





UNIVERSITÉ DE SHERBROOKE  
Faculté de génie  
Département de génie électrique et de génie informatique

# ENCODAGE D'UN SIGNAL AUDIO DANS UN ÉLECTROENCÉPHALOGRAMME

Mémoire de maîtrise  
Spécialité : génie électrique

Marc-Antoine MOINNEREAU

Jury : Éric PLOURDE (directeur)  
Kevin WHITTINGSTALL (co-directeur)  
Denis GINGRAS  
Yves BÉRUBÉ-LAUZIÈRE



# RÉSUMÉ

Les interfaces cerveau-machine visent à établir un lien de communication entre le cerveau et un système externe à ce dernier. Les électroencéphalogrammes (EEG), dans ce contexte, ont l'avantage d'être non invasifs. Par contre, l'information sensorielle qui se retrouve dans un signal EEG est beaucoup moins ciblée que dans un signal neuronal acquis par une méthode invasive. De plus, étant donné que le cortex auditif est situé dans des repliements du tissu cortical, les neurones qui déchargent, suite à un stimulus auditif, sont parallèles à la surface corticale sur laquelle les EEG sont enregistrés. Par conséquent, l'information auditive qui se retrouve dans le canal EEG situé vis-à-vis du cortex auditif est faible. L'objectif principal de ce projet de recherche consiste donc à étudier la répartition de l'information auditive dans l'ensemble des canaux EEG. Pour ce faire, nous utilisons deux approches. Dans la première, nous tenterons d'estimer l'activité corticale sous-jacente à partir des signaux EEG en utilisant un modèle de couplage bande fréquence. En effet, certaines bandes de fréquences sont des bons prédicteurs des décharges neuronales. Cependant, cette approche n'a pas été validée pour le système auditif, nous confronterons donc l'estimation obtenue à une autre estimation en ayant recours à un modèle spécialisé pour l'encodage du signal de parole faisant appel aux processus ponctuels. Ce modèle prend en compte les dynamiques intrasèques des neurones et également des propriétés spectrotemporelles du stimulus d'entrée. Dans la seconde approche, nous étudierons la possibilité de classifier 3 voyelles (a, i et u) en fonction du nombre de canaux EEG utilisés ainsi que leur répartition sur le cuir chevelu. Nous aurons recours, pour cela, à un réservoir de neurone à décharge récurrent activé en entrée par les données EEG. Les résultats démontrent que l'information auditive se retrouve en fait dans l'ensemble des canaux EEG et qu'elle n'est pas confinée à un nombre restreint d'électrodes. Il est également montré que lorsque l'on utilise les 64 électrodes que comporte l'EEG pour classifier les 3 voyelles, on obtient une classification de l'ordre de 80%, mais aussi qu'un nombre limité de 10 électrodes suffit pour obtenir une classification satisfaisante et, qu'en plus, la position de ces électrodes sur le cuir chevelu est peu importante.

**Mots-clés :** Électroencéphalogramme (EEG), Encodage neuronal, Modèle linéaire généralisé, Données spatio- et spectro-temporelles, Réservoir, Réseaux de neurones récurrents, Apprentissage machine, Cortex auditif



# REMERCIEMENTS

Ce mémoire est le résultat d'un travail de recherche de près de trois ans. Je veux donc adresser tous mes remerciements aux personnes avec lesquelles j'ai pu échanger et qui m'ont aidé pour la réalisation de ce projet.

Tout d'abord, je voudrais remercier mon directeur de recherche, Éric Plourde, pour sa confiance et sa grande disponibilité tout au long de ce projet. Je lui suis également très reconnaissant de m'avoir guidé et aidé à trouver des solutions pour avancer dans la réalisation du projet. Je remercie ensuite mon codirecteur, Kevin Whittingstall, pour ses précieux conseils et son implication dans mes recherches. Je remercie également Russell Butler pour sa patience et sa collaboration. Je tenais à remercier tout particulièrement Simon Brodeur qui m'a accordé un peu de son temps et qui m'a fourni des données techniques précises dans mon travail. J'adresse aussi mes remerciements à tous mes collègues du laboratoire NECOTIS de l'Université de Sherbrooke qui ont participé de près ou de loin à mes recherches.

Enfin, j'adresse mes plus sincères remerciements à ma famille, tous mes proches et amis, qui m'ont accompagné, aidé, soutenu et encouragé tout au long de ma recherche.





# TABLE DES MATIÈRES

<b>1</b>	<b>INTRODUCTION</b>	<b>1</b>
<b>2</b>	<b>ÉLÉMENTS DE PHONÉTIQUE ET DE NEUROPHYSIOLOGIE</b>	<b>5</b>
2.1	Phonétique . . . . .	5
2.2	De l'oreille jusqu'au cortex auditif . . . . .	7
2.2.1	Le système périphérique . . . . .	7
2.2.2	Le système auditif central : du noyau cochléaire au cortex auditif . . . . .	8
2.2.3	Le cortex auditif . . . . .	10
2.3	Activité électrique des neurones recueillis par l'EEG . . . . .	10
2.3.1	Les potentiels post-synaptiques et les potentiels d'actions . . . . .	11
2.3.2	Dipôle équivalent . . . . .	11
2.3.3	Le dispositif EEG . . . . .	12
2.3.4	Activité rythmique . . . . .	15
<b>3</b>	<b>ÉTAT DE L'ART</b>	<b>17</b>
3.1	Estimation de l'activité corticale . . . . .	17
3.1.1	Analyse des potentiels de champs locaux et de l'activité multi-unitaire . . . . .	18
3.1.2	Corrélation des signaux LFP avec les signaux BOLD . . . . .	19
3.1.3	Corrélation des signaux LFP avec les signaux EEG . . . . .	20
3.1.4	Modèle de couplage bande-fréquence . . . . .	21
3.2	Technique d'encodage du signal . . . . .	23
3.2.1	Modèle linéaire généralisé pour l'encodage . . . . .	23
3.3	Classification de données spatio- et spectro-temporelles . . . . .	26
3.3.1	Technique d'apprentissage machine standard . . . . .	26
3.3.2	Réseaux de neurones récurrents . . . . .	30
<b>4</b>	<b>MÉTHODOLOGIE</b>	<b>35</b>
4.1	Acquisition et prétraitement des signaux EEG . . . . .	35
4.1.1	Matériels . . . . .	35
4.1.2	Acquisition des données EEG . . . . .	35
4.1.3	Prétraitement des données EEG . . . . .	36
4.2	Potentiel évoqué . . . . .	37
4.3	Estimation de l'activité corticale . . . . .	38
4.3.1	Estimation de l'activité corticale à partir d'EEG . . . . .	38
4.3.2	Estimation de l'activité corticale avec un modèle d'encodage . . . . .	39
4.4	Classification à l'aide d'un réservoir de neurone à décharge récurrent . . . . .	41
4.4.1	Encodage des données . . . . .	41
4.4.2	Réservoir RNN . . . . .	42
4.4.3	Couche de sortie . . . . .	43
4.4.4	Classification . . . . .	44

<b>5</b>	<b>TRAITEMENT DES DONNÉES ET ANALYSE DES RÉSULTATS</b>	<b>45</b>
5.1	Potentiel évoqué . . . . .	45
5.2	Estimation de l'activité corticale . . . . .	49
5.2.1	Estimation de l'activité corticale à partir des EEGs . . . . .	49
5.2.2	Validation de l'activité corticale à l'aide d'un modèle d'encodage . .	51
5.2.3	Déviance relative . . . . .	53
5.3	Classification des données EEG . . . . .	54
5.3.1	Classification obtenue pour les 8 sujets . . . . .	54
5.3.2	Classification de l'estimation des décharges neuronales vs les données brutes . . . . .	55
5.3.3	Classification par région du cortex . . . . .	57
5.3.4	Classification par nombre d'électrodes . . . . .	58
5.3.5	Bilan de la classification . . . . .	60
<b>6</b>	<b>CONCLUSION</b>	<b>61</b>
	<b>LISTE DES RÉFÉRENCES</b>	<b>63</b>

# LISTE DES FIGURES

2.1	Triangle vocalique. . . . .	6
2.2	Coupe anatomique de l'oreille externe, moyenne et interne. . . . .	8
2.3	Voies auditives primaires. . . . .	9
2.4	Représentation du neurone. . . . .	10
2.5	Neurones pyramidaux perpendiculaires à la surface corticale. . . . .	12
2.6	A - Représentation spatiale des canaux EEG en fonction de leurs noms ; B - Représentation spatiale des canaux EEG en fonction de leurs numéros. La représentation schématique présente une vue de haut du crane où la présence du nez indique le devant. . . . .	14
2.7	Système 10-20 à 21 électrodes. . . . .	15
3.1	Structure du cortex visuel. . . . .	19
3.2	L'encodage neuronal tente de prédire la réponse neuronale en utilisant le stimulus. Inversement, le décodage neuronal reconstruit le stimulus en uti- lisant la réponse neuronale. . . . .	23
3.3	Modèle linéaire généralisé d'un neurone dans le système auditif. Blocs : 1. Représentation spectro-temporelle du stimulus : s ; 2. STRF : K ; Convolu- tion entre K et s ; 3. Fonction non linéaire : f(.) ; 4. Processus ponctuel et 5. Filtre post-décharge : h. . . . .	24
3.4	Perceptron multicouche (2 couches ici par simplicité) ; la couche la plus à gauche correspond à la couche d'entrée du système, suivi de la couche cachée et d'une sortie scalaire désirée. . . . .	30
3.5	Système expérimental pour le modèle Neucube EEG pour les interfaces cerveau machines. Blocs : 1. Données EEG ; 2. Encodeur ; 3. Réservoir NeuCube ; 4. Vecteurs d'état ; 5. Classificateur. . . . .	32
4.1	Schéma explicatif du déroulement de l'expérience. . . . .	37
4.2	Modèle de classification de données EEG en utilisant un réservoir RNN : 1) données EEG prétraitées ; 2) données EEG encodées en séquences de décharges neuronales ; 3) réservoir RNN ; 4) couche de sortie du réservoir ; 5) classificateur. . . . .	42
5.1	Représentation spatiale des ERPs moyennés sur l'ensemble des stimuli sui- vant les 64 canaux que comporte l'EEG. . . . .	46
5.2	Représentation de l'ERP moyennée sur l'ensemble des stimuli du canal Fz. . . . .	47
5.3	Représentations en 2D des ERPs moyennés sur l'ensemble des stimuli de 0 ms à 500 ms avec un pas de 100 ms. . . . .	47
5.4	A - Représentation frontale en 3D des ERPs moyennées sur l'ensemble des stimuli ; B - Représentation latérale en 3D des ERPs moyennées sur l'en- semble des stimuli ; C - Représentation occipitale en 3D ERPs moyennées sur l'ensemble des stimuli. . . . .	48

5.5	Représentations des ERPs moyennées pour les voyelles a, i et u suivant le canal Fz. . . . .	49
5.6	A - Signal EEG prétraité en réponse au stimulus a; B - Signal EEG filtré dans les bandes delta (2 - 4 Hz) et gamma (30 - 45 Hz); C - La puissance gamma extraite de la bande gamma; D - La phase delta extraite de la bande delta; E - La phase delta et la puissance gamma sont utilisées comme régresseurs pour modéliser l'activité corticale sous-jacente. . . . .	50
5.7	A - Validation croisée effectuée sur le premier quart des décharges neuronales; B - Validation croisée effectuée sur le deuxième quart des décharges neuronales; C - Validation croisée effectuée sur le troisième quart des décharges neuronales; D - Validation croisée effectuée sur le dernier quart des décharges neuronales; E - Validation croisée effectuée sur la moyenne de toutes les validations ci-dessus. . . . .	52
5.8	Moyennes des déviations relatives de l'historique et du stimulus en fonction des électrodes. . . . .	54
5.9	Représentation spatiale des classifications obtenues sur un sujet avec les électrodes suivantes : F1, F2, F3, F4, Fz, FC3, FC4, C3, C4, CP3, CP4, Pz et Oz. . . . .	59

# LISTE DES TABLEAUX

2.1	Formants F1 et F2 de l'alphabet phonétique international [38]. . . . .	6
2.2	Avantages et inconvénients de l'EEG. . . . .	13
2.3	Identification des électrodes. . . . .	13
5.1	Performances de la classification obtenues sur 8 sujets. . . . .	55
5.2	Performances de la classification des données brutes et de l'estimation corticale sous-jacente obtenues sur 8 sujets. . . . .	56
5.3	Performances de la classification obtenues par région du cortex sur 8 sujets. . . . .	57
5.4	Performances de la classification obtenues en fonction du nombre d'électrodes sur 8 sujets. . . . .	60



# LISTE DES ACRONYMES

<b>Acronyme</b>	<b>Définition</b>
BOLD	Blood-Oxygen-Level Dependent
CIF	Conditional Intensity Function
EEG	Électroencéphalogramme
EQM	Erreur quadratique moyenne
ERP	Event-Related Potential
ESN	Echo State Machine
FBC	Frequency-Band Coupling
GLM	Generalized Linear Model
IRM	Imagerie par résonance magnétique
IRMf	Imagerie par résonance magnétique fonctionnelle
LFP	Local Field Potential
LIF	Leaky Integrate-and-Fire
LSM	Liquid State Machine
MEG	Magnétoencéphalogramme
MLP	Multilayer Perceptron
MSE	Mean Squared Error
MUA	Multiunit Activity
RNN	Recurrent Neural Network
SOC	Self-organized Criticality
STBD	Spatio- and Spectro-Temporal Brain Data
STRF	Spectro-Temporal Receptive Field
SVM	Support Vector Machine
TEMP	Tomographie par émission monophotonique
TEP	Tomographie par émission de positrons
TGC	Transformée de Gabor continue





# CHAPITRE 1

## INTRODUCTION

Les progrès réalisés dans la compréhension du système cérébral ont abouti au développement de nouveaux dispositifs, appelés interfaces cerveau-machine, permettant à des individus, souffrant de handicaps majeurs, d'améliorer, d'assister ou de restaurer leurs fonctions cognitives défaillantes. Ces systèmes visent à établir un lien de communication direct entre le cerveau et un système externe à ce dernier [51]. L'enregistrement de l'activité électrique émise par les neurones requiert souvent l'utilisation de dispositifs invasifs, c'est à dire qui nécessite l'ouverture du crâne, ce qui comporte des risques pour le patient. Dans ce contexte, les électroencéphalogrammes (EEG) ont l'avantage d'être non invasifs. Par contre, l'information sensorielle qui se retrouve dans un signal EEG est beaucoup moins ciblée que dans un signal neuronal acquis par une méthode invasive. Les premiers enregistrements EEG ont été faits il y a plus de 80 ans [24] et depuis, c'est devenu un des outils les plus utilisés pour étudier l'activité électrique du cerveau humain du fait qu'il soit peu cher et facile d'utilisation.

Dans ce projet de recherche, on désire étudier de quelle façon est distribuée l'information d'un stimulus auditif dans les différents canaux EEG, en particulier si cette information est confinée dans une zone cérébrale restreinte. Pour stimuler l'activité électrique des neurones dans le cortex auditif, on utilise trois sons de paroles correspondant aux voyelles a, i et u. Ces sons sont ensuite traités par le système auditif et acheminés jusqu'au cortex auditif. L'utilisation d'EEG pour étudier le traitement ayant été effectué jusqu'au cortex auditif comporte des défis particuliers. En effet, le cortex auditif est situé dans des repliements du tissu cortical et les neurones qui déchargent, suite à un stimulus auditif, sont parallèles à la surface corticale sur laquelle les EEG sont enregistrés. Par conséquent, les signaux EEG situés vis-à-vis du cortex auditif et censés contenir le plus d'information auditive seront faibles. D'où la question de recherche suivante :

*Comment est distribuée l'information d'un stimulus auditif dans les différents canaux EEG et comment cette distribution affecte-t-elle la classification de stimuli auditifs à partir d'EEG ?*

Le but de ce projet de recherche consiste donc à étudier la localisation spatiale de l'information auditive dans l'ensemble des canaux EEG. Pour ce faire, nous utilisons deux approches :

- un modèle de couplage bande fréquence [50] et un modèle d'encodage pour estimer l'activité corticale sous-jacente à partir des signaux EEG afin d'identifier les électrodes ayant les plus fortes activités neuronales ;
- un réservoir de neurones à décharge récurrent [6] (*recurrent neural network* - RNN) pour classifier les trois voyelles en fonction de la position et du nombre de canaux utilisés.

Pour la première approche, on explore la possibilité d'estimer l'activité du cortex auditif à partir des signaux EEG enregistrés suite à l'écoute de stimuli auditifs. De récentes études [50] ont démontré une corrélation entre les potentiels de champs locaux (*local field potential* - LFP) obtenus à partir des signaux EEG et l'activité corticale sous-jacente. Les signaux LFP sont une variante plus localisée d'EEG et représentent la somme de toutes les excitations ou inhibitions synaptiques dans une région donnée autour de l'électrode extracellulaire et intracrânienne. Les propriétés et la signification fonctionnelle des différentes bandes de fréquences du signal LFP ont reçu récemment une attention accrue dans les neurosciences. Des études ont indiqué que les bandes de fréquences plus élevées (20 - 60 Hz) des LFP sont spatialement bien localisées [12] pouvant aller de plusieurs centaines de micromètres à seulement quelques millimètres [2]. Ainsi on peut clairement différencier les réponses neuronales liées au stimulus de celles qui ne le sont pas [1]. En outre, certaines bandes de fréquence peuvent être utilisées de manière fiable pour déduire l'activité corticale sous-jacente [40]. Notre approche utilise un modèle linéaire généralisé [50] (*generalized linear model* - GLM) pour déterminer si le signal EEG peut être utilisé pour déduire les décharges neuronales du cortex auditif. Un couplage bande-fréquence (*frequency-band coupling* - FBC) est utilisé pour estimer cette activité. La validation de cette estimation sera faite avec un algorithme d'encodage du signal de parole.

Nous proposons ensuite d'utiliser un réservoir RNN [6], activé en entrée par les données EEG, pour classifier des stimuli auditifs. Il a été prouvé que les réservoirs RNN donnent des meilleures performances comparativement aux techniques d'apprentissage machine standards telles que le perceptron multicouche ou les machines à vecteurs de support [18]. Ce réseau de neurones a été conçu pour ajuster de manière adaptative un réservoir de neurones connectés de manière récurrente pour être à la limite du chaos. La criticalité auto-organisée (*self-organized criticality* - SOC), qui permet d'étudier les changements brutaux du comportement d'un système, est obtenue avec une règle d'apprentissage local et non supervisé. La SOC a démontré qu'elle pouvait maintenir efficacement une longue activité soutenue tout en s'adaptant rapidement au signal d'entrée et également en améliorant les transitoires [6]. Les réservoirs ont déjà été utilisés dans le passé pour la

classification de signaux spatio- et spectro-temporelles comme l'électroencéphalographie, l'imagerie médicale par résonance magnétique ou la magnétoencéphalographie [18].

Deux contributions originales sont présentées dans cette étude. Nous montrons tout d'abord que l'information auditive est présente sur l'ensemble de la surface du cuir chevelu et ensuite, qu'il est possible de classifier les voyelles avec précision en utilisant le réservoir RNN et qu'un très petit nombre d'électrodes est nécessaire pour effectuer une classification des stimuli.

