

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Ecole Nationale Polytechnique



المدرسة الوطنية المتعددة التقنيات
Ecole Nationale Polytechnique

Département d'Electronique
Mémoire de projet de fin d'études
pour l'obtention du diplôme d'ingénieur d'état en Electronique

Analyse temps fréquence et Classification du Signal EEG : Conception et Réalisation d'une interface graphique dédiée

Imene TARAKLI

Sous la direction de

M. Adel Belouchrani, Professeur

M. Hatim Chakib DELIBA, Professeur Neurochirurgien

Présenté et soutenu publiquement le 30/06/2020

Composition du Jury :

Président	M. Mourad ADNANE	Professeur	Ecole Nationale Polytechnique
Examineur	M. Sid-Ahmed BERRANI	Professeur	Ecole Nationale Polytechnique
Promoteur	M. Adel BELOUCHRANI	Professeur	Ecole Nationale Polytechnique
Co-promoteur	M. Hatim Chakib DELIBA	Professeur	Neurochirurgien

ENP 2020

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Ecole Nationale Polytechnique



المدرسة الوطنية المتعددة التقنيات
Ecole Nationale Polytechnique

Département d'Electronique
Mémoire de projet de fin d'études
pour l'obtention du diplôme d'ingénieur d'état en Electronique

Analyse temps fréquence et Classification du Signal EEG : Conception et Réalisation d'une interface graphique dédiée

Imene TARAKLI

Sous la direction de

M. Adel Belouchrani, Professeur

M. Hatim Chakib DELIBA, Professeur Neurochirurgien

Présenté et soutenu publiquement le 30/06/2020

Composition du Jury :

Président	M. Mourad ADNANE	Professeur	Ecole Nationale Polytechnique
Examineur	M. Sid-Ahmed BERRANI	Professeur	Ecole Nationale Polytechnique
Promoteur	M. Adel BELOUCHRANI	Professeur	Ecole Nationale Polytechnique
Co-promoteur	M. Hatim Chakib DELIBA	Professeur	Neurochirurgien

ENP 2020

ملخص

الهدف من هذه المذكرة هو إنجاز تطبيق متمكن من تحليل التردد الزمني لإشارات التخطيط الدماغي. تسمح الأداة المطورة لهذا الغرض بمشاهدة و معالجة هذه الإشارات مسبقا في المجال الزمني بالإضافة إلى تقييمها في مجال التردد الزمني باستعمال توزيعات التردد الزمني التربيعية المتحصل عنها من خلال مكتبة تم تأليفها ضمن هذا المشروع. بعدها تمكننا من تصنيف إشارات التخطيط الدماغي إلى قسمين : نشاط الخلفية والتشنج و ذلك عن طريق منهجية الجهاز الناقل للدعم التي تعتمد بدورها على واصفات التردد الزمني.

الكلمات الدالة : تحليل التردد الزمني، معالجة الإشارة، تخطيط كهربية الدماغ، جهاز ناقل الدعم، تطوير البرمجيات.

Abstract

This thesis' aim is the design of an application that is dedicated to the time-frequency analysis of EEG signals. The developed tool enables the visualization and preprocess of these signals in the temporal domain and their evaluation in the time-frequency domain using the quadratic time-frequency distributions calculated from a library that was implemented during this project. Using the support vector machine (SVM) along with time-frequency features, we were able to classify EEG signals into two classes : background and seizure.

Keywords : Time-frequency analysis (TFA), Signal processing, Electroencephalogram (EEG), Support Vector Machine (SVM), Software development.

Résumé

Ce mémoire a pour objectif la conception d'une application dédiée à l'analyse temps-fréquence des signaux EEG. L'outil développé permet de visualiser et de prétraiter ces signaux dans le domaine temporel et de les évaluer dans le domaine temps-fréquence en utilisant les distributions temps-fréquence quadratiques calculées à partir d'une bibliothèque implémentée durant ce projet. Une classification avec la méthode de machine à vecteurs de support (SVM), basée sur des descripteurs temps fréquence, a permis ensuite de classer les signaux EEG en deux classes : activité de fond et convulsion.

Mots-clé : Analyse Temps-Fréquence (ATF), Traitement du signal, Electroencéphalogramme (EEG), Machine à Vecteurs de Support (SVM), Développement logiciel.

Remerciements

Je tiens à exprimer toute ma reconnaissance à mon directeur de thèse Mr Adel Belouchrani pour sa disponibilité, ses précieux conseils et sa passion communicative pour la recherche.

Je remercie également le Pr Deliba qui en proposant ce thème, m'a permis de découvrir ce domaine captivant.

J'exprime aussi tout mon respect et ma gratitude aux membres du jury d'avoir accepté de sacrifier de leurs temps pour évaluer ma modeste contribution.

Je souhaite à cette occasion remercier tous mes professeurs depuis le primaire et particulièrement ceux de l'Ecole Nationale Polytechnique, pour leur engagement, encouragement, disponibilité et soutien tout au long de ces années. J'espère que l'aboutissement de ce projet de fin d'études récompensera une partie de leur travail.

Je n'oublie naturellement pas mes camarades. Merci pour tous ces échanges et moments agréables passés ensemble.

Et enfin, merci à tous ceux qui m'ont soutenu et accompagné durant la réalisation de ce projet.

Dédicaces

A mes chers parents, pour leur amour, leurs prières et leur soutien infaillible tout au long de ces années. Puisse ce travail être à la hauteur de vos sacrifices.

A ma soeur Nesrine, pour la complicité et l'entente qui nous unissent, merci d'être toujours là à mes côtés.

A mon beau-frère Fayçal, pour ses encouragements et son soutien moral tout au long de ces années.

A ma nièce Leïla, qu'il me tarde de rencontrer, pour m'avoir apporté bonheur et joie dans les périodes les plus stressantes de ce projet.

A mes chers amis de l'Ecole Nationale Polytechnique pour toutes les épreuves que nous avons relevées et les moments heureux que nous avons partagés.

A tous ceux qui me sont chers, je vous dédie ce travail.

Table des matières

Table des figures

Liste des tableaux

Liste des abréviations

Introduction	13
1 L'électroencéphalographie	15
1.1 Principe de l'EEG	15
1.2 Système d'acquisition	16
1.2.1 Electrodes	17
1.2.2 Amplification	19
1.2.3 Filtrage	19
1.2.4 Numérisation	20
1.3 L'EEG comme outil de pronostic et de diagnostic	21
1.4 Analyse du signal EEG	21
1.4.1 Caractéristiques du signal	21
1.4.2 Importance de l'analyse temps-fréquence du signal	22
2 L'analyse Temps-Fréquence	24
2.1 L'outil temps-fréquence	24
2.1.1 Transformée de Fourier à Court Terme et Spectrogramme	24
2.1.2 Classe quadratique des DTF	25
2.2 Application en neurosciences	28
2.2.1 Choix des distributions	28
2.2.2 Exemple	31

3	Conception de l'interface graphique	34
3.1	Etat de l'art	34
3.2	Spécifications des besoins	36
3.3	Choix de l'architecture et de la programmation	36
3.4	Utilisation de l'outil UML	38
4	Réalisation de l'interface graphique	43
4.1	Choix de l'environnement de développement	43
4.2	Implémentation d'une librairie Temps-Fréquence	44
4.2.1	Optimisation des algorithmes	45
4.2.2	Optimisation de l'implémentation	46
4.2.3	Visualisation	47
4.3	Interfaces de l'application	48
4.3.1	Représentation temporelle	49
4.3.2	Prétraitement	50
4.3.3	Représentation temps-fréquence	51
4.3.4	Atlas EEG	52
4.4	Exemple d'utilisation	52
5	Classification des signaux EEG pour l'aide au diagnostic	55
5.1	Choix des descripteurs	55
5.1.1	Descripteurs statistiques du signal	55
5.1.2	Descripteurs temps-fréquence	56
5.1.3	Descripteurs d'images	57
5.2	Choix du classifieur	60
5.3	Résultats, comparaison et discussion	62
5.3.1	Base de données	62
5.3.2	Métriques d'évaluation de la classification	63
5.3.3	Comparaison de la classification à l'aide des descripteurs statistiques	64
5.3.4	Comparaison de la classification à l'aide des descripteurs d'image .	65
5.4	Implémentation de la classification	65
	Conclusion générale	67

A Expressions des descripteurs	69
A.1 Moments de Hu	69
A.2 Descripteurs de Harlick	70
B Guide d'utilisation	73
B.1 Interface d'accueil	74
B.2 Prétraitement	75
B.3 Représentation temps-fréquence	76
B.4 Atlas EEG	79
Bibliographie	82

Table des figures

1.1	Structure d'un neurone (à gauche) et d'une synapse (à droite) [1]	16
1.2	Épaisseurs et résistivités des couches principales de la tête [2]	16
1.3	Signaux EEG normaux et anormaux : sommeil actif (AS : Active Sleep), sommeil passif (QS : Quiet Sleep) et suppression des salves (BS : Burst Suppression) [3]	17
1.4	Système d'acquisition des EEG	17
1.5	Schéma électrique de l'électrode active [4]	17
1.6	Le système 10-20 de positionnement normalisé des électrodes [5]	18
1.7	Convention de polarité : (a) Fp2 plus négative que F8, (b) F8 plus négative que Fp2 [6]	18
1.8	Montage unipolaire [6]	19
1.9	Montage bipolaire : (a) longitudinal, (b) transversale [6]	20
1.10	Signal EEG d'un nouveau-né : (a) représentation temporelle, (b) représen- tation fréquentielle.	22
1.11	Représentation temps-fréquence du signal EEG d'un nouveau-né.	23
2.1	Distirbution de Wigner-Ville d'une somme de deux signaux LFM	26
2.2	Analyse temps-fréquence d'un signal composé de sinusoides et de pointes. (a) EMBD ($\alpha = 0.2$, $\beta = 0.1$), (b) CBD ($c=0.01$, $D=0.075$, $E=0.075$), (c) WVD (d) référence [16]	30
2.3	Représentation temps-fréquence de signaux EEG de nouveaux nés. (a) Som- meil profond.(b) Sommeil léger. (c) Suppression des salves. (d) Convulsion avec chirp linéaire décroissante. (e) Convulsion avec chirp linéaire crois- sante. (f) Convulsion complexe avec chirp linéaire par morceau [3].	32
3.1	Nombre de citations par année des outils logiciels [21]	35
3.2	Diagramme de la classe EEG	37
3.3	Interactions de l'architecture MVC	38

3.4	Interactions de de l'architecture MVC passive	38
3.5	Diagramme de séquence "Représentation temporelle du signal"	40
3.6	Diagramme de séquence "Prétraitement"	41
3.7	Diagramme de séquence "Représentation temps-fréquence"	42
3.8	Diagramme de séquence "Accès à l'atlas EEG"	42
4.1	Algorithme de calcul des distributions temps-fréquence quadratiques	45
4.2	Architecture du module temps-fréquence	47
4.3	CBD d'une FM sinusoïdale (C=1.0, D=0.04, E=0.04)	48
4.4	Interface "Représentation temporelle".	49
4.5	Interface prétraitement	50
4.6	Interface représentation temps-fréquence	51
4.7	Interface atlas EEG	52
4.8	EEG d'un nouveau-né : (a) avant filtrage et (b) après filtrage.	53
4.9	Représentation temporelle de l'EEG d'un nouveau-né : (a) activité de fond et (b) Convulsion.	53
4.10	RTF de l'EEG d'un nouveau-né : (a) activité de fond et (b) Convulsion	54
5.1	Principe de la 8-connectivité : Les pixels sont connectés si leurs bords ou coins se touchent. Deux pixels adjacents font partie du même objet s'ils sont tous les deux activés et connectés le long de la direction horizontale, verticale ou diagonale.	58
5.2	Principe du LBP	59
5.3	Principe du SVM [37].	61
5.4	Astuce du noyau [38].	62
5.5	Schéma de la classification	62
5.6	Prédiction des convulsions.	66
B.1	Interface d'accueil	73
B.2	Barre de menu de l'applicaton	73
B.3	Représentation temporelle des données chargées.	74
B.4	Panneau du parcours temporel.	75
B.5	Outils de visualisation.	75
B.6	Interface de prétraitement.	76

B.7	Interface représentation temps-fréquence.	77
B.8	Choix de la distribution et des paramètres.	77
B.9	Représentation temps-fréquence.	78
B.10	Panneau de parcours temporel.	78
B.11	Atlas EEG.	79

Liste des tableaux

2.1	Exemples de filtres noyaux des DTF	29
2.2	Types de signaux utilisés dans les expériences.	29
3.1	Bases de données du modèle.	37
4.1	Comparaison des écosystèmes Matlab et Python	44
4.2	Temps d'exécution des différentes méthodes	47
5.1	Descripteurs du domaine temporel	55
5.2	Descripteurs du domaine fréquentiel	56
5.3	Descripteurs du domaine temps-fréquentiel	56
5.4	Matrice de confusion.	63
5.5	Résultat de la détection des convulsion par descripteurs statistiques.	64
5.6	Résultat de la détection des convulsion par descripteurs d'images	65

Liste des abréviations

ATF analyse temps-fréquence.

BD B-distribution.

CBD Cheriet-Belouchrani Distribution.

DELP décharges épileptiformes latérales périodiques.

DTF distribution temps-fréquence.

DTFQ distributions temps-fréquence quadratiques.

DWV distribution de Wigner-Ville.

EEG électroencéphalographie ou électroencéphalogramme.

EMBD Extended modified B-distribution.

FAI fonction d'autocorrélation instantanée.

FI fréquences instantanées.

LBP local binary pattern.

MBD Modified B-distribution.

MVC modèle-vue-contrôleur.

RTF représentation temps-fréquence.

SVM support vector machine.

TF transformée de Fourier.

TFCT transformée de Fourier à court terme.

UML unified Modeling language.

Introduction

L'électroencéphalographie est une méthode permettant d'étudier l'activité cérébrale d'une personne en enregistrant des signaux électriques. Elle est utilisée dans divers domaines tels qu'en sciences cognitives ou en neurologie. Afin d'extraire des informations à partir des signaux enregistrés, les chercheurs ont souvent recours à des outils d'analyse standards tels que l'électroencéphalogramme, qui fournit un tracé temporel de ces signaux, ou le spectrogramme, qui permet de visualiser la distribution fréquentielle de ces données. Ces outils ne prennent pas en considération la nature non-stationnaire des EEG et l'évaluent de manière stationnaire donnant donc des résultats imprécis voire erronés.

Une solution à cela est l'utilisation de l'analyse temps-fréquence qui permet d'évaluer les signaux EEG dans le domaine conjoint temps-fréquence. Les distributions temps-fréquence quadratiques sont particulièrement bénéfiques, car ayant de hautes résolutions, elles permettent de caractériser diverses activités neurologiques et de les distinguer aussi bien de manière visuelle qu'automatique. Bien qu'offrant de réels avantages, l'analyse temps-fréquence reste conditionnée par le nombre réduit d'outils informatiques permettant son exploitation ; les logiciels offrant cette option sont souvent chers et nécessitent une connaissance préalable en programmation.

Ce présent travail a pour objectif de concevoir et de réaliser une interface dédiée à l'analyse temps-fréquence des signaux EEG. Cette dernière devra être intuitive à l'utilisation. Elle fournira essentiellement des outils pour calculer et visualiser les distributions temps-fréquence quadratiques mais aussi de les exploiter pour la classification automatique des signaux.

Ce mémoire est structuré comme suit :

- Le premier chapitre fournit des généralités sur l'électroencéphalographie et met en avant les caractéristiques des signaux EEG.
- Le chapitre suivant expose une définition de l'analyse temps-fréquence, plus particulièrement des distributions temps-fréquence quadratiques, et décrit des exemples de son application dans le domaine des neurosciences.
- Le chapitre 3 est dédié à la conception de l'application en fournissant le cahier de charge du projet et le modèle architectural utilisé pour sa réalisation.
- Dans le chapitre 4, il est question de la réalisation du projet. Les étapes de développement d'une librairie temps-fréquence ainsi que les différentes interfaces de l'application y sont exposées. Un exemple est ensuite donné pour illustrer l'utilisation de l'application.
- Le dernier chapitre présente les outils nécessaires à l'aide au diagnostic en utilisant une classification des signaux EEG.
- Enfin, une conclusion générale sera donnée ainsi que quelques perspectives.

Chapitre 1

L'électroencéphalographie

L'électroencéphalographie (EEG) est une méthode d'exploration cérébrale permettant l'évaluation de l'activité électrique d'un cerveau. Cela a commencé en 1875, avec la découverte des propriétés électriques du cerveau par le scientifique Richard Caton. En 1924, Hans Berger, un neuropsychiatre allemand, a effectué le premier enregistrement EEG chez l'être humain. Il a pu enregistrer et amplifier l'activité cérébrale d'un jeune patient ayant subi une trépanation pour exciser une tumeur cervicale, marquant ainsi le début de l'utilisation de l'EEG dans le milieu clinique. Depuis, l'EEG a bien évolué et est devenue un outil numérique, indolore et dénué de risques, présent aussi bien dans les neurosciences cognitives qu'en examen neurologique.

1.1 Principe de l'EEG

Le cerveau est composé de 100 milliards de cellules nerveuses appelées neurones. Chaque neurone est constitué d'un corps cellulaire de prolongements : les dendrites et l'axone. Ces derniers permettent d'établir des connexions avec d'autres neurones à travers des terminaisons synaptiques (voir figure 1.1).

L'activité synchrone post-synaptique produit un potentiel électrique. La sommation de ces potentiels issus d'un grand nombre de neurones adjacents constitue le signal électrique à la base de l'EEG. Ce signal subit une atténuation en traversant les différentes couches de la tête : le cerveau, le crâne, le cuir chevelu et de nombreuses autres couches minces séparant chaque partie (figure 1.2).

Des électrodes, placées généralement sur le cuir chevelu, permettent de mesurer cette activité électrique. Elle est ensuite amplifiée et représentée sous forme d'un tracé appelé

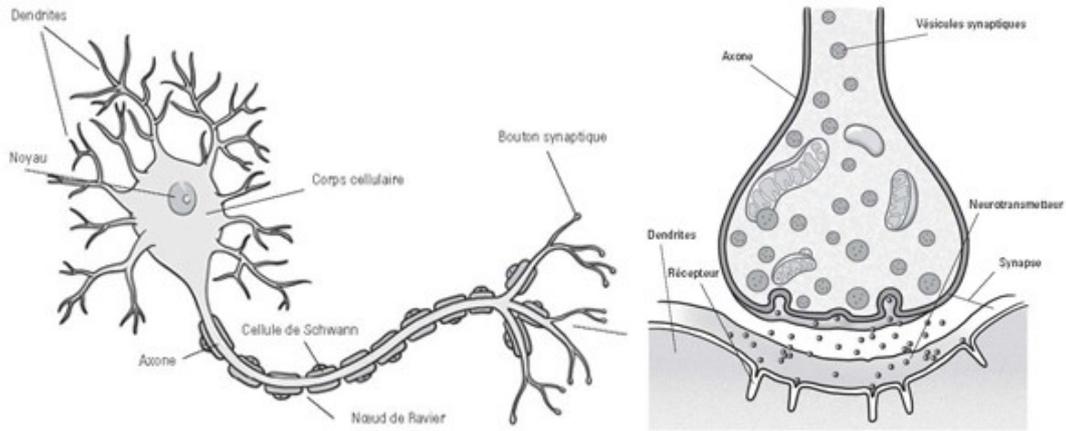


FIGURE 1.1: Structure d'un neurone (à gauche) et d'une synapse (à droite) [1]

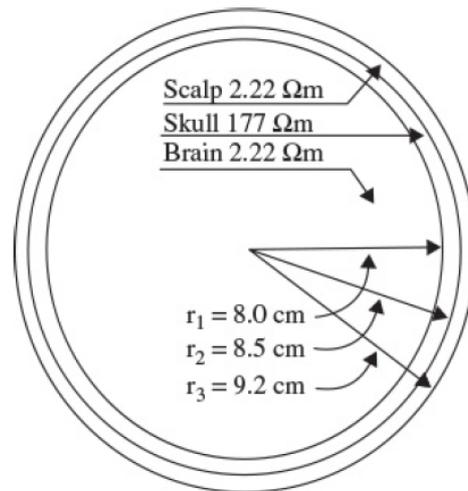


FIGURE 1.2: Épaisseurs et résistivités des couches principales de la tête [2]

électroencéphalogramme (EEG).

L'application principale de l'EEG consiste à observer et à étudier manuellement ces enregistrements pour établir des liens entre l'activité neurophysiologique et les troubles et lésions cérébrales ou encore l'exécution de tâches cognitives ou motrices. La figure 1.3 montre les EEG obtenus pour diverses activités normales et anormales.

1.2 Système d'acquisition

La figure 1.4 schématise la chaîne d'acquisition des EEG. Dans ce qui suit, chaque étape sera expliquée.

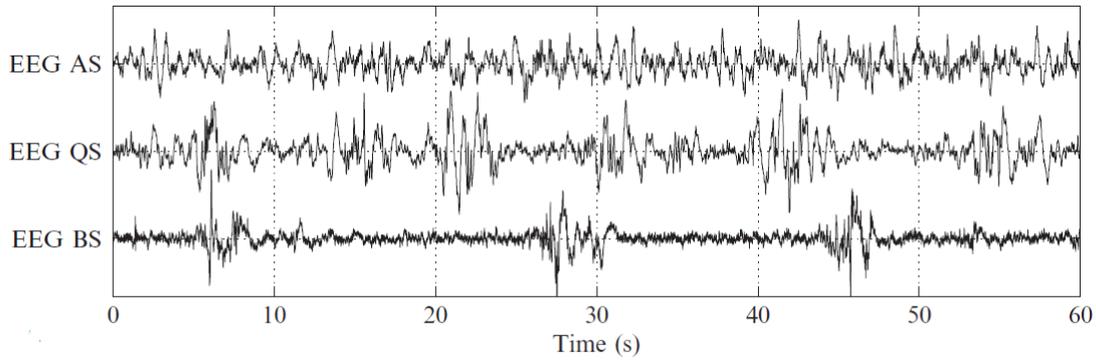


FIGURE 1.3: Signaux EEG normaux et anormaux : sommeil actif (AS : Active Sleep), sommeil passif (QS : Quiet Sleep) et suppression des salves (BS : Burst Suppression) [3]

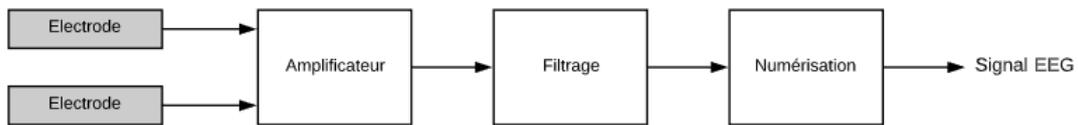


FIGURE 1.4: Système d'acquisition des EEG

1.2.1 Electrodes

Il s'agit de conducteurs électroniques placés sur la surface de la tête qui permettent de mesurer le signal électrique issu de potentiels post-synaptiques. On distingue deux types d'électrodes : *l'électrode active* qui, dotée d'un circuit intégré, permet d'amplifier le signal (voir figure 1.5) et *l'électrode passive*, un simple conducteur qui nécessite la préparation préalable de la peau (application d'un gel conducteur, etc).

