis: A detailed tutorial *AIC* **30** 169–90
- [144] Muthukrishnan N, Maleki F, Ovens K, Reinhold C, Forghani B and Forghani R 2020 Brief History of Artificial Intelligence *Neuroimaging Clinics of North America* **30** 393–9
- [145] Mishra Z, Mishra B K and Aloosh O 2019 Impact of Artificial Intelligence on the Healthcare Industry
- [146] Cunningham P, Cord M and Delany S J 2008 Supervised Learning *Machine Learning Techniques for Multimedia: Case Studies on Organization and Retrieval* Cognitive Technologies ed M Cord and P Cunningham (Berlin, Heidelberg: Springer) pp 21–49
- [147] Ghahramani Z 2004 Unsupervised Learning *Advanced Lectures on Machine Learning: ML Summer Schools 2003, Canberra, Australia, February 2 - 14, 2003, Tübingen, Germany, August 4 - 16, 2003, Revised Lectures* Lecture Notes in Computer Science ed O Bousquet, U von Luxburg and G Rätsch (Berlin, Heidelberg: Springer) pp 72–112
- [148] Chassagnon G, Vakalopolou M, Paragios N and Revel M-P 2020 Deep learning: definition and perspectives for thoracic imaging *Eur Radiol* **30** 2021–30
- [149] Charniak E 2021 *Introduction au Deep Learning* (Dunod)
- [150] Gyamfi N K and Abdulai J-D 2018 *Bank Fraud Detection Using Support Vector Machine*
- [151] Alzahab N A, Apollonio L, Di Iorio A, Alshalak M, Iarlori S, Ferracuti F, Monteriù A and Porcaro C 2021 Hybrid Deep Learning (hDL)-Based Brain-Computer Interface (BCI) Systems: A Systematic Review *Brain Sciences* **11** 75

- [152] Bahadure N B, Ray A K and Thethi H P 2017 Image Analysis for MRI Based Brain Tumor Detection and Feature Extraction Using Biologically Inspired BWT and SVM *International Journal of Biomedical Imaging* **2017** e9749108
- [153] Noble W S 2006 What is a support vector machine? *Nat Biotechnol* **24** 1565–7
- [154] Loosli G, Canu S and Bottou L 2006 SVM et apprentissage des très grandes bases de données
- [155] Lin J-S and She B-H 2020 A BCI System with Motor Imagery Based on Bidirectional Long-Short Term Memory *IOP Conf. Ser.: Mater. Sci. Eng.* **719** 012026
- [156] Ravi A, Beni N H, Manuel J and Jiang N 2020 Comparing user-dependent and user-independent training of CNN for SSVEP BCI *J. Neural Eng.* **17** 026028
- [157] Chakravarthi B, Ng S-C, Ezilarasan M R and Leung M-F 2022 EEG-based emotion recognition using hybrid CNN and LSTM classification *Frontiers in Computational Neuroscience* **16**
- [158] Bhatt D, Patel C, Talsania H, Patel J, Vaghela R, Pandya S, Modi K and Ghayvat H 2021 CNN Variants for Computer Vision: History, Architecture, Application, Challenges and Future Scope *Electronics* **10** 2470
- [159] Gelly G Réseaux de neurones récurrents pour le traitement automatique de la parole
- [160] Morere Y Les Réseaux de Neurones Récurrents
- [161] Jung Y 2018 Multiple predicting K-fold cross-validation for model selection *Journal of Nonparametric Statistics* **30** 197–215
- [162] Ingolfsson T M, Hersche M, Wang X, Kobayashi N, Cavigelli L and Benini L 2020 EEG-TCNet: An Accurate Temporal Convolutional Network for Embedded Motor-Imagery Brain-Machine Interfaces
- [163] Xu B, Zhang L, Song A, Wu C, Li W, Zhang D, Xu G, Li H and Zeng H 2019 Wavelet Transform Time-Frequency Image and Convolutional Network-Based Motor Imagery EEG Classification *IEEE Access* **7** 6084–93
- [164] Gaur P, Gupta H, Chowdhury A, Mc Creadie K, Pachori R B and Wang H 2021 A Sliding Window Common Spatial Pattern for Enhancing Motor Imagery Classification in EEG-BCI *IEEE Transactions on Instrumentation and Measurement* **70** 1–9
- [165] Bria A, Marrocco C and Tortorella F 2021 Sinc-based convolutional neural networks for EEG-BCI-based motor imagery classification
- [166] Dong Y, Han D, Wen X, Gao C, Cao R, Guo Y, Xiang J and Cao R 2022 *Subject-independent EEG classification of motor imagery based on a dual-branch feature fusion* (In Review)
- [167] Song Y, Yang L, Jia X and Xie L 2021 Common Spatial Generative Adversarial Networks based EEG Data Augmentation for Cross-Subject Brain-Computer Interface
- [168] Ang K, Chin Z, Zhang H and Guan C 2012 Mutual information-based selection of optimal spatial-temporal patterns for single-trial EEG-based BCIs *Pattern Recognition* **45** 2137–44