Ce mémoire est organisé de la façon suivante. Au chapitre 2, nous allons tout d'abord introduire des éléments de phonétique et de neurophysiologie pour mieux comprendre quels sont les stimuli qui ont été utilisés dans cette recherche, comment voyage le son jusqu'au cortex auditif puis quelle activité électrique est enregistrée par l'EEG. Nous étudierons ensuite, au chapitre 3, les différentes techniques qui ont déjà été élaborées pour estimer l'activité corticale, pour encoder un signal de parole et pour classifier des données spatio- et spectro-temporelles. Le chapitre 4 sera consacré à la méthodologie que nous avons adoptée pour mener à bien ce projet de recherche. Puis, les résultats obtenus seront présentés au chapitre 5 et enfin, le dernier chapitre conclura sur les travaux de recherche réalisés.



## CHAPITRE 2

# ÉLÉMENTS DE PHONÉTIQUE ET DE NEUROPHYSIOLOGIE

Ce chapitre a pour but premièrement de présenter des éléments de phonétiques pour comprendre quels stimuli ont été utilisés dans ce projet de recherche. Ensuite, une étude du traitement que subit le son de l'oreille jusqu'au système auditif sera faite. Puis, on verra comment les neurones réagissent face au signal de parole et comment ils traitent cette information. Enfin, nous présenterons quelle activité électrique des neurones est enregistrée par l'EEG et ainsi que l'appareillage EEG en tant que tel.

### 2.1 Phonétique

La coordination et l'action d'un certain nombre de muscles sont à l'origine de la parole. Elle fait intervenir plusieurs éléments corporels et est obtenue par la modulation de l'air de la cage thoracique aux éléments buccaux. On peut décomposer l'appareil phonatoire en quatre éléments : la soufflerie (les poumons), le vibreur (les cordes vocales), les résonateurs et le système articulateur qui permettent de distinguer trois classes phonétiques principales que sont les voyelles, les semi-voyelles et les consonnes. La production de voyelle s'effectue lorsque le conduit vocal est suffisamment ouvert pour que l'air poussé par les poumons le traverse sans obstacle. Le timbre vocalique est modifié lorsque la bouche se réduit. Contrairement, si le passage de l'air est rétréci ou s'il se ferme, cela donne naissance à une consonne.

Comme on vient de le voir, les voyelles se caractérisent par un libre passage de l'air dans le conduit vocal. Le timbre d'une voyelle dépend en partie de la résonance ou non de la cavité nasale, de la forme ainsi que du volume du résonateur buccal et de l'arrondissement ou non des lèvres. La configuration adoptée par ces différents facteurs détermine une fonction de transfert caractéristique. Ainsi, l'allure de l'onde excitatrice produite par la vibration ou non des cordes vocales est modulée par cette fonction de transfert et fait émerger des zones fréquentielles de concentration d'énergie appelée formants.




Figure 2.1 Triangle vocalique.

Tableau 2.1 Formants F1 et F2 de l'alphabet phonétique international [38].

Alphabet phonétique international	Formant F1	Formant F2
u	320 Hz	800 Hz
o	500 Hz	1000 Hz
α	700 Hz	1150 Hz
a	1000 Hz	1400 Hz
ø	500 Hz	1500 Hz
y	320 Hz	1650 Hz
ε	700 Hz	1800 Hz
e	500 Hz	2300 Hz
i	320 Hz	3200 Hz

On distingue ainsi, selon la localisation de la masse de la langue, les voyelles antérieures, moyennes et postérieures et l'écartement entre l'organe et le lieu d'articulation, les voyelles fermées et ouvertes [3]. La forme de cette fonction de transfert reste constante au cours de la production de la voyelle, la rendant assimilable à un signal quasi stationnaire, c'est-à-dire que ses propriétés statistiques sont indépendantes du temps. On peut approximativement représenter les voyelles dans le plan des deux premiers formants. Les voyelles sont donc identifiables par la position de leurs formants sur le spectre. Les deux premiers formants (notés F1 et F2) sont les plus importants pour la caractérisation de la voyelle. Delatte [10] propose de caractériser les voyelles selon deux axes représentés par F1 et F2 (figure 2.1).

Les stimuli utilisés dans cette étude sont les voyelles : a, i et u, prononcés en anglais. Ces voyelles sont situées au niveau des sommets du triangle vocalique (figure 2.1 et tableau 2.1) indiquant que leurs deux premières résonances (formants) sont aussi distinctes que possible. On représente alors, dans un plan, les voyelles en fonction des valeurs de F1 et de F2.

## 2.2 De l'oreille jusqu'au cortex auditif

Cette section donne un aperçu de l'organisation du système nerveux à travers l'étude du système périphérique et du système auditif central. On s'intéresse au traitement que subit le son de l'oreille jusqu'au système auditif.

### 2.2.1 Le système périphérique

Le système périphérique permet de transmettre un signal sonore de l'oreille externe jusqu'aux premiers neurones du nerf auditif (fig 2.2). Chacune des parties de ce système a un but bien spécifique [37]. Tout d'abord, l'oreille externe amplifie le signal sonore grâce au conduit auditif. L'oreille moyenne est composée du tympan et de trois osselets (marteau, enclume et étrier). Lorsqu'une onde sonore passe par le conduit auditif, elle fait vibrer le tympan. Le tympan transmet les vibrations aux osselets qui vont les transmettre à l'oreille interne par la fenêtre ovale. La cochlée, dans l'oreille interne, possède des capacités d'analyse sonore exceptionnelles, autant en fréquence (de 20 Hz et 20 000 Hz) qu'en intensité et fait une décomposition du son. Lorsque la pression acoustique est transmise aux liquides de l'oreille interne par l'intermédiaire de l'étrier, l'onde de pression va déformer la membrane basilaire, située à l'intérieur de la cochlée, en un lieu qui dépend de la fréquence. Les fréquences aiguës agissent à la base de la cochlée et les fréquences graves à l'apex.

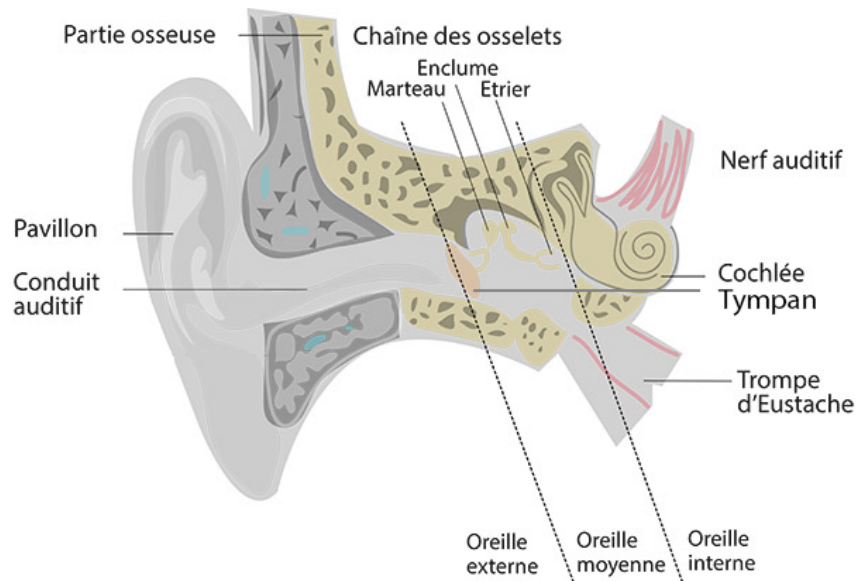


Figure 2.2 Coupe anatomique de l'oreille externe, moyenne et interne.

C'est ce qu'on appelle la tonotopie cochléaire. Sur la membrane basilaire, on retrouve l'organe de Corti où se trouvent les cellules ciliées. Lorsque les osselets transmettent les vibrations à la cochlée, ces cellules se mettent en mouvement, ce qui génère un message nerveux transmis au cortex via le nerf auditif. De nombreux acousticiens pensent que le modèle physique, de la cochlée, le plus proche de la réalité est un système d'oscillateurs accordés en fréquence qui peuvent être régulés par le système nerveux central. La position du maximum d'amplitude de l'onde propagée dépend de la fréquence du son.

### 2.2.2 Le système auditif central : du noyau cochléaire au cortex auditif

Le système auditif central a pour but d'interpréter le signal de parole émis et de le transmettre jusqu'au cortex par le nerf auditif. Il fournit également des indications sur l'intensité du son et sa localisation spatiale [26]. Le système périphérique et le système central communiquent par le biais de fibres nerveuses qui partent de l'organe de Corti jusqu'au cortex auditif. Les cellules ciliées internes et externes présentent dans l'organe de Corti sont reliées à des fibres nerveuses, c'est ce qui forme les deux nerfs auditifs. Une fois dans le nerf auditif, le signal de parole est envoyé vers le cortex en passant principalement par quatre relais (voies auditives primaires) : les noyaux cochléaires, le complexe olivaire supérieur, le colliculus et le thalamus (figure 2.3). Ces relais effectuent un travail qui permet de décoder et d'interpréter l'information codée en provenance de la cochlée. Tout d'abord, les noyaux cochléaires sont situés dans le tronc cérébral. Après sa sortie de la



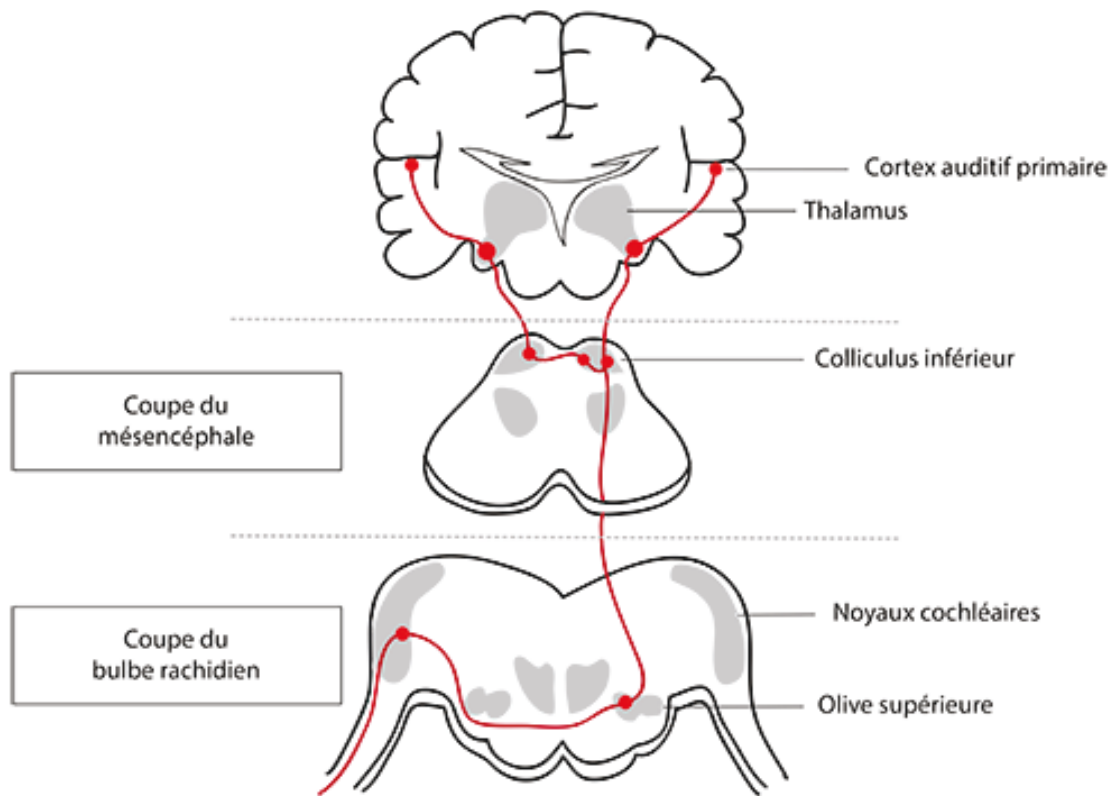


Figure 2.3 Voies auditives primaires.

cochlée, l'influx nerveux se dirige vers ces noyaux. Ceux-ci décodent les caractéristiques du son. En effet, ils participent au décodage de l'intensité, de la fréquence et des paramètres temporels qui définissent le début, la fin et la durée du son. Ces noyaux permettent d'analyser le signal auditif primaire provenant de la cochlée et de repartir vers les autres relais supérieurs. Ensuite, l'olive supérieure (ou complexe olivaire supérieur) est composée d'un certain nombre de noyaux. Elle est impliquée dans l'analyse et le filtrage de l'information auditive débouchant sur le cortex cérébral. Elle joue également un rôle important dans la localisation de la source sonore, rôle qu'elle partage avec le colliculus inférieur. Puis, le colliculus inférieur fait partie de la voie auditive ascendante entre l'oreille et le cortex auditif et joue un rôle dans la localisation de la source sonore. Les colliculus sont quatre petites masses de l'encéphale humain dans la partie supérieure du tronc cérébral. Le thalamus possède deux parties, se divisant en sous-noyaux et se situant dans la partie moyenne du diencephale entre le cortex et le tronc. Son rôle est d'intégrer des afférences sensibles et sensorielles. Il possède également une fonction de régulation de la conscience et du sommeil.

### 2.2.3 Le cortex auditif

Le cortex auditif correspond à 8% de la surface du cortex cérébral et se situe dans la partie supérieure du lobe temporal. Il a pour but d'analyser les informations auditives. Le cortex primaire (localisé au niveau du gyrus temporal transverse) permet de mémoriser les fréquences, l'intensité, le timbre et la durée d'un son. Le cortex secondaire (se trouvant à l'arrière du cortex auditif primaire) permet la compréhension et la classification des mots. La partie droite du cortex auditif secondaire est consacrée aux sons musicaux et celle de gauche aux sons du langage.

Dans la prochaine section, on va maintenant voir l'activité électrique que l'EEG enregistre.

## 2.3 Activité électrique des neurones recueillis par l'EEG

Le cerveau humain est constitué d'environ 100 milliards de neurones et leurs corps cellulaires constituent la matière grise. Le rôle principal des neurones est de recevoir, traiter et émettre l'information [20]. Un neurone est composé de trois parties principales (fig 2.4) :

1. les dendrites qui ont pour rôle d'établir les connexions entre les neurones à travers les synapses ;
2. le soma (le noyau de la cellule) ; et
3. l'axone qui transmet les signaux électriques, qu'on appelle les potentiels d'actions.

Les neurones d'intérêt pour l'EEG sont les neurones pyramidaux (correspondant à 85% du cortex auditif primaire), car ils sont principalement responsables de l'activité électrique




Figure 2.4 Représentation du neurone.

enregistrée par l'EEG [27]. Ils sont caractérisés par leurs arbres dendritiques et la forme de leurs corps cellulaires. En effet, les cellules pyramidales disposent d'une grande dendrite orientée perpendiculairement à la surface du cortex. Mais elles ne sont pas toutes identiques, leur forme change en fonction de la couche cérébrale dans laquelle elles se trouvent.

### 2.3.1 Les potentiels post-synaptiques et les potentiels d'actions

Chaque neurone intègre de l'information par l'intermédiaire des synapses et la transmet à l'aide de l'axone [27]. Ce système de transfert d'information résulte d'un processus électrique. On peut distinguer deux types de potentiels :

1. Les potentiels d'actions qui sont des ondes d'amplitude de 70 à 110 mV avec une durée de 0.3 ms qui se propagent le long des axones. Ils correspondent à un changement de potentiel ; de ce fait, ils sont moins significatifs sur l'EEG. Si on veut les enregistrer, il faut placer les électrodes aux voisinages des neurones.
2. Les potentiels post-synaptiques qui correspondent à la somme des potentiels excitateurs et inhibiteurs présynaptiques dans le soma. Ils ont des amplitudes de l'ordre de 0.1 à 10 mV et une durée plus longue de 10 à 20 ms.

Ce sont les potentiels post-synaptiques qu'on enregistre sur l'EEG, car ils ont un temps d'existence plus long. De ce fait, la probabilité qu'un groupe de neurones génèrent ces potentiels ensemble est plus grande que les potentiels d'actions.

### 2.3.2 Dipôle équivalent

Les cellules pyramidales peuvent être modélisées par un dipôle de courant (fig 2.5). En effet, une différence de potentiel est produite entre le soma (positif) et les dendrites (négatif).

Pour récupérer un signal avec l'EEG, il faut que des milliers de neurones se synchronisent sur une surface corticale suffisamment grande [27]. On fait la somme des courants de chacun pour former le dipôle. Les neurones pyramidaux sont les principaux générateurs de l'activité électrique dans le cortex, car ils sont parallèles entre eux et perpendiculaires à la surface du cortex. Aussi, l'amplitude du signal EEG est proportionnelle au degré de synchronisation des neurones corticaux entre eux dans une région donnée.

Certains dipôles sont perpendiculaires à la surface corticale (dipôle radial), une seule extrémité du vecteur sera enregistrée, alors que d'autres sont parallèles à la surface corticale




Figure 2.5 Neurones pyramidaux perpendiculaires à la surface corticale.

(dipôle tangentiel). Le dipôle tangentiel étant parallèle, il participe peu au signal. C'est pourtant celui-ci qui va être enregistré par les électrodes vis-à-vis du cortex auditif.

### 2.3.3 Le dispositif EEG

L'EEG est, aujourd'hui, le principal outil de diagnostic en neurologie clinique [27]. C'est un dispositif non invasif avec une résolution spatiale de quelques millimètres et une résolution temporelle de l'ordre de la milliseconde. Il enregistre l'activité électrique de groupes de 100 millions à 1 milliard de neurones du cortex en plaçant directement les électrodes sur le cuir chevelu. L'EEG permet, par exemple, de confirmer qu'il existe des troubles à l'origine de crise épileptique chez un patient. On peut aussi l'utiliser pour étudier le fonctionnement du cerveau d'un patient qui a des difficultés intellectuelles (mémoire par exemple). Le tableau 2.2 résume les avantages et inconvénients de l'EEG.

Tableau 2.2 Avantages et inconvénients de l'EEG.

Avantages	Inconvénients
Bonne résolution temporelle Tout le monde peut l'utiliser Facilement transportable Faible coût Non invasif	Mauvais rapport signal sur bruit Temps de mise en oeuvre Signaux corrélés Ne mesure que l'activité surfacique Nécessite l'utilisation d'un gel Perte d'information, car signaux atténués par la boîte crânienne


### Le système international 10-20

Les électrodes utilisées pour l'EEG sont placées sur le cuir chevelu de façon universelle suivant le système international 10-20 comprenant 21 électrodes [16] (fig 2.7). Ce système assure à la fois un positionnement des électrodes identique, mais qui est propre à chaque patient. Chaque position d'une électrode est identifiée par des lettres et des chiffres. Les chiffres pairs représentent les électrodes du côté droit de la tête et les chiffres impairs, le côté gauche. Les lettres indiquent la position de l'électrode aux zones du cerveau (voir le tableau 2.3). On présente à la figure 2.6 les représentations spatiales des canaux EEG en fonction de leurs noms puis en fonction de leurs numéros.

Tableau 2.3 Identification des électrodes.