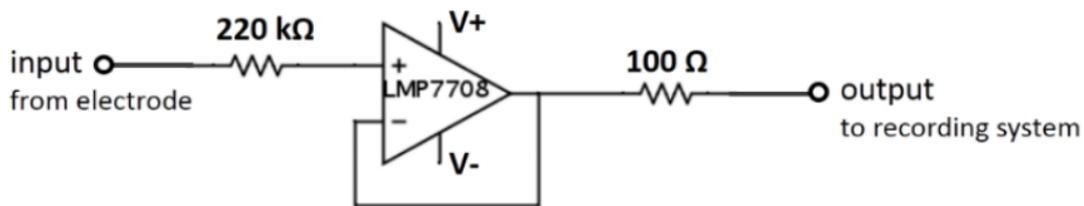


FIGURE 1.5: Schéma électrique de l'électrode active [4]

Emplacement des électrodes

L'emplacement des électrodes sur la tête doit être conforme à des méthodes standards. Parmi celles les plus utilisées se trouve le système international 10-20. Les «10» et «20» décrivent la distance entre les électrodes voisines comme 10 ou 20 pour cent de la distance totale droite-gauche ou avant-arrière du crâne. La figure 1.6 montre l'emplacement des électrodes dans ce système. Les lettres sont utilisées pour identifier le lobe (A = Auri-

culaire; F = Frontale; T = Temporale; C = Centrale; P = Pariétale; O = Occipitale) tandis que les chiffres correspondent à la position de l'hémisphère (chiffres impairs = hémisphère gauche, chiffres pairs = hémisphère droit) [5].

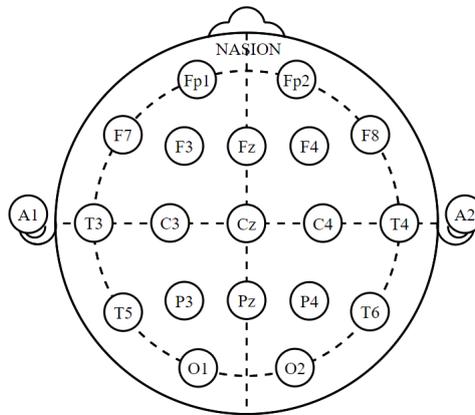


FIGURE 1.6: Le système 10-20 de positionnement normalisé des électrodes [5]

Conventions de polarité et d'annotation des canaux

Les enregistrements EEG sont basés sur le principe de l'amplification différentielle avec rejet du bruit en mode commun. Les tracés obtenus sont la différence de potentiel des deux entrées de l'amplificateur. L'annotation des canaux est conventionnée de telle manière à indiquer les électrodes aux entrées de l'amplificateur. Pour exemple, le canal Fp2-F8 montre que les électrodes Fp2 et F8 sont l'entrée 1 et l'entrée 2 de l'amplificateur, respectivement. Concernant la polarité, si l'entrée 1 est plus négative que l'entrée 2, une déviation vers le haut (négative) est observée. Et si, au contraire, l'entrée 2 est plus négative que l'entrée 1, une déviation vers le bas (positive) est observée (voir figure 1.7).

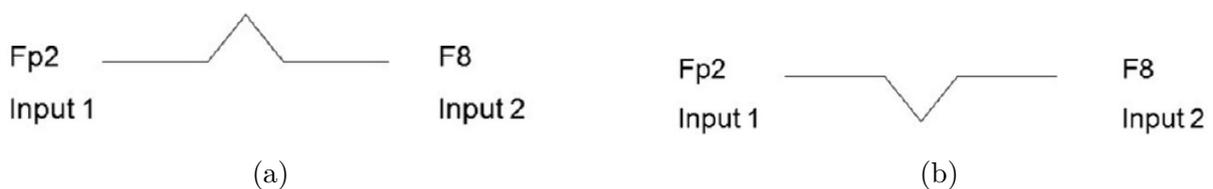


FIGURE 1.7: Convention de polarité : (a) Fp2 plus négative que F8, (b) F8 plus négative que Fp2 [6]

Montages des électrodes

Il s'agit de combinaisons spécifiques des électrodes permettant de représenter, simultanément et de manière logique, l'activité cérébrale de tout le scalp.

1. Montage unipolaire :

Différentes électrodes sont connectées à l'entrée 1 tandis qu'une référence commune est reliée à l'entrée 2 (figure 1.8).

2. Montage bipolaire :

Différentes électrodes sont connectées aux entrées 1 et 2 pour chaque série d'électrodes longitudinale ou transversale(figure 1.9).

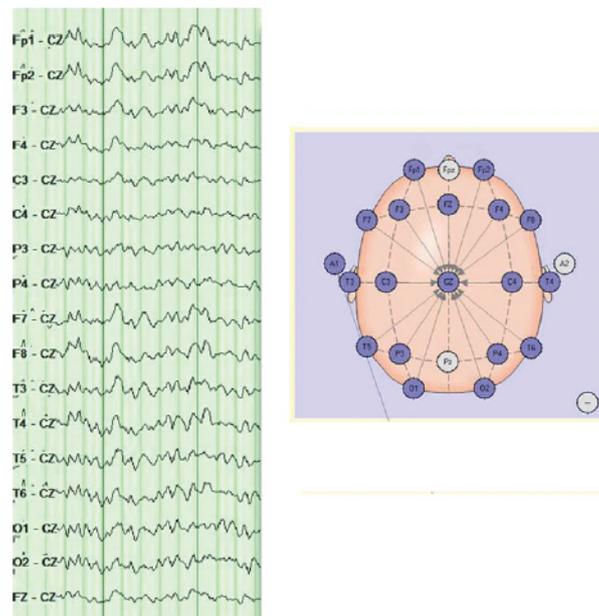


FIGURE 1.8: Montage unipolaire [6]

1.2.2 Amplification

Les signaux EEG ont de faibles amplitudes ($1-100 \mu V$). Le moindre bruit introduit par le reste du système d'acquisition peut l'affecter de manière considérable, il est donc nécessaire de l'amplifier. Dans le cas des électrodes actives, utilisées généralement en sciences cognitives, cette amplification est déjà réalisée au niveau de la tête, lors de l'enregistrement. Dans le domaine clinique, il est plus commun d'utiliser des électrodes passives et donc de recourir à un dispositif d'amplification externe.

1.2.3 Filtrage

Les signaux EEG transportent des informations dans une bande passante comprise entre 0,5 Hz et 80 Hz. Il s'agit des rythmes cérébraux delta (0,5 - 4 Hz), thêta (4 - 8 Hz),

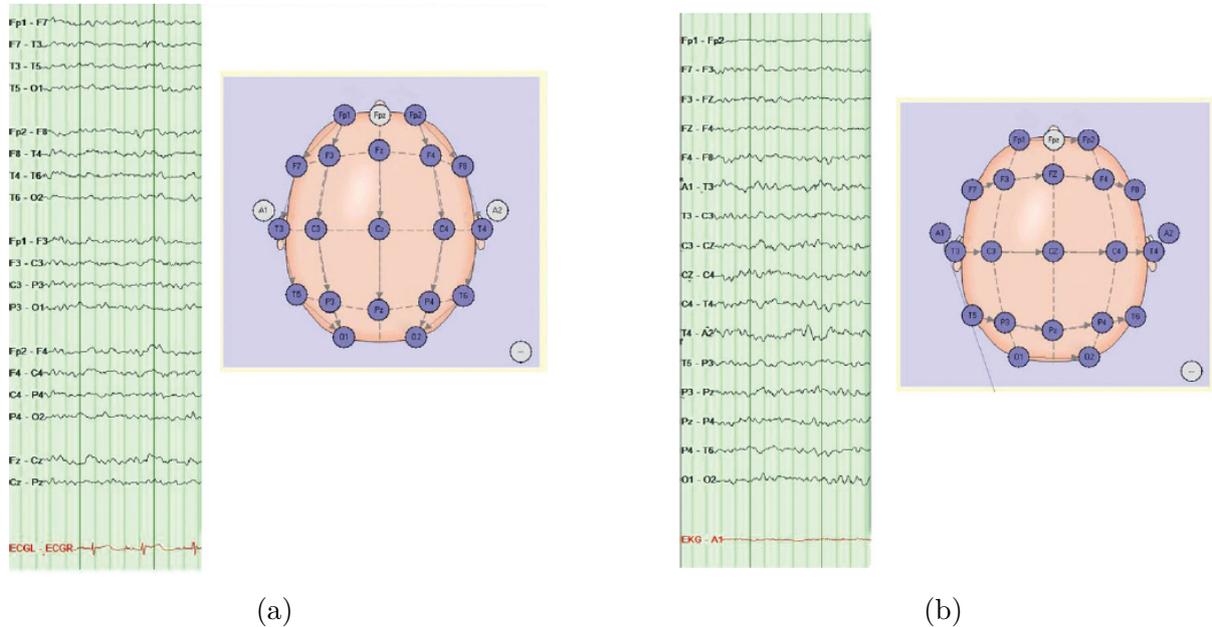


FIGURE 1.9: Montage bipolaire : (a) longitudinal, (b) transversale [6]

alpha (8 - 12 Hz), bêta (16 - 24 Hz) et gamma (jusqu'à 80 Hz).

Au delà de cette bande, il s'agit de bruits provenant de diverses sources (variation du rythme cardiaque, clignements des yeux, mouvements durant l'amplification, etc). Afin d'éliminer ces hautes fréquence, un filtre passe-bas dont la fréquence de coupure avoisine les 100 Hz, est utilisé.

Les fréquences très basses doivent également être supprimées afin d'éliminer l'offset et les composantes continues des signaux EEG. Pour cela, un filtre passe-haut, d'une fréquence de coupure avoisinant les 0.5 Hz, est utilisé.

1.2.4 Numérisation

Cela se fait en utilisant un convertisseur analogique-numérique (CAN). Les signaux filtrés sont échantillonnés à une fréquence d'échantillonnage au moins deux fois supérieure à la fréquence maximale du signal mesuré (théorème de Nyquist). Plus la fréquence d'échantillonnage est importante, meilleure est la résolution mais plus lente est la transmission. Pour des applications à temps réel, une fréquence de 256 Hz est utilisée avec une résolution de 24 bits [7].

1.3 L'EEG comme outil de pronostic et de diagnostic

L'électroencéphalographie possède de vastes domaines d'applications notamment en sciences cognitives et dans l'élaboration d'interface cerveau-machine. Mais son application principale reste dans le milieu clinique où elle est utilisée pour l'investigation des lésions et pathologies neurologiques. Le neurologue inspecte attentivement les enregistrements EEG (par fenêtres d'environ 10 sec) pour relever toute anomalie. D'après R.D. Bickford [8], les applications les plus notables de l'EEG dans le domaine clinique sont :

- monitoring du coma et de la mort cérébrale,
- localisation des zones endommagées suite à un traumatisme crânien, un accident vasculaire cérébral ou une tumeur,
- contrôle de la profondeur de l'anesthésie,
- investigation et localisation des pointes épileptiques,
- étude de la physiologie et des troubles du sommeil,
- étude des troubles mentaux.

1.4 Analyse du signal EEG

1.4.1 Caractéristiques du signal

L'EEG est un signal complexe représentant l'activité électrique du cerveau sur une période de temps. La figure 1.10a montre un exemple d'un signal EEG comme fonction du temps. L'analyse de pareille fonction s'appelle *l'analyse temporelle*.

On remarque que dans ce signal, certaines formes d'ondes se répètent ; il est **pseudo-périodique**. Des informations fréquentielles peuvent être alors extraites en appliquant la transformée de Fourier (TF) sur un signal $x(t)$ (Eq. 1.1), il s'agit de *l'analyse fréquentielle*. La figure 1.10b montre la distribution fréquentiel du signal précédent.

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-j2\pi ft}df \quad (1.1)$$

où $X(f)$ représente le signal dans le domaine fréquentiel.

Les signaux peuvent être classés en signaux stationnaires et non-stationnaires. Les signaux stationnaires ont un contenu fréquentiel et des propriétés statistiques indépendants de l'origine des temps, tandis que les signaux non-stationnaires ont un contenu

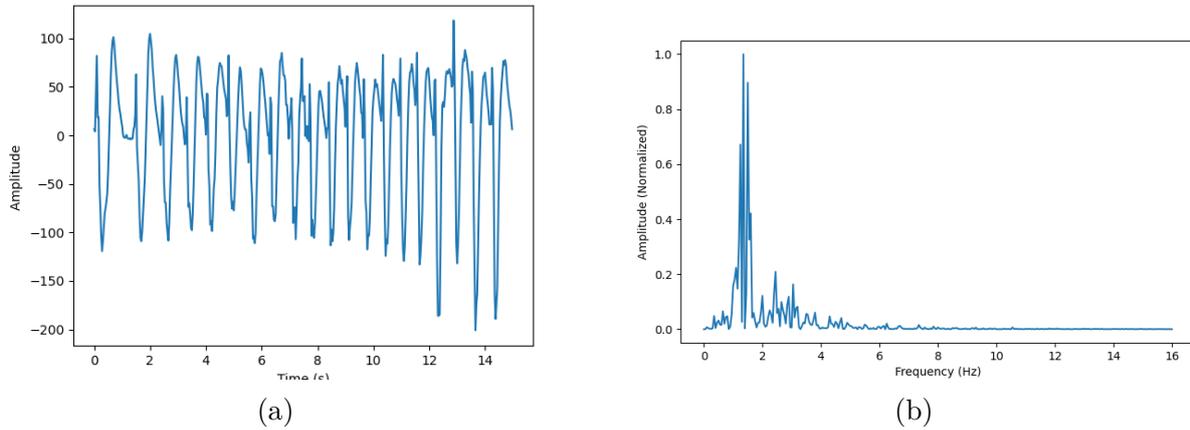


FIGURE 1.10: Signal EEG d'un nouveau-né : (a) représentation temporelle, (b) représentation fréquentielle.

fréquentiel variant dans le temps. La plupart des signaux issus du monde réel ne sont pas stationnaires, y compris les signaux EEG dont le contenu spectral varie en réponse aux stimuli internes et externes. Les analyses temporelles et fréquentielles ne donnent que des informations limitées et ne suffisent donc pas pour décrire entièrement ce type de signal.

1.4.2 Importance de l'analyse temps-fréquence du signal

Les représentations temps-fréquence sont capables de caractériser pleinement la nature des signaux non-stationnaires contrairement aux représentations classiques. En effet, dans les représentations temporelles et fréquentielles vues précédemment, les variables temps et fréquences, respectivement, sont mutuellement exclusives : pour représenter une variable, l'autre est moyennée. Par conséquent, le signal devient non-localisé par rapport à la valeur exclue.

En revanche, la représentation temps-fréquence (RTF), qui utilise la distribution temps-fréquence (DTF), permet de représenter l'énergie du signal comme une fonction à la fois du temps et de la fréquence. La figure 1.11 montre la RTF du signal d'un nouveau-né vu précédemment et met en avant la variation de la fréquence au fil du temps.

Cette propriété motive de plus en plus les chercheurs à traiter et analyser les signaux biomédicaux à l'aide des DTF afin de dévoiler toutes les caractéristiques du signal. Ce présent travail a pour objectif de fournir à ces chercheurs un outil leur permettant d'exploiter de manière simple les distributions temps-fréquence pour caractériser les différents modèles d'EEG.

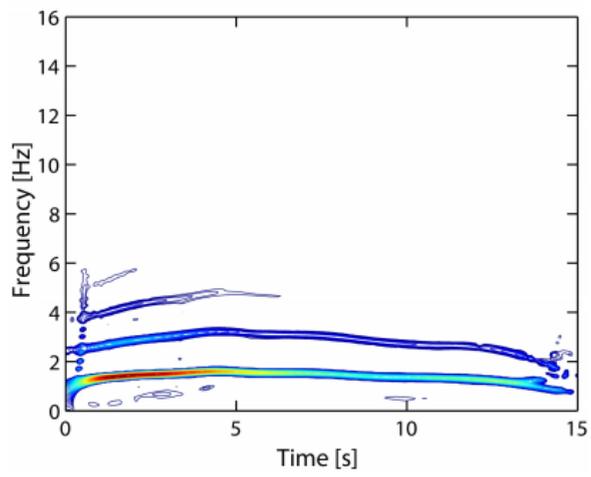


FIGURE 1.11: Représentation temps-fréquence du signal EEG d'un nouveau-né.

Chapitre 2

L'analyse Temps-Fréquence

Le chapitre précédent a mis en lumière les avantages des distributions temps-fréquence pour les signaux électrophysiologiques. Dans ce chapitre, une définition mathématique plus concise sera donnée. Nous verrons par la suite les distributions les plus adéquates pour une caractérisation précise des EEG ainsi que des exemples d'application des DTF en neurosciences.

2.1 L'outil temps-fréquence

Pour évaluer la distribution énergétique d'un signal dans le domaine conjoint temps-fréquence, plusieurs méthodes d'analyse temps-fréquence (ATF) furent développées :

2.1.1 Transformée de Fourier à Court Terme et Spectrogramme

Afin de localiser l'information spectrale dans le temps, il suffit d'effectuer une transition de l'analyse spectrale stationnaire (Eq. (1.1)) vers une analyse spectrale variante dans le temps. Une solution à cela est de multiplier le signal par une fenêtre temporelle centrée en un temps t et de calculer sa transformée de Fourier. Pour une définition plus aiguë, cette procédure est refaite sur l'ensemble des points temporels (Eq. (2.1)). Cette méthode est connue sous le nom de la *Transformée de Fourier à court terme* (TFCT) [9].

$$F_s(t, f) = \int_{-\infty}^{\infty} s(\tau)w(t - \tau)e^{-j2\pi f\tau} d\tau \quad (2.1)$$

Le carré de l'amplitude de la TFCT définit le *spectrogramme* comme suit :

$$S(t, f) = \left| \int_{-\infty}^{\infty} s(\tau)w(t - \tau)e^{-j2\pi f\tau} d\tau \right|^2 \quad (2.2)$$

De l'Eq 2.2, il est évident que pour avoir une bonne résolution temporelle, la taille de la fenêtre $w(t)$ doit être la plus petite possible. Cela a pour effet la dégradation de la résolution fréquentielle, une conséquence du *principe d'incertitude d'Heisenberg* ($\Delta t \Delta f \geq 1/4\pi$, Δt et Δf représentant les résolutions en temps et en fréquence, respectivement). Il est donc nécessaire de trouver un compromis entre ces deux résolutions pour pouvoir utiliser de façon efficace le spectrogramme.

2.1.2 Classe quadratique des DTF

Distribution de Wigner-Ville

L'introduction de la distribution de Wigner-Ville (DWV) a contribué grandement au développement de l'ATF. La DWV est le fruit des travaux indépendants de Wigner dans la mécanique quantique et de Ville dans la théorie des probabilités.

La distribution de Wigner-Ville d'un signal réel $s(t)$ est définie comme suit [9] :

$$W_z(t, f) = \int_{-\infty}^{\infty} z\left(t + \frac{\tau}{2}\right) z^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi f\tau} d\tau \quad (2.3)$$

où $z(t)$ est le signal analytique associé à $s(t)$.

Le signal analytique $z(t)$ est un signal complexe ne contenant que des fréquences positives. Le signal $s(t)$ étant réel, sa TF possède une symétrie Hermitienne (Eq. 2.4), il possède donc des fréquences négatives et positives.

$$S(-f) = S^*(f) \quad (2.4)$$

Le signal analytique $z(t)$ du signal réel $s(t)$ est obtenu en appliquant la transformée de Hilbert :

$$z(t) = s(t) + j \left\{ s(t) * \frac{1}{\pi t} \right\} \quad (2.5)$$

où $*$ représente la convolution temporelle qui définit la transformée de Hilbert, $H[s(t)] = s(t) * \frac{1}{\pi t} = \int \frac{1}{\pi\tau} s(t - \tau) d\tau$.

L'inconvénient majeur de la DWV est la présence de des termes d'interférence, appelés en anglais cross-terms, pour les signaux possédant plusieurs composantes. Si $x(t) = x_1(t) + x_2(t)$, alors la distribution de Wigner-Ville est la suivante :

$$W_x(t, f) = W_{x_1}(t, f) + W_{x_2}(t, f) + W_{x_1, x_2}(t, f) + W_{x_2, x_1}(t, f)$$

où $W_{x_1, x_2}(t, f)$ et $W_{x_2, x_1}(t, f)$ sont des termes d'interférences qui représentent de fausses manifestations d'énergies.

Ce phénomène est mis en avant par la figure 2.1 qui représente la DWV d'une somme de deux signaux modulés linéairement en fréquence (en anglais linear-frequency modulation LFM) d'intervalles de fréquence 0.1-0.2 et 0.3-0.4 Hz. Des termes d'interférences apparaissent dans l'intervalle 0.2-0.3 Hz.

L'utilisation du signal analytique dans la DWV permet, en supprimant les fréquences négatives, de réduire le nombre de composantes du signal et par conséquent, de limiter le nombre d'interactions entre ces composantes.

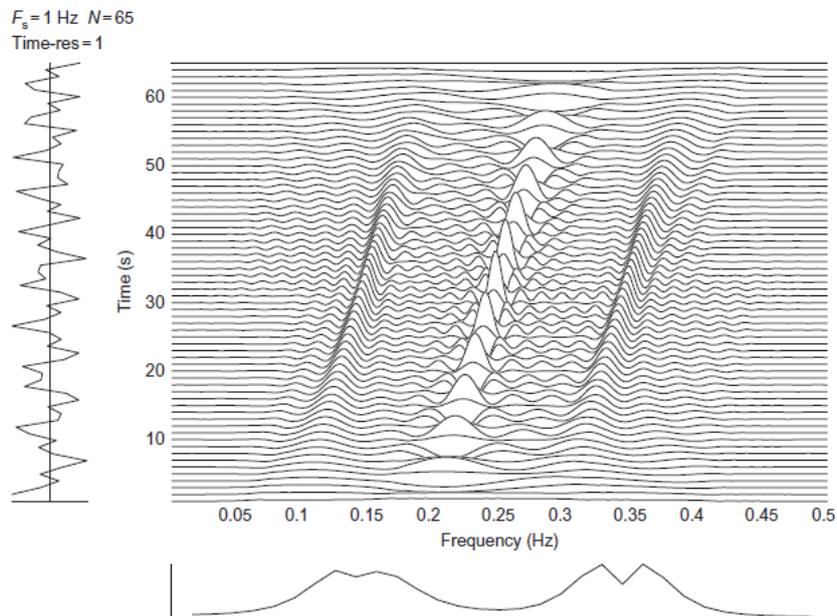


FIGURE 2.1: Distirbution de Wigner-Ville d'une somme de deux signaux LFM

Signal asymptotique et lissage de la DWV

En théorie, un signal à durée fini possède une largeur de bande en fréquence infinie. Du fait des moyens d'acquisition, les signaux ont une énergie finie pour une durée de temps

T finie et une largeur de bande de fréquence B finie. Pour garder les mêmes propriétés théoriques des signaux, on définit une classe de signaux appelés *signaux asymptotiques* pour lesquels le produit TB » 1. En pratique, on accepte en général un produit TB > 10.

Le signal à durée finie est obtenu en multipliant le signal par une fenêtre de durée finie $g(t)$. Cela revient à convoluer, dans le domaine fréquentiel, $W_z(t, f)$ avec $G(f) = \mathcal{F}_{t \rightarrow f}\{g(t)\}$.

La largeur de bande finie est quant à elle obtenue en multipliant le spectre fréquentiel par une fenêtre de largeur de bande finie $H(f)$. Ce qui revient, cette fois-ci à convoluer, dans le domaine temporel, $W_z(t, f)$ avec $h(t) = \mathcal{F}_{f \rightarrow t}^{-1}\{H(f)\}$.

