



HAL
open science

Classification des oscillations hautes fréquences dans le déroulement des crises épileptiques

Fatma Krikid

► **To cite this version:**

Fatma Krikid. Classification des oscillations hautes fréquences dans le déroulement des crises épileptiques. Traitement du signal et de l'image [eess.SP]. Université de Rennes; École nationale d'ingénieurs de Sfax (Tunisie), 2022. Français. NNT : 2022REN1S119 . tel-04146916

HAL Id: tel-04146916

<https://theses.hal.science/tel-04146916>

Submitted on 30 Jun 2023

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

THESE DE DOCTORAT DE

L'UNIVERSITE DE RENNES 1

ECOLE DOCTORALE N° 601
*Mathématiques et Sciences et Technologies
de l'Information et de la Communication*
Spécialité : Signal, Image, Vision

Par

Fatma KRIKID

Classification des oscillations hautes fréquences dans le déroulement des crises épileptiques

Thèse présentée et soutenue à Sfax, le 15/12/2022

Unité de recherche : Laboratoire Traitement du Signal et de l'Image, Inserm U1099

Rapporteurs avant soutenance :

Christian Bénar
Mohamed Hédi Bedoui

Directeur de recherches à l'Université Aix-Marseille
Professeur à la Faculté de Médecine de Monastir

Composition du Jury :

Président : Mounir Samet

Professeur à l'École Nationale d'Ingénieurs de Sfax

Rapporteurs : Christian Bénar
Mohamed Hédi Bedoui

Directeur de recherches à l'Université Aix-Marseille
Professeur à la Faculté de Médecine de Monastir

Examineurs : Catherine Marque
Nawel Jmail

Professeur à l'Université de Technologie de Compiègne
Maître de conférences à l'École supérieure de commerce de Sfax

Dir. de thèse : Régine Le Bouquin Jeannès

Professeur à l'Université de Rennes 1

Dir. de thèse : Abdennaceur Kachouri

Professeur à l'École Nationale d'Ingénieurs de Sfax

Co-encadrant : Ahmad Karfoul

Maître de conférences à l'Université de Rennes 1

Sommaire

Liste des abréviations	5
Liste des figures.....	7
Liste des tableaux.....	9
Introduction générale.....	11
Chapitre 1. Contexte clinique.....	15
1.1. Introduction	15
1.2. Cerveau humain et physiologie	15
1.2.1 Morphologie du cerveau.....	15
1.2.2 Physiologie cérébrale	16
1.3. L'épilepsie	17
1.3.1 Définition	17
1.3.2 Classification des crises épileptiques	18
1.3.2.1 Les crises généralisées	18
1.3.2.2 Les crises focales ou partielles	18
1.3.2.3 Les crises inconnues ou inclassables	19
1.4. Étiologie de la maladie	19
1.5. Méthodes d'investigation	20
1.5.1 Exploration électrophysiologique	20
1.5.1.1 L'électroencéphalographie.....	20
1.5.1.2 La magnétoencéphalographie	20
1.5.1.3 L'électrocorticographie.....	21
1.5.1.4 L'électroencéphalographie intracrânienne	22
1.5.2 Exploration anatomique et fonctionnelle	22
1.5.2.1 La tomodensitométrie ou scanner cérébral	22
1.5.2.2 L'imagerie par résonance magnétique	23
1.5.2.3 L'imagerie fonctionnelle	23
1.6. Traitement de l'épilepsie	25
1.7. Le réseau épileptogène.....	26
1.7.1 La zone épileptogène	26
1.7.2 La zone irritative.....	26
1.7.3 La zone symptomatique	26
1.8. Les biomarqueurs la zone épileptogène	27
1.8.1 Qu'est-ce qu'un biomarqueur ?	27
1.8.2 Les oscillations hautes fréquences.....	27

1.8.3	Les pointes épileptiques intercritiques.....	29
1.9.	Conclusion	30
Chapitre 2.	Etat de l'art.....	31
2.1.	Introduction	31
2.2.	Concepts de base sur l'intelligence artificielle.....	31
2.2.1	Intelligence artificielle	31
2.2.2	Apprentissage automatique.....	32
2.2.3	Apprentissage profond	33
2.2.3.1	Les réseaux de neurones convolutifs.....	34
2.2.4	Bases d'apprentissage, de validation et de test.....	37
2.3.	Généralités sur la détection des HFOs	37
2.4.	Classification des HFOs : état de l'art.....	39
2.4.1	Approches basées sur les techniques ML	40
2.4.1.1	Approches basées sur les domaines temporel et/ou fréquentiel	40
2.4.1.2	Approches basées sur le domaine temps-fréquence	41
2.4.2	Approches basées sur l'apprentissage profond	43
2.5.	Conclusion	46
Chapitre 3.	Approches proposées.....	47
3.1.	Introduction	47
3.2.	Bases de données.....	47
3.2.1	Données cliniques.....	48
3.2.2	Données bruitées	48
3.3.	Approche 1 – Classification des oscillations hautes fréquences basée sur la combinaison des caractéristiques extraites de la représentation TF et celles liées à l'image TF associée	48
3.3.1	Notations.....	49
3.3.2	Prétraitement des données	50
3.3.3	Analyse temps-fréquence.....	50
3.3.4	Extraction des caractéristiques.....	51
3.3.4.1	Caractéristiques extraites de la représentation TF	51
3.3.4.2	Caractéristiques extraites de l'image TF binarisée associée	53
3.3.5	Les classifieurs.....	58
3.3.5.1	Machine à vecteurs de support multi-classes.....	58
3.3.5.2	Algorithme des K-plus proches voisins	59
3.3.5.3	La forêt aléatoire.....	60
3.3.5.4	Le classifieur naïf bayésien.....	61
3.3.6	Synthèse	61
3.4.	Approche 2 – Multi-classification de HFOs basée sur l'apprentissage profond	61

3.4.1	Prétraitement et génération des images TF via la transformée en S	63
3.4.2	Multi-classification des HFOs via le CNN	63
3.4.2.1	Schéma 1 : multi-classification des HFOs basée CNN sans augmentation de données 64	
3.4.2.2	Schéma 2 : multi-classification de HFOs basée CNN avec augmentation des données 65	
3.5.	Conclusion	67
Chapitre 4.	Expérimentations	69
4.1.	Introduction	69
4.2.	Outils de développement.....	69
4.3.	Analyse des performances des approches proposées	69
4.4.	Approche 1 : classification des HFOs basée sur des caractéristiques TF.....	70
4.4.1	Protocole expérimental.....	72
4.4.1.1	Analyse des caractéristiques utilisées.....	72
4.4.1.2	Sélection des hyperparamètres des classifieurs	73
4.4.2	Choix du meilleur modèle : analyse et résultats.....	75
4.4.2.1	Cas des données réelles	75
4.4.2.2	Cas des données bruitées	76
4.4.3	Comparaison avec l'état de l'art	78
4.4.3.1	Cas des données réelles	79
4.4.3.2	Cas des données bruitées	80
4.5.	Approche 2 : multi-classification de HFOs basée sur l'apprentissage profond	82
4.5.1	Protocole expérimental.....	82
4.5.2	Evaluation des performances du modèle CNN : cas de données réelles.....	83
4.5.2.1	Apprentissage du CNN sans augmentation de données	83
4.5.2.2	Apprentissage du CNN avec augmentation de données	84
4.5.2.3	Performance de classification du CNN sans augmentation de données	85
4.5.2.4	Impact de l'augmentation de données sur la performance du modèle CNN	86
4.5.2.5	Etude comparative.....	87
4.5.3	Evaluation des performances du modèle CNN : cas de données bruitées.....	88
4.5.3.1	Apprentissage du modèle sans augmentation de données	88
4.5.3.2	Apprentissage du modèle avec augmentation de données	89
4.5.3.3	Performance globale.....	90
4.5.3.4	Etude comparative.....	90
4.6.	Discussion générale	91
4.7.	Conclusion	92
	Conclusion & perspectives.....	93
	Bibliographie	97

Liste des abréviations

- ACC : accuracy
- AD : augmentation des données
- AUC : area under the curve
- BN : batch normalisation
- CNN : convolutional neural network
- CWT : continuous wavelet transform
- DA : data augmentation
- DL : deep learning
- ECoG : électrocorticographie
- EEG : électroencéphalographie / électroencéphalographique
- FC : fully connected
- FRs : fast ripples
- GAN : generative adversarial network
- GMM : Gaussian mixture model
- HFOs : high frequency oscillations
- IA : intelligence artificielle
- SEEG : stéréoélectroencéphalographie
- IESs : interictal epileptic spikes
- ILAE : international league against epilepsy
- IRM : imagerie par résonance magnétique
- IRMf : imagerie par résonance magnétique fonctionnelle
- KNN : *K*-nearest neighbors
- LDA : linear discriminant analysis
- LL : line length
- LR : logistic regression
- LSTM : long short-term memory
- MEG : magnétoencéphalographie
- ML : machine learning
- NB : naive Bayes
- NREM : non-rapid eye movement
- RBF : radial basis function
- ReLU : rectified linear unit
- RF : random forest

- RMN : résonance magnétique nucléaire
- RMS : root-mean-square
- RNA : réseaux de neurones artificiels
- RNN : recurrent neural network
- ROC : receiver operating characteristic
- Rs : ripples
- S-transform : Stockwell transform
- SARSA : state–action–reward–state–action
- SD : standard deviation
- SEN : sensitivity
- SGDM : stochastic gradient descent with momentum
- SNR : signal to noise ratio
- SOZ : seizure onset zone
- STE : short time energy
- SPE : specificity
- STFT : short-time Fourier transform
- STLL : short time line length
- SVM : support vector machine
- TDM : tomodensitométrie
- TEMP : tomographie par émission monophotonique
- TEP : tomographie par émission de positons
- TF : temps-fréquence
- TL : transfer learning
- ZE : zone épileptogène
- ZI : zone irritative
- ZL : zone lésionnelle
- ZS : zone symptomatique

Liste des figures

Figure 1.1 - Les deux hémisphères cérébraux.....	16
Figure 1.2 - Représentation des quatre lobes de l'hémisphère	16
Figure 1.3 - Neurone et ses principales composantes (Hébert, 2012)	17
Figure 1.4 - Les trois phases de crises épileptiques (Moghim et al., 2014)	17
Figure 1.5 - Classification des types de crise (version de base) selon ILAE en 2017 (Figure adaptée de (Fisher et al., 2017))	18
Figure 1.6 - (a) Crises généralisées : hyperactivité d'un réseau de neurones cortico-sous-cortical étendu, bilatéral, (b) Crises focales (ou partielles) : hyperactivité d'un réseau de neurones cortical, unilatéral.....	19
Figure 1.7 - Exemple d'un enregistrement EEG (Velez-Perez, 2010)	20
Figure 1.8 - (a) Installation du Système MEG sur la tête, (b) Enregistrement MEG	21
Figure 1.9 - Enregistrement ECoG (Velez-Perez, 2010)	21
Figure 1.10 - Exemple de SEEG dans l'épilepsie temporale non lésionnelle (Velez-Perez, 2010).....	22
Figure 1.11 - (a) Principe de la tomodensitométrie, (b) Image 2D anatomique obtenue par la tomodensitométrie (Grouiller, 2008)	23
Figure 1.12 - Image 2D anatomique cérébrale obtenue par IRM (Grouiller, 2008).....	23
Figure 1.13 - (a) Principe de la tomographie par émission de positons, (b) Image TEP-2D ..	24
Figure 1.14 - (a) Principe de la tomographie par émission monophotonique, (b) Image 3D anatomique obtenue par la TEMP	25
Figure 1.15 - Illustration des différentes régions d'un réseau épileptique (Nair et al., 2004)..	27
Figure 1.16 - Exemple de HFOs (Fast Ripples ici) visibles en SEEG, limitées par les lignes en pointillés rouges. Figure adaptée de (Lai et al., 2019)	28
Figure 1.17 - Exemple d'IESs (Gardy, 2021)	29
Figure 2.1 - Les domaines de l'intelligence artificielle.	32
Figure 2.2 - Différents types d'apprentissage automatique	32
Figure 2.3 - Architecture d'un réseau CNN.....	35
Figure 2.4 - Différentes fonctions d'activation pour un réseau de neurones.....	36
Figure 2.5 - Schéma de classification de HFOs	39
Figure 2.6 - Exemple de HFOs. Figure adaptée de (Zijlmans et al., 2017).....	41
Figure 2.7 - Représentations de différentes classes de HFOs. (A) Rs; (B) FRs, (C) Artéfact et (D) Activités épileptiformes. Pour chaque sous-figure, sont représentés le signal SEEG à large bande (en haut), le signal filtré de 80 à 500 Hz (au milieu) et la décomposition temps-fréquence (en bas). Figure adaptée de (Remakanthakurup Sindhu et al., 2020)	43
Figure 2.8 - Extraction des caractéristiques et classification par CNN. Figure adaptée de (Lai et al., 2019)	45
Figure 3.1 - Organigramme proposé pour la multi-classification des HFOs et IESs	49
Figure 3.2 - Exemple d'un événement HFO de type FR	51
Figure 3.3 - Représentation des événements HFOs et IESs dans le domaine temporel (première ligne) (i) Plan TF (deuxième ligne), (ii) Image en niveaux de gris (troisième ligne), (iii) Image TF binarisée (quatrième ligne) et (iv) gradient de l'image (cinquième ligne).....	55

Figure 3.4 - Organigramme du framework proposé pour la mutli-classification des HFOs basée sur le CNN	63
Figure 3.5 - Schéma 1 : architecture du modèle CNN.....	64
Figure 3.6 - Exemple d'images augmentées pour chaque classe (γ , $H\gamma$, R_s , FR_s et IES_s) ..	66
Figure 3.7 - Schéma 2 : architecture du CNN avec l'augmentation des données.....	66
Figure 4.1 - Exemple typique d'une courbe ROC.....	70
Figure 4.2 - Architecture fonctionnelle de l'approche 1	71
Figure 4.3 - Diagramme en violon des caractéristiques choisies pour les cinq classes :.....	73
Figure 4.4 - Boîte à moustaches des performances de l'approche proposée en utilisant les classifieurs SVM, RF, KNN et NB. (a) : SEN, (b) : SPE, (c) : ACC, (d) : AUC, (e) : F1-score. Cas des données réelles	76
Figure 4.5 - Boîte à moustaches des performances de l'approche proposée en utilisant les classifieurs SVM, RF, KNN and NB pour différentes valeurs de SNR : (a) : SEN, (b) : SPE, (c) : ACC, (d) : AUC, (e) : F1-score. Cas des données bruitées.....	78
Figure 4.6 - Performances de la classification des HFOs entre l'approche proposée utilisant le classifieur SVM et des approches issues de la littérature en termes de SEN, SPE, ACC, AUC, F1-score. Cas des données réelles.....	80
Figure 4.7 - Performances de la classification des HFOs entre l'approche proposée utilisant le classifieur SVM et des approches de l'état de l'art en termes de	81
Figure 4.8 - Architecture fonctionnelle pour les expérimentations de l'approche 2.....	82
Figure 4.9 - Le modèle CNN sans augmentation de données :.....	84
Figure 4.10 - Le modèle CNN avec augmentation de données :.....	85
Figure 4.11 - Performance de classification des HFOs du modèle CNN proposé sans et avec AD	87
Figure 4.12 - Comparaison des performances du modèle CNN proposé (avec AD) avec l'algorithme SVM	87
Figure 4.13 - Le modèle CNN sans AD :.....	88
Figure 4.14 – Le modèle CNN avec AD :.....	89