- [169] Liang Y and Ma Y 2020 Calibrating EEG features in motor imagery classification tasks with a small amount of current data using multisource fusion transfer learning *Biomedical Signal Processing and Control* **62** 102101
- [170] Weiss R, Karimijafarbigloo S, Roggenbuck D and Rödiger S 2022 Applications of Neural Networks in Biomedical Data Analysis *Biomedicines* **10** 1469
- [171] Shahid N, Rappon T and Berta W 2019 Applications of artificial neural networks in health care organizational decision-making: A scoping review *PLoS One* **14** e0212356
- [172] Barachant A, Bonnet S, Congedo M and Jutten C 2010 Riemannian Geometry Applied to BCI Classification *Latent Variable Analysis and Signal Separation Lecture Notes in Computer Science* ed V Vigneron, V Zarzoso, E Moreau, R Gribonval and E Vincent (Berlin, Heidelberg: Springer) pp 629–36
- [173] Chevallier S, Corsi M-C, Yger F and De Vico Fallani F 2022 Riemannian geometry for combining functional connectivity metrics and covariance in BCI *Software Impacts* **12** 100254
- [174] Brunner C, Leeb R, Muller-Putz G R and Schlogl A BCI Competition 2008 – Graz data set A 6

## Liste des tableaux

Tableau 1 : Historique de l'interface cerveau-machine.....	18
Tableau 2 : Exactitudes de classification (%) obtenues respectivement par les méthodes EGGNet, EEG-TCN <sub>ET</sub> , DFFN.....	66
Tableau 3 : Performances d'exactitude du modèle 2D et 1D.....	67
Tableau 4 : Exactitude (%) de la méthode SW-LCR.....	68
Tableau 5 : Exactitude (%) de la méthode SW-Mode.....	69
Tableau 6 : Comparatif de la méthode Sinc-EEG aux méthodes de références de l'étude.....	70
Tableau 7 : Performances des méthodes de classification dans le cadre inter-sujets.....	72
Tableau 8 : Exactitude des classifications (%) dans le contexte intra-sujets.....	73
Tableau 9 : Résultats expérimentaux dans un cadre de validation croisée à 10x10-fold cross validation.....	74
Tableau 10 : Performances de classification (%) des méthodes MDRM et FGMDM.....	75
Tableau 11 : Exactitudes des classifications avec une validation croisée.....	76
Tableau 12 : Comparatif des exactitudes de classification (%) des méthodes étudiées.....	77
Tableau 13 : Exactitude (%) moyenne des méthodes de classification.....	78
Tableau 14 : Comparatif entre méthode ANN et SVM dans le contexte intra-sujets.....	93
Tableau 15 : Résultats d'exactitude (%) de notre approche avec les méthodes étudiées de l'état de l'art.....	94
Tableau 16 : Performance du filtrage géodésique sur les différentes méthodes.....	94
Tableau 17 : comparatif entre méthode ARK-ANN et ARK-SVM dans le contexte inter-sujets.....	96
Tableau 18 : comparatif de notre approche avec les approches de la littérature dans un contexte inter-sujets.....	96