En combinant les effets des fenêtrages de $g(t)$ dans le temps et $H(f)$ en fréquence, l'expression suivante est obtenue :

$$\rho_z(t, f) = h(t) *_t W_z(t, f) *_f G(f) \quad (2.6)$$

où $\rho_z(t, f)$ est la *représentation temps-fréquence* du signal $z(t)$, $G(f)$ et $h(t)$ sont des fonctions paires et $*_t$ et $*_f$ représentent respectivement les convolutions dans le domaine temporel et le domaine fréquentiel.

Une équation plus générale de l'Eq. (2.6) est souvent utilisée :

$$\rho_z(t, f) = W_z(t, f) *_t *_f \gamma(t, f) \quad (2.7)$$

où $\gamma(t, f)$ est une fonction paire, pas forcément séparable, représentant les limitations finies du signal dans les domaines temporel et fréquentiel et $**_{t f}$ est la convolution bi-dimensionnelle (2D) en temps et en fréquence.

En développant les expressions de $W_z(t, f)$ et de la double convolution dans l'Eq. (2.7), on obtient l'expression générale des *distributions temps-fréquence quadratiques* (DTFQ) :

$$\rho_z(t, f) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} e^{j2\pi\nu(u-t)} g(\nu, \tau) z\left(u + \frac{\tau}{2}\right) z^*\left(u - \frac{\tau}{2}\right) e^{-j2\pi f\tau} d\nu d\tau \quad (2.8)$$

où $g(\nu, \tau)$, connue comme le filtre noyau de la DTF, est la transformée de Fourier 2D de $\gamma(t, f)$.

Les filtres noyaux sont généralement conçus de manière à réduire les termes d'interférences en évitant le plus possible de compromettre les résolutions du signal.

L'expression des DTFQ ayant une formulation unifiées dans plusieurs domaines de représentation, il est possible de l'exprimer dans le domaine temps-retard :

$$\begin{aligned} R_Z(t, \tau) &= \int_{-\infty}^{\infty} G(t - u, \tau) z \left(u + \frac{\tau}{2} \right) z^* \left(u - \frac{\tau}{2} \right) du \\ &= G(t, \tau) * K_z(t, \tau) \end{aligned} \quad (2.9)$$

où $K_z(t, \tau)$ est appelée *Fonction d'autocorrélation instantanée* (FAI) et $G(t, \tau)$ est le noyau temps-retard.

$$K(t, \tau) = z \left(t + \frac{\tau}{2} \right) z^* \left(t - \frac{\tau}{2} \right) \quad (2.10)$$

$$G(t, \tau) = \mathcal{F}_{\nu \rightarrow t}^{-1}[g(\nu, \tau)] \quad (2.11)$$

Pour implémenter les DTF, une version *discrète* de l'Eq. (2.9) est utilisée :

$$\rho_z[n, k] = \text{DFT}_{m \rightarrow k} \left\{ G[n, m] * (K_z[n, m]) \right\} \quad (2.12)$$

où $G[n, m]$ est la version discrète du noyau temps-échelle et $K_z[n, m]$ la FAI échantillonnée.

Le tableau 2.1 montre les filtres noyaux les plus courants dans la littérature dans le domaine continu et discret [9]-[15].

2.2 Application en neurosciences

2.2.1 Choix des distributions

L'objectif de l'utilisation de l'ATF en neurosciences est de trouver un outils permettant la classification, visuelle et/ou automatique, des différents signaux issus de l'EEG. De récentes études ont montré que les DTFQ dont les noyaux sont séparables possèdent

Nom	$G(t, \tau)$	$G[n, m]$
DWV	$\delta(t)$	$\delta[n]$
Born-Jordan (BJ)	$\frac{1}{ 2\alpha\tau } \text{rect} \frac{t}{2\alpha\tau}$	$\frac{1}{4 \alpha m } \text{rect} \left(\frac{n}{4\alpha m} \right)$
Choi-Williams (CW)	$\frac{\sqrt{\pi\sigma}}{ \tau } e^{-\pi^2\sigma t^2/\tau^2}$	$\frac{\sqrt{\pi\sigma}}{2 m } \exp \left(\frac{-\pi^2\sigma n^2}{4m^2} \right) ** [\text{sinc } n \text{ sinc } m]$
Zhao-Atlas-Marks (ZAM)	$w(\tau) \text{rect} \frac{t}{2\tau/a}$	$[w[m] \text{rect} \left(\frac{an}{4m} \right)] ** [\text{sinc } n \text{ sinc } m]$
B-distribution (BD)	$ \tau ^\beta \cosh^{-2\beta} t$	$\left(\frac{-2m }{\cosh^2 n} \right)^\beta * \text{sinc } m$
Modified B-distribution (MBD)	$\int_{-\infty}^{\infty} \frac{\cosh^{-2\beta} t}{\cosh^{-2\beta} \xi d\xi}$	$\sum_n \frac{\cosh^{-2\beta} n}{\cosh^{-2\beta} n}$
Extended modified B-distribution (EMBD)	$\frac{\cosh^{-2\beta} t}{\int_{-\infty}^{\infty} \cosh^{-2\beta} \xi d\xi} \frac{ \Gamma(\alpha+j\pi\tau) ^2}{\Gamma^2(\alpha)}$	$\sum_n \frac{\cosh^{-2\beta} n}{\cosh^{-2\beta} n} \frac{ \Gamma(\alpha+j\pi\tau) ^2}{\Gamma^2(\alpha)}$
Cheriet-Belouchrani Distribution (CBD)	$\begin{cases} e^{\frac{1}{2} \left(\frac{\gamma}{t^2+\tau^2-1} + \gamma \right)} & t^2 + \tau^2 < 1 \\ 0 & \text{sinon} \end{cases}$	$\begin{cases} e^{C \left(\frac{1}{(n^2+m^2)(B/M)^2-1} + 1 \right)} & (n^2 + m^2) (B/M)^2 < 1 \\ 0 & \text{sinon} \end{cases}$

TABLE 2.1: Exemples de filtres noyaux des DTF

de meilleures résolutions temporelles et fréquentielles et pourraient donc fournir de bons résultats en classification [16].

Parmi les DTFQ citées précédemment, trois sont "séparables". Il s'agit de : Modified B-distribution, Extended modified B-distribution et Cheriet-Belouchrani Distribution.

Après sélection des DTFQ, il faut s'assurer que ces distributions caractérisent, avec précision, la signature temps-fréquences des signaux électrophysiologiques.

Des études antérieures sur l'analyse visuelle des signaux EEG ont montré que ces signaux peuvent être divisés en deux catégories : 1) signaux composés de pointes et de sinusoides [17] ; 2) signaux composés de chirps d'amplitudes variantes [18].

Pour évaluer la performance de classification des DTFQ sélectionnées, Boashash et al. dans [16], ont conduit quatre expériences en se basant essentiellement sur ces catégories. Dans chaque expérience, un type de signal particulier a été utilisé (voir tableau 2.2). Pour chacun de ces signaux, diverses DTFQ ont été appliquées puis comparées visuellement. La figure 2.2 montre les différentes RTF obtenues par l'expérience 1¹.

	Type du signal
Expérience 1	Simulation d'un signal composé de sinusoides et de pointes.
Expérience 2	Signal EEG réel composé de sinusoides et de pointes.
Expérience 3	Simulation d'un signal composé de chirps d'amplitudes variantes
Expérience 4	Signal EEG réel composé de chirps d'amplitudes variantes

TABLE 2.2: Types de signaux utilisés dans les expériences.

1. La représentation de référence est obtenue en sommant les distributions de Wigner-Ville pour chaque composant du signal de manière à avoir une distribution artificielle, sans cross-terms.

Les résultats de ces expériences ont montré que les distributions quadratiques les plus adéquates aux signaux EEG sont : **MB-distribution**, **EMB-distribution** et **CB-distribution**. Elles seront donc utilisées dans la suite de ce projet.

La **DWV**, bien que ne donnant pas de bons résultats visuellement, sera aussi exploitée car en plus d'être l'une des DTF les plus utilisées dans plusieurs applications réelles, des études [19], [20] montrent que la présence de cross-terms dans cette distribution pourrait renforcer les performances de classification.

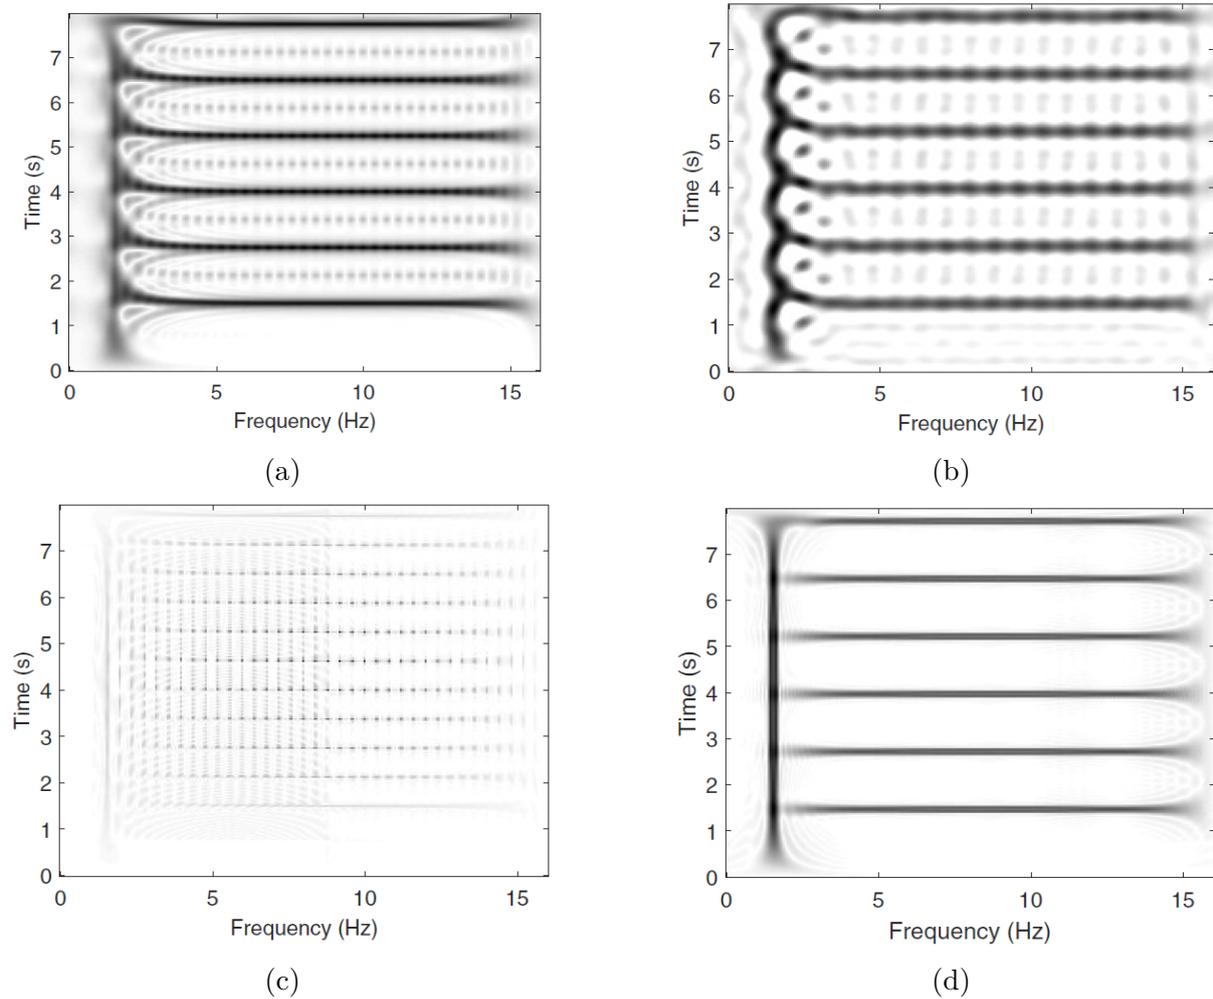


FIGURE 2.2: Analyse temps-fréquence d'un signal composé de sinusoides et de pointes. (a) EMBD ($\alpha = 0.2, \beta = 0.1$), (b) CBD ($c=0.01, D=0.075, E=0.075$), (c) WVD (d) référence [16]

2.2.2 Exemple

Plusieurs études récentes utilisent l'outil temps-fréquence pour le pronostic et le diagnostic d'anomalies neurologiques. Dans ce qui suit, une illustration de cela est donnée en mettant en avant les résultats obtenus.

Analyse des signaux EEG de nouveau-nés

Une des modalités clés du signal physiologique du nouveau-né est l'EEG. Il peut être considéré comme un processus de bruit coloré avec des périodes distinctes de modulation d'amplitude (AM) qui dénotent différents états d'activité cérébrale [3]. La figure 2.3 montre la RTF de ces différents états.

1. Sommeil profond :

Il est défini comme un processus de bruit coloré modulé par une sinusoïde variante dans le temps. Ceci est représenté dans le domaine (t, f) comme une concentration périodique d'activité à haute énergie, suivie d'une activité à faible énergie. Ce modèle est analogue aux prématurés.

2. Sommeil léger :

Onde thêtas (4-8 Hz) et delta (0,5-4 Hz) avec une activité irrégulière entremêlée, représenté dans le domaine (t, f) comme processus de bruit coloré avec une coloration spectrale suivant une loi de puissance inverse.

3. Suppression des salves :

Signaux de courte période avec une énergie élevée qui durent quelques secondes et se produisent généralement à des fréquences inférieures à 4 Hz. Représenté dans le temps-fréquence par une activité à haute tension d'une durée de 1 à 10 s et composée de diverses formes d'onde [ex : delta (0-4 Hz) et thêta (4-8 Hz)] avec des pointes superposées et mélangées, des ondes pointues et une activité plus rapide, suivies d'une atténuation marquée.

4. Convulsion néonatale :

Événement caractérisé par l'apparition de formes d'onde soudaines, répétitives, évolutives et stéréotypées qui ont un début, un milieu et une fin définis, et durent au moins 10 s. En ATF, elle est représentée par une composante principale, décrivant un chirp dont l'amplitude varie lentement, entourée de crêtes sous-harmoniques.

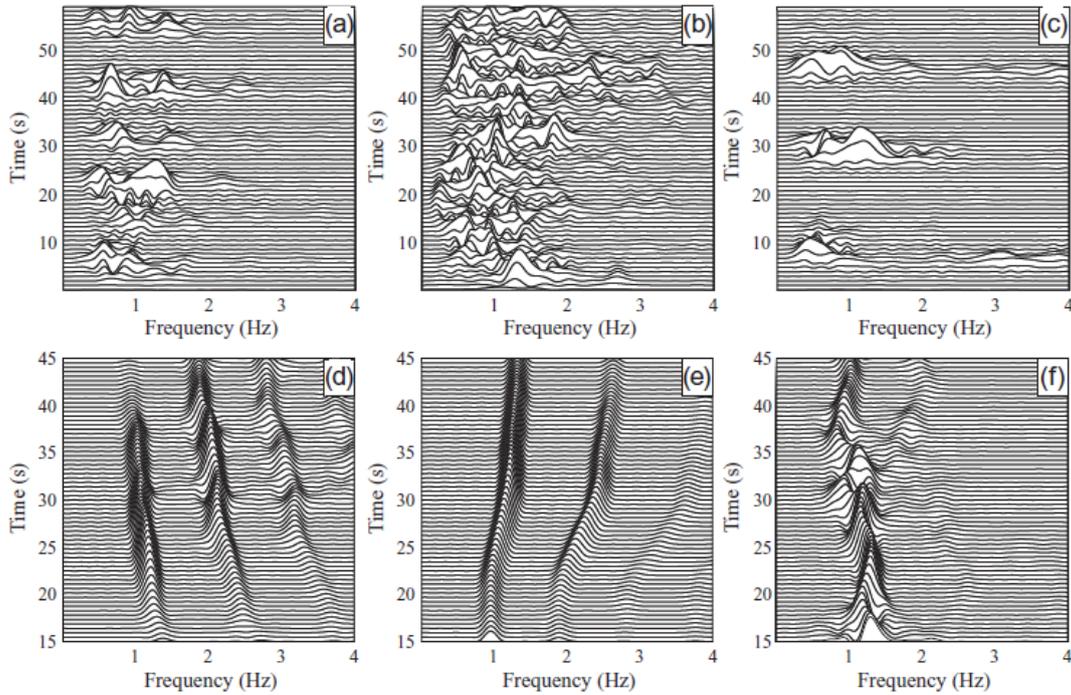


FIGURE 2.3: Représentation temps-fréquence de signaux EEG de nouveaux nés. (a) Sommeil profond. (b) Sommeil léger. (c) Suppression des salves. (d) Convulsion avec chirp linéaire décroissante. (e) Convulsion avec chirp linéaire croissante. (f) Convulsion complexe avec chirp linéaire par morceau [3].

Evaluation des lésions cérébrales

Les décharges épileptiformes latérales périodiques (DELP) sont de nettes transitions dans l'EEG qui peuvent survenir après une lésion cérébrale ; la prescription de traitement des ce cas est très ambiguë. La périodicité des DELP est une donnée influente qui peut aider dans le choix du traitement.

Bien que les DELP soient dites périodiques, la période entre les décharges peut varier considérablement dans le temps. Elles sont donc de nature non stationnaire. Il est très difficile d'estimer les différentes périodes du signal en raison de l'amplitude relativement élevée de l'activité background de l'EEG qui masque les pointes des DELP.

Une solution consiste à accroître l'amplitude des pointes en appliquant l'opérateur de Teager-Kaiser sur le signal discret $s[n]$ (Eq. (2.13)).

$$y[n] = s^2[n] - s[n+1]s[n-1] \quad (2.13)$$

Le signal est ensuite transformé dans le domaine temps-fréquence en appliquant une DTF à noyau séparable. Après cela, l'enveloppe spectrale de la DTF est supprimée en utilisant l'Eq. (2.14). A partir de la nouvelle DTF, les fréquences instantanées (FI) sont faciles à estimer.

$$\eta_z[n, k] = \exp \left[\mathcal{F}_{m \rightarrow k} \{ R_z^m[n, m] l[m] \} \right] \quad (2.14)$$

où : $R_z[n, m]$ est la DTF du signal analytique $z[n]$ associé à $y[n]$ et $l[m]$ est un filtre passe-bas.

Cette méthode, réalisée dans l'hôpital universitaire de Cruces, en Espagne, a pu améliorer de manière significative l'estimation des FI et a donc aidé les médecins à optimiser les traitements neuroprotecteurs [18].

Chapitre 3

Conception de l'interface graphique

Dans le chapitre précédent, les DTFQ se sont révélées être très efficaces en termes de résolution et de précision dans l'analyse et la caractérisation des signaux non stationnaires et/ou multicomposants. Leur utilisation dans le domaine des neurosciences est très prometteuse mais reste restreinte car elle nécessite souvent une bonne expertise en programmation ou l'utilisation d'un logiciel commercial assez coûteux. Dans ce chapitre, nous verrons les étapes de conception d'une interface graphique open-source dédiée à l'analyse temps-fréquence des signaux EEG.

3.1 Etat de l'art

Il existe plusieurs solutions commerciales permettant la visualisation et l'analyse des signaux EEG. La plupart sont développées par les fabricants des systèmes d'acquisition mais conviennent peu à la recherche. Ils doivent répondre aux stricts exigences des certifications cliniques, offrent peu de fonctionnalités et sont assez coûteuses.

Pour y remédier, les laboratoires de recherches ont développé leurs propres outils informatiques. Ces derniers, ne répondent qu'aux problématiques propres aux recherches menées, ne sont souvent pas partagés au grand public en raison des faibles ressources humaines pour le maintien logiciel et de la limitation de leurs expertises.

Les deux dernières décennies ont vu naître le développement collaboratif permettant l'apparition de nombreux logiciels open-source dédiés à l'analyse des signaux EEG. La figure 3.1 montre les outils les plus cités dans la littérature par les experts en électrophysiologie jusqu'au début 2020.

EEGLab est une interface, développée sous Matlab, simple mais fonctionnelle. Son application cible est orientée vers le prétraitement des enregistrements et l'analyse en

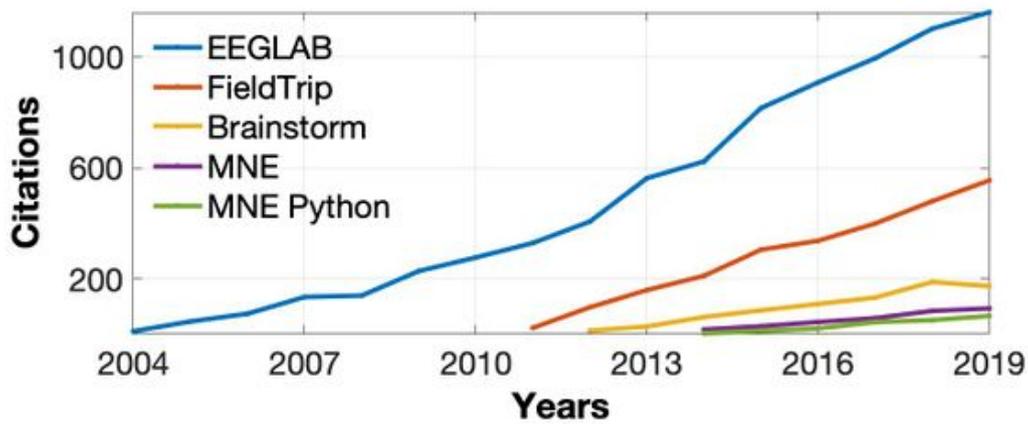


FIGURE 3.1: Nombre de citations par année des outils logiciels [21]

composantes indépendantes[22]. **FieldTrip** est une boîte à outils de Matlab riche et puissante qui offre la plus large gamme de fonctionnalités, mais sans interface graphique ; son utilisation nécessite de bonnes compétences en programmation [23]. **Brainstorm** est une application de haut niveau développée sous Matlab et Java. En cours de développement, elle offre moins de fonctionnalités que FieldTrip ; mais d'un autre côté, son interface intuitive, ses puissants outils de visualisation et la structure de sa base de données permettent à l'utilisateur de travailler aisément [24]. **MNE** est une bibliothèque compilée en C comprenant un ensemble de fonctions indépendantes, facilement implémentable et principalement orientées vers le prétraitement des enregistrements et l'estimation de la source. Une implémentation de cette bibliothèque est également disponible sous Python (MNE-Python)[25].

Ces outils sont des programmes généralistes pour l'analyse des données EEG. Bien que certains offrent la possibilité d'effectuer l'analyse temps-fréquence, cette dernière ne repose essentiellement que sur la décomposition en ondelettes et l'analyse de Fourier.

Ce présent projet se distingue des travaux existants en étant exclusivement dédié à l'analyse temps-fréquence. Celle-ci sera basée sur les distributions temps-fréquence quadratiques, inemployées jusqu'à présent dans les logiciels dédiés aux données électrophysiologiques.

3.2 Spécifications des besoins

Le présent travail a pour objectif la conception d'une application d'analyse temps-fréquence des signaux EEG. Les principaux **acteurs** en interaction avec le système sont les chercheurs en neurologie, en neurosciences et en électrophysiologie. Ils doivent, à travers l'interface, pouvoir effectuer les tâches suivantes :

- chargement et pré-traitement de données électroencéphalographiques,
- visualisation temporelle sur l'ensemble des canaux des données,
- calcul et visualisation de la distribution temps-fréquence d'un signal donné selon les paramètres choisis par l'utilisateur,
- annotation et sauvegarde de la DTF dans une base de données,
- accès à un atlas d'EEG comprenant divers états d'activité cérébrale.

En plus de ces fonctionnalités, l'application doit répondre à des besoins non-fonctionnels assurant la fluidité de l'interface et de son déploiement. Le logiciel doit donc :

- être portable et multiplateforme,
- avoir une interface épurée et simple à utiliser,
- avoir un temps d'exécution s'approchant du temps réel,
- être performant en répondant aux exigences des usagers d'une manière optimale.