Liste des tableaux

Tableau 1.1 - Classification des bandes EEG selon leurs fréquences	29
Tableau 2.1 - Approches basées ML pour la classification des HFOs	44
Tableau 2.2 - Approches basées sur le DL pour la classification des HFOs	45
Tableau 3.1 - Synthèse des différentes caractéristiques utilisées	57
Tableau 4.1 - Valeurs des hyperparamètres utilisés pour les différents classifieurs.....	74
Tableau 4.2 - Approches de l'état de l'art testées pour comparaison.....	79
Tableau 4.3 - Valeurs des hyperparamètres pour l'apprentissage du modèle CNN proposé	83
Tableau 4.4 - Performances de classification du modèle CNN sans augmentation de données	86
Tableau 4.5 - Performances de classification du modèle CNN sans et avec augmentation de données : cas de données bruitées	90
Tableau 4.6 - Comparaison des performances du modèle CNN proposé (avec AD) avec l'algorithme SVM	91

Introduction générale

Cadre de la recherche

Cette thèse de doctorat en cotutelle intitulée « Classification des oscillations hautes fréquences dans le déroulement des crises épileptiques » est menée dans le cadre des travaux de recherche du projet franco-tunisien « Conception et réalisation d'un outil d'aide au diagnostic dans l'identification et la classification de réseaux épileptogènes » (CREDIADIC), au sein des laboratoires LETI¹ (ENIS, Sfax, Tunisie) et LTSI²-Inserm U1099 (Université de Rennes 1, Rennes, France) partenaires de ce projet. Ce dernier est financé par la bourse du programme franco-tunisien PHC (Partenariat Hubert Curien) UTIQUE n°41711PK, Code CMCU 19G1411.

Motivation et définition du problème

L'épilepsie est une maladie neurologique qui affecte environ 1% de la population mondiale et se caractérise par la répétition de crises dont la fréquence et la durée sont variables (Fisher et al., 2005). La crise d'épilepsie entraîne un dysfonctionnement temporaire de l'activité électrique cérébrale résultant de décharges électriques anormales et soudaines. Ces décharges se produisent de manière répétée dans une ou plusieurs régions du cerveau. Selon les zones corticales impliquées, les symptômes cliniques associés aux décharges épileptiques varient d'un patient à l'autre et peuvent entraîner des déficiences physiques et/ou mentales. Dans environ 70% de cas (WHO, 2022), l'épilepsie peut être soignée par un traitement médicamenteux. Cependant, dans les 30% de cas restants, la réponse des patients au traitement n'est pas satisfaisante. Pour les épilepsies pharmaco-résistantes, d'autres solutions peuvent être envisagées telles que la stimulation électrique ou la chirurgie. Dans ce dernier cas, la phase préchirurgicale consiste notamment à localiser et à identifier la zone épileptogène (ZE). Cette zone est définie comme la zone du cortex indispensable à la génération de crises épileptiques. Elle est responsable de l'initiation et de la propagation des activités critiques. La ZE doit être réséquée de sorte que les crises soient supprimées ou au moins atténuées tout en limitant, autant que faire se peut, les déficits postopératoires (Wendling et al., 2010).

Étant donné qu'une crise d'épilepsie est un phénomène dynamique, les techniques de neuroimagerie, telles que la tomographie par émission de positons et l'imagerie par résonance magnétique fournissant des images statiques du cerveau, ne sont pas souvent les meilleurs outils pour identifier la ZE. Bien souvent, les signaux électroencéphalographiques (EEG) recueillis sur des patients épileptiques contiennent des motifs spécifiques qui n'existent pas sur le tracé normal de signaux EEG. De ce fait, les enregistrements électroencéphalographiques intracérébraux (notés SEEG) représentent la technique la plus adaptée pour caractériser l'étendue et le dynamisme du réseau épileptogène. Même si cette procédure est invasive, elle permet une exploration cérébrale plus précise, relativement aux enregistrements classiques de surface non invasifs.

¹ LETI : Laboratoire d'Électronique et des Technologies de l'Information

² LTSI : Laboratoire Traitement du Signal et de l'Image

La recherche des biomarqueurs est une étape déterminante pour caractériser l'étendue et le dynamisme du réseau épileptogène. Depuis 2002, plusieurs recherches ont montré l'efficacité des oscillations hautes fréquences (HFOs : high frequency oscillations) comme des biomarqueurs fiables et précis pour la localisation de la ZE. Cependant, depuis quelques années, la recherche s'intéresse (Jrad et al., 2017; Roehri et al., 2019), en plus de HFOs, à d'autres biomarqueurs, plus spécifiques de la ZE : les pointes épileptiques intercritiques (IESs : interictal epileptic spikes). Ces deux biomarqueurs (*i.e.* HFOs et IESs) posent le contexte de cette thèse. Une HFO est définie comme une onde rythmique spontanée (Thomschewski et al. 2019), qui s'écoule pendant au moins trois périodes (cycles), dont la fréquence est comprise généralement entre 30 et 500 Hz. Les HFOs se divisent en quatre ondes (Jrad et al., 2017) à savoir les ondes Gamma (γ (30 - 80 Hz)), High Gamma (H γ (80 - 120 Hz)), Ripples (Rs (120 - 250 Hz)) et Fast Ripples (FRs (250 - 500 Hz)). Les IESs sont définies comme des activités transitoires clairement distinctes de l'activité de fond qui apparaissent de manière spontanée entre les périodes de crises. Dans la dernière décennie, de nombreuses études (Jacobs et al., 2010; Fedele et al., 2017; Jiang et al., 2018) ont montré une forte corrélation entre les résultats post-chirurgicaux et l'exérèse des canaux EEG présentant des taux élevés de HFOs, ce qui prouve leur importance dans le diagnostic de l'épilepsie. Habituellement, l'identification de ces événements cérébraux est faite suivant un marquage visuel. Cependant, le SEEG est en général enregistré durant deux à trois semaines chez un patient épileptique, afin d'identifier les HFOs et de pouvoir par la suite extraire un maximum d'informations permettant de localiser la ZE avec précision. Le marquage visuel de ces événements associé aux enregistrements de longue durée est un processus extrêmement fastidieux, chronophage et implique des interprétations subjectives. On estime que le marquage de l'enregistrement d'une dizaine de canaux d'une dizaine de minutes peut nécessiter plus de dix heures (Zelmann et al., 2009; Zelmann et al., 2012). La fatigue ou la distraction pendant le marquage visuel des HFOs peut alors facilement entraîner des erreurs. Ainsi, le traitement visuel des HFOs exige une forte concentration mentale et des experts expérimentés.

L'investigation manuelle de biomarqueurs épileptiques étant extrêmement coûteuse surtout dans la pratique clinique, il est nécessaire de mettre en œuvre des algorithmes performants de détection automatique de ces événements. Dans ce contexte, plusieurs détecteurs automatiques des HFOs ont été introduits dans la littérature (Staba et al., 2002; Khalilov et al., 2005; Chander, 2007; Doshi, 2011; Zelmann et al., 2012). Par ailleurs, pour une meilleure caractérisation du réseau épileptogène, non seulement la détection de biomarqueurs (*i.e.* HFOs et IESs) est importante mais également leur classification. Cela revient principalement à **catégoriser** ces biomarqueurs en se basant sur différents attributs permettant de caractériser leur aspect pathologique et à les **discriminer** des autres événements présents dans le signal EEG.

Dans ce travail de thèse, nous nous intéressons à l'étape de classification des HFOs et IESs. Plusieurs stratégies ont été mises en œuvre pour classifier automatiquement ces événements d'intérêt. Certaines d'entre elles opèrent dans le domaine temporel et/ou fréquentiel (Firpi et al., 2007; Blanco et al., 2010; Dümpelmann et al., 2012; Matsumoto et al., 2013; Chaibi et al., 2014). D'autres approches sont basées sur des techniques temps-fréquence (TF) (Wan et al., 2016; Du et al., 2019). Cependant, aucune méthode n'a encore montré une efficacité suffisamment importante pour une bonne discrimination. A ce titre, l'objectif de cette thèse est la proposition de systèmes de classification des biomarqueurs intercritiques de la ZE (*i.e.* HFOs et IESs) basés sur une caractérisation efficace et profonde

de ces biomarqueurs dans le plan TF. En fait, l'émergence de l'analyse TF dans la caractérisation des HFOs revient à leur apparence particulière sous forme de *blobs* dans le plan temps-fréquence (Bénar et al., 2010; Jmail, 2012; Burnos et al., 2014). Ainsi, des techniques de traitement de l'image peuvent être intégrées pour exploiter leurs caractéristiques énergétiques et géométriques. Ces caractéristiques vont être abordées en détail dans cette thèse.

Organisation du manuscrit

Ce mémoire de thèse est constitué de 4 chapitres :

Dans le premier chapitre relatif au **contexte clinique**, nous introduirons le fonctionnement du cerveau et du système nerveux. Par la suite, nous présenterons les notions générales associées au contexte médical de l'épilepsie : définition du réseau épileptogène, classification des crises épileptiques et revue sur les modalités d'exploration cérébrale. Dans la dernière partie de ce chapitre, nous exposerons une description détaillée des biomarqueurs de la ZE (*i.e.* HFOs et IESs).

Dans le second chapitre dédié à l'**état de l'art**, nous exposerons en premier lieu des concepts de base sur les méthodes d'apprentissage automatique, et dresserons, en second lieu, un état de l'art sur les méthodes utilisées pour la classification automatique des HFOs.

Le troisième chapitre sera consacré aux **approches proposées**. Après une présentation des bases de données cliniques, nous proposerons et développerons une première approche de classification des HFOs basée sur l'apprentissage automatique (machine learning). L'originalité de cette approche consiste à caractériser des motifs particuliers des biomarqueurs épileptiques dans l'espace TF. Les différentes caractéristiques calculées, pour chaque événement d'intérêt, sont des caractéristiques extraites de la représentation de Stockwell avec celles liées à l'image TF binarisée associée. Puis nous présenterons la deuxième approche basée sur l'apprentissage profond (deep learning). Nous détaillerons dans ce chapitre l'architecture du réseau de neurones convolutifs utilisé. Nous présenterons également les deux stratégies d'apprentissage adoptées à savoir sans et avec augmentation de données.

Dans le quatrième chapitre, nous présenterons et discuterons les **résultats** obtenus. Nous commencerons par la présentation des outils de développement conduisant à la mise en pratique des approches proposées. Nous expliciterons ensuite les expérimentations réalisées et nous évaluerons nos approches sur données réelles, éventuellement bruitées. Celles-ci seront évaluées et comparées aux approches issues de la littérature, en utilisant les mêmes bases de données pour tester et comparer leur robustesse et leur fiabilité.

Nous terminerons ce manuscrit par un bilan de l'ensemble des travaux réalisés et proposerons des axes d'améliorations.

Chapitre 1. Contexte clinique

1.1. Introduction

Le cerveau humain est caractérisé par sa physiologie complexe. Cet organe est considéré comme le premier animateur de la vie humaine qui traite tous les signes et les actions de vie. Le système le plus connu pour l'acquisition de l'activité électrique du cerveau est l'électroencéphalographie. Cette technique d'enregistrement a été utilisée pour de nombreux objectifs tels que le diagnostic précoce et la localisation des tumeurs cérébrales, l'évaluation du coma, l'étude des stades du sommeil et, également, pour le diagnostic de la maladie de l'épilepsie.

La première partie de ce chapitre présente la structure du cerveau humain, une description détaillée du contexte clinique de la pathologie de l'épilepsie et, par la suite, nous introduirons les biomarqueurs de l'épilepsie à savoir les oscillations hautes fréquences (HFOs : high frequency oscillations) et les pointes épileptiques intercritiques (IESs : interictal epileptic spikes).

1.2. Cerveau humain et physiologie

1.2.1 Morphologie du cerveau

Le cerveau est le centre du système nerveux humain. Chez l'adulte, le cerveau est un milieu visqueux qui pèse environ 1300 ~ 1400 grammes (à peu près 2% du poids total d'un être humain) (Seron et al., 1998). Il est constitué de centaines de millions de neurones interconnectés entre eux *via* des terminaisons synaptiques. Le cerveau agit comme un centre de commande (Seron et al., 1998) dont le principal rôle est l'échange et le traitement d'informations à travers l'ensemble du corps humain.

Physiologiquement, le cerveau est composé de deux hémisphères, l'hémisphère gauche et l'hémisphère droit, qui sont presque symétriques (Figure 1.1). Ils sont reliés l'un à l'autre par des ponts de tissus nerveux (*i.e.* fissures interhémisphériques). Le cortex de chaque hémisphère du cerveau est divisé en quatre zones appelées lobes, le lobe frontal, le lobe pariétal, le lobe temporal et le lobe occipital, comme illustré sur la Figure 1.2.

Les lobes sont impliqués dans différentes fonctions (Westen, 2000) :

- le lobe occipital, localisé à l'arrière du cortex, est spécialisé dans la vision ;
- le lobe pariétal est situé à l'avant du lobe occipital. Il est impliqué dans le sens du toucher, dans la détection de mouvements dans l'environnement et le repérage dans l'espace ;
- le lobe frontal est impliqué dans le mouvement, l'attention, la planification, la prise de décision, le jugement, le raisonnement, la mémoire et certains aspects de la personnalité ;
- le lobe temporal est important dans l'audition, le langage et les émotions.