## Liste des figures

Figure 1 : Structure d'une interface cerveau-machine.....	21
Figure 2 : Constituants du système nerveux central.....	28
Figure 3 : Principaux lobes du cerveau.....	30
Figure 4 : Composantes et fonctions du système nerveux autonome.....	32
Figure 5 : Les aires fonctionnelles du cerveau.....	33
Figure 6 : Structure d'un neurone.....	34
Figure 7 : Configuration du système international 10-20.....	37
Figure 8 : Montage électronique de l'amplificateur différentiel.....	38
Figure 9 : Notion de passage de dimension infinie (a) à dimension finie (b).....	43
Figure 10 : Transformation topologique de l'espace sur un seul axe.....	44
Figure 11 : Transformation topologique du cylindre pour l'obtention d'un tore.....	44
Figure 12 : Représentation de la propriété localement vraie en « a » et localement.....	45
Figure 13 : Représentation de l'espace tangent $T_p$ .....	47
Figure 14 : Longueur minimale $l$ entre $P_1$ et $P_2$ .....	49
Figure 15 : Représentation du principe de classification par SVM.....	55
Figure 16 : Représentation d'un réseau de neurones convolutif.....	59
Figure 17 : Différence entre un réseau de neurones récurrent et un réseau de neurones à propagation avant.....	60
Figure 18 : Représentation de la 10 cross fold validation.....	61
Figure 19 : Transformation de données.....	83
Figure 20 : Perceptron multicouche utilisé dans notre étude.....	84

## Résumé

Au cours de ce travail de recherche, deux approches ont été étudiées ; la classification des signaux d'imagerie motrice par un perceptron multicouches à noyau riemannien adaptatif et le filtrage géodésique sur les méthodes à base SVM et ANN. La première partie a été consacrée à étudier les interfaces cerveau-machine et les méthodes déjà existantes. La seconde partie, s'est focalisée sur la reproduction de la méthode à géométrie riemannienne, la méthode ARK-SVM, pour ensuite présenter nos approches. Nous avons étudié d'une part l'application d'un filtrage géodésique sur la méthode SVM pour produire la FG-ARK-SVM avant de procéder, d'autre part à l'élaboration de la méthode ARK-ANN.

Ces approches ont été utilisées dans deux contextes de classification binaire. Le premier dans un contexte intra-sujet, où les modèles proposés ont appris sur le jeu de donnée du même sujet séparé en deux sessions d'enregistrement, la première pour l'entraînement et la seconde pour le test. Le deuxième contexte quant à lui est inter-sujet, où les modèles ont appris sur les sessions d'entraînement de divers sujets, pour faire une généralisation sur un sujet à part.

Les résultats ont démontré la robustesse de la méthode ARK-ANN, tant sur la partie intra-sujet que sur la partie inter-sujet. Cette méthode a été comparée à l'ARK-SVM et à des approches riemanniennes et non riemanniennes ayant exploité la même base de donnée, BCI Compétition IV set IIa. Le filtrage géodésique quant à lui a apporté des résultats différents en fonction de la méthode, avec une légère amélioration sur la méthode SVM, mais nous observons une dégradation des performances de la méthode à réseau de neurones, quel que soit le contexte de classification.

## **Abstract**

During this research work, two approaches were studied: the classification of motor imagery signals using an adaptive Riemannian kernel multilayer perceptron, and geodesic filtering on SVM and ANN-based methods. The first part was devoted to studying brain-machine interfaces and existing methods. The second part focused on reproducing the Riemannian geometry method, the ARK-SVM method, and then presenting our approaches. We investigated applying geodesic filtering to the SVM method to produce FG-ARK-SVM on one hand and developing the ARK-ANN method on the other hand.

These approaches were applied in two binary classification contexts. The first context was intra-subject, where the proposed models learned from the dataset of the same subject divided into two recording sessions: the first for training and the second for testing. The second context was inter-subject, where the models learned from the training sessions of various subjects to generalize to a separate subject.

The results demonstrated the robustness of the ARK-ANN method in both intra-subject and inter-subject scenarios. This method was compared to ARK-SVM and Riemannian and non-Riemannian approaches that utilized the same dataset, BCI Competition IV set IIa. Geodesic filtering, on the other hand, yielded different results depending on the method, with a slight improvement in the SVM method, but a degradation in the performance of the neural network method, regardless of the classification context.