3.3 Choix de l'architecture et de la programmation

L'architecture convenant le plus à l'application est l'architecture Modèle-Vue-Contrôleur (MVC). Elle permet d'organiser l'interface graphique en distinguant trois parties : le modèle, la vue et le contrôleur. Chaque partie joue un rôle précis dans l'interface :

1. Le modèle :

Il contient les données manipulées par le programme, assure leur gestion et garantit leur intégrité.

Dans ce projet, trois structures de base de données sont nécessaires. Elles sont citées dans le tableau 3.1.

Base de données	Détails
Base de données EEG	Signaux EEG entrés par l'utilisateur.
Base de données Atlas	Signaux EEG issus de différentes activités cérébrales.
Base de données DTF	DTF des signaux EEG entrés par l'utilisateur.

TABLE 3.1: Bases de données du modèle.

Pour structurer les variables de l'application, à savoir les signaux EEG, une classe est définie dans le modèle. Elle est schématisée dans la figure 3.2.

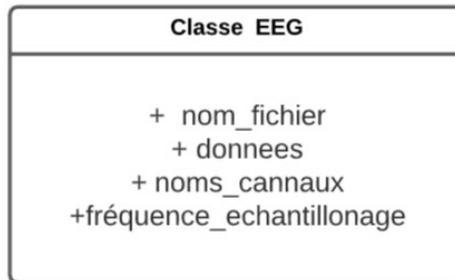


FIGURE 3.2: Diagramme de la classe EEG

2. La vue :

Elle permet de créer l'interface avec l'utilisateur. Dans ce projet, la partie vue comprend les éléments suivants :

- un menu permettant le défilement des pages,
- une page permettant la visualisation de la représentation temporelle du signal,
- une page permettant l'analyse temps-fréquence du signal,
- une page contenant l'Atlas EEG.

Son rôle consiste aussi à recevoir les actions de l'utilisateur (sélection, clic,...) et de les envoyer vers le contrôleur à travers des fonctions callback.

3. Le contrôleur :

Il joue le rôle d'intermédiaire entre le modèle et la vue et assure la synchronisation de toutes les parties.

La figure 3.3 montre les interactions du modèle MVC. Pour une implémentation plus optimale, la version passive de cette architecture a été utilisée (figure 3.4).

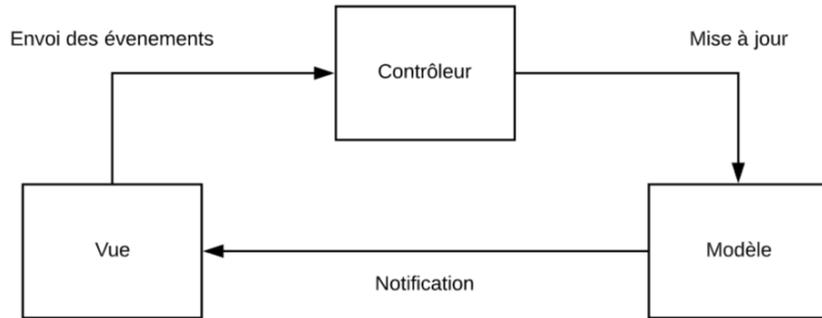


FIGURE 3.3: Interactions de l'architecture MVC

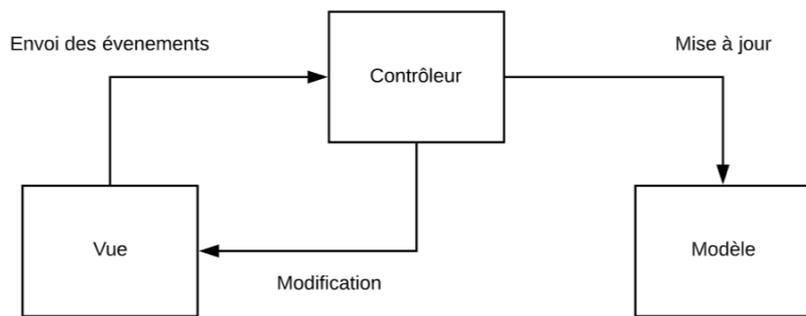


FIGURE 3.4: Interactions de de l'architecture MVC passive

Concernant la programmation, il est plus intéressant d'utiliser la programmation orientée objet que celle procédurale. Parmi ses avantages :

- la facilité de compréhension et la clarté du code,
- la maintenabilité et l'évolutivité de par la modularité du code,
- la possibilité de réutilisation du code et donc un gain de ressources.

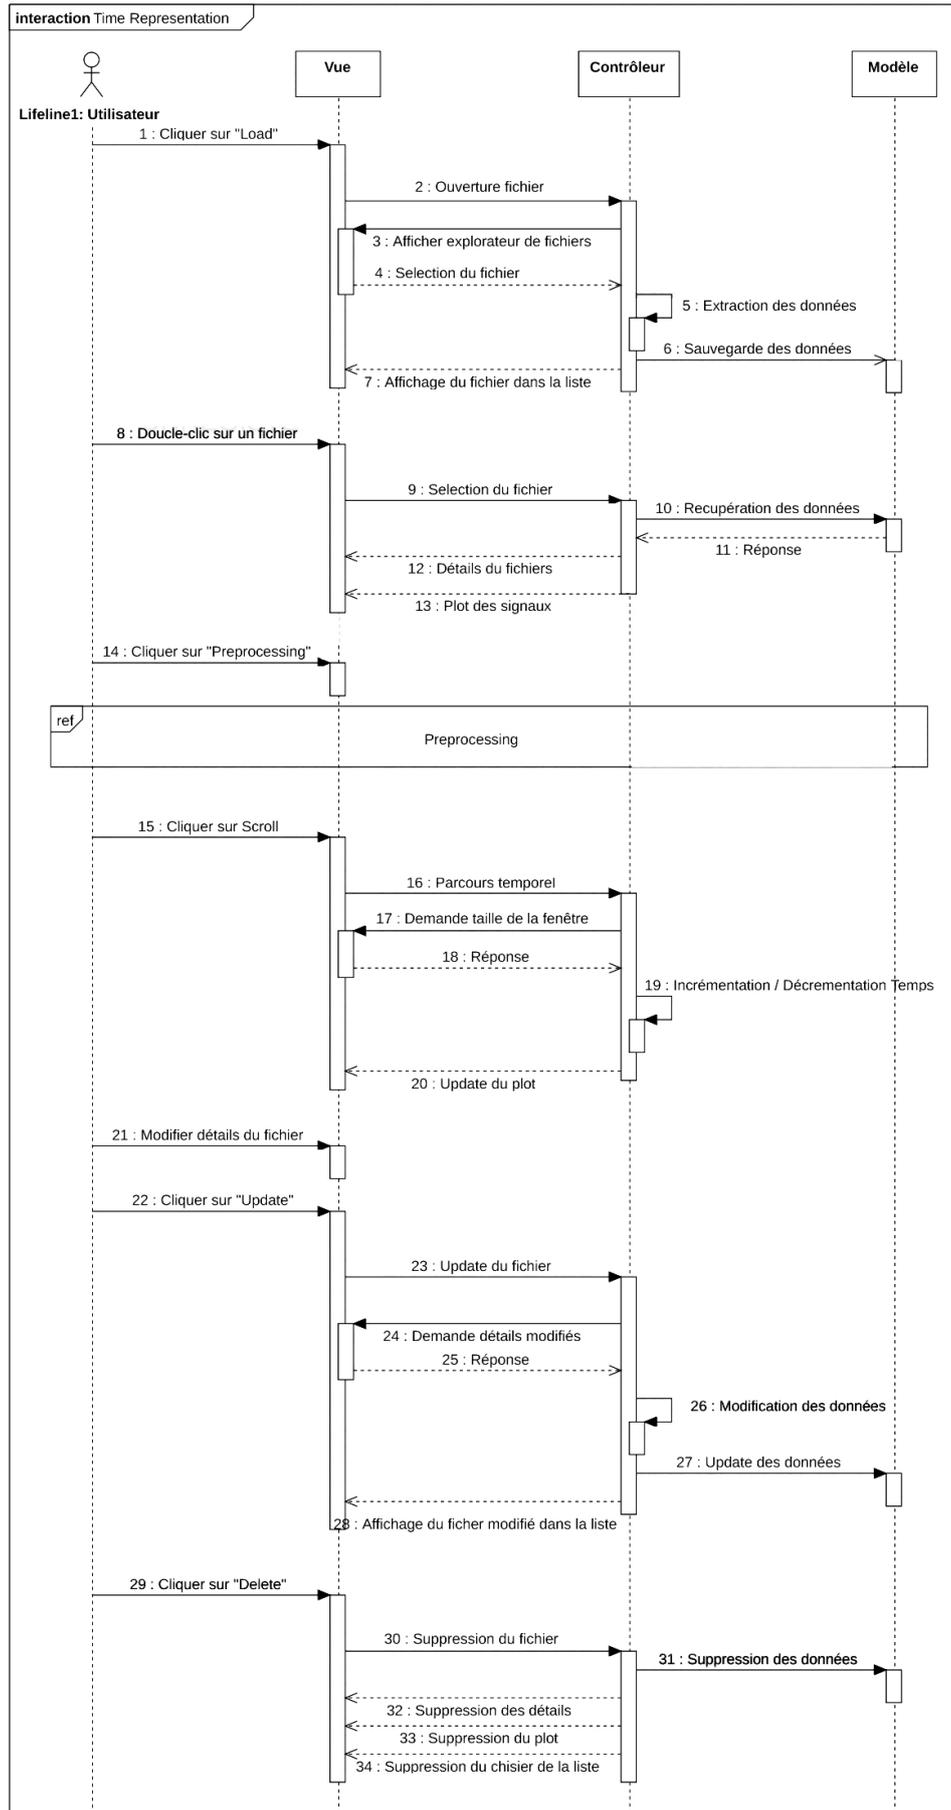
3.4 Utilisation de l'outil UML

D'après wikipedia, «Le Langage de Modélisation Unifié, de l'anglais Unified Modeling Language (UML), est un langage de modélisation graphique à base de pictogrammes conçu pour fournir une méthode normalisée pour visualiser la conception d'un système. Il est couramment utilisé en développement logiciel et en conception orientée objet» [26].

L'un des diagrammes les plus parlant de l'UML est le diagramme de séquences. Il décrit l'interaction des éléments du système entre eux.

Ce projet contient quatre cas d'utilisations : "Représentation temporelle du signal", "Prétraitement", "Représentation temps-fréquence" et "Accès à l'atlas EEG". Les figures 3.5, 3.6, 3.7 et 3.8 montrent les diagrammes de séquences de chaque utilisation.

FIGURE 3.5: Diagramme de séquence "Représentation temporelle du signal"



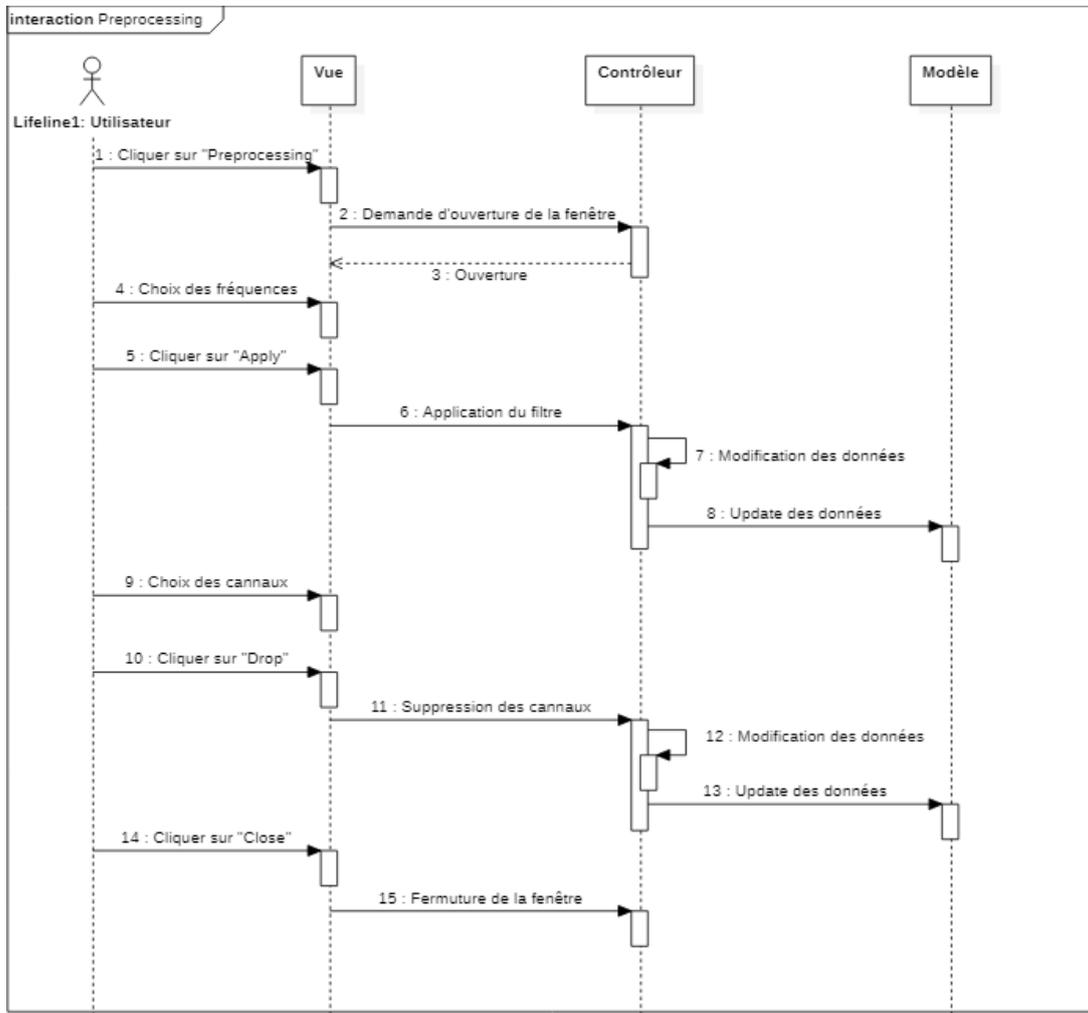


FIGURE 3.6: Diagramme de séquence "Prétraitement"

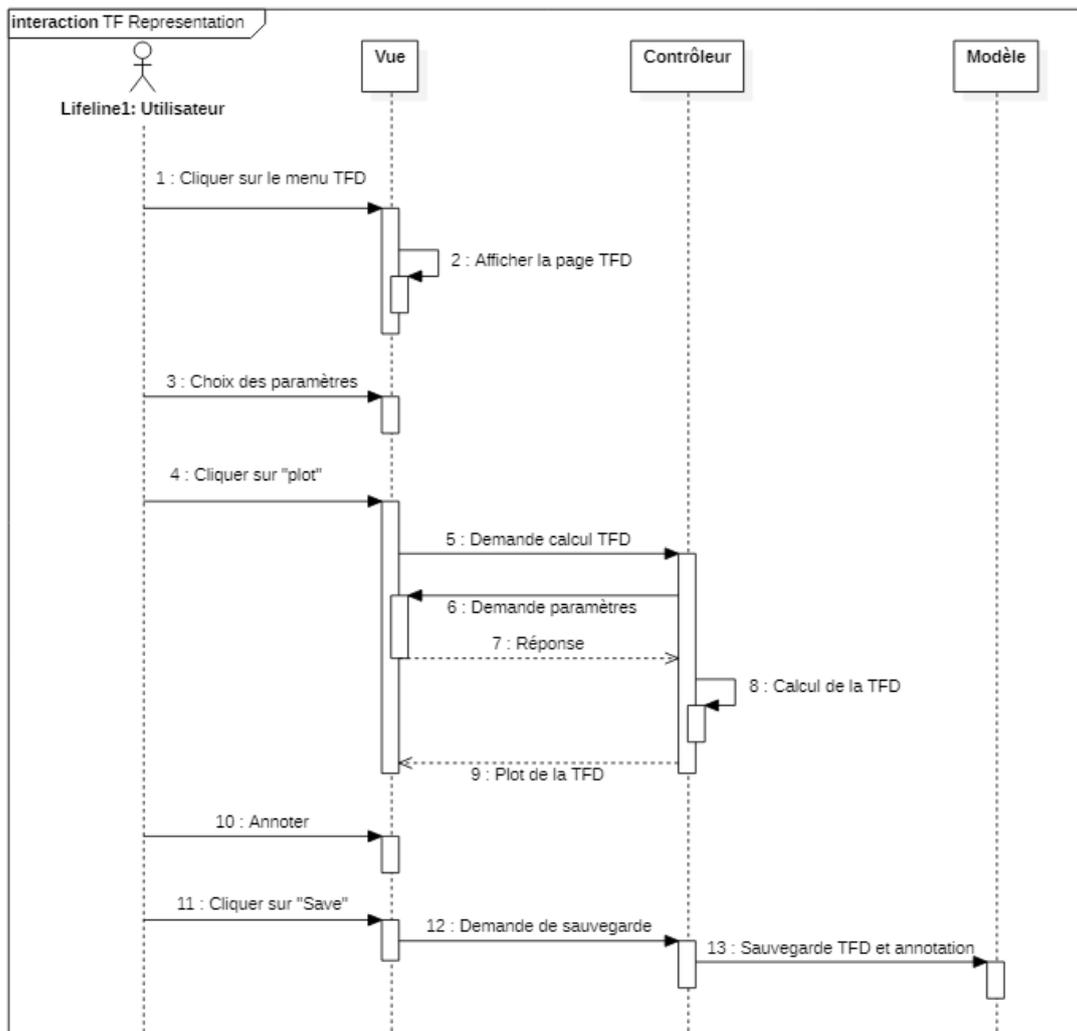


FIGURE 3.7: Diagramme de séquence "Représentation temps-fréquence"

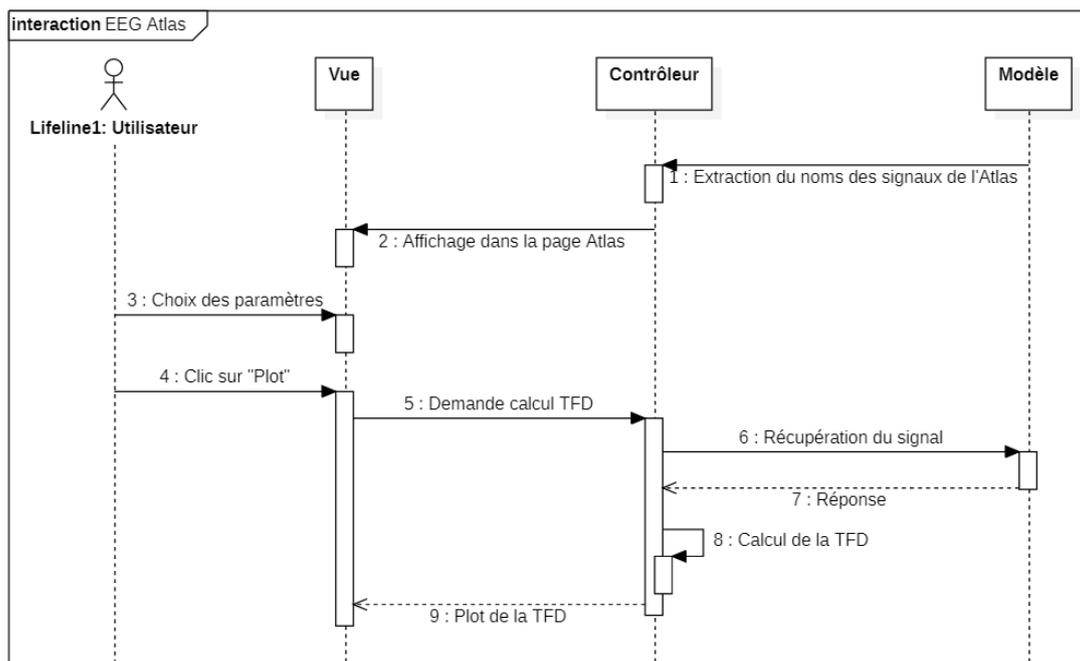


FIGURE 3.8: Diagramme de séquence "Accès à l'atlas EEG"

Chapitre 4

Réalisation de l'interface graphique

Après avoir décrit notre système d'un point de vue conceptuel, nous verrons dans ce présent chapitre l'implémentation de l'application. Il s'agit de la création et de la mise en œuvre des différents programmes, interfaces, et bases de données et de la présentation des fonctionnalités et des outils utilisés pour la réaliser.

4.1 Choix de l'environnement de développement

Ils existent plusieurs langages de programmation dédiés au calcul scientifique, les plus performants selon la littérature sont Matlab et Python.

En neurosciences, la figure 3.1 montre que 90 % des citations utilisent des outils développés sous **Matlab**. Une des raisons derrière cela est la maturité et la stabilité actuelles de Matlab dans ce domaine résultant et de ses vastes fonctions prédéfinies.

En parallèle, l'écosystème scientifique **Python** a mûri rapidement au cours des dernières années et est devenu une alternative attrayante pour les scientifiques car il est gratuit, open source et de plus en plus puissant. Sa vaste bibliothèque de modules facilite le développement et la maintenabilité de systèmes complexes et offre plusieurs outils de développement d'interface graphique.

Le tableau 4.1 présente un comparatif des écosystèmes Matlab et Python.

En prenant en compte les besoins spécifiés au chapitre précédent, l'environnement le plus adéquat au développement du projet est Python. Sa portabilité et son interopérabilité sont de réels avantages pour une performance optimisée de l'application sans compter

Matlab	Python
Logiciel propriétaire et closed-source.	Logiciel Open-source.
Licence assez coûteuse et toolboxes facturées en plus.	IDE, packages et extensions gratuits.
Exclusivité et dépendance de Mathworks.	Intégrité des codes.
Portabilité restreinte.	Portabilité sur Windows, Linux, and OS X.

TABLE 4.1: Comparaison des écosystèmes Matlab et Python

que sa structure orientée objet est intuitive et facile à utiliser.

Parmi les outils offerts sous cet environnement pour le développement d’interfaces graphiques se trouve **Tkinter** ; un module de base intégré dans Python. Il s’agit d’un module simple et facile à utiliser et bien qu’il offre des widgets peu esthétiques, il permet de réaliser des interfaces épurées, répondant au cahier de charge précédemment cité.

4.2 Implémentation d’une librairie Temps-Fréquence

Il a été établi que Python est un puissant outil pour le calcul scientifique, notamment en traitement du signal. Il en reste néanmoins que l’analyse temps-fréquence est peu développée sous cet environnement.

L’API principal de Python permettant l’ATF est Scipy. Ce module, généralement utilisé pour le traitement du signal, permet entre autres la décomposition en ondelettes et le calcul de la STFT du signal [27]. Il ne permet toutefois pas le calcul des distributions temps-fréquence quadratiques sur lesquels ce présent projet est basé.

Un module complémentaire, développé avec Scipy et Matplotlib, est en cours de développement. Il s’agit de Py-TFTB ; une implémentation Python de la bibliothèque TFTB de Matlab. Il permet de calculer quelques distributions quadratiques mais étant très peu optimisé, il demande un temps d’exécution important ne répondant donc pas au cahier de charge du projet.

La solution à cela était de développer une bibliothèque propre au projet se basant à la fois sur l’optimisation et des algorithmes et de leur implémentation afin d’aboutir à un résultat répondant aux besoins de l’application.