Figure 1.1 - Les deux hémisphères cérébraux
 (Image extraite du site <https://marinne76.wixsite.com/gaucher-droitier/hemisphere>)




Figure 1.2 - Représentation des quatre lobes de l'hémisphère
 (Image extraite du site <https://parlonssciences.ca/ressources-pedagogiques/documents-dinformation/architecture-du-cerveau>)

1.2.2 Physiologie cérébrale

Le cerveau humain comprend environ 100 milliards de neurones (Williams et al., 1988) qui ont la capacité de collecter et de transmettre des signaux à d'autres neurones. Le cerveau, à l'aide de ce réseau neuronal, contrôle les actions mentales et physiques du corps humain. Un neurone (Figure 1.3) est une cellule constituée d'un corps cellulaire, contenant son noyau, de ramifications appelées dendrites, qui lui permettent de recevoir des informations d'autres neurones, et d'une ramification plus longue appelée axone, qui lui permet d'envoyer de l'information vers d'autres neurones. Chaque neurone est capable d'en influencer beaucoup d'autres. Naturellement, il faut des mécanismes extrêmement complexes et efficaces pour rendre possible la communication entre ce nombre important d'éléments. C'est ce que font les synapses, c'est-à-dire les contacts fonctionnels entre neurones.

Cette interaction neuronale, de nature biochimique et électrique, caractérisée par le transport d'ions de sodium entre les milieux intra- et extra-cellulaires, crée ainsi une impulsion électrique unidirectionnelle appelée potentiel d'action. Lorsque le potentiel interne dépasse un seuil d'activation, on parle alors de décharge électrique.




Figure 1.3 - Neurone et ses principales composantes (Hébert, 2012)

1.3. L'épilepsie

1.3.1 Définition

D'après la ligue internationale contre l'épilepsie (ILAE : international league against epilepsy), l'épilepsie est l'une des maladies neurologiques chroniques du système nerveux les plus courantes et les plus graves au monde affectant 1% de la population mondiale (WHO, 2022). Elle se caractérise par des crises récurrentes et brutales qui se manifestent par de brefs épisodes de mouvements involontaires pouvant toucher une partie du corps ou le corps entier. D'un point de vue médical, les crises sont la conséquence d'un dysfonctionnement (décharge) cérébral localisé ou généralisé dû à une synchronie anormale entre les populations de neurones. Les crises peuvent passer de manques d'attention très brefs ou de saccades musculaires à des convulsions graves et prolongées. La fréquence des crises peut également varier, de moins d'une crise par an à plusieurs crises par jour. Une crise d'épilepsie peut généralement être divisée en trois phases comme indiqué dans la Figure 1.4 : la phase pré-ictale (juste avant le démarrage de la crise), la phase ictale (pendant la crise), la phase post-ictale (en fin de crise).

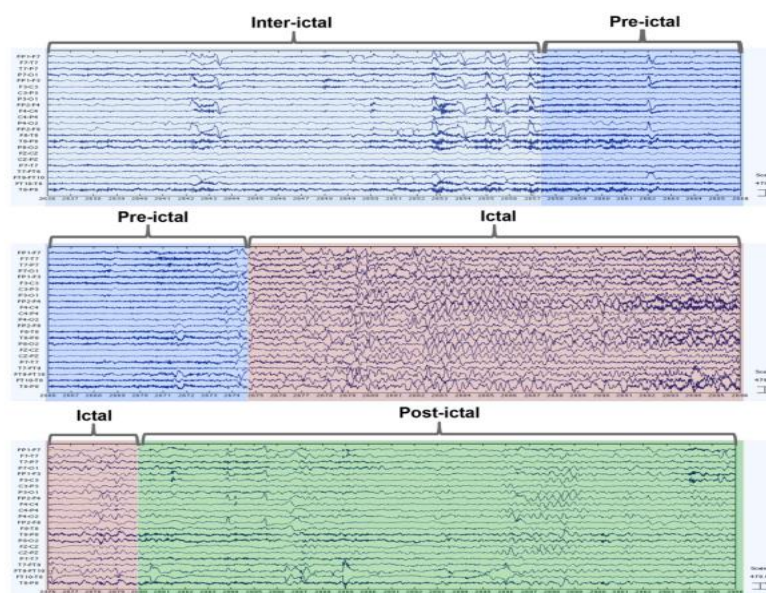


Figure 1.4 - Les trois phases de crises épileptiques (Moghim et al., 2014)

1.3.2 Classification des crises épileptiques

La première tâche du clinicien est de vérifier si un événement présente les caractéristiques d'une crise épileptique. Lorsqu'il est prouvé qu'il s'agit d'une crise, sa classification commence par la localisation de la décharge électrique, soit dans une zone précise du cerveau, soit dans son ensemble.

D'après la dernière classification de la ligue internationale de lutte contre l'épilepsie en 2017, les crises peuvent être divisées en trois groupes selon leur mode d'apparition : focale, généralisée ou inconnue (Fisher et al., 2017) . Chaque catégorie peut être subdivisée de la manière décrite à la Figure 1.5.

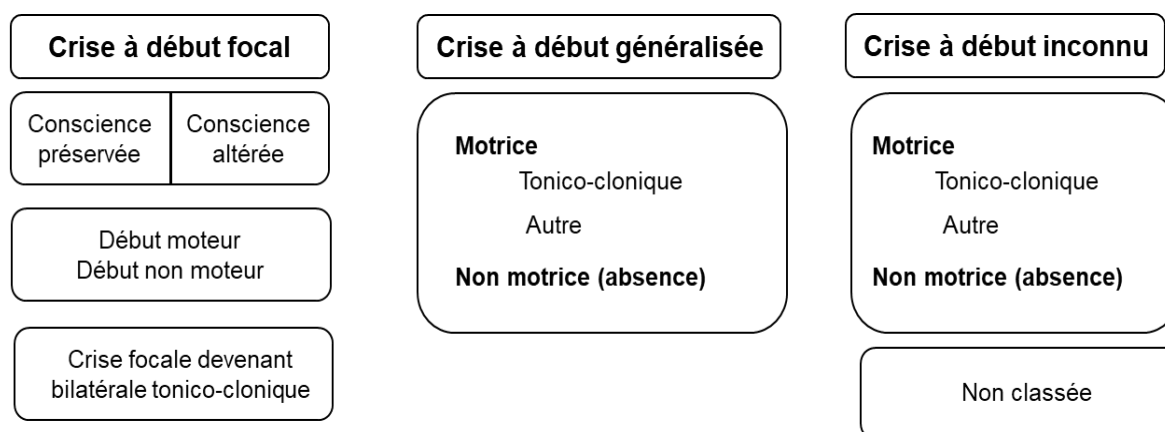


Figure 1.5 - Classification des types de crise (version de base) selon ILAE en 2017 (Figure adaptée de (Fisher et al., 2017))

1.3.2.1 Les crises généralisées

Les crises généralisées sont caractérisées par une décharge paroxystique, où le départ de la crise se propage simultanément dans les deux hémisphères (Figure 1.6 (a)). La perte de connaissance brutale est l'expression clinique la plus connue pour ces types de crises (Grouiller, 2008). Différents types de crises généralisées peuvent être rencontrés. Nous pouvons citer quelques types de crises généralisées :

- les crises tonico-cloniques : ce sont les crises les plus connues mais non les plus fréquentes. Elles se caractérisent par une perte totale de conscience avec chute, mouvements convulsifs, morsure de la langue, etc. ;
- les absences épileptiques : elles se caractérisent par une brève rupture de contact se manifestant par une fixité du regard. Des mâchonnements ou des gestes involontaires et inadaptés apparaissent dans ces types des crises.

1.3.2.2 Les crises focales ou partielles

Les crises focales ou partielles n'affectent que certaines parties du cerveau (Figure 1.6 (b)). Elles peuvent se manifester par des troubles moteurs, des troubles sensoriels et sensitifs, des troubles de la mémoire ou de la conscience. Nous pouvons distinguer trois types de crises partielles (Grouiller, 2008) :

- les crises partielles simples : ces types de crises ne s'accompagnent pas d'altération de l'état de conscience au cours de la crise ;
- les crises partielles complexes : ces types de crises touchent des structures centrales profondes du cerveau qui régissent la conscience. Ces crises entraînent une perte ou des altérations de la conscience ;
- les crises partielles secondairement généralisées : ces types de crises se manifestent par une crise partielle habituelle suivie par des convulsions bilatérales associées à une perte de conscience.




Figure 1.6 - (a) Crises généralisées : hyperactivité d'un réseau de neurones cortico-sous-cortical étendu, bilatéral, (b) Crises focales (ou partielles) : hyperactivité d'un réseau de neurones cortical, unilatéral

(Image extraite du site <https://www.cen-neurologie.fr/fr/deuxieme-cycle/epilepsies-lenfant-ladulte>)

1.3.2.3 Les crises inconnues ou inclassables

Les crises qui ne peuvent pas être classées par manque d'informations cliniques sont dites inconnues ou inclassables.

1.4. Étiologie de la maladie

Les causes de l'épilepsie sont parfois difficiles à identifier. Selon l'origine de l'épilepsie, les crises partielles et les crises généralisées peuvent être symptomatiques, cryptogéniques ou idiopathiques :

- les épilepsies symptomatiques sont dues à une lésion cérébrale : malformation congénitale, encéphalite, séquelles d'une souffrance à la naissance, traumatisme crânien, accident vasculaire cérébral, tumeur, infections du système nerveux central, maladies neurologiques évolutives, anomalies des chromosomes, etc. ;
- les épilepsies cryptogéniques, sans cause identifiée par les moyens diagnostiques usuels et pour lesquels aucun antécédent n'est retrouvé ;
- les épilepsies idiopathiques présentent un caractère génétique plus ou moins démontrable et concernent des sujets le plus souvent sans lésion cérébrale. L'épilepsie

idiopathique est le type d'épilepsie le plus courant, qui touche 6 personnes sur 10 atteintes de la maladie.

1.5. Méthodes d'investigation

Pour le diagnostic de l'épilepsie, différents examens sont demandés, parmi lesquels on trouve l'exploration électrophysiologique via l'électroencéphalographie (EEG) qui est l'outil le plus utilisé, la magnétoencéphalographie (MEG), et l'électrocorticographie (ECoG), L'électroencéphalographie intracérébral (SEEG), ainsi que l'exploration anatomique et fonctionnelle via l'imagerie par résonance magnétique (IRM) et l'imagerie par résonance magnétique fonctionnelle (IRMf) qui sont généralement utilisées pour un bilan chirurgical (Caparos, 2006). Une description détaillée de ces différentes techniques est présentée dans la section suivante.

1.5.1 Exploration électrophysiologique

1.5.1.1 L'électroencéphalographie

L'électroencéphalographie (EEG) joue un rôle crucial dans le diagnostic de l'épilepsie. Cet examen est le plus utilisé pour mettre en évidence l'activité électrique du cerveau ainsi que pour poser le diagnostic et aider à la classification des épilepsies. L'EEG (Figure 1.7) fournit des informations en temps réel avec une excellente résolution temporelle de l'ordre de la milliseconde comparé aux autres techniques d'enregistrement. L'EEG permet aussi de surveiller l'épilepsie lorsqu'il existe une modification de la symptomatologie ou de la fréquence des crises lorsqu'un arrêt du traitement est envisagé (Velez-Perez, 2010).

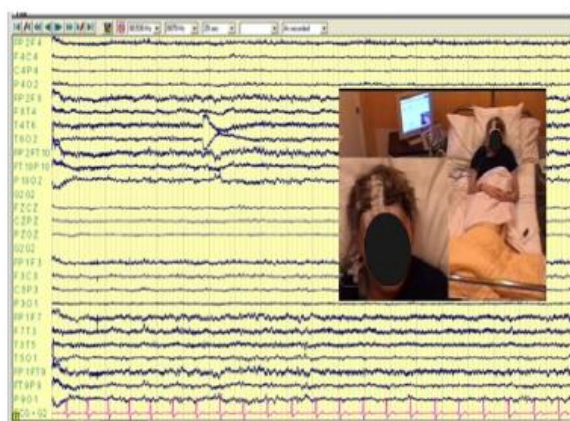


Figure 1.7 - Exemple d'un enregistrement EEG (Velez-Perez, 2010)

1.5.1.2 La magnétoencéphalographie

La magnétoencéphalographie (MEG) est une technique non invasive relativement récente, découverte par David Cohen en 1968. Elle permet le recueil des champs magnétiques d'origine cérébrale à la surface du scalp. Elle est utilisée pour étudier les fonctionnements normaux et anormaux du cerveau. L'origine du signal MEG est directement reliée à celle de l'EEG. En effet, selon la loi de Bio-Savart, chaque courant élémentaire issu de l'activité de neurones produit un champ magnétique induit. Il est donc possible de mesurer à la surface du

cerveau les variations du champ magnétique global, qui somme des champs générés par tous les courants des neurones. Le champ magnétique généré par l'activité cérébrale est de l'ordre du femto Tesla, qui est beaucoup plus faible que le bruit magnétique terrestre. Un exemple du système MEG est illustré sur la Figure 1.8 (a) et un exemple d'un enregistrement MEG est illustré sur la Figure 1.8 (b).

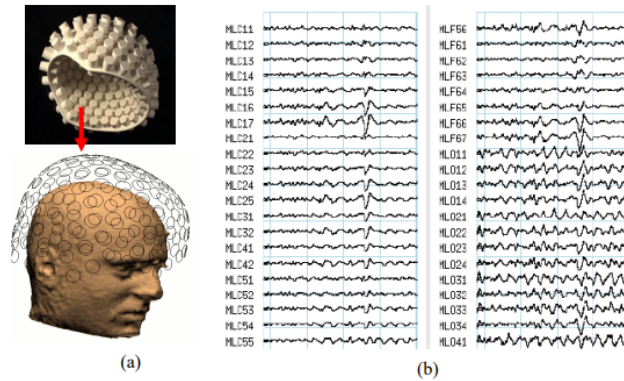


Figure 1.8 - (a) Installation du Système MEG sur la tête, (b) Enregistrement MEG

1.5.1.3 L'électrocorticographie

L'électrocorticographie (ECoG) est l'enregistrement de l'activité neuronale par l'intermédiaire d'électrodes directement placées sur le cortex cérébral, mise en place par H. Jasper aux Etats-Unis dans les années 1950. Cet examen est pratiqué en peropératoire après craniotomie dans le cadre de la chirurgie curative d'une épilepsie pharmaco-résistante. Le principal avantage de cet enregistrement par rapport à l'EEG de surface est qu'il permet de s'affranchir des transformations du signal par le crâne et le cuir chevelu, par les courants superficiels, lors du transfert du signal vers la surface. La Figure 1.9 schématise l'électrocorticographie.




Figure 1.9 - Enregistrement ECoG (Velez-Perez, 2010)

1.5.1.4 L'électroencéphalographie intracrânienne

L'électroencéphalographie intracérébrale (SEEG) est la technique la plus courante pour des enregistrements de signaux EEG invasifs (Jmail, 2012). Cet examen enregistre l'activité électrique de certaines structures potentiellement impliquées dans les crises d'épilepsie. La SEEG (Figure 1.10) peut être implantée bilatéralement et permet le suivi des structures corticales profondes (Parvizi et al., 2018). Dix à quinze électrodes peuvent être implantées par patient.