A	Auriculaire
C	Centrale
F	frontale
Fp	Fronto-polaire
O	Occipitale
P	Pariétale
T	Temporale
z	Ligne médiane

**A**



**B**




Figure 2.6 A - Représentation spatiale des canaux EEG en fonction de leurs noms; B - Représentation spatiale des canaux EEG en fonction de leurs numéros. La représentation schématique présente une vue de haut du crane où la présence du nez indique le devant.

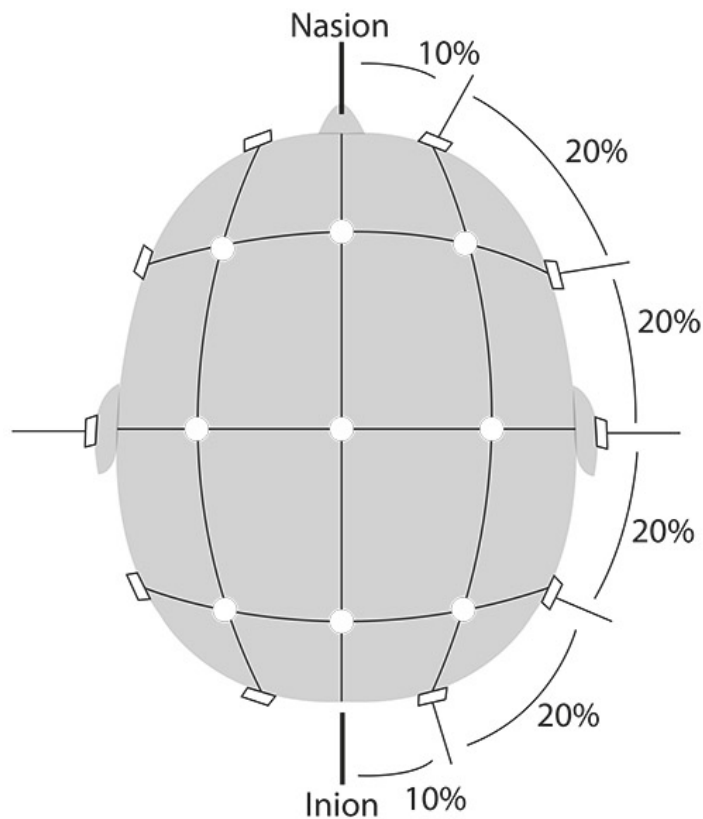


Figure 2.7 Système 10-20 à 21 électrodes.

### L'EEG Haute Résolution

L'EEG à haute résolution permet d'enregistrer l'activité électrique cérébrale avec une excellente résolution spatiale. En effet, le nombre d'électrodes a fortement augmenté pouvant s'étendre jusqu'à plus de 300 en utilisant les systèmes 10-10 et 10-5 [17]. Dans ces systèmes, l'espacement entre chacune des électrodes est donc réduit.

#### 2.3.4 Activité rythmique

L'influx nerveux est caractérisé par une activité rythmique, c'est-à-dire que les neurones s'activent comme des pulsations. Le rythme de ces pulsations peut se traduire par des ondes cérébrales que l'on peut enregistrer à l'aide de l'EEG. Ces ondes sont de faible amplitude (de l'ordre du  $\mu V$ ). Les caractéristiques des rythmes cérébraux dépendent de l'état psychologique et pathologique du patient. Ainsi, l'enregistrement de l'activité rythmique cérébrale permet, par exemple, d'étudier les phases du sommeil ou de caractériser des maladies neurologiques (comme l'épilepsie). Les ondes cérébrales sont principalement définies par les bandes de fréquence auxquelles elles appartiennent, mais elles sont également caractérisées par leurs localisations, leurs morphologies, leurs amplitudes et leurs réactivités

(c'est à dire lorsque l'activité locale du cortex change sous l'effet d'un événement sensoriel ou moteur). Elles ne peuvent être interprétées que dans un contexte comportemental (éveil, somnolence...). Ainsi, avec l'EEG, on peut identifier les ondes delta, thêta, alpha, mu, beta et gamma.

- ONDES DELTA ;

Ces ondes ont une fréquence inférieure 4 Hz. Elles possèdent la plus grande amplitude et les vagues les plus lentes. On peut les observer pendant le sommeil lent et elles caractérisent certaines lésions cérébrales. Plus on vieillit, plus l'activité delta diminue ; elle tient une grande part lors du sommeil chez l'enfant.

- ONDES THETA ;

La fréquence des ondes thêta varie de 4 à 8 Hz. Celles-ci peuvent être observées chez les enfants, les adolescents et les jeunes adultes. Elles caractérisent certains états de somnolence, excitation ou d'hypnose et ont une amplitude de 10 à 50  $\mu V$ .

- ONDES ALPHA ;

Les ondes alpha ont une fréquence de 8 à 12 Hz et une amplitude de 10 à 100  $\mu V$ . Elles sont observées dans les régions postérieures de la tête lors de la fermeture des yeux et de la relaxation. Elles disparaissent lors de l'ouverture des yeux ou d'un effort mental.

- ONDES MU ;

Les ondes de type mu sont une particularité du rythme alpha (dans les basses fréquences d'alpha : 8 à 10 Hz). On les observe dans les zones centrales lors de l'exécution d'un mouvement. Elles reflètent la décharge synchrone des neurones moteurs.

- ONDES BETA ;

Ces ondes sont assez rapides, couvrant des fréquences entre 12 et 40 Hz avec une amplitude de 10  $\mu V$ . L'activité bêta est liée au comportement moteur. Elles apparaissent lors d'activité intense, d'anxiété ou de concentration.

- ONDES GAMMA ;

Elles sont centrées autour de 50 Hz et représentent la liaison de différentes populations de neurones dans un réseau dans le but de réaliser une fonction cognitive ou motrice.



# CHAPITRE 3

## ÉTAT DE L'ART

Ce chapitre a pour objectif, tout d'abord, de dresser une revue de littérature sur l'estimation de l'activité corticale. Ensuite on étudie quelles techniques d'encodage du signal de parole peuvent être utilisées pour valider l'estimation des décharges neuronales dans le cortex. Enfin, on verra la classification de données spatio- et spectro- temporelles à l'aide de techniques d'apprentissage machine standard et de réservoir de neurones à décharges.

### 3.1 Estimation de l'activité corticale

La communication entre les neurones est un phénomène électrochimique. Lorsqu'un neurone communique avec son voisin, il émet des potentiels d'action qui en arrivant à la synapse entraînent la libération de neurotransmetteurs qui vont activer ou inhiber le neurone cible [20]. Le potentiel d'action étant dû à un mouvement d'ions, il peut être enregistré avec une électrode. Lorsqu'on implante une électrode dans le cerveau, on enregistre deux types de signaux : les potentiels d'action (à très haute fréquence) et le potentiel de champ local (potentiel post-synaptique). Ce dernier représente la somme de toutes les excitations ou inhibitions synaptiques dans une région donnée autour de l'électrode (somme des potentiels d'action).

Le signal enregistré avec une électrode intracrânienne est le signal électrique généré à proximité de l'électrode. Une source à distance peut par contre être également captée par une électrode. C'est d'ailleurs le principe de l'EEG. Le signal capté en EEG est un signal électrique généré dans le cerveau et détecté à distance par des capteurs à la surface du crâne [27]. Il est donc fortement modifié par le crâne et la peau et il est également perturbé par l'activité musculaire qui elle aussi implique une activité électrique.

Le 1<sup>er</sup> enregistrement EEG a été fait il y a plus de 80 ans [24] et depuis, c'est devenu un des outils les plus utilisés pour étudier l'activité électrique du cerveau humain. Des études ont démontré une correspondance proche entre l'activité des EEG et les potentiels post-synaptiques inhibiteurs et excitateurs d'une population de neurones qui sont des composantes majeures du signal EEG [8]. Les propriétés et la signification fonctionnelle des différentes bandes de fréquences du signal correspondant aux potentiels post-synaptiques (aussi appelés : *local field potential* - LFP) ont reçu récemment une attention accrue dans

les neurosciences. Des études ont indiqué que les bandes du signal LFP avec des fréquences plus élevées (20 - 60 Hz) sont spatialement bien localisées [12] pouvant aller de plusieurs centaines de micromètres à seulement quelques millimètres [2]. Ainsi on peut clairement différencier les réponses neuronales liées au stimulus de celles qui ne le sont pas [1]. De plus, il a également été démontré que certaines bandes de fréquence peuvent être utilisées de manière fiable pour déduire l'activité corticale sous-jacente [40].

Dans cette section, on présente d'abord la technique d'analyse des LFP et de l'activité multi-unitaire (*multiunit activity* - MUA). On s'intéresse ensuite à la corrélation des signaux LFP avec les signaux dépendants du niveau d'oxygénation du sang de l'imagerie par résonance magnétique (IRM) et les signaux EEG. Enfin, on étudie une méthode d'estimation de l'activité corticale à partir de mesures EEG qui sera utilisée plus loin.

### 3.1.1 Analyse des potentiels de champs locaux et de l'activité multi-unitaire

Les signaux LFP et MUA sont des signaux extracellulaires enregistrés par une même électrode invasive dans une structure donnée du cerveau. Ils décrivent la dynamique de groupe de neurones locaux. Les LFP, constitués des basses fréquences ( $< 500$  Hz) contenues dans l'enregistrement effectué par l'électrode, sont produits par les courants de membrane de groupe de neurones au voisinage de l'électrode. Ils fournissent une meilleure résolution spatiale sur l'origine du signal (de l'ordre du millimètre). On détecte ainsi les activités rythmiques, divisées en bandes de fréquences, qui traduisent différents états cérébraux. Les signaux MUA, qui sont les hautes fréquences ( $> 1000$  Hz) du signal enregistré par l'électrode, représentent les décharges neuronales de groupes de neurones locaux.

Pour recueillir les signaux MUA, une technique utilisée [44] est d'implanter, deux électrodes dans les zones V2/V3 du cortex visuel (figure 3.1) d'un humain dans le cas d'un traitement épileptique. Il s'avère que les oscillations gamma sont très prononcées dans les signaux LFP et peuvent être utilisées pour estimer l'activité corticale sous-jacente [44]. Pour l'analyse des champs réceptifs, l'activité moyenne des MUA peut être utilisé avec la puissance gamma en réponse à chaque stimulus. Pour estimer les propriétés des oscillations gamma, il faut adapter une fonction gaussienne avec à la variation relative de la puissance gamma entre 30 et 100 Hz. Pour ce faire, on peut utiliser la méthode de Nelder-Mead avec une minimisation non linéaire multidimensionnelle à l'aide de la fonction

$$P(f) = \frac{Ge^{-\frac{1}{2}\left(\frac{f-\mu}{\sigma}\right)^2}}{\sqrt{2\pi}\sigma} + b, \quad (3.1)$$



Figure 3.1 Structure du cortex visuel.

où  $P(f)$  est la puissance à une fréquence  $f$ ,  $G$  l'amplitude,  $b$  l'offset,  $\mu$  est la fréquence du maximum et  $\sigma$  l'écart type. Pour l'analyse des LFP, une adaptation avec une gaussienne elliptique 2D en utilisant une minimisation non linéaire multidimensionnelle est alors faite suivant :

$$R(x, y) = e^{-a(x-rf_x)^2 + 2b(x-rf_x)(y-rf_y) + c(y-rf_y)^2} \quad (3.2)$$

avec :

$$a = \frac{\cos^2 \theta}{2\sigma_x^2} + \frac{\sin^2 \theta}{2\sigma_y^2}, \quad b = \frac{-\sin 2\theta}{4\sigma_x^2} + \frac{\sin 2\theta}{4\sigma_y^2}, \quad c = \frac{\sin^2 \theta}{2\sigma_x^2} + \frac{\cos^2 \theta}{2\sigma_y^2} \quad (3.3)$$

où  $(rf_x, rf_y)$  est le centre de la gaussienne,  $\sigma_x$  et  $\sigma_y$  les écarts type dans les directions  $x$  et  $y$  et  $\theta$  l'orientation de la gaussienne.

### 3.1.2 Corrélation des signaux LFP avec les signaux BOLD

Récemment l'intérêt des signaux LFP a augmenté en raison de sa corrélation avec les signaux dépendants du niveau d'oxygénation du sang (*blood-oxygen-level dependent - BOLD*) lesquelles sont issus de l'imagerie par résonance magnétique fonctionnelle (IRMf). Un des buts principaux de l'IRMf est d'estimer les signaux neuronaux qui traversent le cerveau. Malgré sa résolution spatiale impressionnante, l'IRMf mesure un signal BOLD et, par conséquent, ne reflète que de façon indirecte l'activité neuronale [47]. L'interprétation de ces signaux est sujet à discussions, car les aspects de l'activité neuronale BOLD ne sont pas toujours clairs. L'activité neuronale se réfère à l'activité des décharges neuronales, des courants synaptiques et des neurones excitateurs et inhibiteurs. Les premiers résultats suggèrent que les signaux BOLD sont directement proportionnels aux taux de décharges moyens [47]. Dans le cortex, les signaux BOLD de l'IRMf sont légèrement mieux corrélés avec les LFP (reflétant les formes d'ondes lentes de l'activité neuronale) qu'avec la MUA (reflétant les décharges, [21]).

### 3.1.3 Corrélation des signaux LFP avec les signaux EEG

L'EEG mesure les champs électriques extracrâniens produits par les neurones du cerveau. Lorsque les positions et les orientations des neurones actifs dans le cerveau sont connues, il est possible de calculer des modèles de potentiels électriques sur la surface de la tête. Si, au contraire, la seule information disponible est la mesure du potentiel électrique sur la surface du cuir chevelu, on s'intéresse alors à la détermination de la distribution intracrânienne de l'activité neuronale. C'est ce qu'on appelle le problème inverse ou problème de localisation de source, pour lequel il n'existe pas de solution unique. La seule façon de le résoudre est d'utiliser de l'information supplémentaire pour contraindre un ensemble infini de solutions possibles en une seule. Dépendamment de l'information supplémentaire ajoutée, différentes solutions inverses peuvent être obtenues (c'est à dire, différentes reconstructions de l'activité neuronale avec différentes propriétés) [42, 48].

La contrainte classique utilisée pour résoudre le problème inverse de l'EEG est de considérer les neurones comme des dipôles de courants. Dans ce cas, la grandeur à estimer est un modèle de dipôle supposé représenter un vecteur de densité de courant (réparti sur tout le manteau de la matière grise ou seulement confiné en un point). Lorsqu'on suppose que le dipôle est confiné en un seul ou plusieurs sites cérébraux, la tâche consiste à résoudre un problème d'optimisation non linéaire visant à trouver simultanément la position et le modèle des dipôles de courants [42]. Par contre, lorsque les dipôles sont répartis sur un ensemble discret de points dans le cerveau, la tâche consiste à trouver pour chaque dipôle, conduisant à un problème inverse sous-déterminé, des contraintes linéaires comme la norme minimale [13]. Dans les deux approches, dipôles simples ou dipôles distribués, la grandeur à estimer est un champ vectoriel couramment appelé vecteur de densité de courant. Cependant, dans la deuxième approche, qui considère les modèles distribués, les valeurs des vecteurs de densité de courant sont obtenues pour toute la matière grise apparentée aux images tomographiques produites par d'autres modalités de neuroimagerie fonctionnelle (l'IRMf, la tomographie par émission de positons (TEP) ou la tomographie par émission monophotonique (TEMP)), mais avec une résolution temporelle d'ordre de la milliseconde.

Un changement, dans la formulation du problème inverse EEG, a lieu lorsque les courants neurophysiologiques sont ohmiques et peuvent donc s'exprimer comme des gradients de potentiel de champs. Avec cette contrainte neurophysiologique, le problème inverse EEG peut être reformulé en termes plus restrictifs, fournissant la base de l'estimation non invasive des LFP (un champ scalaire) au lieu du vecteur de densité de courant [48].

Pour le contrôle de neuroprothèses, il est nécessaire d'avoir une estimation fiable des signaux LFP [13], que l'on peut obtenir en solutionnant le problème inverse identifié précédemment. Dans [13], on propose d'utiliser ELECTRA qui est une méthode développée pour estimer les signaux LFP à partir d'EEG. La question est de savoir si les interfaces cerveau machine non-invasive, telles que celles utilisant les EEG, peuvent reproduire les propriétés des systèmes utilisant des mesures invasives. Pour cela, ELECTRA a recours à une estimation non-invasive des LFP dans tout le cerveau humain à partir de mesures EEG en utilisant une distribution gaussienne inverse. L'utilisation de procédures d'inversion linéaire est un aspect clé pour les applications en temps réel. Le développement d'une interface cérébrale basée sur ELECTRA (c'est-à-dire des estimations non invasives de LFP) permet d'appliquer des méthodes identiques à celles utilisées pour les interfaces cérébrales basées sur l'EEG, mais avec l'avantage de cibler l'activité dans des zones cérébrales spécifiques.

### 3.1.4 Modèle de couplage bande-fréquence

Les enregistrements EEG fournissent une activité neuronale directe qui peut être obtenue de manière non invasive. Le manque de résolution spatiale des EEG entraîne cependant une limitation de l'information à la surface du cuir chevelu. Des études récentes utilisant simultanément des enregistrements invasifs et d'EEG suggèrent, par contre, qu'il existe un lien entre la phase d'oscillations obtenue à partir d'EEG et l'activité des décharges neuronales d'une population de neurones [50]. Des progrès technologiques récents ont permis d'enregistrer simultanément l'activité neuronale à différentes échelles spatiales. Dans l'une de ces études [50], il a été démontré que la MUA dans le cortex visuel primaire des singes peut être prédite à partir des augmentations de l'activité enregistrée dans la bande de puissance gamma de signaux EEG qui se produisent pendant la phase négative des oscillations de la bande delta. L'idée que la phase des oscillations lentes des bandes delta et thêta est importante pour comprendre l'activité corticale sous-jacente, n'est pas nouvelle et a été observée dans diverses structures chez les animaux [45] et les humains [14]. L'objectif de [50] était en effet de montrer que de tels liens, entre la phase et la puissance des oscillations, sont vrais pour des mesures EEG.

L'approche [50], décrite ci-dessous, est celle qui sera adoptée ici pour estimer l'activité corticale à partir de mesures EEG.

#### Filtrage des données et analyse spectrale

Le signal EEG est d'abord filtré entre 300 et 3500 Hz pour obtenir le signal LFP avec un seuil d'amplitude équivalent à quatre fois l'écart-type de l'amplitude moyenne. Les taux

de décharge neuronaux (MUA) sont obtenus en faisant un fenêtrage à 10 ms. Les signaux EEG et neuronaux (MUA et LFP) sont d'abord référencés sur les électrodes frontales et ré-échantillonnées à 500 Hz. Pour l'analyse oscillatoire, les données EEG sont filtrées avec des filtres passe-bandes dans les bandes EEG traditionnelles : delta (2-4 Hz), thêta (4-8 Hz), alpha (8-15 Hz), bêta (15-30 Hz). Afin d'extraire les basses fréquences gamma (30-60 Hz) et les hautes fréquences gamma (60-100 Hz), un filtre à réponse impulsionnelle finie bidirectionnel est utilisé pour éliminer les effets de déphasages produits par le filtrage. Dans chaque essai, l'enveloppe de chaque oscillation de largeur de bande limitée peut être calculée, par exemple avec la transformée de Hilbert. Pour une analyse de la phase, il faut calculer l'angle de la transformée de Hilbert et extraire la phase instantanée sur  $[0, 2\pi]$  dans chacune des six bandes EEG. Les diagrammes de couplage bande-fréquence (*frequency-band coupling* - FBC) sont construits suivant la phase sur  $[0, 2\pi]$  et la puissance normalisée sur  $[0, 1]$ . Le couplage de certaines bandes de fréquence peut être utilisé pour déduire l'activité corticale sous-jacente.