4.2.1 Optimisation des algorithmes

Les distributions temps-fréquence permettent de représenter un signal simultanément en temps et en fréquence. Cela implique d'importantes ressources de calculs et de mémoire. Les algorithmes DTF typiques nécessitent approximativement $N^2 \log_2 N$ opérations et N^2 points mémoires [28]. Des études montrent que ces algorithmes peuvent être optimisés en prenant en compte les propriétés mathématiques des distributions [29].

Pour rappel, l'expression de la DTFQ discrète est :

$$\rho_z[n, k] = \text{DFT}_{m \rightarrow k} \left\{ G[n, m] *_n (K_z[n, m]) \right\} \quad (4.1)$$

où $G[n, m]$ et $K_z[n, m]$ sont donnés par l'Eq.(4.1).

L'algorithme suivi pour le calcul des QTFD est schématisé dans la figure 4.1. L'optimisation de chaque partie est ensuite expliquée.

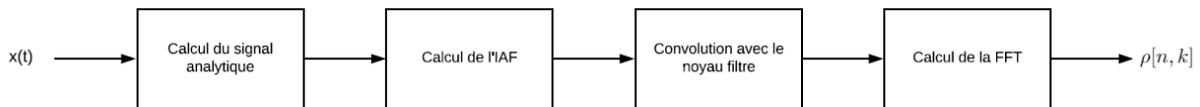


FIGURE 4.1: Algorithme de calcul des distributions temps-fréquence quadratiques

Signal analytique

D'ordinaire, le signal analytique est calculé en annulant la TF du signal pour les fréquences négatives puis en recalculant la TF inverse. Cela peut causer des ondulations indésirables, causées par la longueur finie du signal. Pour éviter ceci, l'Eq. (4.2) est utilisée [30].

$$Z(f) = \begin{cases} 2X(f) & \text{if } 0 \leq f \leq F_S/2 \\ X(f) & \text{if } f = 0 \\ 0 & \text{if } -F_S/2 \leq f \leq 0 \end{cases} \quad (4.2)$$

où : $X(f)$ est la TF de $x(t)$.

Fonction d'autocorrélation instantanée

En utilisant la symétrie Hermitienne, la FAI des TFD quadratiques s'écrit comme suit :

$$K_z[n, m] = \begin{cases} z[n+m]z^*[n-m] & \text{for } m \geq 0 \\ K_z^*[n, -m] & \text{for } m \leq 0 \end{cases} \quad (4.3)$$

La FAI n'ayant besoin d'être calculée que sur les échelles positives, cela permet de réduire de moitié le nombre d'opérations.

Convolution avec le noyau filtre

Cette étape revient à la multiplication matricielle du noyau filtre $G[n, m]$ avec la FAI $K_z[n, m]$. Comme les noyaux des distributions choisies présentent une symétrie aussi bien dans le domaine échelle que temporel, cela réduit considérablement les besoins aussi bien en calcul qu'en mémoire.

Pour la distribution de Wigner-Ville, la noyau étant une dirac, l'élément neutre de la convolution, cette étape est sautée.

Calcul de la FFT

Pour optimiser cette étape, la longueur du signal doit-être une puissance de 2. Cela est fait en appliquant le zero-padding à la FAI filtrée ($K_z[n, m] \otimes_n G[n, m]$).

4.2.2 Optimisation de l'implémentation

Sous python, il est possible d'implémenter ces algorithmes DTFQ de trois manière différente :

- écrire l'intégralité des codes sous Python,
- utiliser l'extension Cython,
- écrire la bibliothèque en C puis utiliser Ctypes comme fonction wrapper.

Les trois cas de figure ont été considérés. Le tableau 4.2 montre le temps d'exécution de chaque méthode pour la calcul de la distribution de Wigner-Ville pour un signal EEG d'une durée de 30s avec une fréquence d'échantillonnage de 256 Hz.

Méthode	Python	Cython	Ctypes
Temps d'exécution (s)	15.64	6.30	0.06

TABLE 4.2: Temps d'exécution des différentes méthodes

Bien que le déploiement sur Python soit facile ne nécessitant qu'un petit nombre de lignes, il était attendu que le temps d'exécution de l'algorithme soit important du fait des caractéristiques du langage interprété et de la présence de nombreuses boucles dans le code.

Cython est une extension du langage C dans Python, elle permet donc de bénéficier de la puissance des deux langages. Cette fois ci, le langage C fut utilisé pour la parcours des itérations. Cela a permis d'avoir une exécution deux fois plus rapide mais ne s'approchant pas du temps-réel spécifié dans les besoins.

L'implémentation des algorithmes en langage C fut une tâche ardue et chronophage. Après création d'une bibliothèque dynamique, Ctypes, une bibliothèque d'appel à des fonctions externes en Python, fut utilisée pour interfacer les codes sous Python. Les résultats obtenus étant les plus optimaux, cette méthode fut choisie pour l'architecture finale du module temps-fréquence (figure 4.2.).

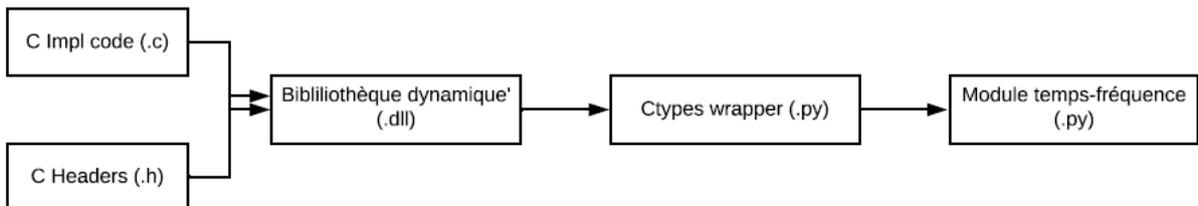


FIGURE 4.2: Architecture du module temps-fréquence

Jusqu'à maintenant, cinq distributions sont implémentées sous cette librairie : DWV, BD, MBD, EMBD et CBD.

4.2.3 Visualisation

Il était nécessaire de fournir dans cette librairie un outil de visualisation des DTF calculées. Ces représentations doivent avoir de bonnes résolutions temporelle et fréquentielle pour permettre une classification visuelle des DTF.

La fonction développée consiste à tracer, pour chaque point temporel, l'amplitude de la DTF sur toute la bande fréquentielle. Cela a été fait en utilisant l'outil LineCollection de la librairie Matplotlib et a permis d'avoir une image texturée du signal.

Pour une description complète du signal, les représentations temporelle et fréquentielle sont aussi données.

La figure 4.3 montre la représentation temps-fréquence d'une modulation fréquentielle sinusoidale obtenue par la CBD en utilisant la librairie développée.

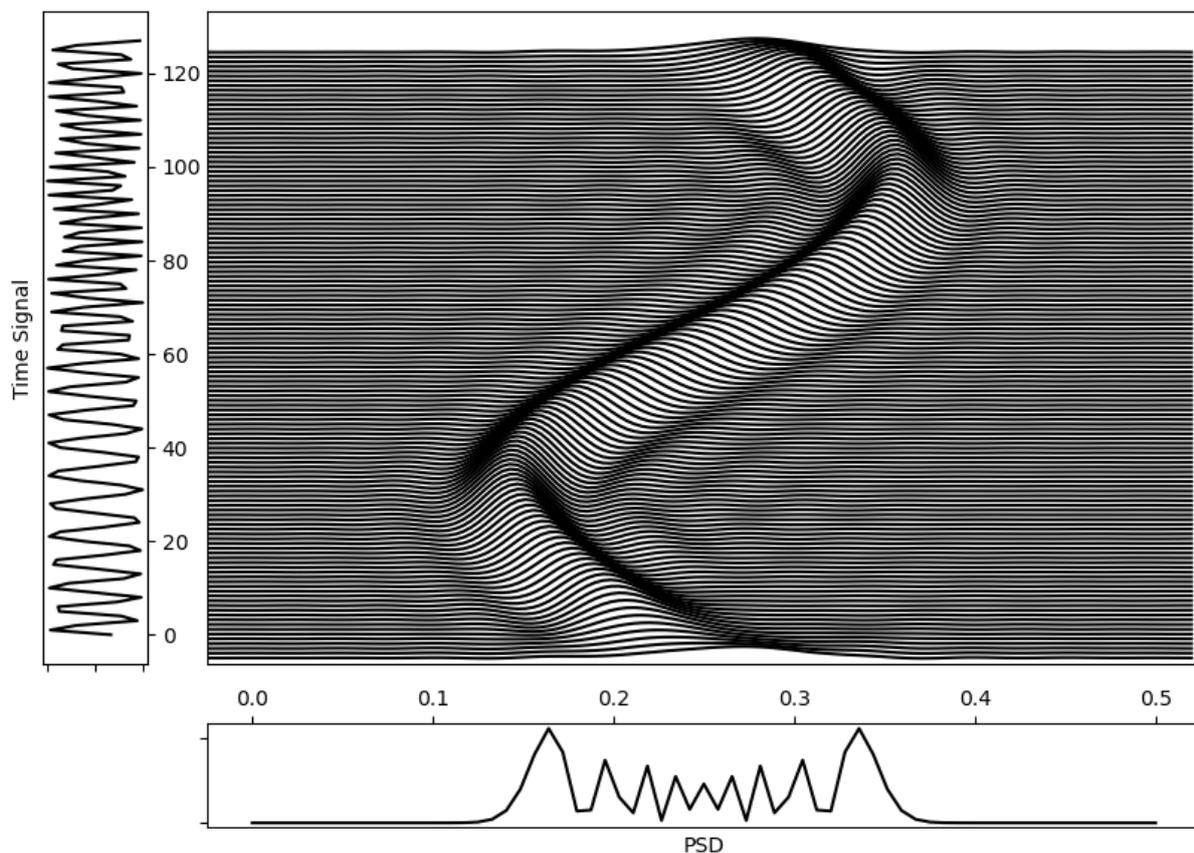


FIGURE 4.3: CBD d'une FM sinusoidale ($C=1.0$, $D=0.04$, $E=0.04$)

4.3 Interfaces de l'application

Durant la conception, quatre cas d'utilisation furent envisagés : "Représentation temporelle du signal", "Prétraitement", "Représentation temps-fréquence" et "Accès à l'atlas EEG". Chaque cas a sa propre page dans l'application. Dans ce qui suit, nous verrons les fonctionnalités de chaque interface ainsi que les outils utilisés pour leur développement.

4.3.1 Représentation temporelle

Au lancement, l'application s'ouvre sur la page "Représentation Temporelle". L'utilisateur y introduit ses fichiers, accède à leurs informations (durée, nombre de canaux et fréquence d'échantillonnage) et peut parcourir le tracé temporel sur l'ensemble de la durée des signaux (figure 4.4).

Pour l'instant, seuls les fichiers EDF¹ sont pris en compte. Ils sont traités par le package MNE-python qui permet d'extraire les données et les informations sur le fichier. Ces derniers sont ensuite sauvegardés dans un dictionnaire comme instance de la classe EEG (figure 3.2) et restent accessibles à l'utilisateur tout au long de l'exécution de l'application. Concernant la représentation temporelle, elle est obtenue en traçant l'ensemble des signaux des canaux sur toute la durée d'enregistrement en utilisant encore une fois la fonction LineCollection de Matplotlib.

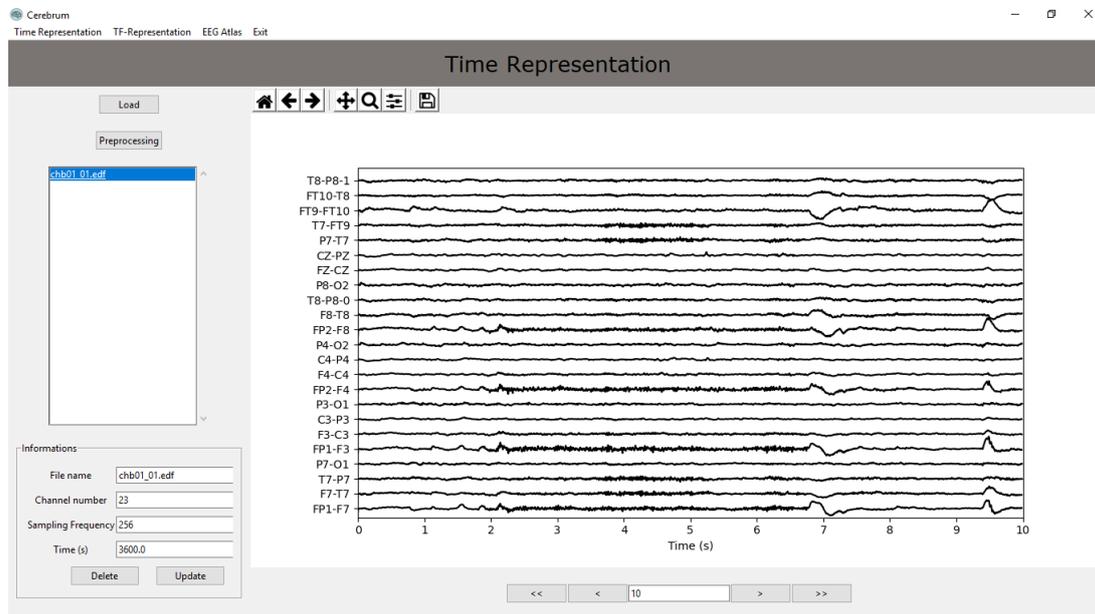


FIGURE 4.4: Interface "Représentation temporelle".

1. European Data Format est un format de fichier informatique destiné au stockage de données médicales ou biologiques organisées en séries temporelles

4.3.2 Prétraitement

Dans la page "Représentation temporelle", l'utilisateur peut, s'il le souhaite, effectuer un prétraitement de ses données en cliquant sur le bouton "Preprocessing". Une fenêtre de dialogue (figure 4.5) s'ouvre alors où il est possible de filtrer les signaux ou de supprimer des canaux dont l'information n'a pas d'intérêt.

Le filtre implémenté est un *filtre à réponse impulsionnelle infinie* de type elliptique. Selon les fréquences données, il peut être passe-bas, passe-bande ou passe-haut.

Les utilisateurs de l'interface n'ayant pas forcément d'expertise en traitement du signal, l'ordre du filtre est calculé de manière automatique selon les fréquences de coupure introduites en faisant appel à la fonction *ellipord* du package Scipy.

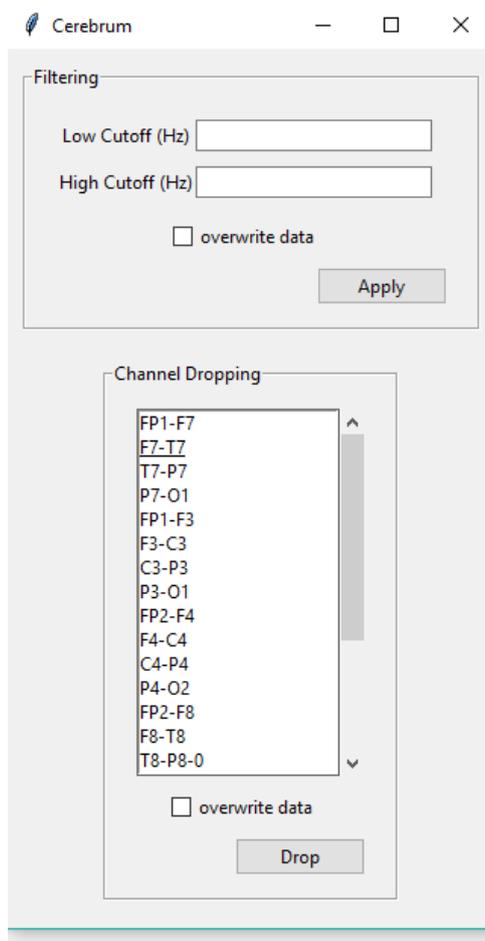


FIGURE 4.5: Interface prétraitement

4.3.3 Représentation temps-fréquence

Dans la page "Représentation temps-fréquence", l'utilisateur peut calculer la DTF d'un des signaux de ses données. Il doit d'abord sélectionner un canal (ou la moyenne de tous les canaux) et choisir une distribution parmi celles proposées. Il doit ensuite introduire les paramètres de la distribution soit en utilisant les sliders ou en les entrant manuellement. Des valeurs initiales, basées sur des tests empiriques menés par Boashash et Al dans [31], sont données à ces paramètres.

Les distributions sont par la suite calculées et visualisées en ayant recours à la librairie temps-fréquence développée durant ce projet (figure 4.6). Il est possible de parcourir ces distributions sur tout le temps d'enregistrement en choisissant la taille de la fenêtre et une résolution temporelle adéquate.

Il est possible de sauvegarder la DTF obtenue, tout en l'annotant, dans une base de données SQLite qui pourrait par la suite être utilisée pour une classification.

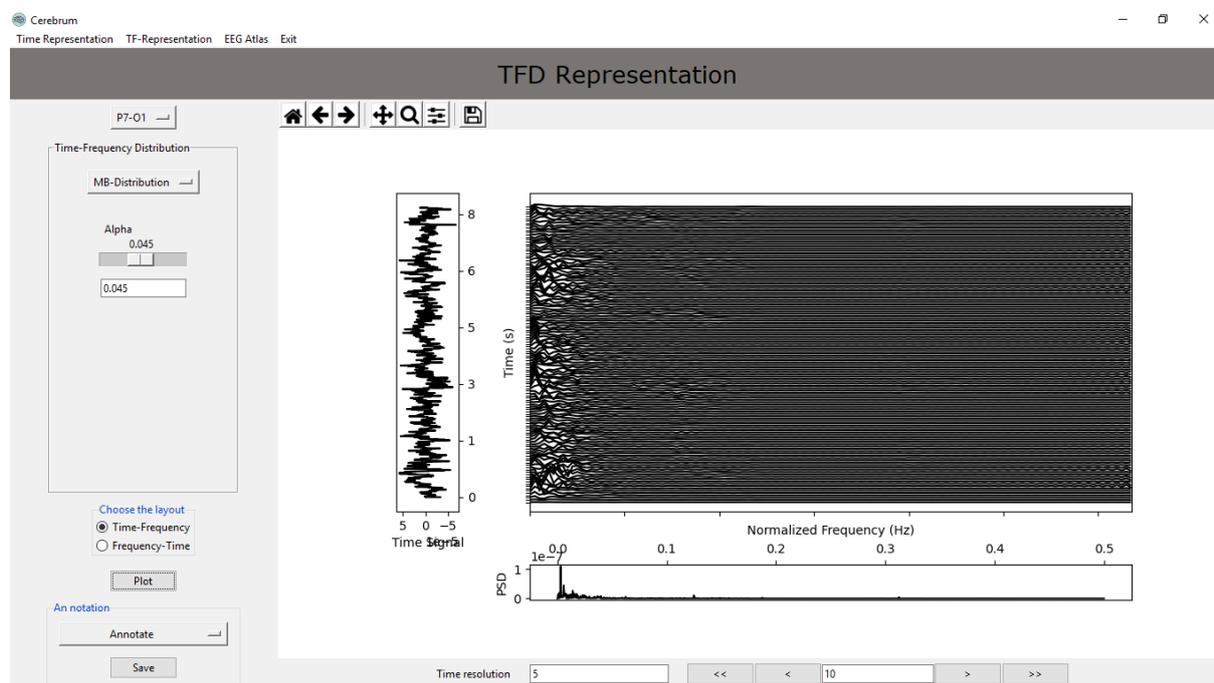


FIGURE 4.6: Interface représentation temps-fréquence

4.3.4 Atlas EEG

Un recueil de signaux EEG représentant divers activités neurologiques est disponible sur la page "EEG Atlas". L'utilisateur sélectionne un de ces signaux et choisit la distribution temps-fréquence voulue (voir figure 4.7). Cette page pourrait servir de référence pour l'annotation des différentes DTF obtenu par l'utilisateur.

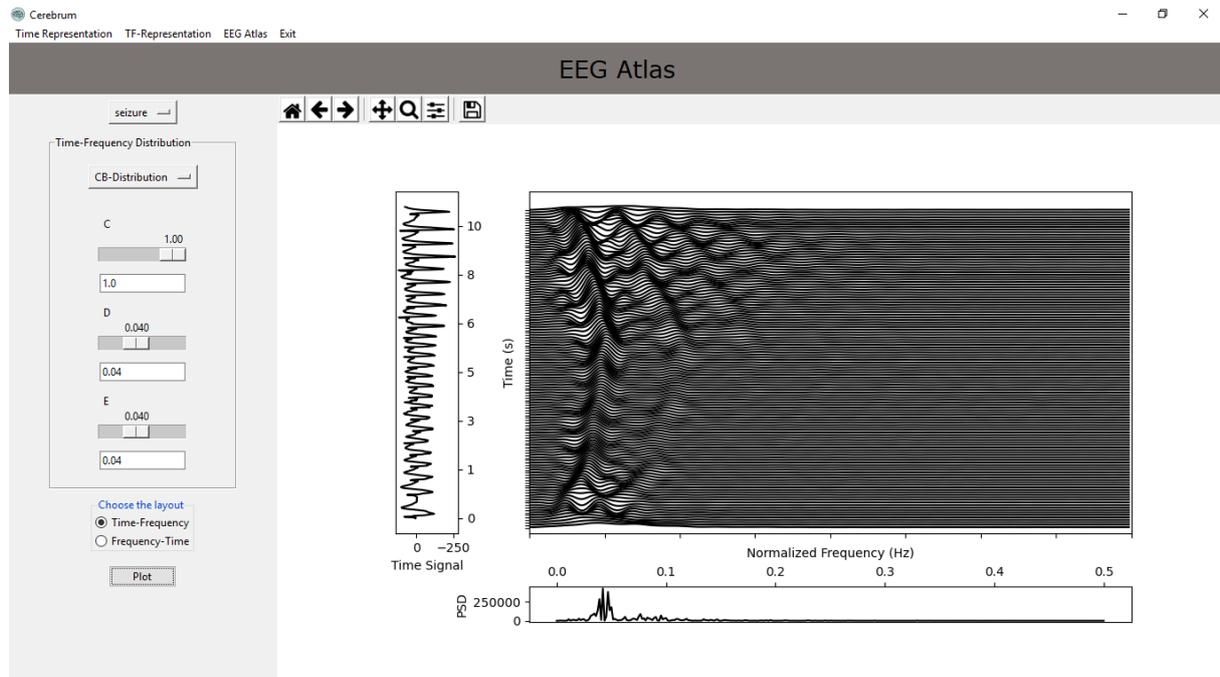


FIGURE 4.7: Interface atlas EEG

4.4 Exemple d'utilisation

Les convulsions néonatales concernent, en moyenne, jusqu'à 1,4 % des nouveau-nés à terme et 20% des prématurés [32]. Elles se présentent sous forme d'une simple révolusion oculaire, d'une fixité insolite du regard ou encore d'une succession de grimaces ou de clignements de paupières [33].

Afin de poser un diagnostic, les médecins ont recours à un examen EEG mais il est souvent difficile de détecter les piques épileptiques sur l'encéphalogramme.

Après chargement des données contenant un enregistrement de 30 min de signaux EEG d'un nouveau-né sur l'application, un filtre passe-bande, de fréquences de coupure de 0.8 et 12 Hz, a été utilisé. La figure 4.8 montre les tracés obtenus avant et après le

filtrage.