Figure 1.10 - Exemple de SEEG dans l'épilepsie temporelle non lésionnelle (Velez-Perez, 2010)

1.5.2 Exploration anatomique et fonctionnelle

Les explorations anatomique et fonctionnelle permettent de détecter les structures cérébrales endommagées et donc de localiser la lésion responsable qui génère les crises. Elles jouent aussi un rôle dans la compréhension des mécanismes physiopathologiques de l'épilepsie.

1.5.2.1 La tomodensitométrie ou scanner cérébral

Le scanner est un examen radiologique également appelé tomodensitométrie ou TDM qui permet la visualisation des vaisseaux sanguins et des différentes structures cérébrales. La TDM est de moins en moins utilisée en raison des progrès de l'imagerie par résonance magnétique (IRM). En fait, la tomodensitométrie est capable de mettre en évidence des lésions associées à une épilepsie avec une sensibilité plutôt faible de 15 à 35%. Généralement, la TDM est indiquée en cas de première crise associée à des signes neurologiques focaux. Elle est aussi le seul examen d'imagerie anatomique disponible lorsque le patient présente une contre-indication à l'IRM. La Figure 1.10 illustre une photo explicative sur le principe de la TDM (Figure 1.11 (a)) et un exemple d'une image TDM-2D (Figure 1.11 (b)).




Figure 1.11 - (a) Principe de la tomodensitométrie, (b) Image 2D anatomique obtenue par la tomodensitométrie (Grouiller, 2008)

1.5.2.2 L'imagerie par résonance magnétique

L'imagerie par résonance magnétique (IRM) est une technique d'imagerie médicale dominante permettant de visualiser l'anatomie du cerveau d'un patient. Elle peut être utilisée pour identifier plusieurs anomalies cérébrales telles que la sclérose de l'hippocampe, une atrophie ou des lésions. L'IRM est basée sur les principes de la résonance magnétique nucléaire (RMN). Cette modalité a été une révolution importante en imagerie médicale considérant son excellente résolution spatiale (de l'ordre du millimètre) et une résolution temporelle moyenne (de l'ordre de la seconde). Dans le cas d'un dépistage de l'épilepsie, l'IRM reste le seul examen anatomique à réaliser et c'est aussi la modalité la plus utilisée pour la recherche et le suivi de l'évolution d'une lésion cérébrale à l'origine de l'épilepsie avec une sensibilité qui peut atteindre 90%. Un exemple d'une image 2D IRM est illustré sur la Figure 1.12.




Figure 1.12 - Image 2D anatomique cérébrale obtenue par IRM (Grouiller, 2008)

1.5.2.3 L'imagerie fonctionnelle

Les techniques d'imagerie fonctionnelle permettent de localiser le foyer épileptogène et aident à la compréhension des mécanismes physiopathologiques de l'épilepsie. Elles sont utilisées dans le cas d'épilepsies partielles et réfractaires afin de proposer une intervention chirurgicale. Les techniques d'imagerie fonctionnelle détaillées ci-dessous sont : l'IRM fonctionnelle (IRMf), la tomographie par émission de positons (TEP), la tomographie par émission monophotonique (TEMP), la spectroscopie par résonance magnétique nucléaire (RMN). Une description détaillée de ces différentes méthodes est présentée ci-dessous.

- L'imagerie par résonance magnétique fonctionnelle

L'imagerie par résonance magnétique fonctionnelle (IRMf) est une technique qui permet de détecter l'activité fonctionnelle du cerveau, dans laquelle le métabolisme ou la demande en oxygène du cerveau est quantifié. En effet, les régions actives du cerveau ont une plus grande demande en oxygène que les régions inactives (Deslauriers-Gauthier, 2010). L'objectif de l'IRM fonctionnelle est de localiser les régions cérébrales impliquées dans des fonctions précises telles que le langage, le mouvement et la mémoire afin de respecter ces régions lors de la chirurgie. Elle possède une résolution spatiale de 3 à 4 mm et une résolution temporelle de l'ordre d'une seconde.

- La tomographie par émission de positons

La tomographie par émission de positons (TEP) permet d'obtenir des images du flux sanguin, du métabolisme et des systèmes de neurotransmission. Cette technique est souvent utilisée pour localiser le foyer de l'épilepsie partielle pharmaco-résistante. La Figure 1.13 illustre une photo explicative sur le principe de TEP (Figure 1.13 (a)) et un exemple d'une image TEP-2D (Figure 1.13 (b)).




Figure 1.13 - (a) Principe de la tomographie par émission de positons, (b) Image TEP-2D

- La tomographie par émission monophotonique

La tomographie par émission monophotonique (TEMP) consiste à injecter un traceur radioactif que l'on va pouvoir ensuite suivre au travers d'une succession d'images prises à différents instants. La Figure 1.14 illustre une photo explicative sur le principe de TEMP (Figure 1.14 (a)) et un exemple d'une image TEMP-3D (Figure 1.14 (b)).

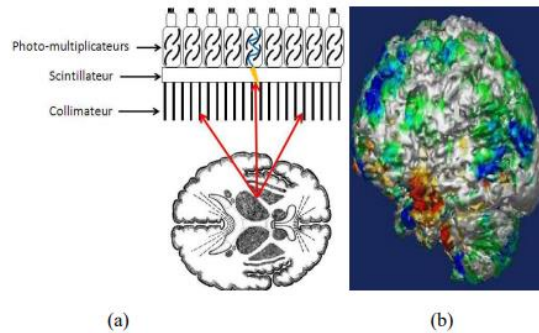


Figure 1.14 - (a) Principe de la tomographie par émission monophotonique, (b) Image 3D anatomique obtenue par la TEMP

- La spectroscopie par résonance magnétique nucléaire

La spectroscopie par résonance magnétique nucléaire (RMN) est une technique non-invasive d'analyse chimique. Elle constitue un outil unique pour l'étude *in vivo* de la biochimie et du métabolisme du cerveau. Cette technique permet une bonne caractérisation métabolique des tissus épileptogènes (Cozzone et al., 1992).

1.6. Traitement de l'épilepsie

Le but du traitement est de supprimer les crises ou de réduire leur fréquence. Il est basé sur le type du syndrome, son intensité et son origine.

- Traitement pharmaceutique

Environ 80% des patients peuvent être traités par des médicaments. Il existe de nombreux médicaments (antiépileptiques) pour traiter l'épilepsie, le médicament et sa posologie sont prescrits par le neurologue. La monothérapie est généralement recommandée. Pour les cas les plus complexes, l'association de deux médicaments peut offrir une meilleure efficacité thérapeutique.

- Traitement par stimulation électrique

Ce traitement est recommandé aux patients dont le traitement médicamenteux offre des résultats insuffisants. Il s'agit d'implanter un stimulateur électrique sous la clavicule gauche et relié à des électrodes fixées sur le nerf. En fait, il existe trois types de stimulation dans le traitement de l'épilepsie : stimulation du nerf vague (George et al., 1994) , stimulation cérébrale profonde (Boëx et al., 2006) et la stimulation corticale (Sun et al., 2014). Cette intervention est réalisée sous anesthésie générale par un neurochirurgien.

- Traitement chirurgical

20% des personnes atteintes d'épilepsie résistent aux médicaments (on parle d'épilepsie pharmaco-résistante) et, pour certaines d'entre elles (5 à 10%) une chirurgie est envisageable.

Lors de l'intervention, le neurochirurgien essaye de réséquer le foyer épileptique. Il existe deux types de chirurgie :

- *la chirurgie curative* : elle est recommandée dans le cas d'une épilepsie focale, son but est de supprimer les crises par l'ablation du foyer épileptique qui doit être bien identifié et se trouver dans une zone sans risque (pour ne pas endommager une zone fonctionnelle) ;

- *la chirurgie palliative* : l'objectif de cette dernière est de réduire la fréquence ou la sévérité des crises en limitant la propagation des décharges épileptiques.

1.7. Le réseau épileptogène

Le réseau épileptogène est constitué de trois régions principales : la zone épileptogène, la zone irritative et la zone symptomatique comme illustré sur la Figure 1.15.

1.7.1 La zone épileptogène

La zone épileptogène (ZE) est définie par l'aire cérébrale dont l'exérèse est nécessaire pour réduire la survenue des crises (Bartolomei et al., 2016). Cette zone inclut essentiellement la zone primaire à l'origine des crises (seizure onset zone : SOZ) et les zones de propagation qui sont le siège des régions cérébrales susceptibles de développer secondairement une potentialité épileptogène. Il est seulement possible d'affirmer que la ZE est incluse dans la zone cérébrale réséquée lorsqu'un patient est totalement libéré de crises épileptiques.

1.7.2 La zone irritative

La zone irritative (ZI) est le siège des décharges intercritiques qui se manifestent sous la forme de pointes intercritiques. L'aire irritative est toutefois plus étendue que la zone épileptogène. L'étendue de cette zone peut être évaluée par l'électroencéphalographie et la magnétoencéphalographie (Lüders et al., 2006).

1.7.3 La zone symptomatique

La zone symptomatique (ZS) est la zone cérébrale qui peut produire des symptômes critiques observés pendant la crise quand elle est stimulée par une décharge épileptique. Dans la majorité des cas, il n'existe pas un recouvrement complet entre la ZS et la ZE. En effet, l'identification de la symptomatologie initiale des crises indique seulement que la zone de départ des crises est directement reliée à la zone symptomatique. La ZS ne localise pas la zone exacte de départ des crises et ne donne également aucune indication sur l'étendue de la zone de départ des crises (Lüders et al., 2006).

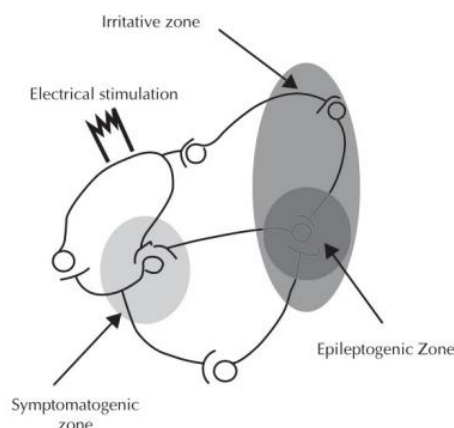


Figure 1.15 - Illustration des différentes régions d'un réseau épileptique (Nair et al., 2004)

1.8. Les biomarqueurs la zone épileptogène

1.8.1 Qu'est-ce qu'un biomarqueur ?

Un biomarqueur est défini comme une caractéristique objective quantifiable qui peut être mesurée comme un indicateur des processus biologiques normaux et pathogènes. Une bonne investigation de la relation qui lie les grandeurs mesurées d'un processus biologique aux mécanismes qui les produisent est d'une importance capitale pour aider au diagnostic et au traitement des maladies. Dans le cas de l'épilepsie, identifier et valider correctement les biomarqueurs de l'épileptogenèse et l'ictogenèse pourraient aider à estimer la tendance à générer des crises, repérer l'emplacement des tissus cérébraux contribuant à la génération de crises spontanées, mesurer la progression du traitement et décider si une intervention chirurgicale est nécessaire en cas d'épilepsie pharmaco-résistante.

Les biomarqueurs épileptiques comprennent une grande variété de catégories, y compris les mesures obtenues à partir d'enregistrements d'imagerie et d'électrophysiologie ainsi que la quantification des changements dans les métabolites dans le sang ou les tissus (biomarqueurs cellulaires et moléculaires). De ce fait, ces biomarqueurs sont des témoignages de l'activité épileptogène. Ils servent à guider les hypothèses cliniques en délimitant les zones épileptogènes et de propagation. L'investigation de ces biomarqueurs est à ce jour essentiellement réalisée manuellement à travers l'exploration visuelle de l'activité cérébrale.

Dans cette étude, nous nous intéressons principalement aux biomarqueurs électrophysiologiques qui peuvent être extraits des données enregistrées de manière invasive avec un EEG intracérébral. Nous détaillons par la suite les biomarqueurs de l'épilepsie : les oscillations hautes fréquences (HFOs) et les pointes épileptiques intercritiques (IESs).

1.8.2 Les oscillations hautes fréquences

Les oscillations hautes fréquences (HFOs) sont des activités cérébrales de type oscillatoire qui reflètent la synchronisation à court terme de l'activité neurale et elles se produisent plus fréquemment pendant le mouvement non-rapide des yeux (NREM : non-rapid eye movement). Les HFOs ont été découvertes au cours de la dernière décennie chez des patients atteints d'épilepsie méso-temporale et dans les modèles animaux reproduisant ce trouble (Bragin et

al., 2002; Staba et al., 2002; Wendling et al., 2012). Les HFOs peuvent être observées pendant les périodes critiques (Zijlmans et al., 2011), les périodes précritiques (Jacobs et al., 2010) et pendant les périodes intercritiques (Zijlmans et al., 2011). Les HFOs peuvent coexister sous deux fonctions : physiologiques et pathologiques. Dans notre étude, nous nous focalisons sur les HFOs pathologiques.

Les HFOs sont spontanées, souvent de faible amplitude et composées d'au moins 3 à 6 périodes distinctes de l'activité de fond (Staba et al., 2002; J. Jacobs et al., 2012; Krikid et al., 2020). Ces événements témoigneraient d'une synchronisation à court terme d'assemblées neuronales. En outre, des recherches récentes ont mis en évidence le lien entre des oscillations hautes fréquences apparaissant en période intercritique et le réseau épileptogène, voire la ZE (Staba et al., 2002; Zijlmans et al., 2012). Être capable de localiser ces HFOs efficacement pourrait permettre une amélioration notable du processus de diagnostic des épilepsies, grâce à une localisation plus rapide et plus précise des tissus à opérer.

Généralement, les HFOs sont classées en deux catégories :

- **Les Ripples** : HFOs comprises entre 80 Hz et 250 Hz [Buzsáki et al., 1992, Buzsáki, 1996] ; ces oscillations peuvent être physiologiques ou pathologiques et d'amplitude variant entre 40 et 200 μ V (Melani et al., 2013; Alvarado-Rojas et al., 2015).
- **Les Fast Ripples** (Figure 1.16) : HFOs comprises entre 250 Hz et 500 Hz (von Ellenrieder et al., 2017) et d'amplitude variant entre 5 et 30 μ V (Jirsch et al., 2006).




Figure 1.16 - Exemple de HFOs (Fast Ripples ici) visibles en SEEG, limitées par les lignes en pointillés rouges. Figure adaptée de (Lai et al., 2019)

En fait, dans certaines études, les auteurs ont prouvé que les bandes de HFOs incluent également les bandes Gamma (γ , [30–80 Hz]) et High-Gamma ($H\gamma$, [80–120 Hz]) (Uhlhaas et al., 2011; Park et al., 2012; Jrad et al., 2017). De ce fait, nous résumons la classification des bandes EEG selon leurs fréquences dans le Tableau 1.1.