Dans la sous-section suivante, on présente un modèle linéaire généralisé pour estimer l'activité des décharges neuronales à partir d'EEG.

### Modèle linéaire généralisé

L'approche proposée en [50] utilise un modèle linéaire généralisé (*Generalized Linear Model* - GLM) pour déterminer si l'information dans le signal EEG peut être utilisée pour modéliser la MUA sous-jacente. Pour être plus spécifiques, la puissance et la phase des différentes bandes de fréquence de l'EEG peuvent être combinées pour estimer la MUA sous-jacente. Le GLM a été construit suivant deux variables, une composée d'une période de la puissance d'une des six bandes de fréquence et l'autre d'une période représentant la phase d'oscillation delta. Il est exprimé suivant :

$$Y = \beta_1 X_1 + \beta_2 X_2 + \epsilon, \quad (3.4)$$

où  $Y$  est la MUA que l'on observe et que l'on souhaite prédire,  $X_{1,2}$  sont connus et correspondent respectivement la puissance d'oscillation et la phase,  $\beta_{1,2}$  sont fixés et sont les coefficients de pondération de la puissance et de la phase et  $\epsilon$  l'erreur. L'analyse du GLM a été effectuée dans chaque essai de chaque simulation. Les résultats du GLM ont montré que la MUA dépend de l'interaction entre la puissance de haute fréquence ( $>30$  Hz) et la phase de basse fréquence ( $<8$  Hz) .

## 3.2 Technique d'encodage du signal

Dans ce qui précède, on a traité des liens entre les signaux EEG et l'activité neuronale proprement dite. On s'attardera maintenant aux liens entre un stimulus extérieur, par exemple un son, et l'activité neuronale que ce dernier génère. Le lien entre le stimulus et la réponse neuronale peut être étudié à partir de deux points de vue opposés (figure 3.2). L'objectif principal du premier, qu'on appelle l'encodage, est de comprendre comment les neurones répondent à une grande variété de stimuli et de construire des modèles qui tentent de prédire les réponses neuronales à d'autres stimuli. L'objectif du second, qu'on appelle le décodage neuronal, est de reconstruire un stimulus à partir des séquences de décharges.

Il est fondamental de comprendre comment le système auditif encode les sons en décharges neuronales et comment l'activité neuronale caractérise les sons. En effet, la connaissance de l'encodage et du décodage neuronal va aider les chercheurs à mieux comprendre comment fonctionne le système auditif et ainsi pouvoir utiliser cette information pour améliorer les applications auditives comme le traitement de la parole, les implants, la reconnaissance de parole ou la séparation de source. On s'attardera dans ce qui suit à l'encodage neuronal.

### 3.2.1 Modèle linéaire généralisé pour l'encodage

Le modèle linéaire généralisé (GLM) étudié dans cette sous-section est différent de celui cité dans la section précédente. En effet, les données utilisées dans le modèle FBC pour estimer les décharges neuronales sont extraites des différentes bandes de fréquences qui prédisent le mieux l'activité corticale. Le modèle FBC a été validé pour le système visuel




Figure 3.2 L'encodage neuronal tente de prédire la réponse neuronale en utilisant le stimulus. Inversement, le décodage neuronal reconstruit le stimulus en utilisant la réponse neuronale.

[50]. Le GLM présenté dans cette sous-section est spécialisé pour l'encodage du signal de parole et fait appel aux processus ponctuels.

Le GLM est l'un des modèles les plus fréquemment utilisés [5, 23, 30, 46] pour estimer le taux de décharge instantané et il a été montré qu'il est suffisamment précis pour représenter la réponse des neurones. Ce modèle est une généralisation du modèle en cascade Poisson non-linéaire linéaire (LNP : *linear-nonlinear-Poisson*) dans lequel les décharges neuronales sont générées selon un processus de Poisson non homogène, avec un taux déterminé par une fonction non-linéaire instantanée de l'entrée filtrée. [30, 32].

Dans [7], on décrit l'encodage d'un spectrogramme du stimulus (une transformation de la forme d'onde de pression sonore en une énergie en fonction du temps dans chaque bande de fréquences),  $s$ , en une séquence de décharges d'un neurone auditif à l'aide GLM (figure 3.3). Dans ce modèle, la réponse cellulaire est décrite par :

1. un stimulus filtré, qu'on appelle aussi un champ récepteur spectro-temporel (STRF - *spectro-temporal receptive field*),  $K$  ;
2. un filtre post-décharge  $h$ , qui capture les dépendances sur l'historique de la cellule (par exemple la réfractarité) ;
3. une constante de décalage (*offset*)  $b$  qui définit le taux de décharge instantané du modèle.

Le STRF permet de mettre en évidence quelle structure temporelle du spectre d'un son excite un neurone auditif. En effet, les neurones du système auditif ne sont excités que par




Figure 3.3 Modèle linéaire généralisé d'un neurone dans le système auditif. Blocs : 1. Représentation spectro-temporelle du stimulus :  $s$  ; 2. STRF :  $K$  ; Convolution entre  $K$  et  $s$  ; 3. Fonction non linéaire :  $f(\cdot)$  ; 4. Processus ponctuel et 5. Filtre post-décharge :  $h$ .



certaines fréquences de sons, on évalue donc le STRF pour mieux décrire le comportement de ces neurones. Pour chaque neurone, une fonction non linéaire statique est appliquée aux réponses filtrées sommées pour obtenir le taux de décharge. Bien que ces types de modèles soient strictement phénoménologiques, leurs composantes peuvent être largement comparées aux mécanismes biophysiques. Par exemple, le stimulus filtré se rapproche de l'intégration spectro-temporelle du stimulus sonore dans un neurone auditif et le filtre post-décharge,  $h$ , imite les courants activés par les tensions d'une décharge alors que la non-linéarité de la sortie implémente un seuil qui convertit le potentiel de la membrane en un taux de décharge instantanée.

L'entrée linéairement filtrée (c'est à dire, l'argument de  $f$ ) est considérée comme l'intégrale des entrées de courants, qui spécifie une tension intracellulaire non dimensionnée ;  $f$  convertit cette tension en une probabilité de décharge instantanée, qui augmente monotoniquement en fonction de la hauteur de la tension au-dessous du seuil [29, 34]. L'équation générale du GLM pour l'encodage neuronal est [7]

$$\lambda_i(t) = f(b_0 + K * s + \sum_{j=1}^J h_i(j)n_i(t-j)), \quad (3.5)$$

où  $\lambda_i(t)$  est le taux de décharge instantané d'un neurone  $i$  à un temps  $t$ ,  $K * s = \sum_{f=0}^M \sum_{\tau=0}^N k_i(f, \tau)s(f, t-\tau)$  est la convolution entre le stimulus à un temps  $t$  et le STRF,  $n_i(t-j)$  est l'historique des décharges du neurone ( $J$  correspond au nombre de décharges passées). Ici,  $f$  est une fonction exponentielle,  $b_0$  est une constante déterminant le taux de décharge instantané.

Les paramètres de ce modèle peuvent être estimés à l'aide d'une approche par maximum de vraisemblance où la fonction log-vraisemblance est

$$L(s, \theta) = \log p(n|s, \theta) = \sum_{i, \alpha} \log \lambda_i(t_{i\alpha}) - \sum_i \int_0^T \lambda_i(t) dt + const, \quad (3.6)$$

$L(s, \theta)$  est une fonction concave soit du stimulus  $s$  ou des paramètres du modèle  $\theta = [b_0, K, h_i]$  peu importe la réponse  $n$  observée [30].

Ce GLM est avantageux parce qu'il a une faible complexité computationnelle, et ses résultats peuvent être facilement interprétés [7]. De plus, il prend en compte l'historique des décharges neuronales, que le modèle LNP ne considère pas. Des modèles similaires ont également été utilisés pour différents systèmes sensoriels tels que le système visuel, où il

a été utilisé pour prédire avec précision les réponses neuronales de cellules ganglionnaires rétiniennes [31].

### 3.3 Classification de données spatio- et spectro-temporelles

Dans ce projet de recherche, on désire classifier différents sons entendus, à partir uniquement des signaux EEG. On présente ici différentes approches de classifications de données.

#### 3.3.1 Technique d'apprentissage machine standard

Pour traiter des données spatio- et spectro-temporelles (*spatio- and spectro-temporal brain data* - STBD) complexes et intégrer différentes sources de données, les chercheurs ont pour habitude d'utiliser des méthodes traditionnelles d'intelligence artificielle. On présentera dans cette sous-section deux méthodes : la machine à vecteur de support (*support vector machine* - SVM) et le perceptron multicouche.

##### Machine à vecteurs de support

Le principe des SVM [49] est de trouver un classificateur dont la capacité de généralisation est la plus grande possible. Le principe fondateur des SVM est justement d'intégrer à l'estimation le contrôle de la complexité, c'est-à-dire le nombre de paramètres qui est associé dans ce cas au nombre de vecteurs de support. Le principe de base des SVM consiste à ramener le problème de la discrimination à celui de la recherche d'un hyperplan optimal.

Lorsque des observations sont linéairement séparables, il existe une infinité de frontières de décision linéaires, si la métrique n'est pas définie, séparant cet échantillon. La notion d'hyperplan offre un critère de choix parmi toutes ces solutions en admettant que maximiser l'hyperplan c'est aussi minimiser la probabilité d'erreur associée au classificateur qui revient à résoudre

$$\max_{v,a} \underbrace{\min_{i \in [1,n]} \text{dist}(x_i, \Delta(v, a))}_{\text{hyperplan : h}}, \quad (3.7)$$

où  $\Delta(v, a)$  est la frontière de décision et l'indice  $i$  étiquette les  $n$  cas d'apprentissage. La frontière est définie par le couple  $(v, a)$  et pour garantir l'unicité de la solution, on peut considérer l'hyperplan canonique par rapport à un point  $x$  tel que :  $v^T x + a = 1$ . En introduisant l'hyperplan  $h$  comme une variable, le problème se réécrit comme un problème

d'optimisation sous contraintes :

$$\begin{cases} \max_{v,a} & h \\ \text{avec} & \min_{i \in [1,n]} \frac{|v^T x_i + a|}{\|v\|} \geq h \end{cases} \quad (3.8)$$

En posant  $w = \frac{v}{h\|v\|}$  et  $b = \frac{a}{h\|v\|}$ , on a alors :

$$\begin{cases} \max_{w,b} & \frac{1}{\|w\|} \\ \text{avec} & y_i(w^T x_i + b) \geq 1 \quad ; i = 1, \dots, n \end{cases} \quad (3.9)$$

où  $w$  est le vecteur de coefficients,  $b$  est une constante et  $y_i \in \pm 1$  représente les étiquettes de classe des variables indépendantes  $x_i$ . La formulation des SVM s'obtient alors en minimisant  $\|v\|^2$  au lieu de maximiser l'inverse de la norme.

#### 1. SVM sur des données linéairement séparables

Pour construire un hyperplan optimal, les SVM utilisent un algorithme d'apprentissage itératif, qui est utilisé pour minimiser la fonction d'erreur. Soit  $\{(x_i, y_i); i = 1, \dots, n\}$  un ensemble de vecteurs étiquetés avec  $x_i \in \mathbb{R}$  et  $y_i \in \{-1, 1\}$ . Si le SVM est un discriminateur linéaire, la résolution du problème est alors définie par

$$\begin{cases} \min_{w,b} & \frac{1}{2} \|w\|^2 \\ \text{avec} & y_i(w^T x_i + b) \geq 1 \quad ; i = 1, \dots, n \end{cases} \quad (3.10)$$

#### 2. SVM sur des données non linéairement séparables

Dans le cas où les données ne sont pas linéairement séparables, il est possible de suivre la même démarche adoptée que dans le cas linéairement séparable au prix de l'introduction de variables binaire. L'idée est de modéliser les erreurs potentielles par des variables d'écart positives  $\xi_i$  associées à chacune des observations  $(x_i, y_i), i \in [1, n]$ . Dans le cas où le point vérifie la contrainte de l'hyperplan  $y_i(w^T x_i + b) \geq 1$ , la variable d'écart est nulle. On a donc les deux cas suivants :

$$\text{pas d'erreur : } y_i(w^T x_i + b) \geq 1 \Rightarrow \xi_i = 0 \quad (3.11)$$

$$\text{erreur : } y_i(w^T x_i + b) < 1 \Rightarrow \xi_i = 1 - y_i(w^T x_i + b) > 0 \quad (3.12)$$

Le problème consiste à simultanément maximiser l'hyperplan et minimiser la somme des termes d'erreurs à la puissance  $d = 1$  ou  $2$ . On peut alors écrire

$$\begin{cases} \min_{w,b,\xi_i} & \begin{cases} \frac{1}{2}\|w\|^2 \\ \frac{1}{d}\sum_{i=1}^n \xi_i^d \end{cases} \\ \text{avec} & y_i(w^T x_i + b) \geq 1 - \xi_i \quad ; \quad \xi_i \geq 0, \quad i = 1, \dots, n \end{cases} \quad (3.13)$$

On remarque que si toutes les variables d'écarts  $\xi_i$  sont égales à  $0$ , on retrouve le problème des SVM linéairement séparables. La résolution du problème peut s'effectuer grâce à l'introduction d'un terme d'équilibrage  $C > 0$  fixé qui permet de poser le problème sous la forme suivante :

$$\begin{cases} \min_{w,b,\xi_i} & \frac{1}{2}\|w\|^2 + \frac{C}{d}\sum_{i=1}^n \xi_i^d \\ \text{avec} & y_i(w^T x_i + b) \geq 1 - \xi_i \quad ; \quad \xi_i \geq 0, \quad i = 1, \dots, n \end{cases} \quad (3.14)$$

Il convient de noter que plus  $C$  est élevé, plus l'erreur est grande donc son choix doit être fait avec précaution pour éviter le surapprentissage.

### Perceptron multicouche

Le perceptron multicouche (*multilayer perceptron* - MLP) est un classificateur linéaire de type réseau de neurones formel organisé en plusieurs couches au sein desquelles une information circule de la couche d'entrée vers la couche de sortie uniquement (figure 3.4). Chaque couche est constituée d'un nombre variable de neurones, les neurones de la couche de sortie correspondant toujours aux sorties du système [41].

Les premiers réseaux de neurones n'étaient pas capables de résoudre des problèmes non-linéaires ; cette limitation fut supprimée au travers de la rétropropagation du gradient de l'erreur dans les systèmes multicouches. Dans le perceptron multicouche à rétropropagation, les neurones d'une couche sont reliés à la totalité des neurones des couches adjacentes. Ces liaisons sont soumises à un coefficient altérant l'effet de l'information sur le neurone de destination. Ainsi, le poids de chacune de ces liaisons est l'élément clef du fonctionnement du réseau : la mise en place d'un MLP pour résoudre un problème passe donc par la détermination des meilleurs poids applicables à chacune des connexions inter-neuronales. Ici, cette détermination s'effectue au travers d'un algorithme de rétropropagation. Le MLP est un algorithme d'apprentissage supervisé qui apprend une fonction  $f(\cdot) : R^m \leftarrow R^o$  en faisant l'apprentissage avec un ensemble de données, où  $m$  est le nombre de dimension de l'entrée et  $o$  le nombre de dimensions de la sortie. Avec un ensemble de données  $X = x_1, x_2, \dots, x_m$  et une sortie désirée  $y$ , le MLP peut apprendre une

approximation non-linéaire pour la classification et la régression. Il peut y avoir une ou plusieurs couches non linéaires, qu'on appelle couche cachée. La figure 3.4 montre un MLP avec une couche cachée et une sortie scalaire. La couche la plus à gauche, connue comme la couche d'entrée, consiste en un ensemble de neurones  $\{x_i | x_1, x_2, \dots, x_m\}$  représentant les caractéristiques d'entrée. Chaque neurone de la couche cachée transforme les valeurs de la précédente couche avec une sommation linéaire pondérée :  $w_1x_1 + w_2x_2 + \dots + w_mx_m$ , suivi d'une fonction d'activation non linéaire  $g(\cdot)$  comme une fonction hyperbolique tangentielle. La couche de sortie reçoit les valeurs de la couche cachée et les transforme en une valeur de sortie.

L'algorithme de rétropropagation standard se résume donc à la série d'étapes suivantes :

1. Initialiser tous les poids à des petites valeurs aléatoires dans l'intervalle  $[-0.5, 0.5]$  ;
2. Normaliser les données d'entraînement ;
3. Permuter aléatoirement les données d'entraînement ;
4. Pour chaque donnée d'entraînement  $n$  :  
Calculer les sorties observées en propageant les entrées vers l'avant ;  
ajuster les poids en rétropropageant l'erreur observée :

$$w_{ji}(n) = w_{ji}(n-1) + \Delta w_{ji}(n) = w_{ji}(n-1) + \eta \delta_j(n) y_i(n) \quad (3.15)$$

où  $0 \leq \eta \leq 1$  représente le taux d'apprentissage, le gradient local est défini par :

$$\delta_j(n) = \begin{cases} e_j(n) y_j(n) [1 - y_j(n)] & \text{Si } j \in \text{couche de sortie} \\ y_j(n) [1 - y_j(n)] \sum_k \delta_k(n) w_{kj}(n) & \text{Si } j \in \text{couche cachée} \end{cases} \quad (3.16)$$

où  $y_i(n)$  représente soit la sortie du neurone  $i$  sur la couche précédente, si celui-ci existe, soit l'entrée  $i$  autrement.

5. Répéter les étapes 3 et 4 jusqu'à un nombre maximum d'itérations ou jusqu'à ce que la racine de l'erreur quadratique moyenne (*mean square error* - MSE) soit inférieure à un certain seuil.

Du fait de la complexité des STBD, les techniques citées précédemment sont moins efficaces pour créer des relations spatio-temporelles complexes. C'est pourquoi on introduit la notion de réseaux de neurones récurrents qui traitent très bien ce type de données.




Figure 3.4 Perceptron multicouche (2 couches ici par simplicité) ; la couche la plus à gauche correspond à la couche d'entrée du système, suivi de la couche cachée et d'une sortie scalaire désirée.

### 3.3.2 Réseaux de neurones récurrents

Les réseaux de neurones récurrents ont récemment connu un gain en popularité dans les domaines d'apprentissage machine, du traitement de signal et des neurosciences computationnelles. On distingue deux catégories majeures de réseaux de neurones récurrents :

1. les machines à état liquide (LSM) introduit par Wolfgang Maass [22].
2. les machines d'état d'écho (*echo state networks* - ESN) introduit par Herbert Jaeger [15].

Ces réseaux récurrents sont des types de réservoirs, dont les topologies sont fondées sur des probabilités de connexions aléatoires entre les neurones du réseau. LSM et ESN sont des réseaux en trois couches : la couche d'entrée, la couche cachée et la couche de sortie.