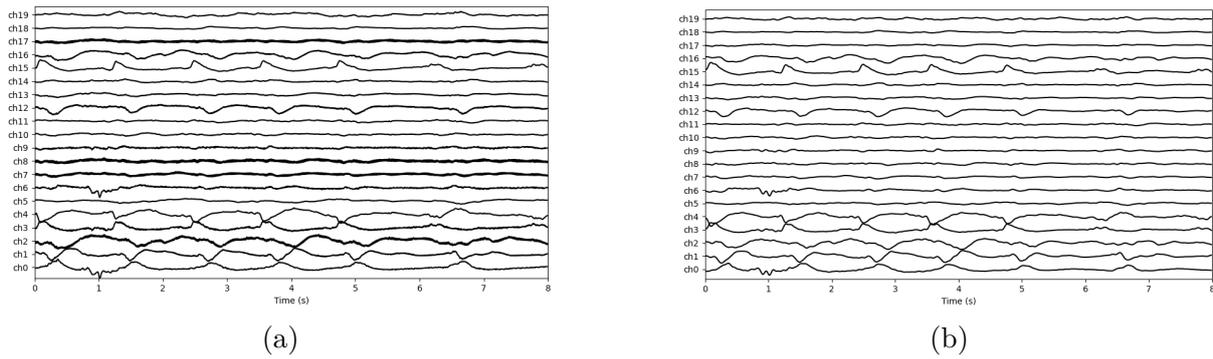


FIGURE 4.8: EEG d'un nouveau-né : (a) avant filtrage et (b) après filtrage.

On peut ensuite visualiser les signaux filtrés sur toute la durée de l'enregistrement. Dans le domaine temporel, il est difficile de détecter les convulsions d'un nouveau-né visuellement. La figure 4.9 montre les représentations temporelles obtenues durant une activité de fond et d'une convulsion néonatale.

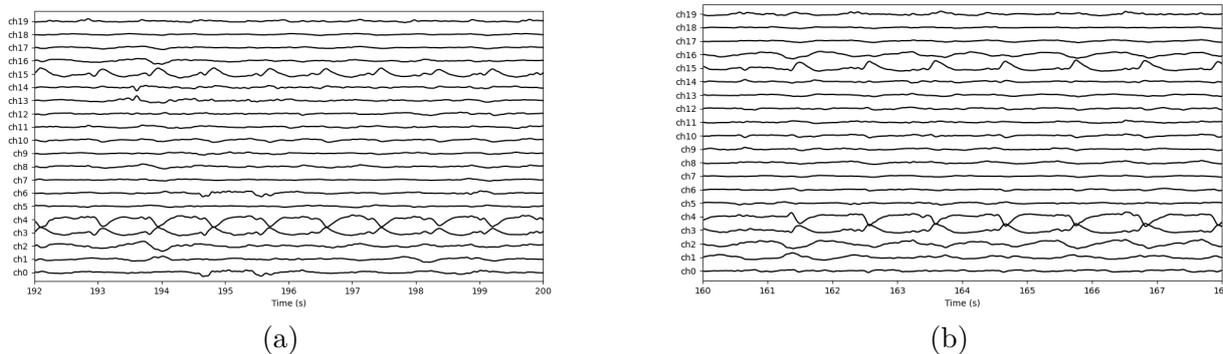
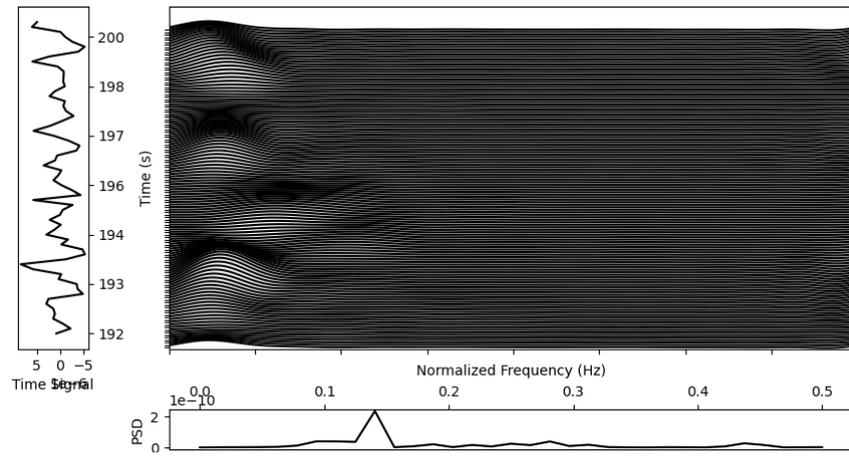
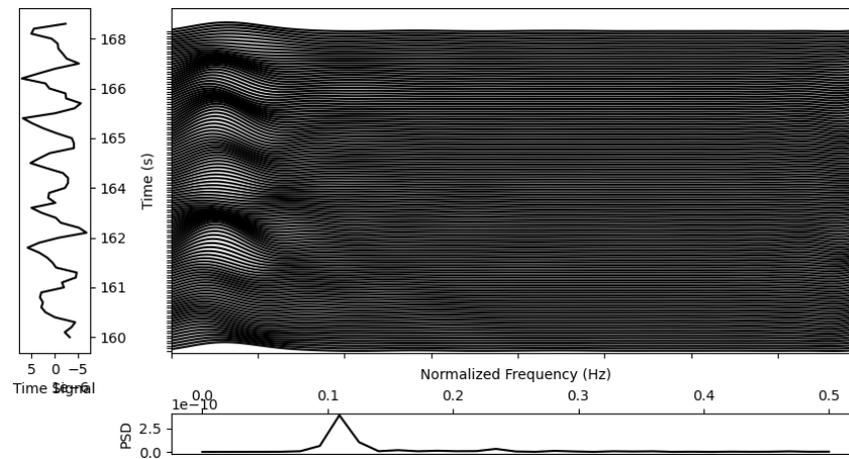


FIGURE 4.9: Représentation temporelle de l'EEG d'un nouveau-né : (a) activité de fond et (b) Convulsion.

En calculant les distributions temps-fréquence, on s'aperçoit qu'il est possible de distinguer visuellement entre l'activité normale et la convulsion. La figure 4.10 montre que les pics de convulsions sont caractérisés par une FM variant lentement tandis que l'activité de fond est représentée par l'apparition de packets d'énergie distincts.



(a)



(b)

FIGURE 4.10: RTF de l'EEG d'un nouveau-né : (a) activité de fond et (b) Convulsion

Chapitre 5

Classification des signaux EEG pour l'aide au diagnostic

Le chapitre précédent a mis en avant l'aptitude de l'application développée à fournir un outil permettant la classification visuelle de différentes activités neurologiques. Dans ce chapitre, une approche automatique de cette classification, basée sur les caractéristiques temps-fréquence des signaux EEG, sera présentée.

5.1 Choix des descripteurs

En utilisant les caractéristiques du signal et les outils temps-fréquence présentés au chapitre 2, il est possible d'en extraire différents descripteurs appropriés à des fins de classification. On distingue trois grands axes : (1) descripteurs statistiques du signal, (2) descripteurs temps-fréquence et (3) descripteurs d'images.

5.1.1 Descripteurs statistiques du signal

L'histogramme des EEG varie de classe en classe. Afin de caractériser leurs différentes fonctions de répartition, divers outils statistiques sont utilisés. Les formules de ces descripteurs pour un signal réel $x[n]$ sont données dans le tableau 5.1 [34].

Descripteur	Expression
Moyenne	$m_{(t)} = \frac{1}{N} \sum_n x[n]$
Variance	$\sigma_{(t)}^2 = \frac{1}{N} \sum_n (x[n] - m_{(t)})^2$
Coefficient d'asymétrie	$\gamma_{(t)} = \frac{1}{N\sigma_{(t)}^3} \sum_n (x[n] - m_{(t)})^3$
Kurtosis	$k_{(t)} = \frac{1}{N\sigma_{(t)}^4} \sum_n (x[n] - m_{(t)})^4$
Coefficient de variation x	$c_{(t)} = \frac{\sigma_{(t)}}{m_{(t)}}$

TABLE 5.1: Descripteurs du domaine temporel

Dans le domaine fréquentiel, il est possible de distinguer des signaux dont le spectre diffère en les caractérisant par des grandeurs spectrales. Nous citerons : le flux spectral, qui mesure le taux de variation du contenu spectral d'un signal dans le temps, l'entropie spectrale, qui évalue le degré d'imprévu de la distribution dans le domaine fréquentiel et l'entropie de Wiener qui permet de mesurer la largeur et l'uniformité du spectre de puissance. Les expressions de ces descripteurs sont données dans le tableau 5.2 où : $Z_x[k]$ est la TF du signal analytique $z[n]$ associé au signal réel $x[n]$.

Descripteur	Expression
Flux spectral	$\mathcal{FL}_{(f)} = \sum_{k=1}^{M/2} Z_r[k] - Z_{r-1}[k] $
Entropie spectrale	$\mathcal{SE}_{(f)} = - \sum_{k=1}^M \mathcal{Z}_x[k] \log_2 \mathcal{Z}_x[k]$
Entropie de Wiener	$\mathcal{SF}_{(f)} = M \frac{(\prod_{k=1}^M Z_x[k])^{M-1}}{\sum_{k=1}^M Z_x[k] }$

TABLE 5.2: Descripteurs du domaine fréquentiel

5.1.2 Descripteurs temps-fréquence

Il est possible d'étendre les descripteurs temporels et fréquentiels, vus précédemment, au domaine conjoint temps-fréquence [35]. Le tableau 5.3 donne les nouvelles expressions de ces descripteurs dans ce domaine où : $\rho_z[n, k]$ est la DTF du signal analytique $z[n]$ associé au signal réel $x[n]$.

Descripteur	Expression
Moyenne	$m_{(t,f)} = \frac{1}{NM} \sum_n \sum_k \rho_z[n, k]$
Variance	$\sigma_{(t,f)}^2 = \frac{1}{NM} \sum_n \sum_k (\rho_z[n, k] - m_{(t,f)})^2$
Coefficient d'asymétrie	$\gamma_{(t,f)} = \frac{1}{NM\sigma_{(t,f)}^3} \sum_n \sum_k (\rho_z[n, k] - m_{(t,f)})^3$
Kurtosis	$k_{(t,f)} = \frac{1}{NM\sigma_{(t,f)}^4} \sum_n \sum_k (\rho_z[n, k] - m_{(t,f)})^4$
Coefficient de variation	$c_{(t,f)} = \frac{\sigma_{(t,f)}}{m_{(t,f)}}$
Flux spectral	$\mathcal{FL}_{(t,f)} = \sum_{n=1}^{N-l} \sum_{k=1}^{M-m} \rho_z[n+l, k+m] - \rho_z[n, k] ^\alpha$
Entropie spectrale	$RE_{(t,f)} = \frac{1}{1-\alpha} \log_2 \sum_{n=1}^N \sum_{k=1}^M \left(\frac{\rho_z[n, k]}{\sum_n \sum_k \rho_z[n, k]} \right)^\alpha$
Entropie de Wiener	$\mathcal{SF}_{(t,f)} = MN \frac{\prod_n \prod_k \rho_z[n, k] ^{NM}}{\sum_n \sum_k \rho_z[n, k]}$

TABLE 5.3: Descripteurs du domaine temps-fréquentiel

5.1.3 Descripteurs d'images

Les DTF sont une représentation de la répartition de l'énergie dans le plan temps-fréquence, résultant en une distribution 2D de l'énergie qui peut être perçue comme une image. En conséquence, des techniques basées sur le traitement d'image peuvent ensuite être utilisées pour localiser et extraire des caractéristiques de ces distributions.

Cette section présente les caractéristiques extraites des images temps-fréquence; elle comprend trois types de descripteurs souvent cités dans la littérature : (1) descripteurs géométriques, (2) descripteurs à modèle binaire local et (3) descripteurs de Harlick.

Descripteurs géométriques

Ces descripteurs permettent d'effectuer une reconnaissance de formes sur l'image temps-fréquence. Les principales étapes de traitement d'image utilisées sont les suivantes [34] :

- **Binarisation de l'image temps-fréquence :**

En utilisant un seuillage T :

$$B[n, k] = \begin{cases} 1 & \text{si } \rho[n, k] > T \\ 0 & \text{autrement} \end{cases} \quad (5.1)$$

L'image binaire est composée donc de deux parties : (i) l'arrière plan de l'image $B_0[n, k]$ où le signal n'a pas d'énergie ($B[n, k] = 0$) et (ii) l'avant plan de l'image où il y a manifestation de l'énergie ($B[n, k] = 1$).

Il est d'autant plus intéressant de choisir un seuil adaptatif. Une manière de le faire est d'initier le seuil T à la moyenne de l'image $\rho[n, k]$. A partir de cette image, deux matrices sont générées K et L .

K , de moyenne m_1 , ne contient que les valeurs de $\rho[n, k]$ supérieures à T . Les autres éléments sont mis à 0. De même, L , de moyenne m_2 , ne contient que les éléments de $\rho[n, k]$ inférieurs à T , le reste de la matrice étant également mis à 0.

Le seuil adaptatif de l'image $\rho[n, k]$ est la moyenne de m_1 et m_2 .

- **Segmentation de l'image binarisée :**

En utilisant le critère de connectivité (voir figure 5.1), l'avant plan de l'image est divisé en

l segments non-coïncidables constituant les l objets de cet avant plan. L'image binarisée peut être alors décrite comme union de l'arrière plan avec ces l segments :

$$B[n, k] = B_0[n, k] \cup s_1[n, k] \cup s_2[n, k] \cup \dots \cup s_l[n, k] \quad (5.2)$$

où : $B_0[n, k]$ est l'arrière plan de l'image et s_1, s_2, \dots, s_l sont les segments de l'image binarisée.

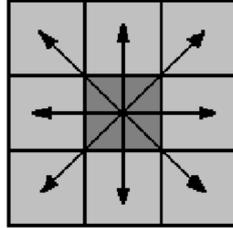


FIGURE 5.1: Principe de la 8-connectivité : Les pixels sont connectés si leurs bords ou coins se touchent. Deux pixels adjacents font partie du même objet s'ils sont tous les deux activés et connectés le long de la direction horizontale, verticale ou diagonale.

- **Extraction des moments :**

Cela se fait à partir du plus grand segment de l'image $s_L[n, k]$ (correspondant au plus grand objet de l'image). Le moment d'ordre (n, k) est calculé en utilisant l'expression suivante [36] :

$$m_{pq} = \sum_n \sum_k n^p k^q s_L[n, k] \quad (5.3)$$

où : $s_L[n, k]$ est le plus grand segment de l'image.

Un sous-ensemble de ces moments, invariants aux transformations de l'image, est utilisé pour la classification pour gagner en robustesse et en performance ; il s'agit des **moments de Hu**. Leurs expressions sont données en annexe (A).

Modèle binaire local

De l'anglais, Local Binary Pattern (LBP), ce descripteur permet de caractériser les textures locales de l'image temps-fréquence. Il consiste à considérer un voisinage 3x3 pour chaque pixel et d'y effectuer un seuillage par rapport au pixel central. Chacun des 8 pixels voisins est mis à 0, si son intensité est inférieure à celle du pixel central, ou à 1 autrement. Les valeurs du voisinage, parcourues dans un sens prédéfini, forment un nombre binaire

qui est converti en valeur décimale pour obtenir la nouvelle valeur du pixel central (voir figure 5.2).

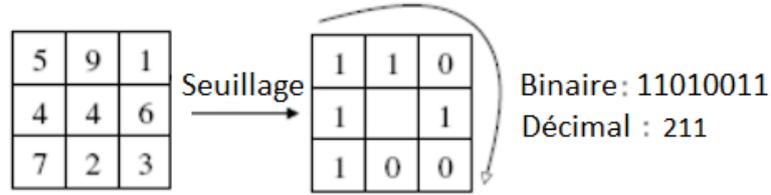


FIGURE 5.2: Principe du LBP

Pour une définition plus mathématique :

$$LBP(p_c) = \sum_{i=0}^7 t \times 2^i \quad (5.4)$$

où : $t = 1$ si $\rho_z[p_i] \geq \rho_z[p_c]$ et 0 autrement.

En répétant cette opération sur l'ensemble des pixels de la distribution, une nouvelle matrice est obtenue . A partir de cette dernière, l'histogramme sur 256 niveaux de gris est utilisé comme paramètre de caractérisation.

Descripteurs de Harlick

Des descripteurs de texture peuvent aussi être extraits à partir de la matrice de co-occurrence de l'image. Cette dernière consiste à quantifier la texture d'une image comme distribution de paires de pixels co-occurentes à une distance et un angle donnés.

Pour une DTF discrète $\rho_z[n, k]$ et pour un décalage (Δ_n, Δ_k) dépendant à la fois de la distance D et l'angle θ entre les pairs de pixels voisins, la matrice de co-occurrence est définie comme suit [31] :

$$C_{\rho_z, (\Delta_n, \Delta_k)}[i, j] = \sum_{n=1}^N \sum_{k=1}^M \begin{cases} 1 & \text{si } \rho_z[n, k] = i \text{ et } \rho_z[n + \Delta_n, k + \Delta_k] = j \\ 0 & \text{ailleurs} \end{cases} \quad (5.5)$$

Dans ce travail, le paramètre de distance D est mis à 8 tandis que l'angle θ varie de 0 à 135 degrés d'un pas de 45 degrés avec une quantification de 256 niveaux de gris.

Il en résultera donc quatre matrices de co-occurrences. A partir de chaque matrice, 14 descripteurs de Harlick H_i , caractérisant la texture de l'image, sont calculés. Leurs expressions sont données en annexe.

Afin de réduire la dimension de ces descripteurs (56 à présent), chaque ensemble de quatre paramètres H_i est remplacé par sa moyenne et son étendu résultant donc à 28 descripteurs qui seront par la suite utilisés.

5.2 Choix du classifieur

La classification permet d'associer à un ensemble de données non-étiquetées une classe bien définie en se basant sur les descripteurs fournis. Afin de classer les signaux EEG, plusieurs classifieurs sont utilisés dans la littérature comme l'arbre de décision ou encore les réseaux de neurones [34].

Dans ce travail, il a été jugé plus opportun d'utiliser les **machines à vecteurs de support** (en anglais support vector machine SVM) pour les raisons suivantes :

- Leur grande précision de prédiction avec de petite base de données.
- Leur efficience avec des données aussi bien linéaires que non-linéaires.
- Leur faible consommation de mémoire car seul un sous-ensemble de points (appelé vecteurs de support) est utilisé pour la prise de décision.

D'un point de vue théorique, les SVM sont des algorithmes d'apprentissage automatique supervisé qui séparent les observations en deux classes. Cela est fait en construisant, dans un espace de haute dimension, un hyperplan permettant de séparer les données et de maximiser la distance, appelée *marge*, entre ces classes. Seuls les points se trouvant à la frontières des classes sont utilisés, ce sont les *vecteurs de support*. La figure 5.3 illustre cette technique, H étant l'hyperplan séparateur.

Pour une séparation linéaire, les données de chaque classe doivent se trouver d'un seul coté de l'hyperplan dont l'équation est :

$$\vec{\omega} \cdot \vec{X} + b = 0 \tag{5.6}$$

où : $\vec{\omega}$ est la normale de l'hyperplan, b est une constante et \vec{X} définit les points ap-

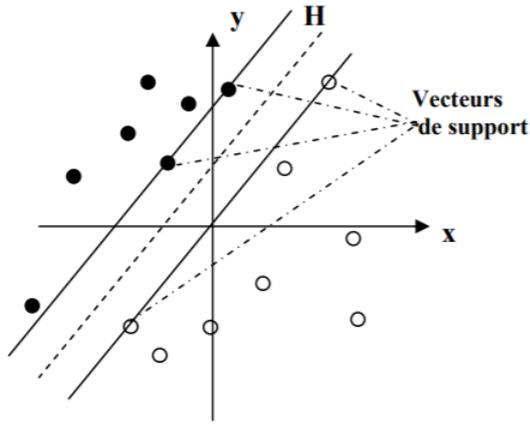


FIGURE 5.3: Principe du SVM [37].

partenant à l'hyperplan.

Pour une donnée d'entraînement X_i de classe y_i , une des deux inégalités doit être satisfaite :

$$\vec{\omega} \cdot \vec{X}_i + b \geq +1, y_i = +1 \quad (5.7)$$

$$\vec{\omega} \cdot \vec{X}_i + b \leq -1, y_i = -1 \quad (5.8)$$

La fonction de décision permettant de classifier une donnée X est :

$$f(X) = \text{sign} \left(\sum_{X_i \in SV} \alpha_i y_i \vec{X}_i \cdot \vec{X} + b \right) \quad (5.9)$$

où : α_i est un multiplicateur de Lagrange.

Les données réelles n'étant pas toujours linéaires, il est parfois impossible de trouver un hyperplan linéaire permettant la séparation des classes. Une solution à cela est de reconsidérer le problème dans un espace de dimension supérieure voire infinie, il s'agit de l'astuce du noyau (voir figure 5.4) . La fonction de décision devient donc :

$$f(X) = \text{sign} \left(\sum_{X_i \in SV} \alpha_i y_i K(\vec{X}_i \cdot \vec{X}) + b \right) \quad (5.10)$$

où : $K(\vec{X}_i \cdot \vec{X})$ est une fonction noyau.

Plusieurs types de noyaux existent. Le plus populaire, et celui utilisé dans ce travail, est la fonction de base radiale (radial base function en anglais (RBF)). Etant flexible, il permet de modéliser des fonctions complexes donnant donc de bons résultats pour la

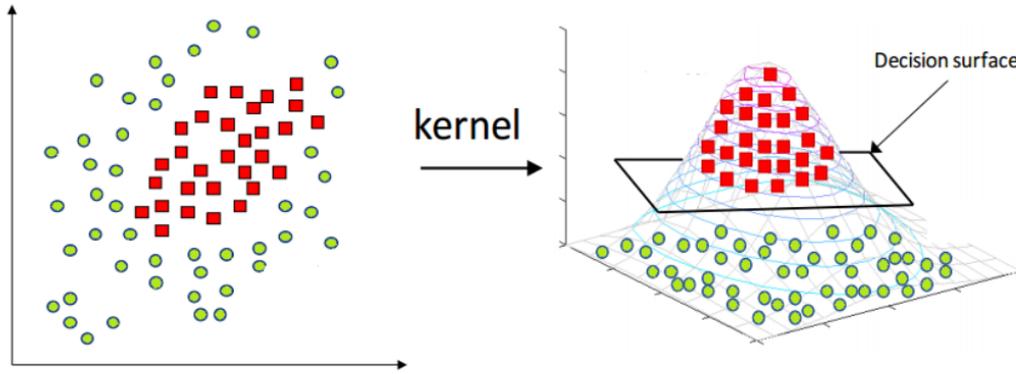


FIGURE 5.4: Astuce du noyau [38].

majorité des applications. L'expression de ce noyau est défini comme suit :

$$K(\vec{X}_i \cdot \vec{X}) = \exp\left(-\frac{\|\vec{X} - \vec{X}_i\|^2}{2\sigma^2}\right) \quad (5.11)$$

5.3 Résultats, comparaison et discussion

Pour reprendre l'exemple du chapitre 4, les descripteurs précédemment cités sont utilisés pour la détection des convulsions néonatales en classifiant le signal en deux classes : (i) activité de fond et (ii) convulsion. Le modèle de classification est schématisé dans la figure 5.5.