Tableau 1.1 - Classification des bandes EEG selon leurs fréquences

Classification	Bande	Fréquence
Conventionnelle	Delta	1-4 Hz
	Theta	4-7 Hz
	Alpha	8-13 Hz
	Beta	13-30 Hz
HFOs	Gamma	30-80 Hz
	High Gamma	80-120 Hz
	Ripples	120-250 Hz
	Fast Ripples	250-500 Hz

1.8.3 Les pointes épileptiques intercritiques

Les pointes épileptiques intercritiques (IESs) sont de brèves décharges paroxystiques de grande amplitude, mesurant souvent plusieurs centaines de μV et relativement durables avec une composante rapide d'une durée de 50 à 100 ms généralement suivie d'une onde lente d'une durée de 200 à 500 ms (Gotman et al., 1976; Staley et al., 2006). Les IESs apparaissent généralement de manière spontanée entre périodes de crises dans les EEG de patients atteints de crises focales. Les pointes sont très corrélées à l'épilepsie (Ayala et al., 1973; Schulze-Bonhage et al., 2011). Certaines études montrent que (i) la survenue de pointes intercritiques est fortement associée aux crises spontanées, (ii) leur présence contient des informations importantes qui peuvent être utilisées dans le diagnostic de l'épilepsie (Ayala et al., 1973; Schulze-Bonhage et al., 2011). Un exemple classique de visualisation de SEEG en clinique montrant plusieurs IESs est illustré sur la Figure 1.17.




Figure 1.17 - Exemple d'IESs (Gardy, 2021)

1.9. Conclusion

Dans ce chapitre, nous avons introduit, dans un premier temps, quelques généralités sur l'épilepsie ainsi que les méthodes de traitement et les modalités d'exploration cérébrale. Nous avons mis l'accent, dans un second temps, sur les différentes régions du réseau épileptique. Nous avons présenté par la suite les différents biomarqueurs de la ZE : les HFOs et les IESs. Une étude (Roehri et al., 2019) a montré que les HFOs et les IESs sont des biomarqueurs complémentaires de la ZE. De ce fait, une bonne identification de la ZE revient principalement à une meilleure détection de ces biomarqueurs. Dans le but de localiser la ZE, non seulement l'étape de détection est importante, mais la classification des différents événements HFOs est également cruciale (Zhao et al., 2020). Le chapitre suivant sera ainsi consacré à la présentation d'un état de l'art des principales méthodes issues de la littérature en vue de cette classification.

Chapitre 2. Etat de l'art

2.1. Introduction

La caractérisation du réseau épileptogène requiert l'utilisation de biomarqueurs pertinents présents dans les enregistrements EEG/SEEG. Pour garantir une caractérisation fiable du réseau épileptogène, les biomarqueurs utilisés doivent être induits directement de ce réseau. Les biomarqueurs intercritiques suscitent une attention particulière auprès des chercheurs pour leur intérêt comme miroirs de l'activité pathogène au sein de la ZE. Une étude récente (Roehri et al., 2019) a montré que les oscillations hautes fréquences et les pointes épileptiques intercritiques sont reconnues pour être des biomarqueurs fiables dans la localisation du tissu épileptogène en cas d'exploration pré-chirurgicale. En fait, il a été observé que les zones du cerveau où les HFOs étaient les plus fréquentes pouvaient coïncider avec la zone épileptogène. Il est judicieux alors de se pencher sur la détection automatique de ces biomarqueurs. En revanche, pour une meilleure caractérisation de la zone épileptogène, non seulement l'étape de détection des HFOs est importante, mais la classification de différents événements est également primordiale (Zhao et al., 2020). Dans ce chapitre, nous nous intéressons aux travaux adressant le problème de classification des HFOs.

Dans ce chapitre, nous commencerons, dans un premier temps, par présenter les différents concepts de base utiles dans ce travail de thèse. Dans un second temps, nous donnerons quelques généralités sur la détection des HFOs ainsi que sur les méthodes de détection les plus connues dans la littérature. Finalement, nous synthétiserons les travaux déjà existants sur la classification automatique des HFOs.

2.2. Concepts de base sur l'intelligence artificielle

Les techniques d'intelligence artificielle (IA) sont en plein essor et permettent déjà de répondre à des problèmes pour lesquels aucune solution n'existait. Mais cette discipline est très vaste, elle recouvre plusieurs notions et se situe à l'interface entre mathématiques, informatique, biologie et même psychologie voire sociologie. Avant d'entrer dans le détail des algorithmes utilisés pour catégoriser les biomarqueurs de l'épilepsie, nous proposons d'introduire quelques notions importantes tout d'abord sur l'IA, l'apprentissage machine et l'apprentissage profond.

2.2.1 Intelligence artificielle

L'IA est une branche de la science qui est restée dans l'ombre pendant longtemps (Sinapin, 2020). L'IA représente un ensemble d'algorithmes conférant à une machine des capacités d'analyse et de décision lui permettant de s'adapter de manière intelligente aux diverses situations en faisant des prédictions tels que la reconnaissance d'objets, ou encore la résolution de problèmes, à partir des données acquises. Comme montré sur la Figure 2.1, l'IA revient principalement à étudier deux concepts très populaires tels que l'apprentissage automatique ou machine learning (ML) et l'apprentissage profond ou deep learning (DL).




Figure 2.1 - Les domaines de l'intelligence artificielle.

(Image extraite du site <https://www.bial-r.com/2019/05/22/comprendre-le-machine-learning-et-le-deep-learning>)

2.2.2 Apprentissage automatique

L'apprentissage automatique (machine learning) fait partie de l'intelligence artificielle, introduit pour la première fois par Arthur Samuel chez IBM en 1959. Cependant, cette technique n'a commencé à prospérer que dans les années 1990, lorsque la quantité d'informations numérisées a augmenté. Il a été utilisé à grande échelle dans divers domaines, tels que l'analyse commerciale, les moteurs de recherche, le marketing numérique et le traitement du langage. Depuis, l'apprentissage automatique a été défini comme des méthodes et des modèles fondés sur les statistiques et la théorie de probabilités pour la résolution de problèmes complexes. Il a rapidement gagné en popularité au cours des dernières décennies en raison de son applicabilité pour résoudre un large éventail de problèmes.

Il existe divers types d'algorithmes d'apprentissage automatique, suivant la tâche à accomplir et le type de données disponibles. Ces algorithmes se divisent principalement en trois catégories comme présenté sur la Figure 2.2 : les algorithmes d'apprentissage supervisé, non supervisé et par renforcement :

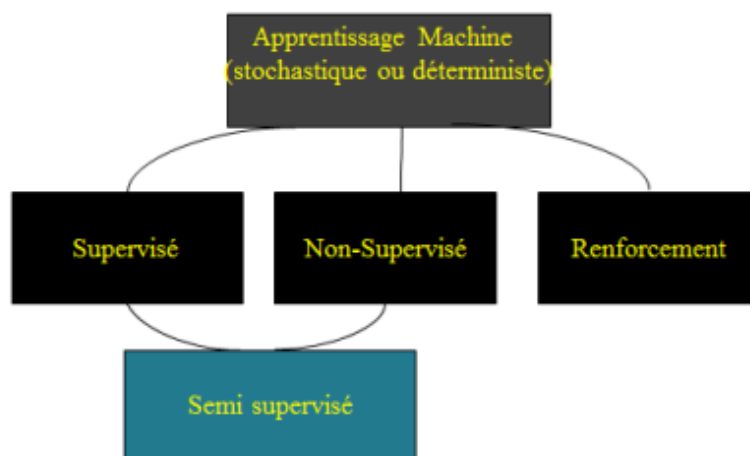


Figure 2.2 - Différents types d'apprentissage automatique

- **Apprentissage supervisé**

L'apprentissage supervisé (supervised learning) consiste à guider l'algorithme avec des entrées qui sont étiquetées préalablement avec des sorties prédéterminées. Dans ce cas, les classes sont connues à l'avance. L'objectif de cette technique est de trouver le bon modèle en minimisant l'erreur de prédiction/classification. Parmi les algorithmes populaires d'apprentissage supervisé nous trouvons la régression linéaire, la régression logistique, les arbres de décision, les machines à vecteurs de support, les réseaux de neurones, ainsi que les modèles non paramétriques tels que les k -plus proches voisins.

- **Apprentissage non supervisé**

L'apprentissage non supervisé (unsupervised learning) traite des entrées non étiquetées. Dans ce cas, l'algorithme d'apprentissage va déterminer les classes d'une façon autonome avec pour objectif d'identifier automatiquement des caractéristiques communes aux observations. Ce type d'apprentissage est utile pour traiter des données complexes et les organiser d'une manière significative. Ce type d'apprentissage est basé essentiellement sur le principe du partitionnement (clustering) dans lequel l'objectif est d'identifier automatiquement des groupes (ou clusters) d'observations partageant des profils communs. Parmi les algorithmes connus d'apprentissage non supervisé nous trouvons l'algorithme des k -moyennes et les analyses en composantes principales.

- **Apprentissage par renforcement**

Ce type d'apprentissage (reinforcement learning) se positionne également entre l'apprentissage supervisé et non supervisé. L'apprentissage par renforcement s'intéresse à l'interaction avec l'environnement, ce qui permet de renforcer les comportements produisant les réponses adéquates. Il prend en compte des concepts clés basés sur le fait que l'agent intelligent observe les effets de ses actions, déduit de ses observations la qualité de ses actions et améliore ses futures actions. Parmi les algorithmes pour ce type d'apprentissage, on trouve les algorithmes SARSA (state–action–reward–state–action) et Q-learning (Watkins et al., 1992).

2.2.3 Apprentissage profond

L'apprentissage profond (deep learning) diffère des autres techniques d'apprentissage automatique. Il a été introduit pour la première fois dans les années 1980 (LeCun et al., 2015). C'est un type spécial de réseaux de neurones artificiels (RNA) qui ressemble à un système cognitif humain multicouche. L'apprentissage profond suscite beaucoup d'intérêt grâce à sa capacité d'extraire les différentes caractéristiques de manière automatique contrairement aux approches d'apprentissage automatique où les caractéristiques sont utilisateur-dépendant. C'est une technologie clé pour la résolution des problèmes à complexité élevée. Généralement, les modèles d'apprentissage profond peuvent atteindre une précision élevée qui dépasse souvent les capacités humaines. Ces modèles sont formés à partir d'une énorme

quantité de données étiquetées et d'architectures présentant de nombreuses couches (Suzuki, 2017).

Le type d'algorithme et la définition des paramètres dépendent principalement de la tâche à réaliser. Ainsi, pour travailler sur des images on choisira plutôt des réseaux de neurones convolutifs (CNNs : convolutional neural networks). Pour travailler sur des séries temporelles, on privilégiera des réseaux de neurones récurrents (RNNs : recurrent neural networks). On trouve également les réseaux antagonistes génératifs (GANs : generative adversarial networks) qui comptent parmi les architectures les plus répandues de deep learning. La principale utilisation des GANs est de permettre la génération des images avec un fort degré de réalisme. Dans la section suivante, nous donnerons plus de détails sur les réseaux de neurones convolutifs qui seront utilisés dans le cadre de cette thèse.

2.2.3.1 Les réseaux de neurones convolutifs

Les réseaux de neurones convolutifs (CNNs) sont parmi les meilleurs algorithmes d'apprentissage pour comprendre le contenu d'une image et ont montré d'excellentes performances de segmentation (Sultana et al., 2020), de classification (Liu et al., 2019) et de détection d'images (Ciresan et al., 2012). L'efficacité des réseaux de neurones convolutifs notamment dans la reconnaissance d'images est l'une des raisons principales pour lesquelles plusieurs chercheurs se sont rendus compte de l'efficacité de l'apprentissage profond.

Le CNN peut prendre en entrée une quantité 1D pour le traitement du signal, 2D pour le traitement d'images et 3D pour le traitement vidéo. Dans ce manuscrit, nous nous intéressons seulement à l'entrée 2D. Ainsi, les différentes caractéristiques de l'image sont extraites, mémorisées et affinées grâce à plusieurs couches de convolution consécutives. Il convient de noter que le CNN est d'autant plus profond que le nombre de couches convolutives utilisées est grand. Comme évoqué sur la Figure 2.3, les CNNs comportent deux blocs consécutifs bien distincts. Le premier bloc est celui de l'extraction de caractéristiques et le deuxième concerne l'étape de classification. L'extraction des caractéristiques dans le premier bloc est faite grâce aux multiples opérations de convolutions réalisées à travers les différentes couches de convolutions utilisées. Toutes les caractéristiques extraites sont ensuite introduites au bloc de classification. Ce dernier consiste en des couches de neurones entièrement connectées dont l'objectif est d'agréger les caractéristiques extraites afin de prendre une décision sur la classe attendue de l'image d'entrée. Cette décision est fondée sur le calcul de la probabilité de l'appartenance de l'image d'entrée aux classes prédéfinies. Par conséquent, la classe désignée correspond à celle ayant la probabilité la plus élevée. Ci-après nous donnons une brève description des différents éléments définissant une structure type d'un CNN pour la classification d'images.

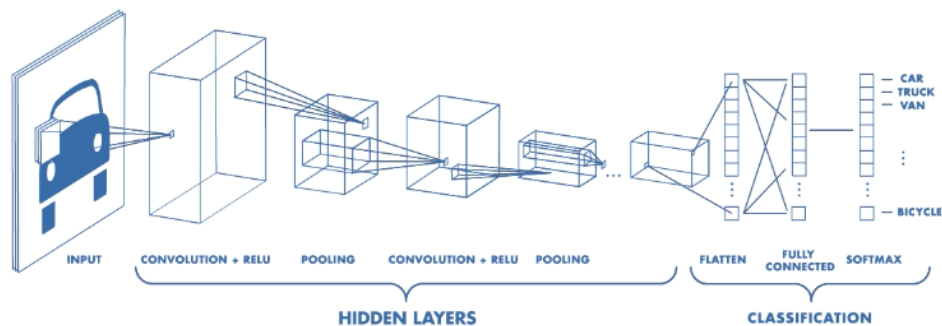


Figure 2.3 - Architecture d'un réseau CNN

(Image extraite du site <https://towardsdatascience.com/convolutional-neural-networks-explained-9cc5188c4939>)

- **Couche convolutive**

Le rôle de la couche de convolution (convolution layer) est d'extraire des caractéristiques de l'image présentée à son entrée. Comme mentionné précédemment, cette extraction est réalisée en convoluant l'image d'entrée avec un noyau de convolution (filtre). Par conséquent, l'image de sortie, communément appelée carte des caractéristiques, est donc le résultat d'une convolution bi-dimensionnelle entre l'image présente à l'entrée de la couche de convolution et le noyau de convolution utilisé. Cette opération de convolution se poursuit dans les couches de convolution suivantes où l'entrée de la couche présente correspond à la carte des caractéristiques issue de couche de convolution précédente. A noter que les noyaux optimaux sont déterminés lors de la phase d'entraînement du réseau.