Pour résoudre des tâches avec ces réseaux, le signal d'entrée est envoyé dans une couche cachée récurrente à grande dimensionnalité. Les ESNs sont des réseaux récurrents à temps discret et non-linéaire. Les LSMs, quant à eux, sont des modèles biologiquement inspirés avec un modèle de neurones intègre-et-tire (en anglais, *integrate-and-fire*) possédant une adaptation dynamique des synapses. Ils sont implémentés avec des neurones à décharges, présentant une dynamique fortement non linéaire. Ils utilisent tous les deux un réseau avec une couche d'entrée qui est connectée avec la couche cachée. Cependant, ce ne sont pas nécessairement tous les neurones de la couche cachée qui sont reliés à la couche d'entrée. Par exemple, dans [22], environ 30% sont connectés de la couche d'entrée vers la couche cachée. En revanche, dans [15], l'entrée est entièrement connectée à la couche cachée. Jaeger utilise une couche cachée entièrement récurrente (alors que Maass utilise une topologie de connexion spatiale dans laquelle les neurones sont plus densément connectés à leurs voisins locaux plutôt qu'aux neurones plus distants et à peu près 10% de ces connexions sont inhibiteurs. La connectivité dans les deux approches est stochastique, c'est à dire aléatoire. Les poids de la couche de sortie sont définis avec une règle d'apprentissage. Ils sont ajustés en minimisant l'erreur entre la sortie actuelle et la sortie désirée pendant toute la période d'apprentissage. LSM et ESN utilisent une régression linéaire entre les états enregistrés de la couche cachée et de la couche sortie désirée.

En outre, un LSM est composé de deux éléments principaux, un liquide (qu'on appelle aussi le réservoir) sous la forme récurrente d'un réseau de neurones à décharges et une fonction de sortie entraînée pour la sortie désirée. Le liquide est stimulé par les entrées du système provoquant une activité neuronale qui est propagée à travers le réseau en raison de sa topologie récurrente. Par conséquent, à un instant donné dans le réservoir, l'activité neuronale contient des informations sur les entrées. La fonction du liquide est d'accumuler l'information temporelle et spatiale de l'ensemble des signaux d'entrée en un état intermédiaire unique de grande dimension afin d'améliorer la capacité de séparation entre les entrées du réseau. La couche de sortie du réservoir est alors formée pour transformer cet état intermédiaire dans une sortie de système désiré. Le LSM est beaucoup utilisé pour la classification de données cérébrales spatio- et spectro-temporelles, par exemple, avec des données EEG, IRMf ou magnétoencéphalogramme (MEG) [18].

### Architecture NeuCube

L'architecture NeuCube, présentée dans [18], introduit un réseau de neurones à décharges en utilisant un LSM pour créer des modèles concrets de cartographie, d'apprentissage et de compréhension de données STBD. NeuCube apprend à partir des STBD et créer des connexions entre des groupes de neurones dans un réservoir qui manifeste des trajectoires




Figure 3.5 Système expérimental pour le modèle Neucube EEG pour les interfaces cerveau machines. Blocs : 1. Données EEG ; 2. Encodeur ; 3. Réservoir NeuCube ; 4. Vecteurs d'état ; 5. Classificateur.

de l'activité neuronale. Une fois l'apprentissage appliqué, NeuCube peut reproduire ces trajectoires, même si seulement une partie des entrées STBD est présentée. Donc, elle permet également d'agir comme un système prédictif de l'activité cérébrale pour prédire et possiblement prévenir de certains événements. Les données EEG peuvent par exemple être combinées avec les données IRMf pour l'étude des connectivités spatio-temporelle fonctionnelle et structurelle dans le cerveau à différentes échelles de fréquence.

Comme nous l'avons dit précédemment, il est commun d'utiliser des méthodes traditionnelles d'intelligences artificielles comme les SVM ou le perceptron multicouche, mais elles sont moins efficaces pour créer des relations spatio-temporelles complexes pour des STBD. Dans [18], une architecture est présentée pour la création de modules computationnels efficace à partir de ce type de données. Chacun des modules est décrit à la figure 3.5 en commençant de gauche à droite par : les données EEG enregistrées et prétraitées pour l'encodeur, l'encodeur pour rendre compatible les données EEG avec le réservoir NeuCube, le réservoir LSM NeuCube, les vecteurs d'état et enfin le classificateur pour la sortie désirée. Pour démontrer que la performance de NeuCube est supérieure à celles des méthodes d'apprentissage machine standards, une étude pour un problème de classification de tâches a été réalisée à partir de données EEG [18]. Dans cette étude, deux scénarios étaient possibles pour le sujet, soit il effectue une expérience de mémoire, soit il se relaxe. Les performances atteintes par la classification avec NeuCube sont de 85% contrairement avec un SVM (74%) ou avec un perceptron multicouche (78%). Le problème majeur de l'architecture NeuCube réside dans l'optimisation des paramètres dans chacun des modules pour obtenir de meilleures performances. En effet, de récentes méthodes ont été développées, comme les algorithmes génétiques [33] ou l'optimisation par essais particuliers [25], et peuvent être appliquées pour optimiser ces paramètres. Les domaines d'application de ce modèle ne sont pas seulement limités aux STBD. Potentiellement, il peut être utilisé



pour modéliser n'importe quelles données spatio-temporelles multivariées telles que la modélisation environnementale, modélisation cognitive et émotive ou encore le traitement de données climatiques (par exemple, pour la prédiction de tremblements de terre).

Dans ce projet de recherche, une architecture semblable à celle de NeuCube sera utilisée, mais qui fera appel à un réservoir de neurones connectés de manière récurrente pour être à la limite du chaos plutôt qu'à un LSM. Ceci devrait en principe améliorer les performances de classification de STBD pour un problème spécifique.

#### Réservoir de neurone à décharge récurrent

Le réservoir utilisé ici pour la classification des données EEG dans les sections subséquentes est présenté dans [6]. Ce réseau de neurones a été conçu pour ajuster de manière adaptative un réservoir de neurones connectés de manière récurrente pour être à la limite du chaos. De ce fait, ce réseau est censé obtenir de meilleures performances comparées aux techniques citées précédemment. La SOC est obtenue avec une règle d'apprentissage local et non supervisé. Ce réservoir a montré qu'il pouvait maintenir efficacement une longue activité soutenue tout en s'adaptant rapidement au signal d'entrée et également en améliorant les transitoires [6]. Les séquences de décharges neuronales sont entrées séquentiellement dans le réservoir et chacune d'elle est connectée à tous les neurones du réservoir. Pour le réservoir, le modèle de neurone utilisé est le *Leaky Integrate-and-Fire* (LIF) avec un seuil adaptatif [1]. Il contient 512 neurones, 80% de ces neurones sont excitateurs et 20% sont inhibiteurs. La connectivité entre les neurones se fait avec une topologie « small-world ». La topologie *small-world* fait l'hypothèse que chacun des neurones est relié à n'importe quels autres neurones du réservoir par une courte chaîne de relations sociales. Ce réservoir est décrit plus précisément dans la section 4.4.2 du chapitre 4.



# CHAPITRE 4

## MÉTHODOLOGIE

Dans ce projet, on désire étudier de quelle façon est distribuée l'information d'un stimulus auditif dans les différents canaux EEG. Ce chapitre énumère toute la méthodologie adoptée pour cette étude. On voit tout d'abord le matériel utilisé pour les simulations et le déroulement pour recueillir les enregistrements EEG. On détaille ensuite le modèle de couplage bande-fréquence (FBC) développé dans [50] pour estimer l'activité corticale sous-jacente à partir de toutes les électrodes que comporte l'EEG. On valide ce modèle avec un modèle d'encodage utilisé dans [39]. Enfin, on effectue la classification de nos données EEG en utilisant un réservoir RNN développé dans [6].

### 4.1 Acquisition et prétraitement des signaux EEG

#### 4.1.1 Matériels

Les signaux EEG sont enregistrés au sein du laboratoire SNAIL (*Sherbrooke Neuro Analysis and Imaging Lab*) du Centre de recherche du Centre Hospitalier Universitaire de Sherbrooke (CRCHUS). Les enregistrements EEG sont effectués grâce à un montage de 64 électrodes Ag/AgCl fixées sur un casque actiCAP *active electrode system Version I et II* (*Brain Products GmbH*, Allemagne) et connectés à des amplificateurs *BrainAmp MR*. Les signaux EEG sont enregistrés à l'aide du logiciel Vision Recorder. Les électrodes sont disposées selon le système standard international 10-20 [16].

#### 4.1.2 Acquisition des données EEG

##### Préparation avant l'expérience

Les expériences ont été effectuées sur un ensemble de 8 sujets en bonne santé. Une préparation spéciale est exigée avant chaque expérience EEG. Si la personne prend un médicament, il se peut qu'il doive cesser de le prendre avant l'examen. Ses cheveux doivent être propre et ne doivent pas contenir de fixatif, de lotion ou de tout autre produit, car les électrodes seront fixées à son cuir chevelu. Les électrodes sont déjà positionnées dans un bonnet. Elles ont pour rôle d'amplifier et d'enregistrer l'activité électrique des neu-

rones. Sous chaque électrode, on enregistrera un signal électrique produit par un groupe de neurones sous-jacent.

### Déroulement de l'expérience

L'expérience dure au total 90 minutes et est divisée en deux parties. La première consiste à installer le casque EEG sur le sujet (30 min). Le sujet est pour cela confortablement assis sur une chaise à roulette conventionnelle devant un écran d'ordinateur et du gel conducteur est déposé sous chaque électrode pour permettre un contact efficace avec le cuir chevelu. Ensuite, durant l'expérience (60 min), le sujet doit rester immobile, les yeux fermés (limiter tout mouvement des yeux), éviter tout mouvement facial et de déglutition. Il doit rester concentré à l'écoute des différents signaux de paroles durant toute l'expérience. Les signaux sont présentés à l'aide d'écouteurs intra-auriculaire. Les voyelles a, i et u ont été choisies, car elles sont situées au sommet du triangle vocalique [38] qui a pour effet que les deux premiers formants soient aussi distinct que possible.

### Simulation

La simulation est développée sous MATLAB en combinaison avec la boîte à outils Psych-Toolbox [4]. Cette boîte à outils est un ensemble de fonctions et d'exécutables MATLAB dédiés à la réalisation d'expériences en psychologie. La figure 4.1 représente un schéma explicatif du déroulement de la simulation. Pendant la simulation, les essais doivent être répétés au moins 80 fois. Pour ne pas que le sujet s'habitue, et par conséquent augmenter son activité électrique, les stimuli sont présentés aléatoirement ; chaque essai dure environ 8 secondes. Une pause de quelques minutes est faite toutes les 5 min pour permettre au sujet de se relaxer et s'étirer. À chaque phase d'un essai, il faut placer un point de repère pour savoir à quel moment le stimulus auditif a été envoyé et ainsi savoir où il est présent sur l'enregistrement.

#### 4.1.3 Prétraitement des données EEG

Le prétraitement est effectué sous MATLAB avec la boîte à outils : EEGLAB [11]. Une fois les données EEG acquises, les signaux sont rééchantillonnés à 500 Hz et filtrés avec un filtre passe-bande entre 0.1 et 45 Hz pour extraire les bandes de fréquence du domaine d'intérêt. Les signaux EEG sont ensuite découpés en intervalles de 2 secondes avec apparition du stimulus à 0.5 seconde pour chaque intervalle. Ensuite, si l'amplitude du signal excède la limite  $\pm 75 \mu\text{V}$ , les essais correspondants sont marqués pour réjection. Initialement, les données EEG sont acquises suivant un site de référence commun (habituellement le lobe de l'oreille ou le nez), mais ces références introduisent du bruit. Donc, les données EEG

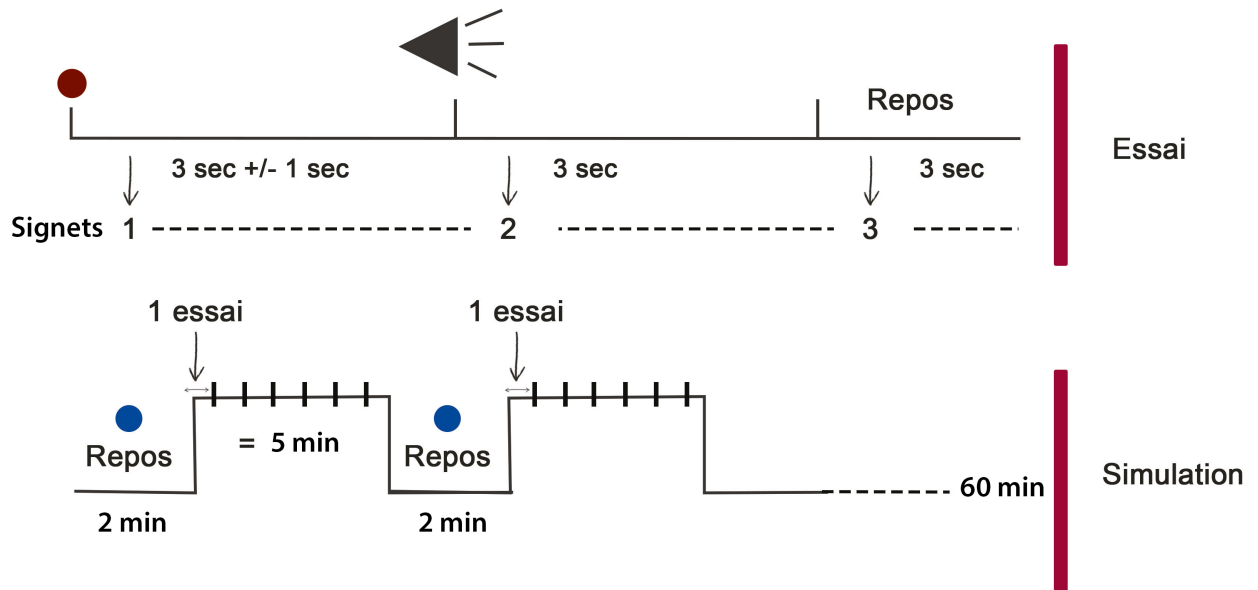


Figure 4.1 Schéma explicatif du déroulement de l'expérience.

sont re-référencées par une moyenne locale [11]. Convertir les données en une moyenne locale est particulièrement important quand le nombre d'électrodes est assez dense pour couvrir toute la tête. En fait, l'avantage d'une moyenne de référence est que la somme des courants positifs et négatifs vers l'extérieur sur toute la tête est nulle.

## 4.2 Potentiel évoqué

Le calcul du potentiel évoqué constitue la première étape d'analyse de l'EEG de la présente étude. Elle permet, entre autre, de valider la qualité des signaux EEG acquis. Le potentiel évoqué (*event-related potential* - ERP) correspond à la modification du potentiel électrique produite par le système nerveux en réponse aux stimuli externes. Les potentiels évoqués sont utilisés pour comprendre l'organisation fonctionnelle du système nerveux. Dans cette étude, le cerveau est stimulé par des signaux auditifs. Les ERPs peuvent être mesurés de façon fiable en utilisant l'EEG. En effet, ils reflètent le processus de milliers de neurones qui déchargent simultanément.

La réponse cérébrale à un seul stimulus n'est généralement pas visible dans l'enregistrement EEG d'un seul essai. Pour voir la réponse du cerveau à un stimulus, on doit répéter un certain nombre de fois les essais (dans cette étude, 80 répétitions par stimulus sont suffisantes) et les moyenner, ce qui résulte en ce qu'on appelle l'ERP. L'ERP fournit une excellente résolution temporelle, étant donné que la vitesse de l'enregistre-

ment n'est limitée que par le taux d'échantillonnage de l'EEG. La résolution spatiale d'un ERP, cependant, est beaucoup plus faible. En fait l'emplacement des sources ERP est un problème inverse qui ne peut pas être exactement résolu, seulement estimé. Les ERP fournissent une mesure continue dans le temps entre un stimulus et une réponse, ce qui permet de déterminer quelle manipulation expérimentale spécifique affecte la réponse. Un autre avantage par rapport aux mesures comportementales est qu'elles peuvent fournir une mesure du traitement des stimuli, même quand il n'y a pas de changement comportemental. Cependant, en raison de l'amplitude significativement petite d'un ERP, il faut généralement un grand nombre d'essais pour le mesurer correctement.

### 4.3 Estimation de l'activité corticale

On désire étudier comment l'information auditive est distribuée dans les différents canaux EEG. Pour ce faire, on estime premièrement l'activité corticale à partir d'EEG. On valide ensuite l'estimation de l'activité corticale obtenue à partir des EEGs avec celle obtenue directement à partir des stimulus auditifs par le modèle d'encodage. Cela permet de déterminer quelles électrodes contiennent effectivement de l'information du stimulus auditif. En effet, les électrodes pour lesquelles le modèle d'encodage arrive à prédire l'activité estimée à partir des EEGs à partir du stimulus contiennent forcément de l'information de ce stimulus auditif. On présente ici ces deux approches d'estimation de l'activité corticale.

#### 4.3.1 Estimation de l'activité corticale à partir d'EEG

La relation entre les EEGs et les taux de décharges des neurones du cortex sous-jacents sont utiles pour l'analyse pratique de l'EEG seulement s'ils amènent à des règles simples de prédiction. Cette méthode, FBC, a été développée et validée pour le système visuel [50] et sera ici utilisée dans le contexte du système auditif et comparé avec un modèle d'encodage neuronal. On procède comme suit pour estimer l'activité neuronale à partir des EEG :

1. Extraction de la puissance Gamma (30 – 45 Hz). On calcule l'enveloppe de la bande de fréquence entre 30 Hz et 45 Hz en calculant l'amplitude de sa transformée d'Hilbert.
2. Extraction de la phase delta (2 – 4 Hz). On calcule l'angle de la transformée de Hilbert pour la bande de fréquence entre 2 Hz et 4 Hz pour en extraire la phase instantanée comprise entre  $[0, 2\pi]$  (correspondant à la limite de la bande de phase).

3. Modèle linéaire généralisé :

$$Y = \beta_1 X_1 + \beta_2 X_2 + \epsilon \quad (4.1)$$

où  $Y$  représente les décharges neuronales,  $X_{1,2}$  sont respectivement la puissance d'oscillation et la phase,  $\beta_{1,2}$  sont les coefficients de pondération de la puissance et de la phase fixés à 0.5.

Bien que cette approche permette d'obtenir une estimation de l'activité corticale, elle ne permet assurément pas d'estimer directement l'activité de neurones présentes directement sous une électrode EEG donnée, comme c'est le cas pour le système visuel. En effet, tel que mentionné précédemment, les neurones du cortex auditif sont situés dans un repliement du cortex et donc parallèle au scalp. Cette approche permet néanmoins d'obtenir une représentation alternative de l'activité neuronale qui devrait se rapprocher de celle de l'activité corticale.