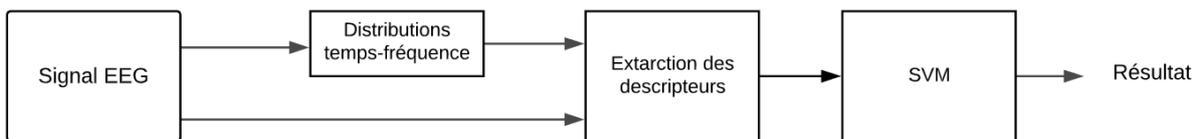


FIGURE 5.5: Schéma de la classification

5.3.1 Base de données

La base de données utilisée contient des données EEG de 36 nouveau-nés malades du Royal Women's Hospital de Brisbane, Australie. Les EEG sont constitués de signaux continus à 20 canaux qui ont été collectés selon le système international de placement d'électrodes 10-20 et en utilisant un montage bipolaire. L'équipement d'enregistrement est un système Medelec Profile (obtenu auprès de Med-elec, Oxford Instruments, Old Woking, Royaume-Uni) fonctionnant à une fréquence d'échantillonnage $f_s = 256$ Hz. Les

signaux possèdent deux annotations : activité de fond et convulsion. Ils ont été étiquetés par un neurologue spécialisé en pédiatrie du Royal Children's Hospital, Brisbane, Australie.

Ces signaux sont filtrés en utilisant un filtre passe-bande de fréquences de coupures de 0.5 et 12 Hz. Les signaux obtenus sont ensuite sous-échantillonnés à 32 Hz. Les canaux de chaque patient sont ensuite moyennés en un seul signal. A partir de ces signaux, 400 échantillons de 8 s sont extraits de manière aléatoire (200 de classe "activité de fond" et 200 de classe "convulsion").

Cette base de données fut ensuite divisée en deux parties de manière aléatoire mais uniforme : la partie apprentissage (70%) et la partie test (30%).

Les DTFQ calculées à partir des signaux de la base de données sont les suivantes : DWV, EMBD ($\alpha = 0.045, \beta = 0.045$) et CBD ($c = 1, D = 0.04, E = 0.04$) constituant la base de données finale.

5.3.2 Métriques d'évaluation de la classification

Avant de discuter des résultats obtenus, il est essentiel de définir des outils permettant l'évaluation du modèle de classification.

La matrice de confusion est une matrice qui permet d'évaluer la qualité de classification d'un système. Les colonnes correspondent aux classes réelles tandis que les lignes correspondent aux classes estimées (voir tableau 5.4).

	Convulsion	Activité de fond
Convulsion estimée	Vrai Positif (VP)	Faux Positif (FP)
Activité de fond estimée	Faux Négatif (FN)	Vrai Négatif (VN)

TABLE 5.4: Matrice de confusion.

A partir de cette matrice, il est possible de définir d'autres outils pour évaluer la classification :

- Sensibilité : elle représente le nombre de convulsions détectées sur l'ensemble des convulsions de la base de données.

$$sen = \frac{VP}{VP+FN}$$

- Précision : elle représente le nombre de convulsions correctement détectées sur l'ensemble des convulsions prédites.

$$pres = \frac{VP}{VP+FP}$$

- F1-score : c'est la moyenne harmonique de la sensibilité et la précision.

$$f1 = 2 \frac{1}{\frac{1}{\text{précision}} + \frac{1}{\text{sensitivité}}}$$

5.3.3 Comparaison de la classification à l'aide des descripteurs statistiques

Dans un premier temps, la classification a été effectuée en utilisant les outils statistiques sur le signal (descripteurs temporels et fréquentiels) et sur les DTFQ (descripteurs temps-fréquence).

Le tableau 5.5 résume les différents résultats obtenus. Il est clair que la classification dans le domaine conjoint temps-fréquence donne une meilleure performance que la classification dans les domaines temporel et fréquentiel. Les descripteurs temporels et fréquentiels ne permettent pas une bonne caractérisation du signal à cause de la non-stationnarité de ce dernier. L'utilisation des descripteurs temps-fréquence a permis d'améliorer la précision de la classification jusqu'à 44%.

	Descripteurs statistiques		
	sen (%)	pres (%)	f1-score (%)
signal	47.00	47.00	47.00
DWV	76.00	77.00	75.00
EMBD	91.00	91.00	91.00
CBD	86.00	86.00	86.00

TABLE 5.5: Résultat de la détection des convulsion par descripteurs statistiques.

5.3.4 Comparaison de la classification à l'aide des descripteurs d'image

Dans un second temps, la classification s'est faite en utilisant les descripteurs d'images sur les distributions temps-fréquence. Le tableau 5.6 montre les résultats obtenus. A première vue, il est évident que le descripteur LBP donne de meilleures performances pour l'ensemble des distributions. Il est suivi de près par les descripteurs de Harlick. Tout deux sont utilisés pour la caractérisation de texture, l'information spatiale caractérise donc bien les distributions temps-fréquences.

TFD	Descripteurs d'images								
	Harlick			Hu			LBP		
	sen(%)	pres(%)	f1-s (%)	sen (%)	pres (%)	f1-s (%)	sen (%)	pres (%)	f1-s (%)
DWV	79.00	79.00	79.00	60.00	61.00	60.00	99.00	99.00	99.00
EMBD	71.00	71.00	71.00	78.00	78.00	78.00	99.00	99.00	99.00
CBD	74.00	76.00	74.00	62.00	62.00	62.00	96.00	96.00	96.00

TABLE 5.6: Résultat de la détection des convulsion par descripteurs d'images

5.4 Implémentation de la classification

L'utilisation de l'apprentissage automatique donnant de bons résultats pour la détection des activités neurologiques (les convulsions, dans notre exemple), il serait intéressant d'ajouter à l'application précédemment développée un outil d'aide au diagnostic qui, pour chaque fenêtre de distribution, prédirait le type d'activité présente.

Les résultats de la section précédente ont montré que le descripteur LBP donne une très bonne performance sur l'ensemble des distributions, le même modèle sera donc utilisé pour la classification des distributions de l'interface.

Pour cela, une autre version de l'application, permettant de classifier les distributions, a été développée. Dans cette version, le descripteur LBP est extrait après calcul de la distribution. Le modèle de classification est ensuite utilisé pour prédire la classe du signal. Ainsi, en visualisant la RTF obtenu, l'utilisateur pourra aussi avoir accès au résultat de la prédiction (figure 5.6), ce qui pourrait l'aider pour établir le diagnostic.

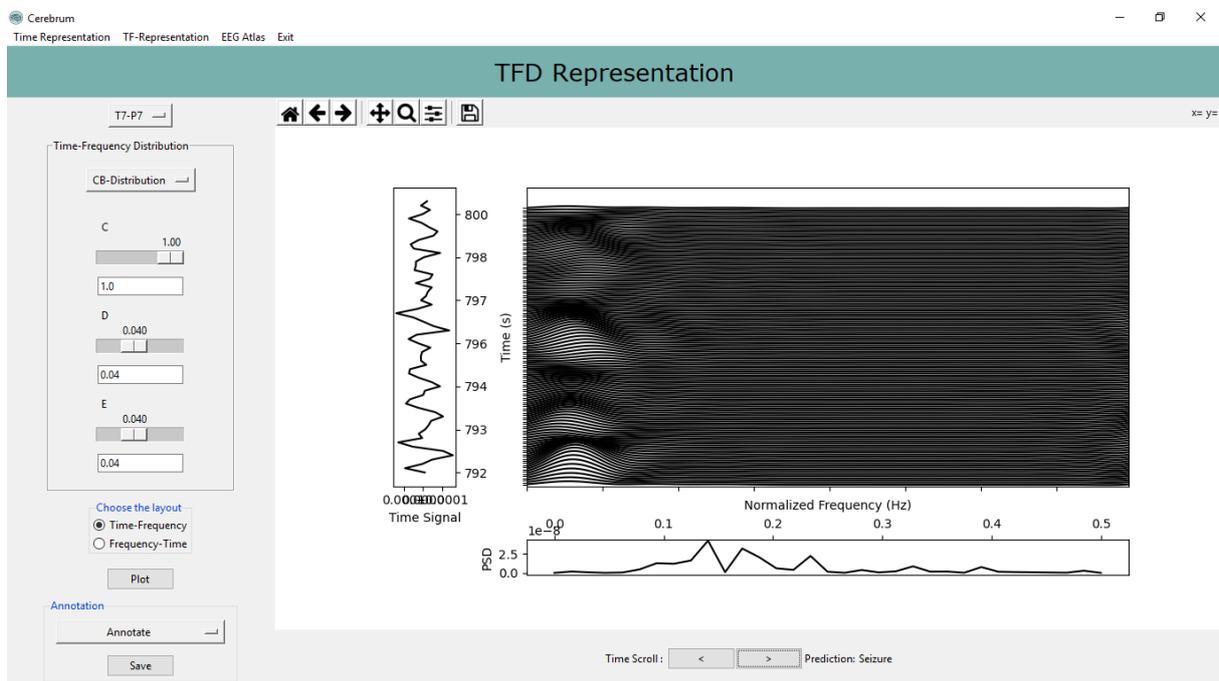


FIGURE 5.6: Prédiction des convulsions.

Conclusion générale

Plusieurs sujets furent abordés dans ce projet de fin d'études.

Le chapitre 1 a permis de connaître les généralités sur l'électroencéphalographie, l'instrumentation derrière cela et les caractéristiques des signaux EEG. Il a aussi mis en avant l'intérêt de l'utilisation des outils temps-fréquence pour l'analyse de ces signaux.

Dans le chapitre 2, la définition mathématique de l'analyse temps-fréquence est discutée, en accordant une attention particulière aux distributions temps-fréquence quadratiques. Des exemples d'applications en neurosciences illustrent ensuite les avantages de l'analyse temps-fréquence dans ce domaine.

Les chapitres 3 et 4 sont dédiés à la conception et à la réalisation de l'application. Le choix de l'architecte et du langage de programmation y sont discutés. Il est aussi question du développement d'une librairie temps-fréquence, étape capitale du projet, qui permet de calculer et visualiser les distributions temps-fréquence en un temps d'exécution s'approchant du temps réel. Les différentes interfaces de l'application sont ensuite exposées ainsi qu'un exemple d'utilisation de cette dernière.

Enfin, une méthodologie de classification des signaux EEG est décrite en utilisant la méthode SVM et des descripteurs statistiques et ceux issus du traitement d'image. Cette classification est par la suite ajoutée à l'interface pour l'aide au diagnostic des convulsions néonatales.

Plusieurs améliorations pourront être mise en place dans les prochaines recherches pour améliorer la performance de l'application. L'objectif principal est d'enrichir l'Atlas EEG avec tout type d'activités cérébrales. Il sera aussi important d'acquérir plus de signaux

pour ainsi avoir une plus grande base de données d'entraînement et pouvoir étendre la classification à diverses classes.

Annexe A

Expressions des descripteurs

A.1 Moments de Hu

Les moments d'une image temps-fréquence dépendent à la fois de l'intensité de $s_L[n, k]$ mais aussi des positions n et k des pixels. Pour les rendre indépendant de la position, les *moments centrés*, invariants en translation, sont introduits [36] :

$$\mu_{pq} = \sum_n \sum_k (n - \bar{n})^p (k - \bar{k})^q s_L[n, k] \quad (\text{A.1})$$

où : $\bar{n} = \frac{m_{10}}{m_{00}}$ et $\bar{k} = \frac{m_{01}}{m_{00}}$ sont les coordonnées du barycentre de l'image.

En normalisant l'Eq.(A.1), les moments deviennent invariants à l'échelle il s'agit des *moments centrés normalisés* [36] :

$$\eta_{pq} = \frac{\mu_{pq}}{\mu_{00}^\gamma} \quad (\text{A.2})$$

où : $\gamma = \frac{p+q}{2} + 1$ et $p, q = 2, 3, \dots$

Depuis l'Eq.(A.2), sept moments invariants à la rotation peuvent être tirés, c'est les *moments de Hu* [36] :

$$\phi_1 = \eta_{20} + \eta_{02} \quad (\text{A.3})$$

$$\phi_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2 \quad (\text{A.4})$$

$$\phi_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \quad (\text{A.5})$$

$$\phi_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2 \quad (\text{A.6})$$

$$\phi_5 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12}) \left[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2 \right] \quad (\text{A.7})$$

$$+ (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03}) \left[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2 \right] \quad (\text{A.8})$$

$$\phi_6 = (\eta_{20} - \eta_{02}) \left[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2 \right] + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \quad (\text{A.9})$$

$$\phi_7 = 3(\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12}) \left[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2 \right] \quad (\text{A.10})$$

$$+ (3\eta_{12} - \eta_{30})(\eta_{21} + \eta_{03}) \left[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2 \right] \quad (\text{A.11})$$

Les six premiers moments sont invariants à toute transformations d'images quant au septième, il change de signe pour une réflexion de l'image.

A.2 Descripteurs de Harlick

Pour une matrice de co-occurrence $C[i, j]$, 14 descripteurs de Harlick sont extraits.

1. Deuxième moment angulaire :

$$H_1 = \sum_{i=1}^L \sum_{j=1}^L \{c_{ij}^2\} \quad (\text{A.12})$$

2. Contrast :

$$H_2 = \sum_{l=0}^{L-1} l^2 \left\{ \sum_{i=1}^L \sum_{j=1, |i-j|=l}^L c_{ij} \right\} \quad (\text{A.13})$$

3. Corrélation :

$$H_3 = \frac{\sum_{i=1}^L \sum_{j=1}^L (ij)c_{ij} - \mu_n \mu_k}{\sigma_n \sigma_k} \quad (\text{A.14})$$

où : μ_n, μ_k, σ_n , et σ_k représentent les moyennes et les écart-types le long des axes temporel et fréquentiel.

4. Somme des variances :

$$H_4 = \sum_{i=1}^L \sum_{j=1}^L (i - \mu)^2 c_{ij} \quad (\text{A.15})$$

5. Moment de différence inverse :

$$H_5 = \sum_{i=1}^L \sum_{j=1}^L \frac{1}{1 + (i - j)^2} c_{ij} \quad (\text{A.16})$$

6. Somme des moyennes :

$$H_6 = \sum_{i=2}^{2L} i c_{x+y,i} \quad (\text{A.17})$$

7. Somme des entropies :

$$H_7 = - \sum_{i=2}^{2L} c_{x+y,i} \log c_{x+y,i} \quad (\text{A.18})$$

8. Somme des variances :

$$H_8 = \sum_{i=2}^{2L} (i - H_7)^2 c_{x+y,i} \quad (\text{A.19})$$

9. Entropie :

$$H_9 = - \sum_{i=1}^L \sum_{j=1}^L c_{ij} \log c_{ij} \quad (\text{A.20})$$

10. Différence de variance :

$$H_{10} = \text{variance de } c_{x-y} = \sum_{l=0}^{L-1} l^2 C_{\chi-y,i} \quad (\text{A.21})$$

11. Différence d'entropie :

$$H_{11} = - \sum_{l=0}^{L-1} c_{x-y,l} \log c_{x-y,l} \quad (\text{A.22})$$

12. Mesure d'information de la corrélation 1 :

$$H_{12} = \frac{HXY - HXY1}{\max\{HX, HY\}} \quad (\text{A.23})$$

13. Mesure d'information de la corrélation 2 :

$$H_{13} = (1 - \exp[-2.0(HXY2 - HXY)])^{1/2})^2 \quad (\text{A.24})$$

où : HX et HY sont les entropies de p_x et p_y

$$HXY = H_9, \quad HXY1 = - \sum_{i=1}^L \sum_{j=1}^L c_{ij} \log c_{x,i} c_{y,i} \text{ et}$$

$$HXY2 = - \sum_{i=1}^L \sum_{j=1}^L c_{x,i} c_{y,j} \log \{c_{x,i} c_{y,i}\} .$$

14. Coefficient de corrélation maximale :

$$H_{14} = \text{Square root of the second eigenvalue of } Q \quad (\text{A.25})$$

$$\text{où : } Q(i, j) = \sum_{k=1}^L \frac{c_{ik} c_{jk}}{c_{x,i} c_{y,k}}$$

Annexe B

Guide d'utilisation

Au lancement, l'application s'ouvre sur l'interface "Représentation temporelle"(figure B.1).

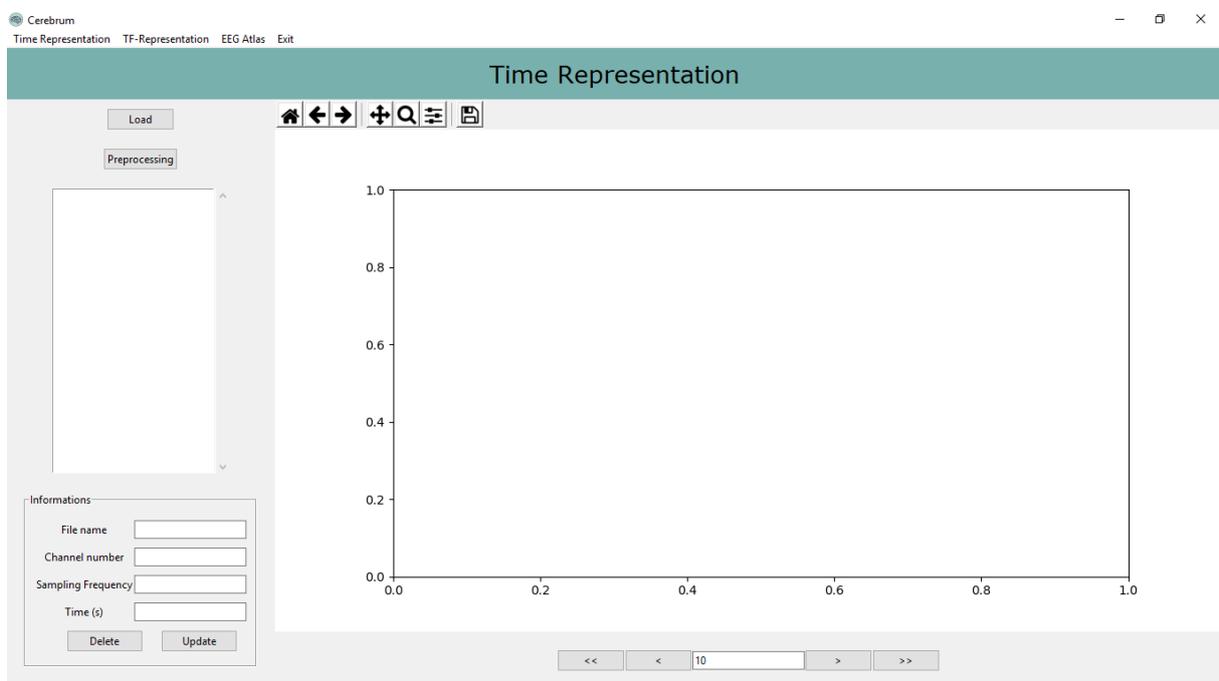


FIGURE B.1: Interface d'accueil

Il est possible de naviguer sur les pages de l'application en cliquant sur le nom de la page voulue depuis le barre de menu. Il est aussi possible de quitter l'application en cliquant sur "Exit" (figure B.2).

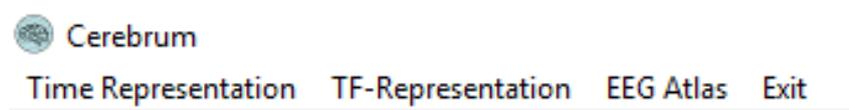


FIGURE B.2: Barre de menu de l'applicaton

Dans ce qui suit, l'utilisation de chaque interface de l'application est expliquée :

B.1 Interface d'accueil

- **Chargement des fichiers :**

Pour charger un fichier, il suffit de cliquer sur "Load". Une fenêtre de dialogue s'ouvre alors permettant de parcourir les fichiers de l'ordinateur pour choisir un fichier EDF. Les noms des fichiers choisis apparaissent alors dans la liste se trouvant à gauche de l'interface.

- **Sélection d'un fichier :**

Pour sélectionner un fichier, il suffit de double-cliquer sur son nom depuis la liste des fichiers se trouvant sur la gauche de l'interface. En faisant cela, les informations du fichier ainsi que le tracé temporel des données s'affichent (figure B.3).

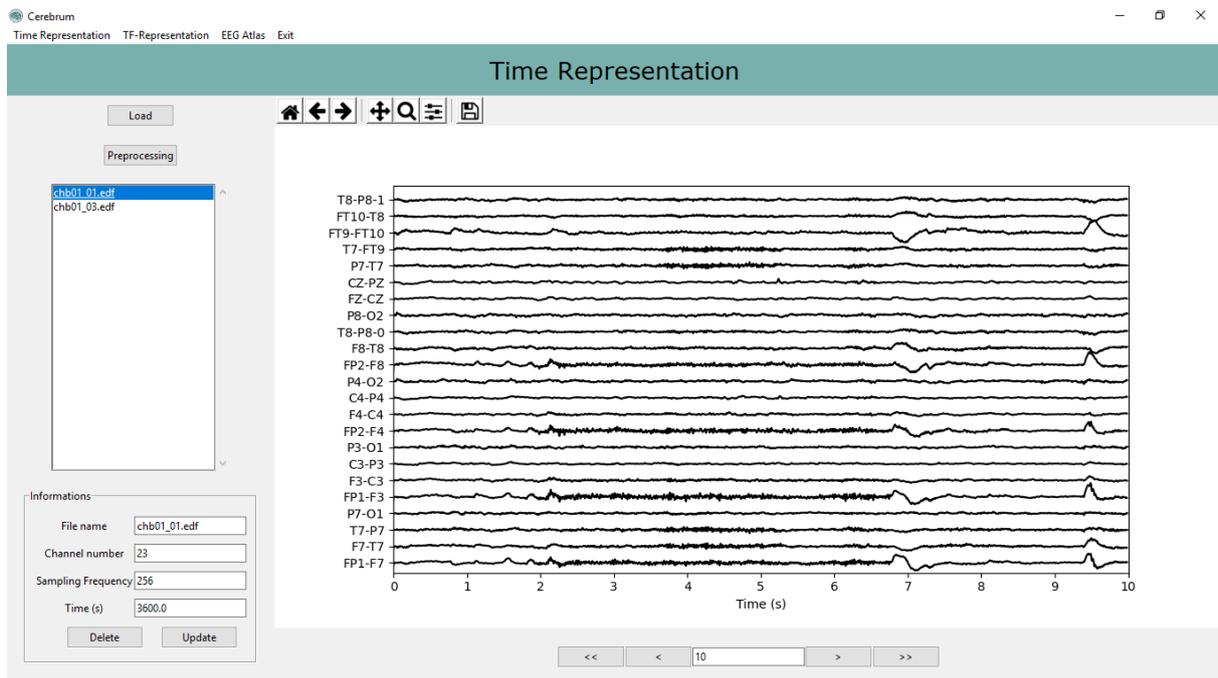


FIGURE B.3: Représentation temporelle des données chargées.

- **Manipulation du tracé :**

Il est possible de changer la taille de la fenêtre et de parcourir le tracé sur toute la durée de l'enregistrement en utilisant le panneau de la figure B.4. L'utilisateur introduit

la taille de la fenêtre en seconde dans la case du milieu puis utilise les flèches :

- ">" : avancer dans le temps.
- "<" : reculer dans le temps.
- "«" : aller au début de l'enregistrement.
- "»" : aller à la fin de l'enregistrement.



FIGURE B.4: Panneau du parcours temporel.

Il est aussi possible de zoomer et sauvegarder le tracé d'une fenêtre en utilisant les outils de la figure B.5.

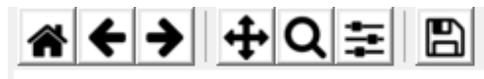


FIGURE B.5: Outils de visualisation.

B.2 Prétraitement

Dans la page "Représentation temporelle", il est possible de cliquer sur le bouton "Pre-processing" pour prétraiter les signaux du fichier sélectionné. Cela fait, une fenêtre de dialogue s'ouvre comme le montre la figure B.6.

• Filtrage des signaux :

Les fréquences de coupures doivent être introduites en Hz. Trois types de filtre peuvent être créés, selon les fréquences données :

- Filtre passe-bas : en mettant Lowcut à 0.
- Filtre passe-haut : en mettant Highcut à 0.
- Filtre passe-bande : en donnant deux valeurs non-nulles à Lowcut et Highcut.