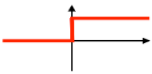
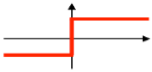
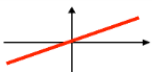
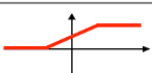
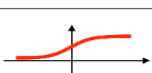
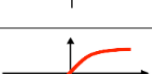
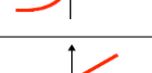

- **Couche de mise en commun**

L'objectif de la couche de mise en commun (pooling layer) est double. En effet, elle permet d'extraire à partir de la carte des caractéristiques une représentation non seulement compacte mais aussi plus riche. Plus précisément, l'opération de pooling consiste à agréger, grâce à une fenêtre glissante appliquée à la carte des caractéristiques, l'ensemble de caractéristiques qui y sont incluses. Il est à noter que la taille de cette fenêtre correspond généralement à celle du noyau de convolution utilisé dans la couche de convolution qui précède l'étape de pooling. Une pratique courante d'agrégation est soit de ne garder que la caractéristique ayant la plus grande valeur parmi l'ensemble des caractéristiques considérées (opération dite de maxpooling) soit de considérer la moyenne de ces dernières (opération dite d'average pooling). L'opération « max pooling » étant, selon plusieurs études (Suárez-Paniagua et al., 2018), plus performante que celle de « average pooling », cette première est largement utilisée. Par ailleurs, l'étape de pooling permet clairement la réduction du nombre de caractéristiques à utiliser dans la couche de convolution suivante. Par ailleurs, le nombre de couches convolutives et de couches de pooling dans un réseau dépend de la complexité des données d'entrée. Ce nombre est généralement contraint par un compromis entre performance et complexité de calcul. La dernière étape de la partie « extraction des caractéristiques » est le « flattening » qui consiste simplement à mettre bout à bout toutes les matrices résultantes pour en faire un seul long vecteur.

- **Couches d'activation**

Cette couche représente la dernière opération de la couche convolutive qui consiste à l'application d'une fonction d'activation. L'expression « fonction d'activation » vient du terme biologique « potentiel activation », un seuil de stimulation qui, s'il est atteint, provoque la réponse d'un neurone. Par définition, les fonctions d'activation sont des fonctions mathématiques qui déterminent la sortie des cellules d'un réseau de neurones. La fonction est ainsi attachée à chaque neurone du réseau et détermine s'il doit être activé ("déclenché") ou non, selon que l'entrée de chaque neurone est pertinente pour la prédiction du modèle. Les fonctions d'activation aident également à normaliser la sortie de chaque neurone dans une plage comprise entre 0 et 1 ou entre -1 et 1. On peut imaginer la fonction d'activation comme une porte entre l'entrée qui alimente le neurone actuel et sa sortie connectée à la couche suivante. Plus simplement, il peut s'agir d'une fonction d'étape qui active et désactive la sortie du neurone, en fonction d'une règle ou d'un seuil.

La fonction d'activation ReLU (rectified linear unit) est l'opération la plus utilisée, elle est appliquée par pixel et consiste à remplacer toutes les valeurs négatives par zéro. Ils existent d'autres fonctions d'activation (c.f. Figure 2.4), mais ReLU reste la plus populaire car elle est simple à calculer et donne d'excellents résultats.

Activation function	Equation	Example	1D Graph
Unit step (Heaviside)	$\phi(z) = \begin{cases} 0, & z < 0, \\ 0.5, & z = 0, \\ 1, & z > 0, \end{cases}$	Perceptron variant	
Sign (Signum)	$\phi(z) = \begin{cases} -1, & z < 0, \\ 0, & z = 0, \\ 1, & z > 0, \end{cases}$	Perceptron variant	
Linear	$\phi(z) = z$	Adaline, linear regression	
Piece-wise linear	$\phi(z) = \begin{cases} 1, & z \geq \frac{1}{2}, \\ z + \frac{1}{2}, & -\frac{1}{2} < z < \frac{1}{2}, \\ 0, & z \leq -\frac{1}{2}, \end{cases}$	Support vector machine	
Logistic (sigmoid)	$\phi(z) = \frac{1}{1 + e^{-z}}$	Logistic regression, Multi-layer NN	
Hyperbolic tangent	$\phi(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$	Multi-layer Neural Networks	
Rectifier, ReLU (Rectified Linear Unit)	$\phi(z) = \max(0, z)$	Multi-layer Neural Networks	
Rectifier, softplus	$\phi(z) = \ln(1 + e^z)$	Multi-layer Neural Networks	

Copyright © Sebastian Raschka 2016
(<http://sebastianraschka.com>)

Figure 2.4 - Différentes fonctions d'activation pour un réseau de neurones
(Image extraite du site <https://sebastianraschka.com/faq/docs/activation-functions.html>)

- **Couche entièrement connectée**

Le bloc de couches entièrement connectées (fully connected layer) n'est rien d'autre qu'un réseau dense de neurones entièrement connectés entre eux. Le rôle de ce bloc est de classifier, à partir de l'ensemble des cartes de caractéristiques résultant des différentes couches de convolution, l'image introduite à l'entrée du CNN. La dernière couche du bloc de couches entièrement connectées est la couche de sortie. Le nombre de neurones dans cette dernière couche est égal à celui des classes prédéfinies. Il convient de noter que l'entrée du bloc de couches entièrement connectées est le vecteur obtenu à la sortie de la couche de mise en commun (flattening). Le modèle est ensuite capable de distinguer les caractéristiques dominantes par rapport à celles qui sont moins importantes après une série d'époques (epochs). Une époque correspond à un cycle d'entraînement complet sur la totalité de la base d'entraînement (Gardy, 2021).

Il existe plusieurs architectures de réseaux de neurones convolutifs qui ont largement contribué à la mise en place et au développement des algorithmes d'IA. Parmi ces architectures nous pouvons citer AlexNet, VGGNet GoogLeNet, ResNet, ZFNet, et LeNet.

2.2.4 Bases d'apprentissage, de validation et de test

Généralement, en apprentissage automatique, pour entraîner et tester un modèle, une base de données constituée d'une grande quantité d'exemples appartenant à plusieurs catégories est utilisée. A partir de cette base de données, le modèle devra apprendre à reconnaître et à classer. En pratique, la base de données est divisée en 3 parties :

- Base d'apprentissage
- Base de validation
- Base de test

La base d'apprentissage : c'est l'ensemble des données utilisées pour entraîner le modèle et apprendre les meilleures caractéristiques des données de cette base.

La base de validation : c'est l'ensemble des données utilisées pour fournir une évaluation non biaisée de la qualité du modèle appris. Ce processus de validation permet entre autres de fournir des informations permettant d'ajuster les hyperparamètres du modèle.

La base de test : c'est l'ensemble des données utilisées pour fournir une évaluation non biaisée du modèle entraîné.

La suite de ce chapitre est consacrée à une brève présentation de l'état de l'art des méthodes de détection des HFOs suivie par une présentation plus détaillée des méthodes de classification existantes, la classification étant le cœur de ce manuscrit.

2.3. Généralités sur la détection des HFOs

Habituellement, chez un patient épileptique, le signal SEEG est enregistré pendant deux à trois semaines (Naeini, 2012). L'objectif principal de cet enregistrement est d'identifier et de localiser la zone cérébrale à l'origine des crises afin d'envisager la stimulation électrique ou la résection chirurgicale (Kahane et al., 2006; Bartolomei et al., 2017). Généralement, la durée moyenne des HFOs varie de 10 à 100 ms (Naeini, 2012). Toutefois, cette durée est

extrêmement petite comparée à la durée entière du signal enregistré pendant quelques jours. La détection visuelle des HFOs sur des données SEEG de longue durée est un processus extrêmement fastidieux qui exige beaucoup de concentration mentale (Zijlmans et al., 2012). En effet, la fatigue ou la distraction pendant le marquage visuel peut facilement mener à des erreurs par les neurologues (Gardner et al., 2007; Naeini, 2012). De plus, la procédure de détection visuelle est chronophage. On estime à environ 10 heures le temps nécessaire pour marquer visuellement des HFOs sur 10 minutes d'activité cérébrale enregistrée sur 10 canaux (Zelmann et al., 2012). Ainsi, les méthodes visuelles peuvent engendrer des interprétations subjectives. Par conséquent, la détection automatique de ces anomalies cérébrales paraît cruciale pour une analyse objective de la maladie de l'épilepsie. De plus, les outils automatisés s'avèrent nécessaires surtout pour un traitement d'une grande quantité de données SEEG et une analyse de la variabilité des événements HFOs (amplitude, durée, caractéristiques spectrales).

L'objectif primordial de la détection automatique des HFOs consiste à les séparer de l'activité de fond. Pour ce faire, de nombreux algorithmes proposés dans la littérature implémentent une série d'étapes communes basées sur des techniques classiques de traitement du signal. La majorité des méthodes proposées de détection des HFOs utilisent des métriques basées sur l'énergie. Parmi les nombreuses mesures existantes d'énergie, les plus couramment utilisées sont la racine de la moyenne du signal au carré (RMS : root-mean-square) (Staba et al., 2002; Zelmann et al., 2009; Chaibi et al., 2013; Gliske et al., 2016; Cimbálník et al., 2018), la puissance (Biro et al., 2013), la longueur de ligne à court terme (STLL : short time line length) (Gardner et al., 2007; Worrell et al., 2008; Pail et al., 2013) et l'enveloppe de la transformée d'Hilbert (Crépon et al., 2010; Burnos et al., 2014; Krikid et al., 2020). Après le calcul de l'énergie, les événements détectés comme HFOs sont ceux dont l'énergie est, pendant une durée minimale égale à 6 ms, supérieure à un seuil prédéterminé. La valeur du seuil peut être choisie égale à 5 écarts-types (SD : standard deviation) (Staba et al., 2002; Crépon et al., 2010) au-dessus de la valeur moyenne du signal filtré. De plus, un seuil non paramétrique basé sur la fonction de distribution cumulative empirique (Gardner et al., 2007) peut être considéré. En outre, pour une détection des HFOs basée sur l'énergie, un nombre minimal de cycles oscillatoires de chaque événement étudié est nécessaire. Les événements, qui sont séparés par moins d'une période de temps minimale égale à 10 ms, sont souvent concaténés pour former un seul événement. Bien souvent, le filtrage des événements transitoires dans l'EEG peut générer une activité à hautes fréquences, qui peut être faussement détectée comme une HFO (Bénar et al., 2010). Les signaux d'origine non neuronale, tels que les activités musculaires et les harmoniques du bruit peuvent également provoquer des détections de faux positifs (Ren et al., 2019). Pour cette raison, de nombreux algorithmes incluant des étapes de rejet des faux positifs après la détection initiale ont été proposés (Charupanit et al., 2017). Bien que cela augmente la spécificité du détecteur, cela introduit également des paramètres supplémentaires qui doivent être optimisés. Le rejet visuel est couramment utilisé, en particulier couplé à des détecteurs de faible sensibilité (Fedele et al., 2017).

La procédure de détection des HFOs est composée de deux étapes : la détection et la classification. Bien souvent, pour une application clinique des HFOs, non seulement la procédure de détection est importante, mais aussi la classification des différents événements de HFOs et leur discrimination vis-à-vis d'autres événements transitoires (Jrad et al., 2017; Sciaraffa et al., 2020; Zuo et al., 2019). Comme mentionné précédemment, ce travail de thèse concerne uniquement la phase de classification.

2.4. Classification des HFOs : état de l'art

Plusieurs algorithmes ont été développés pour la classification automatique des HFOs. Généralement, ces algorithmes suivent principalement deux étapes (Figure 2.5) : (i) extraction de caractéristiques, permettant de caractériser les événements HFOs et (ii) classification de ces caractéristiques, permettant de les séparer en groupes (classes) particuliers, par exemple Gamma (γ), High-Gamma ($H\gamma$), Ripples (Rs), Fast-Ripples (FRs)..., ou de les distinguer des autres événements tels que les IESs.

L'étape d'extraction des caractéristiques est un processus de réduction de dimensionnalité par lequel les données d'entrée sont généralement réduites à un ensemble de caractéristiques à partir de ces données d'origine appelées vecteur de caractéristiques. Ces caractéristiques sont des informations pertinentes qui peuvent aider à identifier un objet ou une entité. Cela permet ainsi de réduire efficacement la redondance dans les données.

Dans le contexte des HFOs, l'étape d'extraction de caractéristiques est généralement effectuée dans le domaine temporel, le domaine fréquentiel et/ou le domaine TF. De plus, les caractéristiques peuvent inclure des mesures linéaires et non linéaires.

L'étape de classification peut être effectuée en utilisant des algorithmes de classification supervisée comme l'analyse linéaire discriminante (LDA : linear discriminant analysis), la machine à vecteurs de support (SVM : support vector machine), la régression logistique (LR : logistic regression), la forêt d'arbres décisionnels (RF : random forest) ou non supervisée comme les algorithmes k -moyennes (k -means), k -médoides (k -medoids), etc...

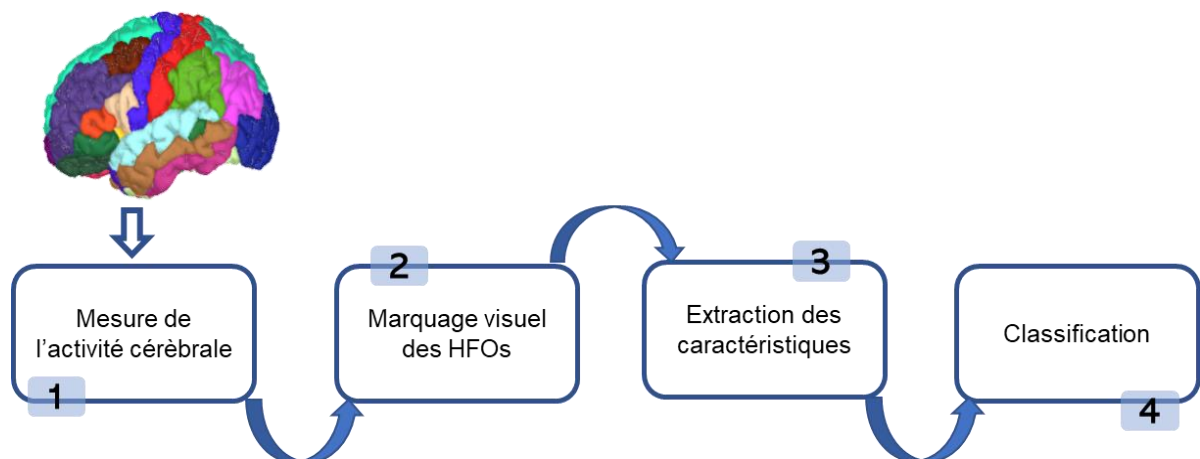


Figure 2.5 - Schéma de classification de HFOs

Nous détaillons dans ce qui suit les approches basées sur les techniques ML et DL développées dans la littérature pour la classification des HFOs.