### 4.3.2 Estimation de l'activité corticale avec un modèle d'encodage

Dans la section 4.3.1, l'activité corticale a été estimée avec un modèle linéaire généralisé à partir des signaux EEG. Puisque cette approche n'a pas été validée pour le système auditif, on veut confronter l'estimation obtenue à une autre estimation de l'activité corticale, faute de pouvoir mesurer cette activité directement. Afin d'effectuer cette autre estimation de l'activité corticale, on part du stimulus auditif et on essaie de voir si on peut aussi estimer l'activité corticale prédite par les EEG [36]. Pour ce faire, on utilise un modèle de l'activité des décharges neuronales faisant appel aux processus ponctuels, présenté à la section 3.2.1 [35]. Le modèle prend en compte les dynamiques intrinsèques des neurones et également des propriétés spectro-temporelles du stimulus d'entrée. Un modèle de processus ponctuel peut être complètement défini par sa fonction d'intensité conditionnelle (*conditional intensity function* - CIF)  $\lambda_i(t)$  d'un neurone  $i$  à un temps  $t$ . Après une expansion de Volterra discrète de premier ordre à la fois de la représentation spectro-temporelle du signal de parole d'entrée,  $s$ , et de l'historique des décharges passées du neurone,  $n_i(t)$ , la CIF peut être obtenue suivant :

$$\lambda_i(t) = \lambda_o \lambda_S \lambda_{N_i}(t) \quad (4.2)$$

où :

$$\lambda_o = \exp(b_0) \quad (4.3)$$

$$\lambda_S = \exp(K * s) \quad (4.4)$$

$$\lambda_{N_i}(t) = \exp\left(\sum_{j=1}^J h_i(j)n_i(t-j)\right) \quad (4.5)$$

et  $b_0$ ,  $K$ ,  $h_i(j)$  sont les noyaux de Volterra du premier ordre. Le paramètre  $\lambda_o$  correspond au taux de décharges instantané,  $\lambda_{N_i}(t)$  à la contribution de l'historique des décharges passées indiquant l'effet de la dynamique neuronale sur le taux de décharge global et  $\lambda_S$  à la contribution des propriétés spectro-temporelles du stimulus d'entrée. Une interprétation possible de ce modèle est que  $\lambda_{N_i}(t)$  et  $\lambda_S$  vont moduler les décharges instantanées représentées par  $\lambda_o$ .

Pour évaluer la qualité du modèle et de l'estimation des paramètres  $b_0$ ,  $K$ ,  $h_i(j)$ , on utilise une validation croisée. La validation croisée désigne le processus qui permet de tester la précision prédictive d'un modèle dans un échantillon test (parfois aussi appelé échantillon de validation croisée) par rapport à la précision prédictive de l'échantillon d'apprentissage à partir duquel le modèle a été développé. Dans l'idéal, avec un échantillon suffisamment grand, une certaine proportion d'observations (par exemple la moitié ou les deux tiers) peut être affectée à l'échantillon d'apprentissage et les observations restantes sont affectées à l'échantillon test. Le modèle peut être construit en utilisant les observations de l'échantillon d'apprentissage, et la puissance prédictive peut être testée en utilisant les observations de l'échantillon test. Si le modèle est validé aussi bien sur l'échantillon test que sur l'échantillon d'apprentissage, on peut dire que la validation croisée est bonne ou plus simplement, qu'il y a validation croisée. Dans cette étude, on utilise 75% des décharges neuronales estimées à l'aide du modèle de couplage bande fréquence pour estimer les paramètres  $b_0$ ,  $K$ ,  $h_i(j)$  et on utilise les autres 25% pour valider le modèle.

Au chapitre suivant, on peut donc comparer l'estimation de l'activité neuronale obtenue à l'aide du modèle d'encodage décrit par l'équation 4.2 et celle obtenue à partir des EEG à l'aide de l'équation 4.1. On désire également étudier l'importance relative, dans le modèle d'encodage, du stimulus d'entrée par rapport aux dynamiques neuronales. Pour ce faire, on regarde la déviance relative qui quantifie l'importance d'un ensemble spécifique de paramètres, c'est-à-dire la dynamique neuronale indiquée ici par l'historique des décharges ou le stimulus d'entrée, dans le modèle. La déviance relative [9] peut être définie suivant les paramètres de l'historique et du stimulus comme :

$$\Theta^H = \frac{\text{Dev}(b_0, K) - \text{Dev}(b_0, K, h_i)}{\text{Dev}(b_0, K, h_i)} \quad (4.6)$$



$$\Theta^S = \frac{\text{Dev}(b_0, h_i) - \text{Dev}(b_0, K, h_i)}{\text{Dev}(b_0, K, h_i)} \quad (4.7)$$

où  $\text{Dev}(\varphi)$  est la déviance du modèle avec les paramètres  $\varphi$ . Une petite déviance indique un meilleur ajustement du modèle aux données expérimentales. Donc, un petit  $\Theta^H$  ( $\Theta^S$ ) indique une plus petite contribution des paramètres de l'historique (stimulus) au modèle et vice versa.

## 4.4 Classification à l'aide d'un réservoir de neurone à décharge récurrent

On veut également étudier s'il est possible d'obtenir des bonnes performances de classification de voyelles avec les données EEG en entrée en fonction du nombre d'électrodes utilisées et de la position de ces dernières sur le cuir chevelu. Cela donnera une indication de la diffusion de l'information associée au stimulus auditif dans les différentes électrodes de l'EEG. Pour faire cette classification, nous allons utiliser un réservoir RNN. La structure du modèle de classification utilisée est présentée à la figure 4.2. Le premier bloc consiste, après avoir acquis les signaux EEG, à prétraiter les données EEG pour les rendre utilisables. Cela consiste à rejeter les artéfacts et à normaliser les données EEG tel que présenté à la section 4.1.3. Les signaux prétraités sont ensuite encodés en séquence de décharges neuronales par un encodeur qui va générer une sortie qui sera compatible avec le réservoir. Les signaux encodés sont propagés à travers le réservoir et les changements temporels de l'activité neuronale dans le réservoir seront lus périodiquement par la couche de sortie du réservoir. La dernière étape utilise un algorithme d'apprentissage machine pour associer les données de la couche de sortie à l'étiquette de classe concernée, c'est-à-dire dans le cas présent aux différentes voyelles. Chacune de ces étapes est décrite en détail dans les sous-sections suivantes.

### 4.4.1 Encodage des données

Pour être compatibles avec les entrées du réservoir RNN, les signaux EEG doivent être transformés en séquences de décharges neuronales. Cet encodage est effectué en utilisant l'algorithme *Ben's Spike Algorithm* (BSA) qui a été validé pour le traitement de données EEG [28]. Cet algorithme assume l'utilisation d'un filtre de reconstruction RIF (réponse impulsionnelle finie),  $h(k)$ , [43] et opère de la manière suivante. À chaque temps  $\tau$  donné,




Figure 4.2 Modèle de classification de données EEG en utilisant un réservoir RNN : 1) données EEG prétraitées ; 2) données EEG encodées en séquences de décharges neuronales ; 3) réservoir RNN ; 4) couche de sortie du réservoir ; 5) classificateur.

deux équations sont calculées :

$$e_1(\tau) = \sum_{k=0}^M |s(k + \tau) - h(k)| \quad (4.8)$$

$$e_2(\tau) = \sum_{k=0}^M |s(k + \tau)| \quad (4.9)$$

où  $s$  est le signal EEG. Si  $e_1(\tau) < e_2(\tau) - \theta$ , le neurone décharge et une valeur de décharge 1 est associée à ce temps, sinon l'activité des décharges neuronales est représentée par la valeur de 0. Selon [19], le seuil  $\theta$  est fixé à 0.9950 et l'ordre du filtre RIF est choisi avec  $M = 10$ .

#### 4.4.2 Réservoir RNN

On propose ensuite d'utiliser un réservoir RNN [6], activés en entrée par les données EEG, pour faciliter la classification des stimuli auditifs. Le réservoir RNN est composé d'un réservoir et d'une fonction de lecture utilisée pour la classification. Le réservoir fournit un prétraitement computationnel pour les sorties linéaires suivantes. Chaque neurone dans le réservoir reçoit une excitation constante de la sortie de l'encodeur et des autres neurones du réseau. Les neurones sont connectés aléatoirement les uns aux autres. Le réservoir inclut de l'information à propos des entrées passées et présentes à un temps donné. La fonction du réservoir est d'accumuler de l'information temporelle et spatiale d'un ensemble de signaux d'entrée en un état intermédiaire unique avec une grande dimension pour améliorer la capacité de séparation entre les entrées de réseau. Ce réseau de neurones a été conçu pour

ajuster de manière adaptative un réservoir de neurones connectés de manière récurrente pour être à la limite du chaos. La SOC est obtenue avec une règle d'apprentissage local et non supervisé et a démontré qu'elle pouvait maintenir efficacement une longue activité soutenue tout en s'adaptant rapidement au signal d'entrée et également en améliorant les transitoires [6].

Pour moduler l'activité à l'intérieur du réservoir, on a utilisé le modèle de neurone *Leaky Integrate-and-Fire* (LIF) avec un seuil adaptatif [6] décrit dans les équations différentielles suivantes :

$$\tau_v \frac{dv(t)}{dt} = v_0 - v(t) \quad (4.10)$$

$$\tau_{v_{th}} \frac{dv_{th}(t)}{dt} = v_{th_0} - v_{th}(t) \quad (4.11)$$

où  $\tau_v$  et  $\tau_{v_{th}}$  sont respectivement la constante de temps de membrane comprise entre [15 ms, 25 ms] et la constante de temps pour le seuil dynamique fixé à 50 ms. Le potentiel de réinitialisation  $v_0$  et le seuil minimum de décharge  $v_{th_0}$  sont respectivement pris dans les intervalles [0.5, 1.0] et [1.0, 2.0]. Quand le potentiel membranaire  $v(t)$  franchit le seuil  $v_{th}$ , le neurone  $i$  décharge et  $v(t)$  est réinitialisé à  $v_0$  avec son seuil augmentant suivant :  $v_{th} \leftarrow v_{th} + v_{th_i}$ . Les poids entre les neurones sont stockés dans la matrice de connectivité du réservoir et sont maintenus fixes. Les poids excitateurs et inhibiteurs sont respectivement pris dans les intervalles [0.25, 0.50] et [-0.50, -0.25]. Seulement les poids de la fonction de lecture associée au classificateur sont entraînés pour une tâche spécifique. Le réservoir contient 512 neurones dans une grille en trois dimensions dont 80% sont des neurones excitateurs choisis aléatoirement et 20% sont inhibiteurs. L'interconnectivité choisie dans le réservoir utilisé ici est une topologie *small-world* décrite dans [6]. La topologie *small-world* fait l'hypothèse que chacun des neurones est relié à n'importe quels autres neurones du réservoir par une courte chaîne de relations sociales. D'un point de vue mathématique, on retient deux particularités pour ce type de topologie. D'une part la distance moyenne entre deux neurones est proportionnelle au logarithme du nombre de neurones et d'autre part que les voisins d'un sommet donné sont connectés entre eux.

### 4.4.3 Couche de sortie

La fonction de lecture affiche à tous les temps  $t$  les états présents et passés des entrées qui sont transformées en états dans le réservoir. Elle a accès à toute l'information à propos de l'état du réservoir. En fait, le réservoir accumule de l'information temporelle de toutes les entrées de séquences de décharges neuronales et les transforme en états dynamiques qui peuvent être classifiés dans le temps. L'état du réservoir est extrait et une fonction de

lecture sans mémoire est utilisée pour convertir ce grand état dimensionnel en une sortie désirée. L'extraction est faite en calculant le taux de décharge moyen de chaque neurone du réservoir dans des trames de 200 ms. Cette simple couche de lecture devrait être très performante pour extraire des états individualisés du réservoir et un modèle linéaire devrait être suffisant pour effectuer une classification si l'espace a une dimension suffisamment élevée. En effet, tous les problèmes de classification sont linéairement séparables si l'entrée est projetée dans une dimension de l'espace suffisamment grand, ce qui est la prémisse des SVM. Dans le cas présent, le réservoir fait l'expansion de la dimensionnalité explicitement et non pas avec une méthode de noyaux.

#### 4.4.4 Classification

L'étape finale est d'effectuer la classification depuis la sortie de la couche de lecture en une étiquette de classe désirée, c'est-à-dire 0 pour la voyelle a, 1 pour la voyelle i et 2 pour la voyelle u. Dans le cas présent, une cartographie de la couche de lecture en étiquette de classe est obtenue par un modèle de régression linéaire. On est ainsi en mesure d'obtenir une bonne classification des trois stimuli auditifs en utilisant ce réservoir RNN.

Le chapitre suivant présente les différents résultats obtenus ainsi que leurs analyses. Ces résultats sont issus des différents algorithmes mentionnés et développés à partir de la méthodologie de projet.

# CHAPITRE 5

## TRAITEMENT DES DONNÉES ET ANALYSE DES RÉSULTATS

On présente dans ce chapitre les différents résultats obtenus à travers ce projet de recherche en commençant tout d'abord par étudier les réponses observées sur tous les canaux EEG. À la suite de la présentation d'un stimulus auditif. Ensuite, l'estimation de l'activité corticale sera étudiée puis validée à l'aide du modèle d'encodage. Enfin, différentes classifications seront présentées. On veut notamment savoir s'il est possible d'obtenir des bonnes performances de classification de voyelles avec les données EEG en entrée en fonction du nombre d'électrodes utilisées et de la position de ces dernières sur le cuir chevelu.

### 5.1 Potentiel évoqué

La figure 5.1 présente les courbes ERP moyennées sur l'ensemble des trois stimuli (a, i, u) pour chacune des 64 électrodes que comporte l'EEG ; à noter que la position des électrodes a subi une rotation de -90 degrés par rapport à la représentation présentée à la figure 2.6 de la section 2.3.3. Les 64 signaux sont découpés dans des intervalles allant de -500 ms à 1500 ms. Les stimuli sont présentés à 0 ms. On remarque que sur les électrodes frontales les courbes sont positives et inversement, que sur les électrodes occipitales, c'est-à-dire situées à l'arrière, elles sont négatives. Ceci s'explique par l'orientation des neurones dans le cortex auditif, ils sont parallèles au cuir chevelu, c'est pourquoi la réponse est faible avec les électrodes temporales où est situé le cortex auditif (se référer à la section 2.3.2). La figure 5.2 est un zoom du canal Fz (frontale - axe central) de la figure 5.1, où on peut y observer le potentiel évoqué cortical (*cortical evoked responses*) qui apparaît entre 100 et 250 ms après la présentation des stimuli. On peut également voir le potentiel évoqué cognitif (correspondant à l'onde P300) qui apparaît à partir de 250 ms après la stimulation. Du fait qu'il y ait une forte réponse positive sur les électrodes frontales et la même réponse, mais négative, sur les électrodes occipitales, il pourrait donc y avoir plus d'information auditive dans les électrodes frontales et occipitales comparativement aux électrodes temporales, centrales et en périphérie du cortex.






Figure 5.2 Représentation de l'ERP moyennée sur l'ensemble des stimuli du canal Fz.




Figure 5.3 Représentations en 2D des ERPs moyennés sur l'ensemble des stimuli de 0 ms à 500 ms avec un pas de 100 ms.




Figure 5.4 A - Représentation frontale en 3D des ERPs moyennées sur l'ensemble des stimuli ; B - Représentation latérale en 3D des ERPs moyennées sur l'ensemble des stimuli ; C - Représentation occipitale en 3D ERPs moyennées sur l'ensemble des stimuli.

On peut confirmer l'observation citée précédemment en faisant la cartographie 2D (figure 5.3) des ERPs moyennés sur l'ensemble des stimuli de 0 à 500 ms avec un pas de 100 ms. En référence à la figure 5.2, la courbe ERP a une réponse positive qui se traduit par la partie en rouge sur la figure 5.3 à 300 ms. En effet, c'est à ce moment précis que la réponse aux stimuli se traduit par une forte augmentation du potentiel. Le potentiel atteint pour le canal Fz un maximum d'environ  $4.2 \mu\text{V}$  vers 300 ms. Puis la réponse s'estompe déjà à 500 ms. On observe exactement la même dynamique pour la région occipitale.

La figure 5.4 présente trois coupes en 3D des ERPs moyennés sur l'ensemble des stimuli à 300 ms. La première est une coupe frontale en 3D où on observe une réponse positive (zone rouge). Sur la deuxième, on voit bien le contraste de l'importance de l'ERP de la zone frontale à la zone occipitale. Enfin, sur la dernière, les potentiels négatifs qui se traduisent par la zone bleue.






Figure 5.5 Représentations des ERPs moyennées pour les voyelles a, i et u suivant le canal Fz.

Les ERPs démontrent donc une réponse attendue plus ou moins prononcée suivant la position spatiale de l'électrode. Nous pouvons également comparer les ERPs de chaque stimulus. La figure 5.5 montre que l'on peut observer un délai entre les réponses neuronales suite à la présentation des différents stimulus et aussi que ces réponses ont des amplitudes maximales différentes (signaux issus de l'électrode centrale : Fz). Les réponses neuronales ne s'activent donc pas de la même manière et dans les mêmes zones.

## 5.2 Estimation de l'activité corticale

Dans cette section, on estime l'activité corticale à partir d'EEGs et on valide cette estimation par un modèle d'encodage. Ce faisant, on souhaite étudier si l'activité corticale estimée contient effectivement de l'information provenant du stimulus auditif.

### 5.2.1 Estimation de l'activité corticale à partir des EEGs

D'après la section 5.1, on sait qu'il y a une réponse neuronale suite à l'envoi de stimuli auditifs. On présente maintenant les résultats obtenus pour l'estimation de l'activité neu-

ronale au niveau du cortex en utilisant un modèle FBC à partir des EEGs [50] (voir section 4.3.1).

D'après [50], les résultats du modèle de couplage bande-fréquence suggèrent que l'activité corticale sous-jacente dépend d'une interaction spécifique entre la puissance haute fréquence et la phase basse fréquence (FBC). Si cela était effectivement le cas, on s'atten-




Figure 5.6 A - Signal EEG prétraité en réponse au stimulus a; B - Signal EEG filtré dans les bandes delta (2 - 4 Hz) et gamma (30 - 45 Hz); C - La puissance gamma extraite de la bande gamma; D - La phase delta extraite de la bande delta; E - La phase delta et la puissance gamma sont utilisées comme régresseurs pour modéliser l'activité corticale sous-jacente.

draît à voir de fortes réponses de l'activité corticale sous-jacente quand une augmentation de la puissance gamma EEG coïncide avec la phase delta préférée, et des réponses plus faibles lorsque des augmentations similaires de la puissance gamma EEG apparaissent à une phase delta différente. D'après la figure 5.6, l'augmentation de la puissance gamma qui apparaît pendant la phase delta préférée mène à une augmentation de l'activité corticale sous-jacente, laquelle est représenté par le modèle GLM dans la figure 5.6 E. La figure 5.6 E représente une estimation de l'activité corticale sous-jacente modulée.