• Suppression des canaux :

La liste des canaux du fichier sélectionné s'affiche dans la fenêtre. Il est possible d'en supprimer quelques-uns en les sélectionnant et en cliquant sur "Drop".

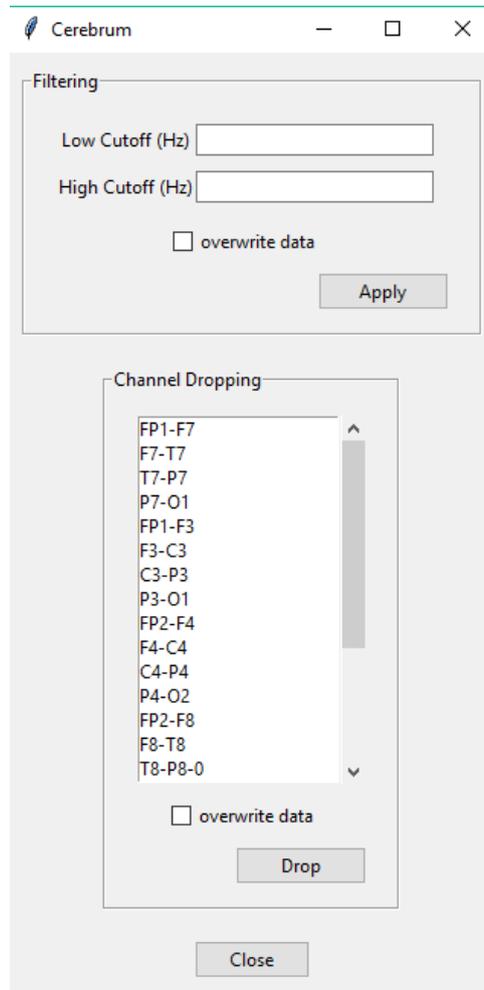


FIGURE B.6: Interface de prétraitement.

Pour sauvegarder le fichier pré-traité, il est possible d'écraser l'ancien fichier ou d'en créer un autre, cela se fait en cochant la case "Overwrite file". Dans le cas où l'utilisateur ne coche pas la case, un nouveau fichier apparaît dans liste.

B.3 Représentation temps-fréquence

La figure B.7 montre l'interface de la représentation temps-fréquence .

- **Sélection du signal :**

En cliquant sur "Select signal" à la gauche de l'interface, une liste déroulante s'ouvre contenant les noms des canaux du fichier précédemment sélectionné. L'utilisateur doit choisir un canal (ou la moyenne de tous les canaux) dont il veut calculer la distribution.

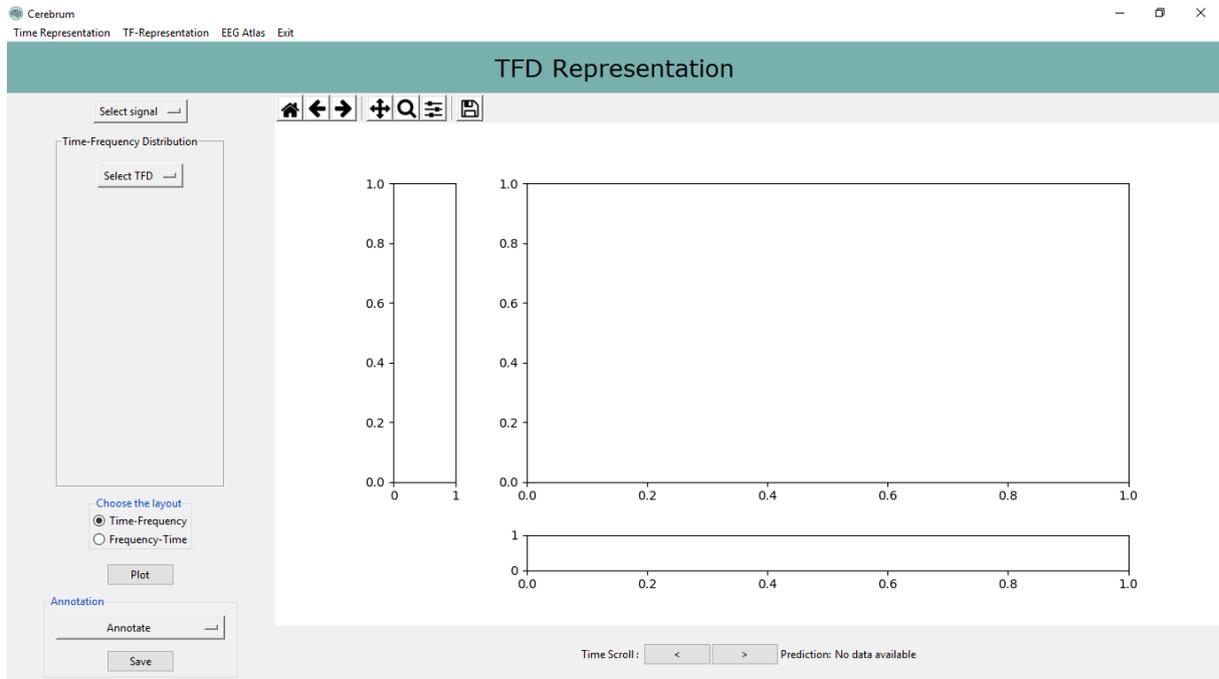


FIGURE B.7: Interface représentation temps-fréquence.

• Sélection des distribution :

En cliquant sur "Select distribution", une autre liste déroulante contenant les distributions implémentées dans l'application (à savoir WVD, MBD, EMBD et CBD) apparaît. L'utilisateur devra choisir la distribution ainsi que ses paramètres en les entrant manuellement ou en utilisant les sliders fournis comme le montre la figure B.8.

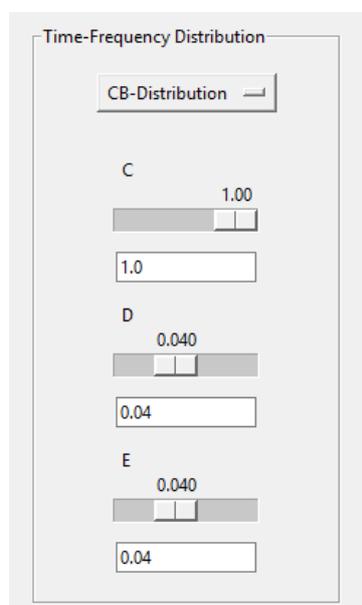


FIGURE B.8: Choix de la distribution et des paramètres.

- **Visualisation de la représentation temps-fréquence :**

Il est possible de choisir la disposition des axes de la représentation (temps-fréquence ou fréquence-temps) à partir du panneau "Choose the layout".

Pour visualiser la distribution, il suffit de cliquer sur plot. La représentation apparaît alors sur l'interface ainsi qu'une suggestion de diagnostic (figure B.9).

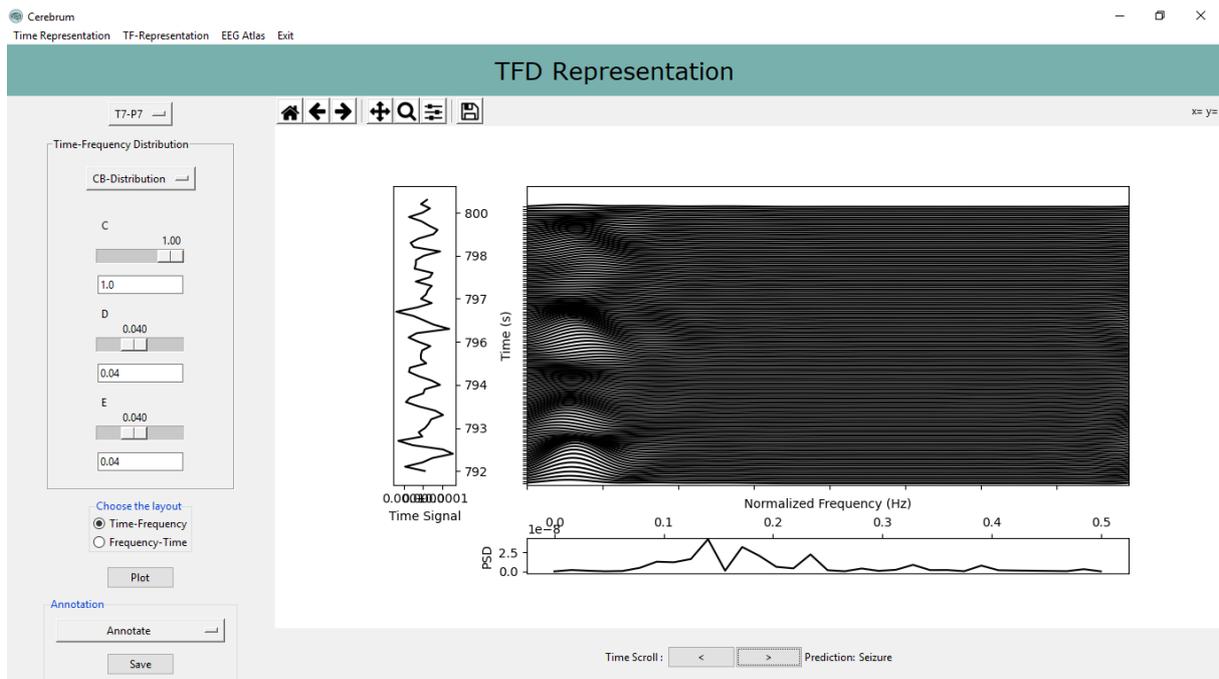


FIGURE B.9: Représentation temps-fréquence.

Pour parcourir la distribution temporellement, le panneau, illustré par la figure B.10, est utilisé. La taille de la fenêtre de parcours est fixé à 8 sec.

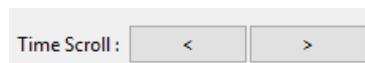


FIGURE B.10: Panneau de parcours temporel.

- **Sauvegrade de la distribuion :**

Il est possible d'enregistrer la distribution obtenue dans une base de données SQL tout en lui attribuant une classe (Seizure : convulsion, Background : activité de fond ou Other : autre).

B.4 Atlas EEG

L'utilisation de l'Atlas est similaire à celle de l'interface "Représentation temps-fréquence" (figure B.11). La seule différence est que le choix du signal se fait à partir d'une liste de signaux prédéfini dans l'application. Pour l'instant, seuls deux exemples sont fournis. L'atlas sera enrichi dès l'acquisition de signaux représentant diverses activités.

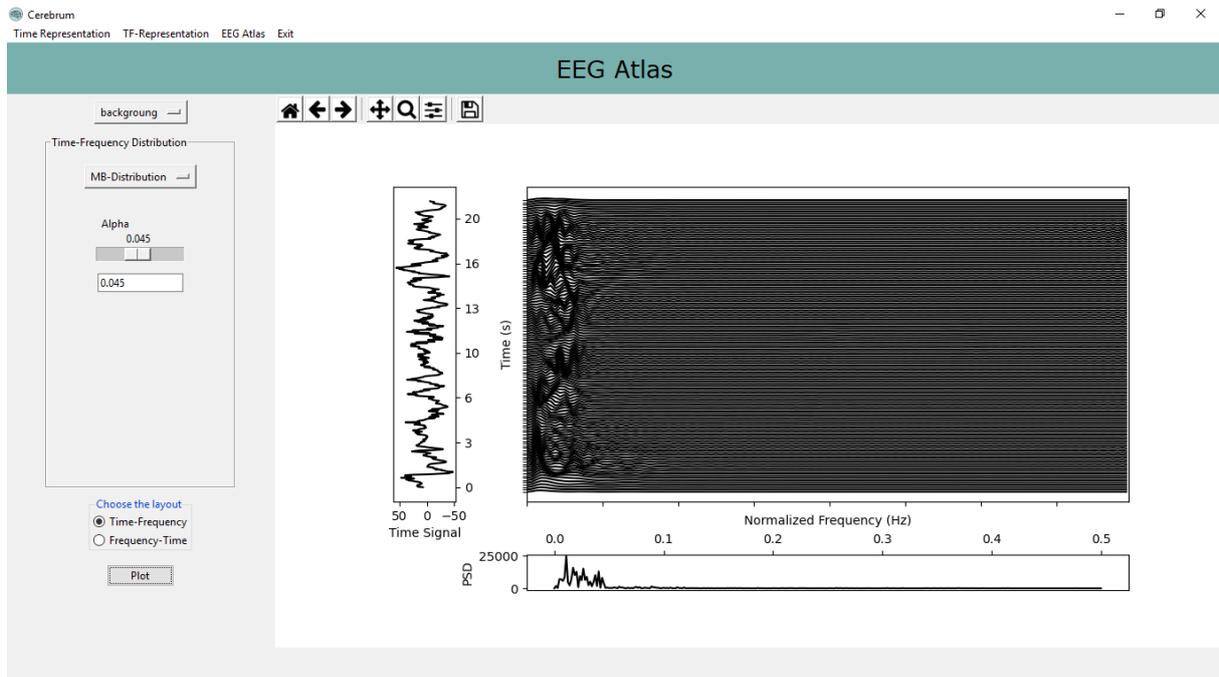


FIGURE B.11: Atlas EEG.

Bibliographie

- [1] F. SEDEL et O. LYON-CAEN, *Le Cerveau Pour les Nuls*, sér. Pour les nuls. edi8, 2010, ISBN : 9782754021784. adresse : <https://books.google.dz/books?id=JN5EBHUQLpgC>.
- [2] S. SANEI et J. CHAMBERS, “Introduction to EEG”, in *EEG Signal Processing*. John Wiley Sons, Ltd, 2013, chap. 1, p. 1-34, ISBN : 9780470511923. DOI : 10.1002/9780470511923.ch1. eprint : <https://onlinelibrary.wiley.com/doi/pdf/10.1002/9780470511923.ch1>. adresse : <https://onlinelibrary.wiley.com/doi/abs/10.1002/9780470511923.ch1>.
- [3] “Chapter 16 - Time-Frequency Methodologies in Neurosciences”, in *Time-Frequency Signal Analysis and Processing (Second Edition)*, B. BOASHASH, éd., Second Edition, Oxford : Academic Press, 2016, p. 915 -966, ISBN : 978-0-12-398499-9. DOI : <https://doi.org/10.1016/B978-0-12-398499-9.00016-9>. adresse : <http://www.sciencedirect.com/science/article/pii/B9780123984999000169>.
- [4] Y.-H. CHEN, M. Op de BEECK, L. VANDERHEYDEN, E. CARRETTE, V. MIHAJLOVIĆ, K. VANSTREELS, B. GRUNDLEHNER, S. GADEYNE, P. BOON et C. VAN HOOF, “Soft, Comfortable Polymer Dry Electrodes for High Quality ECG and EEG Recording”, *Sensors*, t. 14, déc. 2014. DOI : 10.3390/s141223758.
- [5] G. KLEM, H. LÜDERS, H. JASPER et C ELGER, “The ten-twenty electrode system of the International Federation. The International Federation of Clinical Neurophysiology”, *Electroencephalography and clinical neurophysiology. Supplement*, t. 52, 3—6, 1999, ISSN : 0424-8155. adresse : <http://europepmc.org/abstract/MED/10590970>.
- [6] A. RAY et N. ISSA, “EEG Instrumentation and Basics”, in. oct. 2019, p. 203-222, ISBN : 9781108718905. DOI : 10.1017/9781108754200.012.
- [7] *Main features of the EEG amplifier*, <https://www.bitbrain.com/blog/eeg-amplifier>, Consulté le : 21-06-2020.
- [8] L. SQUIRE, F. BLOOM, N. SPITZER, F. GAGE et T. ALBRIGHT, *Encyclopedia of Neuroscience, Volume 1*, vol. 1. Elsevier Science, 2009, ISBN : 9780080963938. adresse : <https://books.google.dz/books?id=qX4KAQAAQBAJ>.
- [9] “Chapter 1 - Time-Frequency and Instantaneous Frequency Concepts0”, in *Time-Frequency Signal Analysis and Processing (Second Edition)*, B. BOASHASH, éd., Second Edition, Oxford : Academic Press, 2016, p. 31 -63, ISBN : 978-0-12-398499-9. DOI : <https://doi.org/10.1016/B978-0-12-398499-9.00001-7>. adresse : <http://www.sciencedirect.com/science/article/pii/B9780123984999000017>.
- [10] M. ABED, A. BELOUHRANI, M. CHERIET et B. BOASHASH, “Time-Frequency Distributions Based on Compact Support Kernels : Properties and Performance Evaluation”, *IEEE Transactions on Signal Processing*, t. 60, n° 6, p. 2814-2827, 2012.

- [11] A. BELOUHRANI et M. CHERIET, “On the use of a new compact support kernel in time frequency analysis”, in *Proceedings of the 11th IEEE Signal Processing Workshop on Statistical Signal Processing (Cat. No. 01TH8563)*, IEEE, 2001, p. 333-336.
- [12] M. ABED, A. BELOUHRANI, M. CHERIET et B. BOASHASH, “Compact support kernels based time-frequency distributions : performance evaluation”, in *2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, IEEE, 2011, p. 4180-4183.
- [13] M. CHERIET et A. BELOUHRANI, *Method and system for measuring the energy of a signal*, US Patent 7,035,744, 2006.
- [14] M. ABED, A. BELOUHRANI, M. CHERIET et B. BOASHASH, “Time-frequency distributions based on compact support kernels : properties and performance evaluation”, *IEEE Transactions on Signal Processing*, t. 60, n° 6, p. 2814-2827, 2012.
- [15] M. ABED et A. BELOUHRANI, “Performance analysis and computational cost evaluation of high-resolution time-frequency distributions derived from compact support time-lag kernels”, *Digital Signal Processing*, t. 78, p. 1-19, 2018.
- [16] B. BOASHASH et S. OUELHA, “Automatic signal abnormality detection using time-frequency features and machine learning : A newborn EEG seizure case study”, *Knowledge-Based Systems*, t. 106, p. 38 -50, 2016, ISSN : 0950-7051. DOI : <https://doi.org/10.1016/j.knosys.2016.05.027>. adresse : <http://www.sciencedirect.com/science/article/pii/S0950705116301174>.
- [17] M. DE VOS, W. DEBURCHGRAEVE, P. CHERIAN, V. MATIC, R. SWARTE, P. GOVAERT, G. H. VISSER et S. VAN HUFFEL, “Automated artifact removal as preprocessing refines neonatal seizure detection”, *Clinical Neurophysiology*, t. 122, n° 12, p. 2345-2354, 2011.
- [18] B. BOASHASH, G. AZEMI et J. M. O’TOOLE, “Time-frequency processing of nonstationary signals : Advanced TFD design to aid diagnosis with highlights from medical applications”, *IEEE signal processing magazine*, t. 30, n° 6, p. 108-119, 2013.
- [19] W. STASZEWSKI, K. WORDEN et G. TOMLINSON, “TIME-FREQUENCY ANALYSIS IN GEARBOX FAULT DETECTION USING THE WIGNER-VILLE DISTRIBUTION AND PATTERN RECOGNITION”, *Mechanical Systems and Signal Processing*, t. 11, n° 5, p. 673 -692, 1997, ISSN : 0888-3270. DOI : <https://doi.org/10.1006/mssp.1997.0102>. adresse : <http://www.sciencedirect.com/science/article/pii/S0888327097901023>.
- [20] M. YUCHAO, Y. WEIMING, H. HAOXIANG et W. KAI, “Damage detection based on cross-term extraction from bilinear time-frequency distributions”, *Mathematical Problems in Engineering*, t. 2014, 2014.
- [21] *EEGLAB and python*, https://sccn.ucsd.edu/wiki/EEGLAB_and_python, Consulté le : 05-04-2020.
- [22] A. DELORME et S. MAKEIG, “EEGLAB : an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis”, *Journal of neuroscience methods*, t. 134, n° 1, p. 9-21, 2004.
- [23] R. OOSTENVELD, P. FRIES, E. MARIS et J.-M. SCHOFFELEN, “FieldTrip : open source software for advanced analysis of MEG, EEG, and invasive electrophysiological data”, *Computational intelligence and neuroscience*, t. 2011, 2011.
- [24] F. TADEL, S. BAILLET, J. C. MOSHER, D. PANTAZIS et R. M. LEAHY, “Brainstorm : a user-friendly application for MEG/EEG analysis”, *Computational intelligence and neuroscience*, t. 2011, 2011.

- [25] A. GRAMFORT, M. LUESSI, E. LARSON, D. A. ENGEMANN, D. STROHMEIER, C. BRODBECK, R. GOJ, M. JAS, T. BROOKS, L. PARKKONEN et al., “MEG and EEG data analysis with MNE-Python”, *Frontiers in neuroscience*, t. 7, p. 267, 2013.
- [26] *UML (informatique)*, [https://fr.wikipedia.org/wiki/UML\(informatique\)](https://fr.wikipedia.org/wiki/UML(informatique)), Consulté le : 18-05-2020.
- [27] P. VIRTANEN, R. GOMMERS, T. E. OLIPHANT, M. HABERLAND, T. REDDY, D. COURNAPEAU, E. BUROVSKI, P. PETERSON, W. WECKESSER, J. BRIGHT et al., “SciPy 1.0 : fundamental algorithms for scientific computing in Python”, *Nature methods*, t. 17, n° 3, p. 261-272, 2020.
- [28] B. BOASHASH et A. REILLY, “Algorithms for time-frequency signal analysis”, in, Citeseer, 1992.
- [29] J. O. TOOLE et B BOASHASH, “Fast and memory-efficient algorithms for computing quadratic time–frequency distributions”, *Applied and Computational Harmonic Analysis*, t. 35, n° 2, p. 350-358, 2013.
- [30] B. BOASHASH, “Estimating and interpreting the instantaneous frequency of a signal. II. Algorithms and applications”, *Proceedings of the IEEE*, t. 80, n° 4, p. 540-568, 1992.
- [31] B. BOASHASH, H. BARKI et S. OUELHA, “Performance evaluation of time-frequency image feature sets for improved classification and analysis of non-stationary signals : Application to newborn EEG seizure detection”, *Knowledge-Based Systems*, t. 132, p. 188-203, 2017.
- [32] *Convulsions néonatales*, <https://www.msmanuals.com/fr/professional/pédiatrie/troubles-neurologiques-chez-l-enfant/convulsions-néonatales>, Consulté le : 13-06-2020.
- [33] *Convulsions du nouveau-né*, https://www.doctissimo.fr/html/sante/encyclopedie/sa_1209_convulsions_nouv_ne.htm, Consulté le : 22-06-2020.
- [34] B. BOASHASH et S. OUELHA, “Designing high-resolution time–frequency and time–scale distributions for the analysis and classification of non-stationary signals : a tutorial review with a comparison of features performance”, *Digital Signal Processing*, t. 77, p. 120-152, 2018.
- [35] P FLANDRIN, W. WILLIAMS, R. BARANIUK, D. JONES, G. PUTLAND, A. PAPANDREOU-SUPPAPPOLA, B. BOASHASH, X.-G. XIA, B. JAWAD, N. KHAN et al., “Advanced design and specifications of TFDs”, 2016.
- [36] M.-K. HU, “Visual pattern recognition by moment invariants”, *IRE transactions on information theory*, t. 8, n° 2, p. 179-187, 1962.
- [37] *Support vector machine*, https://en.wikipedia.org/wiki/Support_vector_machine, Consulté le : 22-06-2020.
- [38] *What is the kernel trick ? Why is it important ?*, <https://medium.com/@zxr.nju/what-is-the-kernel-trick-why-is-it-important-98a98db0961d>, Consulté le : 24-06-2020.