2.4.1 Approches basées sur les techniques ML

2.4.1.1 Approches basées sur les domaines temporel et/ou fréquentiel

Pour la classification automatique des HFOs, plusieurs approches basées sur le domaine temporel, fréquentiel ou temps-fréquence ont été proposées dans la littérature. Dans cette sous-section, une brève revue sur ces techniques est présentée.

Dans une étude publiée en 2007, les auteurs (Firpi et al., 2007) ont proposé l'algorithme PSO-NN (particle swarm optimization–neural network). Cet algorithme est basé sur l'optimisation des essaims de particules (PSO : particle swarm optimization) et des réseaux de neurones pour générer des caractéristiques pertinentes qui séparent les HFOs et l'activité de fond (classification binaire), en utilisant le classifieur des k -plus proches voisins (KNN : k -nearest neighbors). En revanche, une étude proposée en 2010 par Blanco *et al.* (Blanco et al., 2010) a montré que la classification des HFOs est un problème multi-classes si les différentes bandes de HFOs sont prises en compte. Dans ce contexte, (Blanco et al., 2010) ont proposé une méthode de classification basée sur les k -médoïdes pour différencier entre les différentes classes d'HFOs et les discriminer des artefacts. Cet algorithme utilise des caractéristiques telles que la longueur de ligne (LL : line length) et le centroïde spectral, extraites à partir des domaines temporel et fréquentiel. En fait, les différentes caractéristiques extraites pour chaque HFO ont permis d'identifier quatre clusters différents dont trois concernant les Rs, FRs et Rs + FRs (les FRs se produisent simultanément avec les Rs) et un quatrième cluster pour les artefacts.

Bien souvent, dans les signaux EEG épileptiques, la distinction entre les vrais et les faux HFOs est une étape déterminante. Dans ce contexte, Dümpelmann *et al.* (Dümpelmann et al., 2012) ont proposé des caractéristiques basées sur le calcul d'énergie à court terme (STE : short time energy) et sur la fréquence instantanée. Ces caractéristiques ont été introduites à l'entrée d'un réseau de neurones à base radiale (RBF : radial basis function). Depuis, avec l'intérêt croissant pour les HFOs comme biomarqueurs pertinents pour le diagnostic de l'épilepsie, plusieurs auteurs se sont penchés sur la question de leur origine physiologique. Dans ce contexte, pour distinguer entre des HFOs physiologiques et pathologiques (comme biomarqueur de la ZE), les équipes de Matsumoto et Cimbálik (Matsumoto et al., 2013; Cimbálik et al., 2018) ont utilisé une cascade de caractéristiques temporelles et fréquentielles comme entrée pour le classifieur SVM.

Chaibi *et al.* (Chaibi et al., 2014) ont considéré des caractéristiques telles que la moyenne, l'écart-type, le nombre de passages par zéro et le maximum de la densité spectrale. Une classification par arbres de décision (DT : decision tree) a été ensuite utilisée pour distinguer les HFOs de l'activité de fond. Dans le même contexte de discrimination des HFOs, Liu *et al.* (Liu et al., 2016) ont considéré un modèle de mélange gaussien (GMM : Gaussian mixture models) pour regrouper les données en HFOs et non HFOs. Le calcul d'entropies a également été utilisé dans plusieurs recherches dans le but de caractériser l'aspect pathologique des HFOs, telles que l'entropie approximative (López-Cuevas et al., 2013) et l'entropie floue (Wan et al., 2016). Pour augmenter la séparabilité entre les différentes classes des HFOs et les IESs, Jrad et al. (Jrad et al., 2017) ont utilisé le rapport d'énergie entre les différentes bandes de HFOs en se basant sur les atomes de Gabor. Ensuite, un classifieur basé SVM multi-classe a été appliqué. Récemment, l'entropie des ondelettes et l'énergie de Teager ont été utilisées avec les algorithmes k -means et le décalage moyen (mean-shift) dans (Du et al., 2019) pour

former des clusters de HFOs. Plus récemment, d'autres études se sont concentrées sur la discrimination entre les différentes bandes de HFOs en utilisant l'énergie quadratique moyenne (Lachner-Piza et al., 2020), l'énergie de la LL (Lachner-Piza et al., 2020), l'énergie à courte durée et l'énergie de Teager (Sciaraffa et al., 2020) comme caractéristiques. Cinq algorithmes d'apprentissage automatique différents (SVM, LDA, RF, LR et KNN) ont été utilisés dans (Sciaraffa et al., 2020) pour une multi-classification des HFOs en trois classes *i.e.* Rs, FRs et Spikes (Figure 2.6).




Figure 2.6 - Exemple de HFOs. Figure adaptée de (Zijlmans et al., 2017)

2.4.1.2 Approches basées sur le domaine temps-fréquence

Nous nous intéressons dans cette section à des approches TF adaptées à la classification des HFOs.

La représentation TF permet de décrire la variation dans le temps de contenus fréquentiels de signaux non stationnaires (Boashash, 2016) permettant ainsi la mise en évidence de certaines caractéristiques de ce type de signaux. Le domaine TF a été largement utilisé dans le diagnostic de plusieurs maladies neurologiques telles que la maladie d'Alzheimer (Fiscon et al., 2018), la classification de crises épileptiques (Krishnan et al., 2016) et des stades du sommeil (Ghasemzadeh et al., 2019). Plusieurs études ont également intégré l'analyse TF pour étudier la physiologie des HFOs (Axmacher et al., 2008; Bénar et al., 2010; Wang et al., 2013; Birot et al., 2013; Burnos et al., 2014; Amiri et al., 2016).

Les HFOs présentent une signature particulière (*blobs*) dans la représentation TF comme montré sur la Figure 2.7. En effet, cette figure montre que lorsque ces événements sont analysés dans une large bande comprenant des fréquences plus basses, ils apparaissent généralement comme des « îlots isolés » dans la bande des hautes fréquences (Jmail, 2012). Cette caractéristique est le support sur lequel la plupart des détecteurs de HFOs basés sur l'analyse TF (Burnos et al., 2014; Jrad et al., 2017) sont fondés. Cependant, la co-apparition des HFOs avec une activité très intense telle que les activités transitoires de différentes amplitudes, formes et durées peut masquer les composantes fréquentielles de l'événement HFOs, réduisant ainsi la possibilité d'être étudié et analysé (Bénar et al., 2010; Jmail et al., 2011; Chaibi et al., 2014; Amiri et al., 2016). Ceci conduit par conséquent à augmenter le taux

de fausse classification. Néanmoins, des stratégies de traitement du signal comme le blanchiment ou l'égalisation spectrale (Roehri et al., 2016), l'analyse en composantes morphologiques (MCA : morphological component analysis) (Chaibi et al., 2014) ont été suggérées pour améliorer l'identification des HFOs et les séparer des autres types d'événements qui peuvent apparaître dans les signaux SEEG.

Dans le cas de la classification des HFOs, différentes représentations TF ont été utilisées comme la transformée de Stockwell (Burnos et al., 2014; Migliorelli et al., 2020) qui combine les avantages d'une transformation de Fourier à court terme (STFT : short time Fourier transform) et la transformée en ondelettes continue (CWT : continuous wavelet transform). De plus, la STFT a été utilisée pour la classification de vrais HFOs vs faux HFOs à l'aide de l'algorithme k -means (Liu et al., 2015; 2016). Plus particulièrement, Liu *et al.* (Liu et al., 2016) ont étudié l'utilisation de caractéristiques plus avancées telles que l'entropie spectrale, le rapport de puissance des sous-bandes et la fréquence. Les résultats de cette étude montrent que ces caractéristiques sont capables de mieux discriminer les zones du début des crises épileptiques SOZ comparées aux caractéristiques traditionnelles des HFOs telles que les caractéristiques basées sur le calcul d'énergie (Staba et al., 2002; Gardner et al., 2007; Crépon et al., 2010).

Récemment, le CWT a été utilisé pour classifier les HFOs en trois classes *i.e.* HFOs, pointes épileptiques et HFOs avec des pointes épileptiques (Remakanthakurup Sindhu et al., 2020). De plus, des études (Migliorelli et al., 2020; Donos et al., 2020) ont été réalisées pour classifier les HFOs à partir des images associées à leurs représentations TF. Plus précisément, l'étude présentée dans (Migliorelli et al., 2020) consistait à convertir chaque représentation de la transformée en S de l'événement étudié en image binaire. Ensuite, des caractéristiques liées à la forme de la région d'intérêt (ROI : region of interest) ont été extraites de ces images binarisées. Une classification basée GMM a été utilisée pour déterminer si la ROI correspond à une HFO (R ou FR) ou non (*i.e.* artéfact). Pour distinguer les vrais et les faux HFOs, les auteurs dans (Donos et al., 2020) ont proposé un algorithme qui traite chaque carte TF en tant qu'image. Cet algorithme sert à l'extraction des attributs temporels et fréquentiels de chaque événement détecté selon sa position dans l'image TF.

Le Tableau 2.1 récapitule les différentes approches temporelles et fréquentielles ainsi que les méthodes basées sur le domaine TF associées aux différents travaux de recherche dédiés à la classification des HFOs.




Figure 2.7 - Représentations de différentes classes de HFOs. (A) Rs; (B) FRs, (C) Artéfact et (D) Activités épileptiformes. Pour chaque sous-figure, sont représentés le signal SEEG à large bande (en haut), le signal filtré de 80 à 500 Hz (au milieu) et la décomposition temps-fréquence (en bas). Figure adaptée de (Remakanthakurup Sindhu et al., 2020)

2.4.2 Approches basées sur l'apprentissage profond

Ces dernières années, l'apprentissage profond a été largement appliqué dans divers domaines tels que la vision par ordinateur, la classification des images médicales et la reconnaissance de la parole (LeCun et al., 2015; Liu et al., 2019). En Outre, l'apprentissage profond a montré des performances remarquables dans des problèmes de traitement d'images médicales tels que la classification des patches d'images pulmonaires (Li et al., 2014), la classification des images mammographiques du cancer du sein (Kaur, 2016). L'apprentissage profond a également prouvé son efficacité dans le diagnostic de plusieurs maladies neurologiques (Soleimani et al., 2021), notamment la classification de crises épileptiques (Rashed-Al-Mahfuz et al., 2021), la classification de la schizophrénie (Jie Sun et al., 2021) ainsi que la classification de stades du sommeil (Jadhav et al., 2020).

Récemment, quelques architectures d'apprentissage profond ont été proposées Dans le contexte de la classification des HFOs. Bernardo *et al.* (Bernardo et al., 2018) ont développé un algorithme basé CNN uni-dimensionnel (1D) qui a été conçu pour apprendre les caractéristiques de FRs à partir des signaux EEG en vue de distinguer leur vraie et fausse détection. Pour une classification binaire des Rs (80-200 Hz) et des FRs (200-500 Hz), Zuo *et al.* (Zuo et al., 2019) ont développé un algorithme basé sur le CNN. Ce dernier prenait en entrée une image 2D du signal 1D filtré entre 80 et 500 Hz pour chaque type d'événement.

Tableau 2.1 - Approches basées ML pour la classification des HFOs

Etude	Technique de classification	Classes
(Firpi et al., 2007)	Supervisée/KNN	Binaire (HFOs/activité du fond)
(Blanco et al., 2010)	Non supervisée/K-médoïdes	Multi-classes (Rs; FRs; Rs+FRs/artéfacts)
(Dümpelmann et al., 2012)	Supervisée/RBF	Binaire (vrais HFOs/faux HFOs)
(Matsumoto et al., 2013)	Supervisée/SVM	Binaire (HFOs physiologiques/HFOs pathologiques)
(Chaibi et al., 2014)	Supervisée/DT	Binaire (HFOs/activité du fond)
(Su Liu et al., 2016)	Non supervisée/GMM	Binaire (HFOs/bruit)
(Amiri et al., 2016)	Supervisée/SVM	Binaire (HFOs/IESs)
(Wan et al., 2016)	Supervisée/réseaux de neurones flous	Binaire (HFOs/activité normale)
(Jrad et al., 2017)	Supervisée/SVM	Multi-class (γ /H γ / Rs/FRs/IESs)
(Du et al., 2019)	Semi-supervisée/décalage moyen et k -moyennes	Clustering
(Lachner-Piza et al., 2020)	Supervisée/SVM	Multi-classes (Rs, FRs; IESs+Rs; IESs+FRs)
(Sciaraffa et al., 2020)	Supervisée/SVM, LDA, LR, KNN, RF	Multi-classes (Rs; FRs; FRs+Rs)
(Migliorelli et al., 2020)	Non supervisée/GMM	Clustering (HFOs/non HFOs)

Les CNNs se montrent particulièrement performants pour la classification des images. Dans ce contexte, Lai *et al.* (Lai et al., 2019) ont développé un algorithme basé CNN pour une classification binaire (HFOs, non HFOs) en utilisant une image TF 2D comme entrée pour le CNN (Figure 2.8). Cette étude est la première qui a exploité la capacité du CNN dans le traitement des images TF pour la classification binaire des HFOs.

De plus, la technique d'apprentissage par transfert (TL : transfer learning) a été utilisée aussi dans le contexte de la classification des HFOs (Zhao et al., 2020). Cette technique a été particulièrement utilisée pour (i) éviter le temps inutile nécessaire à l'apprentissage du modèle et (ii) éviter les problèmes de sous-apprentissage et sur-apprentissage qui peuvent être engendrés par le manque de données. Pour pallier le problème de manque de données, Nadalin *et al.* (Nadalin et al., 2021) ont intégré la procédure d'augmentation de données (DA : data augmentation), notée AD par la suite, pour générer des données artificielles en vue d'améliorer la diversité des données d'entraînement.