### 5.2.2 Validation de l'activité corticale à l'aide d'un modèle d'encodage

Dans la section précédente, on estime l'activité corticale sous-jacente à partir des signaux EEG. Dans la présente section, on part plutôt du stimulus et on essaie de voir si on peut aussi estimer cette activité et vérifier si on obtient les mêmes résultats avec les 2 modèles. Tel qu'indiqué à la section 4.3.2, le but consiste donc à estimer 3 paramètres qui permettent de calculer le taux de décharge instantané de chaque neurone à un temps donné suivant :

$$\lambda_i(t) = f(b_0 + K * s + \sum_{j=1}^J h_i(j)n_i(t-j)) \quad (5.1)$$

En fait on prend pour acquis qu'il y a 3 paramètres qui vont modifier le taux de décharge du neurone : 1) l'entrée  $b_0$  qui est associée au taux de décharge spontanée de ce neurone, 2)  $K$ , soit le STRF du neurone et 3)  $h_i$  qui tient compte de la dynamique neuronale. La quantité  $s$  correspond au spectrogramme du stimulus et  $n_i$  aux décharges passées. Ce modèle a été démontré par le passé comme représentant de façon adéquate l'activité neuronale au niveau de plusieurs structures du système auditif [35].

Une validation croisée a été effectuée afin d'estimer ces paramètres. Lors de cette validation, 75% des décharges neuronales sont utilisées comme données d'entraînement pour estimer les paramètres du modèle d'encodage, puis les paramètres sont validés sur les données tests constituées des 25% restantes. Cette opération est effectuée 4 fois en prenant tour à tour différentes données tests. Pour mieux illustrer ce traitement, on sépare les données globales que l'on a en 4 parties :

$$[25\% = (1), 25\% = (2), 25\% = (3), 25\% = (4)]. \quad (5.2)$$

À la figure 5.7 A, on montre le résultat lorsque l'on utilise 75% des dernières données de l'estimation corticale sous-jacente pour estimer les 3 paramètres et qu'on valide ces

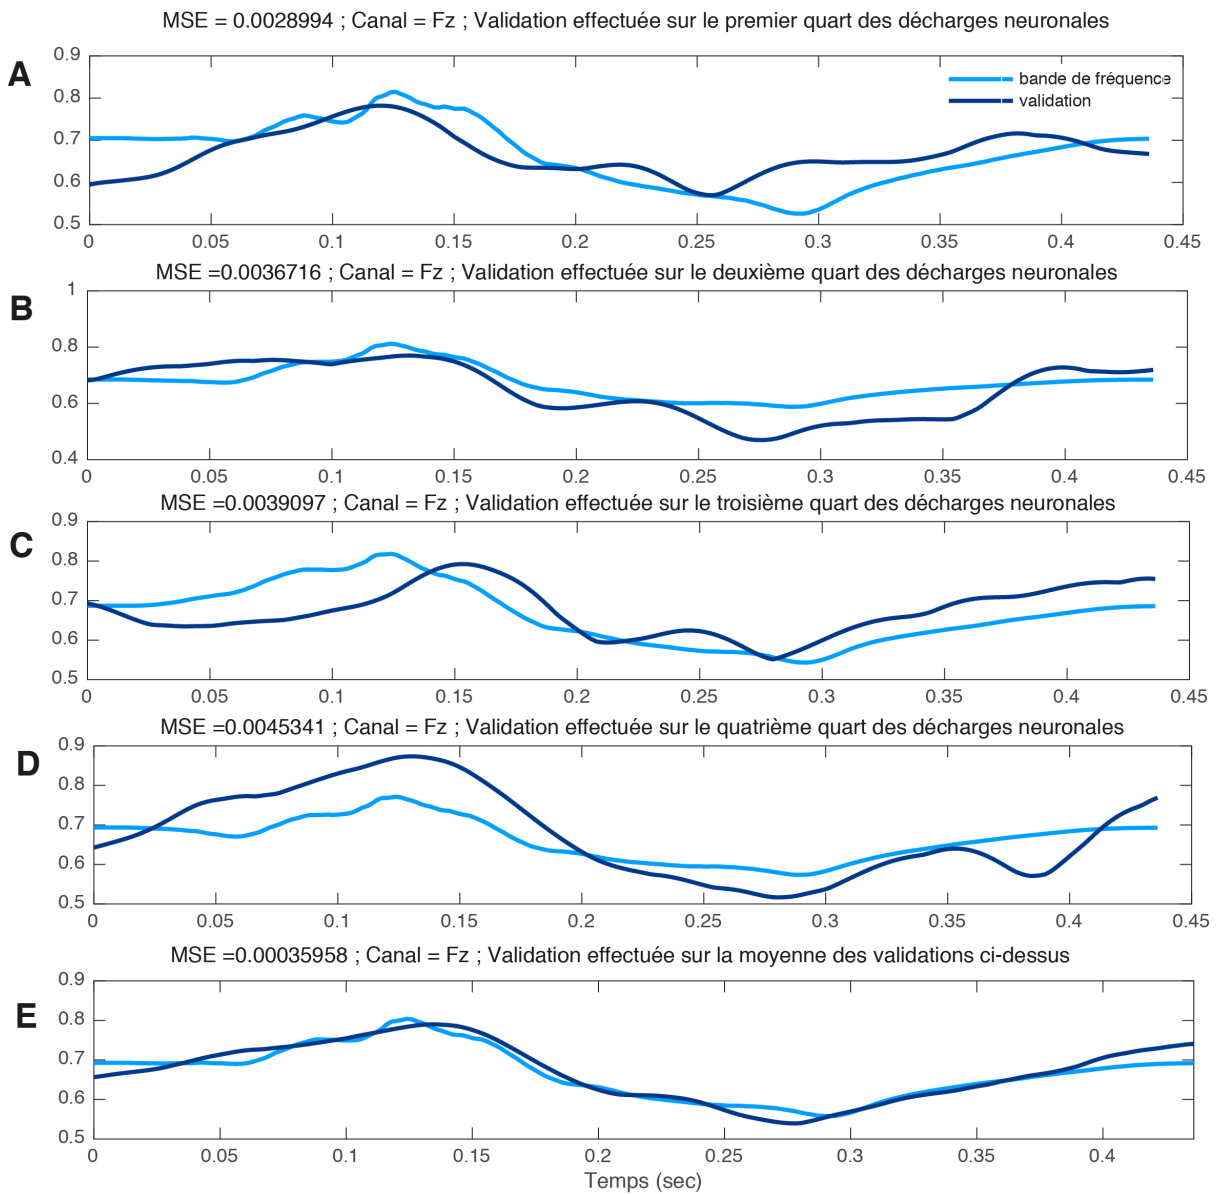


Figure 5.7 A - Validation croisée effectuée sur le premier quart des décharges neuronales ; B - Validation croisée effectuée sur le deuxième quart des décharges neuronales ; C - Validation croisée effectuée sur le troisième quart des décharges neuronales ; D - Validation croisée effectuée sur le dernier quart des décharges neuronales ; E - Validation croisée effectuée sur la moyenne de toutes les validations ci-dessus.

paramètres en utilisant les 25% premier. Autrement dit, on utilise (2),(3) et (4) pour estimer les 3 paramètres et on valide avec (1) en utilisant le modèle d'encodage issu de l'équation (5.1). Dans la figure 5.7, les signaux bande-fréquence réfèrent au signal obtenu à l'aide de modèle FBC présenté à la section 4.3.1 et les signaux validation à l'estimation obtenue par le modèle d'encodage présenté ici. Pour la figure 5.7B, on prend (1),(3) et

(4) pour estimer les paramètres et (2) pour valider. De la même manière pour les figures 5.7C, D, en utilisant respectivement (3) et (4) pour la validation. La figure 5.7E représente la moyenne des validations et de l'estimation de l'activité corticale sous-jacente. Les 4 premières validations ont une MSE de l'ordre de  $10^{-2}$  et pour la figure 5.7E de l'ordre de  $10^{-3}$ . Cette dynamique est constatée sur l'ensemble des 64 électrodes que comporte l'EEG avec un même ordre de grandeur pour la MSE. On montre donc que l'activité estimée par le modèle FBC peut être représentée adéquatement par le modèle d'encodage présenté. Si c'est le paramètre qui tient compte de l'information auditive, c'est-à-dire  $s$  dans (5.1), qui est prédominant dans le modèle d'encodage alors on pourra conclure que de l'information auditive se retrouve effectivement dans toutes les électrodes EEGs. Pour ce faire, on analyse la déviance relative du modèle en fonction des différents paramètres.

### 5.2.3 Déviance relative

Pour l'analyse de l'importance relative du stimulus d'entrée contre les dynamiques neuronales, on regarde la déviance relative qui quantifie l'importance d'un ensemble spécifique de paramètres, c'est-à-dire la dynamique neuronale ou le stimulus d'entrée, dans le modèle. La déviance relative peut être définie suivant les paramètres de l'historique et du stimulus suivant les équations (4.6) et (4.7). Une petite déviance indique une meilleure estimation des données du modèle. Donc, un petit  $\Theta^H$  ( $\Theta^S$ ) indique une plus petite contribution des paramètres de l'historique (stimulus) au modèle et vice versa. La moyenne des déviances relatives est présentée à la figure 5.8. Comme on peut l'observer, la déviance relative moyenne de la composante d'entrée du stimulus est beaucoup plus grande que la composante de l'historique qui est pratiquement négligeable. Ceci indique que l'aspect du stimulus semble beaucoup plus important pour le modèle que les décharges neuronales passées.

Puisque le modèle d'encodage encode effectivement l'activité produite par le stimulus auditif et que ce modèle arrive à prédire l'activité estimée par chacune des électrodes EEG, on peut donc en conclure que de l'information auditive se retrouve effectivement à chacune des électrodes. Cette conclusion sera corroborée par les expériences de classification effectuée à la section suivante.




Figure 5.8 Moyennes des déviations relatives de l'historique et du stimulus en fonction des électrodes.

## 5.3 Classification des données EEG

Dans cette section, on s'intéresse à la classification de données EEG en réponse à des stimuli auditifs en utilisant un réservoir RNN. On compare tout d'abord la classification des données EEG effectuées sur 8 sujets en utilisant l'ensemble des électrodes de l'EEG. Ensuite la classification des données brutes (seulement prétraitées) et celles de l'estimation des décharges neuronales est faite. Puis on étudie la classification en fonction des régions du cortex à savoir : frontale, temporale et occipitale. Enfin on présente les résultats de la classification obtenus en fonction du nombre d'électrodes utilisées.

### 5.3.1 Classification obtenue pour les 8 sujets

On désire premièrement étudier s'il est possible de classifier les trois voyelles à l'aide de l'ensemble des 64 canaux EEG et quels sont les taux de classification ainsi obtenus.

Cela établira les meilleurs taux de classification possibles avec lesquels les résultats subséquents seront comparés. Les résultats de la classification sont présentés dans le tableau 5.1. Une voyelle est classifiée précisément si la classe associée avec le signal EEG d'entrée correspond au stimulus auditif d'entrée qui a été présentée. Les résultats présentés sont la moyenne de 1600 essais et prennent en compte l'ensemble des 64 canaux. L'étape de prétraitement cité dans la section 4.1.3 rejette 30% des essais.

La moyenne des classifications pour les voyelles a, i et u sont respectivement 82.4%, 84.2% et 81.5%, avec une moyenne globale de 82.7%. Les meilleures classifications sont issues des sujets 1 et 7 avec 87.9% et 87.6%, tandis que les moins bonnes sont reportées sur les sujets 4 et 5 avec 73.9% et 79.6%. Les taux de classification sont donc élevés.

Une observation intéressante est que les performances de la classification pour les voyelles a, i et u (respectivement 82.4%, 84.2% et 81.5%) sont directement proportionnelles à leur seconde fréquence de formants (respectivement 1400 Hz, 3200 Hz et 800 Hz). Il faudrait par contre une investigation plus poussée pour confirmer ou infirmer cette relation.

Tableau 5.1 Performances de la classification obtenues sur 8 sujets.

Sujets	Performances de la classification			
	Voyelle a	Voyelle i	Voyelle u	Moyenne
1	87.16%	89.77%	86.74%	87.9%
2	83.45%	88.98%	86.36%	86.1%
3	76.03%	85.00%	81.61%	80.9%
4	81.01%	69.73%	71.00%	73.9%
5	80.34%	80.00%	78.42%	79.6%
6	80.45%	84.61%	77.61%	80.9%
7	88.52%	87.50%	86.81%	87.6%
8	82.21%	87.64%	83.64%	84.5%
Moyenne	82.4%	84.2%	81.5%	82.7%

### 5.3.2 Classification de l'estimation des décharges neuronales vs les données brutes

Dans cette section, on compare la classification obtenue pour les trois voyelles (a, i et u) en utilisant d'une part le signal EEG directement et d'autre part le signal obtenu par le modèle de couplage bande fréquence et validé par le modèle d'encodage. Si le

modèle FBC permet de capter toute l'information auditive présente dans le signal EEG, la classification obtenue avec le FBC et celle obtenue directement avec le signal EEG devraient être semblables. Si la classification obtenue avec le FBC est inférieure à celle obtenue directement avec l'EEG, on pourra donc en déduire qu'une certaine quantité de l'information auditive a été perdue dans la transformation.

Les performances de la classification des données EEG brutes et de l'estimation des décharges neuronales avec le modèle FBC sont présentées dans le tableau 5.2. Ces résultats ont été obtenus sur 8 sujets, soit un total d'environ 1600 essais. Les meilleures performances pour les données sont observées chez les sujets 1 et 7 avec respectivement 87.9% et 87.6% de classification correctement effectuée. Les meilleures performances pour l'estimation des décharges sont observées chez les sujets 7 et 8 avec respectivement 85.7% et 82.3%. 7 sujets sur 8 obtiennent une meilleure classification en utilisant les données brutes plutôt que l'activité corticale sous-jacente. Seulement le sujet 5 obtient une meilleure classification avec les décharges neuronales de l'ordre de 77.3% contre 73.9% avec les données brutes. En effectuant un test statistique de la valeur  $P$  avec une valeur limite de 0.05, pour valider l'hypothèse selon laquelle les performances de classification des décharges neuronales sont plus faibles que celles des données brutes, on obtient  $P = 0.074$  soit  $P > 0.05$ . L'hypothèse est donc acceptée et montre que l'on perd de l'information lors de l'estimation de l'activité corticale sous-jacente en utilisant le modèle FBC.

Tableau 5.2 Performances de la classification des données brutes et de l'estimation corticale sous-jacente obtenues sur 8 sujets.

Sujets	Performances de la classification	
	Données brutes	Estimation des décharges neuronales
1	87.9%	78.2%
2	86.1%	80.0%
3	80.9%	73.3%
4	73.9%	77.3%
5	79.6%	72.2%
6	80.9%	76.8%
7	87.6%	85.7%
8	84.5%	82.3%
Moyenne	82.6%	78.2%



### 5.3.3 Classification par région du cortex

On présente maintenant les résultats des taux de classification obtenus lorsque l'on considère seulement un sous-ensemble d'électrodes situées dans une même région spatiale sur le cuir chevelu.

Les résultats de la classification ainsi obtenue sont présentés dans le tableau 5.3. On a décidé de travailler sur trois régions distinctes dans le domaine d'intérêt des présents travaux en prenant 10 électrodes par région. Tout d'abord, pour la région frontale, on a choisi les électrodes : F1, F2, F3, Fz, F4, F5, F6, FC1, FC2, FC3. La performance moyenne obtenue dans cette région pour 8 sujets est de 80.9%. Ensuite pour la région centrale, on a choisi les électrodes : C1, C2, C3, C4, C5, C6, CP1, CP2, CP4, CP5 et on obtient une moyenne de 83.3% pour la classification. Enfin pour la région occipitale, on a choisi : POz, PO3, PO4, PO7, PO8, PO9, PO10, Oz, O1, O2, la performance moyenne pour la classification est de 81.8%. Si l'on compare ces résultats à la classification moyenne pour les 64 électrodes que comporte l'EEG, on a 82.6%, on a donc des performances similaires dans les trois régions principales du cortex que l'on peut confirmer avec un test statistique de la valeur de  $P$  entre la moyenne de 82.6% (toutes les électrodes) et les moyennes de 81.8% (électrodes occipitales), 83.3% (électrodes centrales) et 80.9% (électrodes frontales). On obtient respectivement  $P_o = 0.74$ ,  $P_c = 0.75$  et  $P_f = 0.48$ .

Tableau 5.3 Performances de la classification obtenues par région du cortex sur 8 sujets.

		Performances de la classification			
		Tout le cortex	Occipitale	Centrale	Frontale
Régions	Sujets				
	1	80.9%	75.8%	81.4%	73.5%
	2	87.6%	84.8%	86.0%	83.0%
	3	86.1%	87.9%	84.2%	82.8%
	4	87.9%	80.0%	86.4%	84.3%
	5	73.1%	77.3%	78.4%	78.8%
	6	79.6%	82.5%	81.3%	77.5%
	7	80.9%	82.5%	88.6%	81.9%
	8	84.5%	83.7%	80.0%	85.7%
	Moyenne	82.6%	81.8%	83.3%	80.9%

D'après la section 5.1, on aurait dû s'attendre à avoir des performances beaucoup plus faibles pour la région centrale, dû au fait que l'activité des neurones du cortex auditif

se retrouve peu dans les électrodes EEG qui y sont situées. Mais on a démontré à la section 5.2.2 que l'information auditive est en fait présente simultanément dans toutes les électrodes de l'EEG. Ces résultats sont confirmés dans le tableau 5.3, car on obtient des performances similaires pour chaque région du cortex à 1% ou 2% près. On est donc capable, en prenant n'importe laquelle de ces régions, d'obtenir les mêmes performances avec 10 électrodes qu'avec les 64 électrodes de l'EEG.

### 5.3.4 Classification par nombre d'électrodes

Dans cette sous-section, on s'intéresse à la classification des données EEG en fonction du nombre d'électrodes. Dans la sous-section précédente, on a déjà démontré que 10 électrodes suffisaient pour obtenir la même classification que si on utilisait toutes les électrodes de l'EEG. On va maintenant réduire ce nombre et étudier la classification obtenue pour 5, 4, 3, 2 et 1 électrode. On a choisi des électrodes dans la région occipitale, car dans la littérature, il y a surtout des études qui touchent cette région. Pour le choix des électrodes, on a pris :

- POz pour une électrode.
- PO3 et PO4 pour deux électrodes.
- PO3, PO4 et POz pour trois électrodes.
- PO3, PO4, PO7 et PO8 pour quatre électrodes.
- PO3, PO4, PO7, PO8 et POz pour cinq électrodes.
- PO3, PO4, PO7, PO8, PO9, PO10, POz, O1, O2 et Oz pour dix électrodes.

Les performances de la classification obtenues en fonction du nombre d'électrodes sont présentées dans le tableau 5.4 pour 8 sujets. On obtient une classification moyenne de 54.4% en choisissant 1 électrode, 63.4% avec 2 électrodes, 70.6% pour 3 électrodes, 72.3% en prenant 4 électrodes, 75.4% avec 5 électrodes et enfin 81.8% pour 10 électrodes. On observe que plus le nombre d'électrodes utilisé pour la classification est grand, meilleures sont les performances. Les performances de la classification sont proportionnelles au nombre d'électrodes. D'après la section précédente, on peut supposer qu'un nombre de 10 électrodes est adéquat pour obtenir des performances similaires à celles obtenues en prenant l'ensemble des électrodes. Malgré cela, on constate également que les performances obtenues en prenant moins de 10 électrodes sont tout à fait acceptables. En effet, même avec une seule électrode, on est capables d'avoir une détection de voyelle qui dépasse le taux aléatoire de classification de 33%. La figure 5.9 est une représentation spatiale des classi-

fications obtenues pour une seule électrode pour un sujet donné (sujet no. 3) en fonction des électrodes suivantes : F1, F2, F3, F4, Fz, FC3, FC4, C3, C4, CP3, CP4, Pz et Oz. Ici encore, la classification obtenue dépasse largement 33% pour l'ensemble des électrodes.

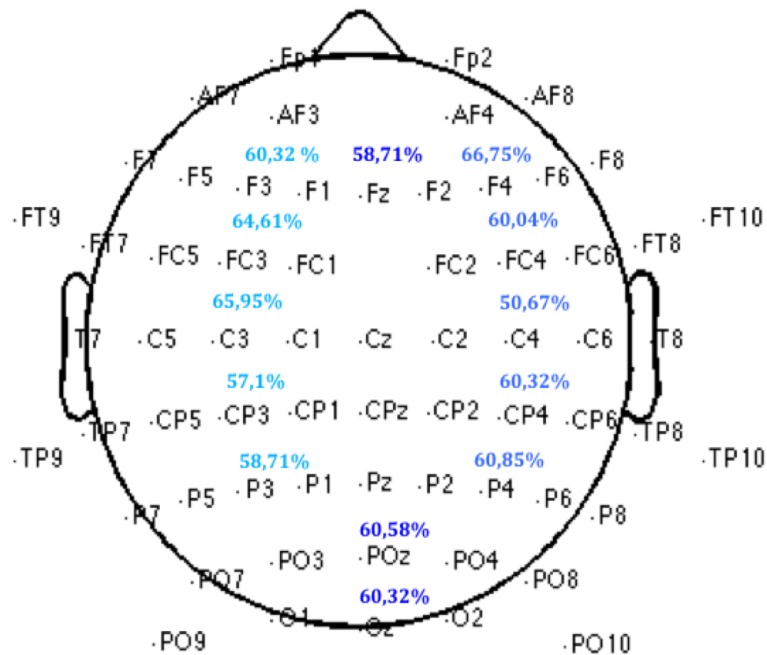


Figure 5.9 Représentation spatiale des classifications obtenues sur un sujet avec les électrodes suivantes : F1, F2, F3, F4, Fz, FC3, FC4, C3, C4, CP3, CP4, Pz et Oz.

Tableau 5.4 Performances de la classification obtenues en fonction du nombre d'électrodes sur 8 sujets.

		Performances de la classification					
		1	2	3	4	5	10
Sujets	Nb canaux						
	1	59.1%	56.8%	69.7%	72.4%	75.4%	75.8%
	2	58.8%	68.4%	71.7%	72.0%	77.3%	84.8%
	3	60.6%	68.9%	69.4%	72.9%	79.6%	87.9%
	4	52.1%	56.8%	76.4%	70.4%	75.4%	80.0%
	5	50.2%	66.3%	71.4%	70.6%	70.2%	77.3%
	6	44.2%	67.9%	70.0%	68.3%	73.8%	82.5%
	7	60.8%	64.7%	73.6%	72.8%	76.4%	82.5%
	8	49.0%	57.1%	62.4%	79.2%	75.1%	83.7%
Moyennes		54.4%	63.4%	70.6%	72.3%	75.4%	81.8%

### 5.3.5 Bilan de la classification

Pour résumer les résultats obtenus pour les différentes classifications, on rappelle qu'on a fait la classification sur l'ensemble des électrodes en utilisant les données EEG brutes et on obtient une classification moyenne pour 8 sujets, tous stimuli confondus, de 82.7%. Puis, on obtient en général de meilleurs taux de classification en utilisant les données EEG brutes plutôt qu'en utilisant le modèle FBC. Ceci peut s'expliquer par le fait qu'avec l'algorithme utilisé lors de l'estimation de cette activité, on perd de l'information auditive pertinente pour la classification ; les performances obtenues sont donc inférieures. On n'utilise donc que les données brutes pour les résultats suivants. On s'est ensuite intéressé si nous obtenons de meilleures performances en utilisant des électrodes provenant de régions spécifiques du cortex, notamment, la région frontale, centrale et occipitale. D'après les résultats, on obtient sensiblement les mêmes performances pour la classification et ces résultats sont confirmés par le fait que l'information auditive se retrouve en fait dans toutes les électrodes de l'EEG. On veut enfin savoir si le nombre d'électrodes a un impact sur la classification. On a trouvé que les performances sont proportionnelles au nombre d'électrodes et on suppose qu'un nombre de 10 électrodes est adéquat pour obtenir des performances similaires à celles obtenues en prenant l'ensemble des électrodes. Les taux de classification obtenus pour un nombre inférieur à 10 électrodes sont tout de même satisfaisants. On obtient d'ailleurs une moyenne de 54.4% sur 8 sujets en utilisant qu'une seule électrode.

# CHAPITRE 6

## CONCLUSION

Ce projet de recherche porte sur la répartition de l'information auditive dans les canaux EEG. Deux approches ont principalement été utilisées soit : 1 - l'estimation de l'activité corticale à partir des EEG et 2 - la classification de voyelles entendues à l'aide de signaux EEG.

Tel que mentionné au préalable dans le mémoire, l'activité neuronale est moindre dans l'électrode sur jacente au cortex auditif puisque les neurones du cortex auditif sont parallèles au cuir chevelu. On devrait donc observer une réponse positive sur les électrodes frontales, une réponse négative sur les électrodes occipitales et une réponse presque inexistante sur les électrodes frontales. Et c'est effectivement ce que on a observé sur les courbes ERPs des 64 électrodes que comporte l'EEG. On a également estimé l'activité du cortex auditif à partir des données EEG prétraitées en utilisant un modèle de couplage bande-fréquence. En effet, certaines bandes de fréquences sont des bons prédicteurs de l'activité corticale sous-jacente. Pour valider l'estimation des décharges neuronales, on a utilisé un modèle d'encodage du signal de parole pour évaluer si l'information est distribuée à travers tous les canaux. Le modèle d'encodage est ensuite ajusté à l'estimation de l'activité corticale obtenu par le modèle de couplage et on montre que la qualité de cet ajustement est très élevée pour l'ensemble des électrodes. Il est par la suite démontré par la déviance relative que l'ajustement du modèle est dominé par le stimulus et on en conclut donc que l'information auditive se retrouve en fait dans l'ensemble des canaux EEG et qu'elle n'est pas confinée à un nombre restreint de canaux.

Dans une approche différente, on a utilisé les performances d'un classificateur pour déterminer si l'information auditive était davantage présente sur certaines électrodes plutôt que d'autres (pour réaliser cette classification, on a utilisé un réservoir RNN activé en entrées par les données EEG). Par exemple, nous avons cherché à étudier les régions du cortex auditif pour lequel on obtiendrait de meilleures performances pour la classification des stimuli. Nous observons que peu importe la région du cuir chevelu d'où proviennent les électrodes, la classification obtenue a des performances très similaires. Nous montrons également que lorsque l'on utilise les 64 électrodes que comporte l'EEG pour classifier les 3 voyelles, on obtient une classification moyenne de 82.7%, mais qu'un nombre limité d'électrodes suffit pour obtenir une classification satisfaisante et ce peu importe la position

de ces électrodes sur le cuir chevelu. Enfin, bien que 10 électrodes semblent nécessaires pour avoir une classification optimale, on obtient des performances satisfaisantes pour la classification, même avec un nombre d'électrodes inférieur à 10.

Pour conclure, les résultats montrent que dans un contexte d'interface cerveau-machine, l'utilisation d'un nombre limité d'électrodes, peu importe leur emplacement sur le scalp, permet d'obtenir suffisamment d'information pour classifier les sons entendus. Il serait donc intéressant dans des travaux futurs, de quantifier l'information auditive présente dans chacun des canaux et de voir si cette information est modifiée selon divers paramètres, par exemple, lors d'un son présenté en présence de bruit.

# LISTE DES RÉFÉRENCES

- [1] Belitski, A., Gretton, A., Magri, C., Murayama, Y., Montemurro, M. A., Logothetis, N. K. et Panzeri, S. (2008). Low-frequency local field potentials and spikes in primary visual cortex convey independent visual information. *Journal of Neuroscience*, volume 28, numéro 22, p. 5696–5709.
- [2] Berens, P., Keliris, G. A., Ecker, A. S., Logothetis, N. K. et Tolias, A. S. (2008). Comparing the feature selectivity of the gamma-band of the local field potential and the underlying spiking activity in primate visual cortex. *Frontiers in Systems Neuroscience*, volume 2, numéro JUN, p. 1–11.
- [3] Boite, R., Boulard, H. et Dutoit, T. (2000). *Traitement de la parole*. Presses polytechniques et universitaires romandes, Lausanne.
- [4] Brainard, D. H. (1997). The psychophysics toolbox. *Spatial Vision*, volume 10, numéro 4, p. 433–436.
- [5] Brillinger, D. R. (1988). Maximum likelihood analysis of spike trains of interacting nerve cells. *Biological Cybernetics*, volume 59, numéro 3, p. 189–200.
- [6] Brodeur, S. et Rouat, J. (2012). Regulation toward self-organized criticality in a recurrent spiking neural reservoir. *22nd International Conference on Artificial Neural Networks. Artificial Neural Networks and Machine Learning - ICANN 2012*, p. 547–554.
- [7] Calabrese, A., Schumacher, J. W., Schneider, D. M., Paninski, L. et Woolley, S. M. N. (2011). A generalized linear model for estimating spectrotemporal receptive fields from responses to natural sounds. *PLOS ONE*, volume 6, numéro 1, p. 16.
- [8] Creutzfeldt, O. D., Watanabe, S. et Lux, H. D. (1966). Relations between eeg phenomena and potentials of single cortical cells. i. evoked responses after thalamic and epicortical stimulation. *Electroencephalography and Clinical Neurophysiology*, volume 20, numéro 1, p. 1–18.
- [9] Czanner, G., Eden, U. T. et Brown, E. N. (2008). A signal-to-noise ratio estimator for generalized linear model systems. Dans *World Congress on Engineering 2008*. volume Vol.2171. International Association of Engineers, p. 1063–1069.
- [10] Delattre, P. (1951). *Principes de phonétique française à l'usage des étudiants Anglo-Américains*. École Française d'Été, Middlebury College, Middlebury, Vermont, 68 p.
- [11] Delorme, A. et Makeig, S. (2004). EEGLAB : An open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *Journal of Neuroscience Methods*, volume 134, numéro 1, p. 9–21.
- [12] Goense, J. B. M. et Logothetis, N. K. (2008). Neurophysiology of the bold fmri signal in awake monkeys. *Current Biology*, volume 18, numéro 9, p. 631–640.

- [13] Grave de Peralta Menendez, R., González Andino, S., Perez, L., Ferrez, P. W. et Millán, J. d. R. (2005). Non-invasive estimation of local field potentials for neuro-prosthesis control. *Cognitive Processing*, volume 6, numéro 1, p. 59–64.
- [14] Jacobs, J., Kahana, M. J., Ekstrom, A. D. et Fried, I. (2007). Brain oscillations control timing of single-neuron activity in humans. *The Journal of Neuroscience*, volume 27, numéro 14, p. 3839.
- [15] Jaeger, H. (2002). *Tutorial on training recurrent neural networks, covering BPPT, RTRL, EKF and the “echo state network” approach* (Rapport technique 159). St. Augustin-Germany.
- [16] Jasper, H. H. (1958). The ten twenty electrode system of the international federation. *Electroencephalography and Clinical Neurophysiology*, volume 10, p. 371–375.
- [17] Jurcak, V., Tsuzuki, D. et Dan, I. (2007). 10/20, 10/10, and 10/5 systems revisited : Their validity as relative head-surface-based positioning systems. *NeuroImage*, volume 34, numéro 4, p. 1600–1611.
- [18] Kasabov, N. K. (2014). NeuCube : A spiking neural network architecture for mapping, learning and understanding of spatio-temporal brain data. *Neural Networks*, volume 52, p. 62–76.
- [19] Kindermans, P., Buteneers, P., Verstraeten, D. et Schrauwen, B. (2010). An uncued brain-computer interface using reservoir computing. Dans *Workshop : Machine learning for assistive technologies, Proceedings*. p. 1–8.
- [20] Lodish, H. (2001). *Molecular cell biology*. Freeman, New York, N.Y.
- [21] Logothetis, N. K., Pauls, J., Augath, M., Trinath, T. et Oeltermann, A. (2001). Neurophysiological investigation of the basis of the fmri signal. *Nature*, volume 412, numéro 6843, p. 150–157.
- [22] Maass, W., Natschläger, T. et Markram, H. (2002). Real-time computing without stable states : A new framework for neural computation based on perturbations. *Neural Computation*, volume 14, numéro 11, p. 2531–2560.
- [23] McCullagh, P. et Nelder, J. A. (1989). *Generalized Linear Models (Second Edition)*. London : Chapman & Hall, 500 p.
- [24] Millett, D. (2001). Hans Berger : From psychic energy to the EEG. *Perspectives in Biology and Medicine*, volume 44, numéro 4, p. 522–542.
- [25] Mohemmed, A., Schliebs, S., Matsuda, S. et Kasabov, N. (2013). Training spiking neural networks to associate spatio-temporal input–output spike patterns. *Neuro-computing*, volume 107, p. 3–10.
- [26] Musiek, F. E. et Baran, J. A. (2016). *The auditory system : anatomy, physiology, and clinical correlates*. Plural Publishing Inc., San Diego.



- [27] Niedermeyer, E., Schomer, D. L. et Lopes da Silva, F. H. (2011). *Niedermeyer's electroencephalography : Basic principles, clinical applications, and related fields*. Wolters Kluwer/Lippincott Williams & Wilkins Health, Philadelphia.
- [28] Nuntalid, N., Dhoble, K. et Kasabov, N. (2011). EEG classification with BSA spike encoding algorithm and evolving probabilistic spiking neural network. Dans *Neural Information Processing - 18th International Conference, ICONIP 2011*. p. 451–460.
- [29] Paninski, L. (2006). The most likely voltage path and large deviations approximations for integrate-and-fire neurons. *Journal of Computational Neuroscience*, volume 21, numéro 1, p. 71–87.
- [30] Paninski, L., Pillow, J. W. et Simoncelli, E. P. (2004). Maximum likelihood estimation of a stochastic integrate-and-fire neural encoding model. *Neural Comput.*, volume 16, numéro 12, p. 2533–2561.
- [31] Pillow, J., Paninski, L., Uzzell, V., Simoncelli, E. et Chichilnisky, E. (2005). Prediction and decoding of retinal ganglion cell responses with a probabilistic spiking model. *Journal of Neuroscience*, volume 25, numéro 47, p. 11003–11013.
- [32] Pillow, J. W. (2009). Time-rescaling methods for the estimation and assessment of non-poisson neural encoding models. Dans Bengio, Y., Schuurmans, D., Lafferty, J. D., Williams, C. K. I. et Culotta, A., *Advances in Neural Information Processing Systems 22*. Curran Associates, Inc., p. 1473–1481.
- [33] Platel, M. D., Schliebs, S. et Kasabov, N. (2009). Quantum-inspired evolutionary algorithm : A multimodel eda. *IEEE Transactions on Evolutionary Computation*, volume 13, numéro 6, p. 1218–1232.
- [34] Plesser, H. E. et Gerstner, W. (2000). Noise in integrate-and-fire neurons : From stochastic input to escape rates. *Neural Computation*, volume 12, numéro 2, p. 367–384.
- [35] Plourde, E., Delgutte, B. et Brown, E. N. (2011). A point process model for auditory neurons considering both their intrinsic dynamics and the spectro-temporal properties of an extrinsic signal. *IEEE Transactions on Biomedical Engineering*, volume 58, numéro 6, p. 1507–1510.
- [36] Plourde, E., Delgutte, B. et Brown, E. N. (2011). The relative importance in the auditory nerve spiking of a neuron's internal dynamics versus an external input stimulus. Dans *2011 5th International IEEE/EMBS Conference on Neural Engineering*. p. 9–12.
- [37] Rabiner, L. et Schafer, R. (2010). *Theory and Applications of Digital Speech Processing*, 1<sup>re</sup> édition. Prentice Hall Press, Upper Saddle River, NJ, USA.
- [38] Rabiner, L. R. et Schafer, R. W. (1978). *Digital processing of speech signals*. Prentice-Hall signal processing series, Englewood Cliffs, N.J. Prentice-Hall.
- [39] Ramirez, A. D., Ahmadian, Y., Schumacher, J., Schneider, D., Woolley, S. M. N. et Paninski, L. (2011). Incorporating naturalistic correlation structure improves spec-

- trogram reconstruction from neuronal activity in the songbird auditory midbrain. *Journal of Neuroscience*, volume 31, numéro 10, p. 3828–3842.
- [40] Rasch, M. J., Gretton, A., Murayama, Y., Maass, W. et Logothetis, N. K. (2008). Inferring spike trains from local field potentials. *Journal of Neurophysiology*, volume 99, numéro 3, p. 1461–1476.
- [41] Russell, S. J., Norvig, P. et Davis, E. (2016). *Artificial intelligence : A modern approach*. Pearson Education, Boston.
- [42] Scherg, M. (1994). From EEG source localization to source imaging. *Acta Neurologica Scandinavica*, volume 89, numéro S152, p. 29–30.
- [43] Schrauwen, B. et Van Campenhout, J. (2003). BSA, a fast and accurate spike train encoding scheme. *2003 International Joint Conference on Neural Networks*, p. 2825–30.
- [44] Self, M., Peters, J., Possel, J., Reithler, J., Goebel, R., Ris, P., Jeurissen, D., Reddy, L., Claus, S., Baayen, J. et Roelfsema, P. (2016). The effects of context and attention on spiking activity in human early visual cortex. *PLoS Biology*, volume 14, numéro 3, p. e1002420.
- [45] Skaggs, W. E., McNaughton, B. L., Wilson, M. A. et Barnes, C. A. (1996). Theta phase precession in hippocampal neuronal populations and the compression of temporal sequences. *Hippocampus*, volume 6, numéro 2, p. 149–172.
- [46] Truccolo, W., Eden, U. T., Fellows, M. R., Donoghue, J. P. et Brown, E. N. (2005). A point process framework for relating neural spiking activity to spiking history, neural ensemble, and extrinsic covariate effects. *Journal of Neurophysiology*, volume 93, numéro 2, p. 1074.
- [47] Tyler, C. W., Howarth, C. et Likova, L. T. (2016). Editorial : Neural signal estimation in the human brain. *Frontiers in Neuroscience*, volume 10, p. 185.
- [48] van Oosterom, A. (1991). History and evolution of methods for solving the inverse problem. *Journal of Clinical Neurophysiology*, volume 8, numéro 4, p. 371–380.
- [49] Vapnik, V. N. (1998). *Statistical learning theory*. Adaptive and learning systems for signal processing, communications, and control, Wiley, New York.
- [50] Whittingstall, K. et Logothetis, N. K. (2009). Frequency-band coupling in surface eeg reflects spiking activity in monkey visual cortex. *Neuron*, volume 64, numéro 2, p. 281–289.
- [51] Wolpaw, J. R. et Wolpaw, E. W. (2012). *Brain-computer interfaces : principles and practice*. Oxford University Press, Oxford ; New York.