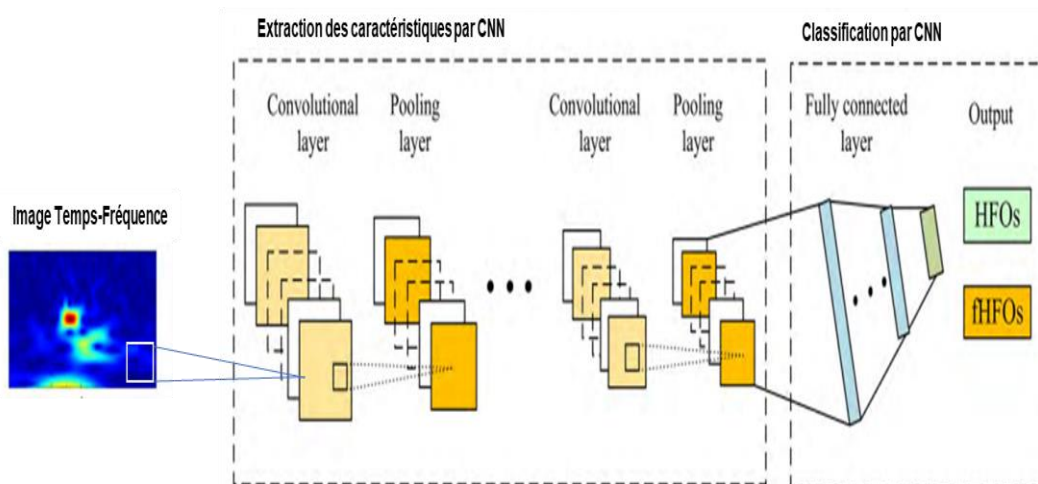


Figure 2.8 - Extraction des caractéristiques et classification par CNN. Figure adaptée de (Lai et al., 2019)

Le Tableau 2.2 récapitule les différentes approches d'apprentissage profond associées aux différents travaux de recherche dédiées à la classification des HFOs.

Tableau 2.2 - Approches basées sur le DL pour la classification des HFOs

Etude	Technique de classification	Classes
(Bernardo et al., 2018)	1D-CNN	Binaire (vrais FRs/faux FRs)
(Zuo et al., 2019)	1D-CNN	Binaire (Rs/FRs)
(Lai et al., 2019)	2D-CNN	Binaire (HFOs/non HFOs)
(Zhao et al., 2020)	2D-CNN/TL	Binaire (Artéfacts/non artéfacts HFOs/non HFOs)
(Liu et al., 2021)	2D-LSTM/CNN	Binaire

(vrais HFOs/faux HFOs)		
(Takayanagi et al., 2021)	2D-CNN/TL	Binaire (HFOs/non HFOs)
(Nadalin et al., 2021)	2D-CNN/TL	Binaire (Rs/Rs+IESs)

2.5. Conclusion

Dans ce chapitre, nous avons en premier lieu présenté les concepts de base de cette thèse, qui sont issus de deux sous-domaines de l'intelligence artificielle : l'apprentissage automatique et l'apprentissage profond. Ensuite, nous avons rappelé les principales approches rencontrées dans la littérature sur la classification automatique des HFOs. En effet, deux grandes familles d'approches de classification des HFOs sont largement répandues à savoir les approches basées sur des méthodes d'apprentissage automatique et celles basées sur l'apprentissage profond. En fait, les méthodes d'apprentissage automatique sont généralement uniquement basées sur des caractéristiques extraites du plan temporel, fréquentiel ou TF de l'événement étudié. Les méthodes d'apprentissage profond sont basées sur l'extraction de caractéristiques et la classification des images TF à l'aide de réseaux de neurones convolutifs. Ces derniers s'avèrent être le meilleur choix pour les problèmes de classification des images. Toutefois, d'après le Tableau 2.2, Il convient de noter que ces approches basées sur l'apprentissage profond sont limitées à une classification binaire (HFOs vs non HFOs). En outre, aucune des méthodes précédentes ne prend en compte l'ensemble de la bande des HFOs (de γ à FRs). Dans le troisième chapitre, nous proposons de développer deux nouvelles méthodes pour la multi-classification des biomarqueurs de l'épilepsie (*i.e.* HFOs et IESs) qui tiennent en compte de la bande de fréquences de chaque événement d'intérêt.

Chapitre 3. Approches proposées

3.1. Introduction

Pour une meilleure caractérisation de la ZE, non seulement l'étape de détection des HFOs est importante mais aussi leur classification. Comme évoqué dans le chapitre précédent, plusieurs travaux de recherche (Firpi et al., 2007; Blanco et al., 2010; Migliorelli et al., 2020) montrent l'intérêt d'étudier les différentes caractéristiques des HFOs pour l'étape de classification. La plupart des techniques mises en œuvre à ce jour présentent des inconvénients, étant limitées couramment à l'utilisation de caractéristiques dans les domaines temporel, fréquentiel et/ou temps-fréquence. Toutefois, ces caractéristiques ne permettent pas toujours de caractériser la nature non stationnaire des HFOs et surtout de donner une caractérisation complète de ces événements cérébraux. Pour faire face à cette limitation, nous proposons deux nouvelles approches pour la multi-classification des HFOs basées sur l'analyse TF : la première, développée en section 3.3, est une approche d'apprentissage machine basée sur la combinaison de certaines caractéristiques extraites de la représentation TF des événements d'intérêt avec d'autres calculées à partir de l'image TF binarisée associée. Ce couplage (ou combinaison) a pour objectif de fournir une caractérisation complète des événements d'intérêt. La deuxième approche, développée dans la section 3.4, vise à fournir une méthode de multi-classification automatique des HFOs basée sur le CNN. Récemment, les CNNs ont montré leur capacité à obtenir de très bonnes performances mais ces performances dépendent généralement de la quantité de données utilisée pour l'entraînement. Ainsi, nous nous intéressons à l'augmentation de données (AD) qui peut s'avérer efficace sur une base de données limitée. De ce fait, nous intégrerons cette procédure pour générer de nouvelles images TF et évaluer son impact sur la performance du modèle CNN proposé.

Dans ce chapitre, nous commencerons par une description détaillée des données cliniques et bruitées utilisées. Ensuite, nous présenterons la méthodologie adoptée pour les deux approches proposées.

3.2. Bases de données

Dans ce travail, deux types de bases de données ont été utilisées pour évaluer la performance des approches proposées : la première contient des signaux SEEG réels enregistrés lors de l'évaluation pré-chirurgicale de patients épileptiques et la deuxième base de données concerne des versions bruitées des signaux SEEG collectés dans la première base de données. Pour l'ensemble de signaux étudiés, la vérité terrain est disponible (type des événements HFOs, rapport signal sur bruit (SNR : signal to noise ratio)).

3.2.1 Données cliniques

Les signaux SEEG réels ont été recueillis chez cinq patients souffrant d'épilepsie réfractaire dans le service de neurologie du centre hospitalo-universitaire (CHU) de Rennes, France. Ce suivi faisait partie de l'évaluation clinique pré-chirurgicale habituelle des patients et visait à délimiter les zones cérébrales épileptogènes. Tous les patients ont donné leur consentement éclairé pour participer aux études de recherche.

Un système d'enregistrement 256-Brain Quick (Micromed, Italie) avec une fréquence d'échantillonnage de 2048 Hz a été utilisé pour l'acquisition des données. Le marquage visuel des événements HFOs a été effectué par deux experts indépendants au Laboratoire Traitement du Signal et de l'Image (LTSI, Inserm U1099) de l'Université de Rennes 1. Un nombre total de 5174 événements marqués ont été employés dans le présent manuscrit. En effet, cinq classes différentes γ , $H\gamma$, Rs, FRs et IESs sont prises en considération dans la procédure d'annotation : γ (1015), $H\gamma$ (1032), Rs (1053), FRs (1071), et IESs (1003) (les nombres entre parenthèses correspondent aux nombres d'événements de ces classes).

3.2.2 Données bruitées

Pour évaluer la robustesse des approches proposées, des données bruitées ont été utilisées. Ces données ont été générées en ajoutant une activité cérébrale de fond simulée à des événements réels de type de ceux décrits ci-dessus. Toutefois, cette nouvelle base contient davantage d'événements que la base précédente. Dans le cas présent, les événements annotés sont : γ (4640), $H\gamma$ (5565), Rs (6495), FRs (6495), et IESs (4640) (les nombres entre parenthèses correspondent aux nombres d'événements de ces classes). L'activité de fond a été simulée au moyen d'un modèle computationnel de population neuronale où des fonctions sigmoïdes ont été utilisées pour contrôler le niveau d'activité de fond. Le SNR a été défini pour contrôler le rapport entre l'événement d'intérêt et l'activité de fond. Cela permet d'évaluer la robustesse des approches proposées pour six valeurs de SNR (-10, -5, 0, 5, 10 et 15 dB). Pour plus de détails sur cette base de données bruitées, le lecteur peut se référer à (Jrad et al., 2017).

3.3. Approche 1 – Classification des oscillations hautes fréquences basée sur la combinaison des caractéristiques extraites de la représentation TF et celles liées à l'image TF associée

Nous détaillons dans cette section la première approche proposée dans ce manuscrit (Krikid et al., 2022). Il s'agit d'une approche basée sur le ML et visant à classifier les HFOs et IESs. L'idée principale de cette approche repose sur la combinaison entre les caractéristiques extraites à partir d'une représentation TF des événements d'intérêt avec d'autres caractéristiques extraites à partir de l'image TF binarisée associée à cette dernière représentation. L'ensemble des caractéristiques est ensuite utilisé pour construire le modèle de classification. A ce titre, nous avons testé quatre algorithmes de classification supervisée : le SVM, le KNN, le RF et le NB. Un intérêt particulier a été réservé à l'algorithme SVM dans la mesure où il a montré les meilleures performances par rapport aux autres classifieurs comme cela sera développé plus en détail dans le chapitre 4. Un organigramme décrivant les

principales étapes de l'approche proposée est donné à la Figure 3.1. Une description détaillée de chaque étape de cet organigramme est présentée dans les sous-sections suivantes.

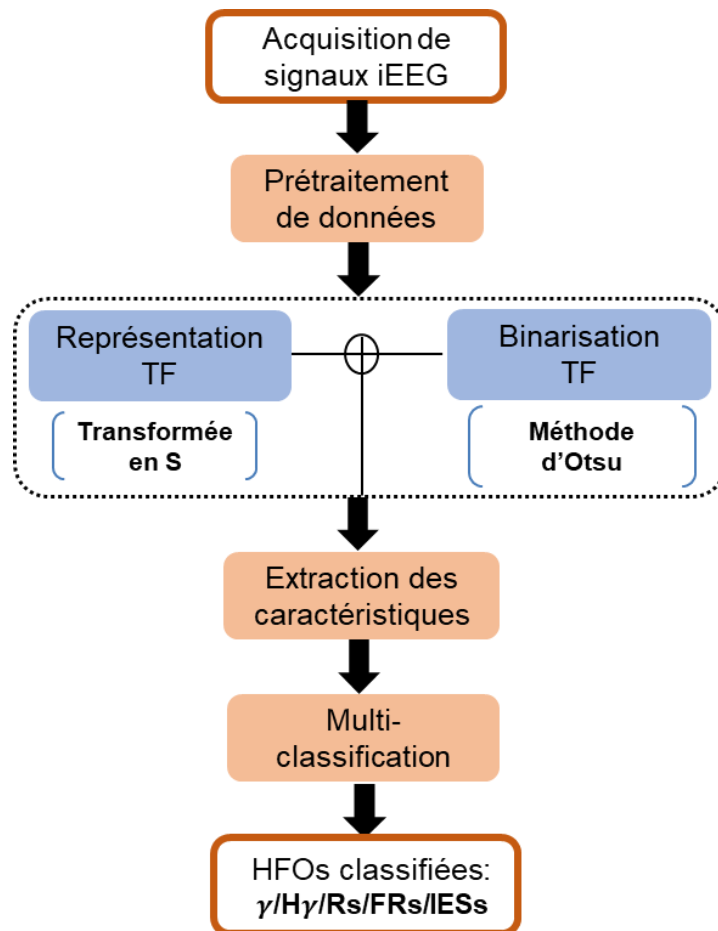


Figure 3.1 - Organigramme proposé pour la multi-classification des HFOs et IESs

3.3.1 Notations

Dans la suite, les matrices sont désignées par des lettres majuscules en gras italique, *i.e.*, \mathbf{A} , les vecteurs sont désignés par des lettres minuscules en gras italique, *i.e.*, \mathbf{a} et les scalaires sont désignés par des lettres minuscules en italique, *i.e.*, a . De plus, le (i, j) ème élément de la matrice \mathbf{A} et la i ème composante du vecteur \mathbf{x} sont notés respectivement par $A(i, j)$ et $x(i)$. Par ailleurs, le symbole $|\cdot|$ désigne soit la fonction de valeur absolue des nombre réels, soit le module en cas d'argument complexe. De plus, les symboles \top et $*$ représentent respectivement les opérateurs de transposition et de convolution.

3.3.2 Prétraitement des données

Après l'étape d'acquisition des données SEEG, suit une étape de prétraitement comme indiqué sur la Figure 3.1. Étant donné que les événements d'intérêt annotés (*i.e.* γ , $H\gamma$, Rs, FRs et IESs) dans notre base de données ne sont pas de même durée, l'étape de prétraitement consiste à représenter chaque événement d'intérêt en un segment d'une durée de 200 ms. Cette période de 200 ms correspond à la moyenne de toutes les périodes d'événements labélisés dans la base de données. Ceci permet de couvrir suffisamment chaque événement sans aucune perte d'information utile. Par la suite, chaque événement d'intérêt de 200 ms est centré de sorte que chaque événement dure de -100 ms à +100 ms.

3.3.3 Analyse temps-fréquence

Les représentations TF permettent de capturer la variation instantanée du contenu fréquentiel d'un signal non stationnaire (Boashash, 2016). Les signaux EEG étant non stationnaires, l'analyse TF est par conséquent une pratique courante dans l'analyse de ces signaux et plus particulièrement pour le diagnostic de troubles neurologiques tels que l'épilepsie (Yan et al., 2019; Mandhouj et al., 2021; Yildiz et al., 2021). Bien souvent, pour atteindre de bonnes performances de classification des HFOs, l'extraction de caractéristiques TF pertinentes nécessite un outil TF permettant une représentation meilleure du contenu des événements HFOs. La transformée de Stockwell (transformée en S) est une méthode puissante d'analyse TF introduite initialement pour traiter les données provenant de l'analyse numérique sismique (Stockwell et al., 1996). C'est une technique de localisation spectrale qui combine des éléments de la transformée en ondelettes (WT : wavelet transform) et de la STFT. Cette méthode a été largement utilisée dans des applications en neurosciences telles que l'identification de la maladie d'Alzheimer (Soleimani et al., 2021), la classification des stades du sommeil (Ghasemzadeh et al., 2019) et la classification de crises épileptiques (Rashed-Al-Mahfuz et al., 2021). Comparée à d'autres transformations TF telles que la transformée de Wigner-Ville (Stockwell, 2007; Ghasemzadeh et al., 2019), la transformée en S présente une meilleure résolution TF. En effet, la forme quadratique de la transformée de Wigner-Ville entraîne généralement l'apparition de termes croisés d'interférence (Boashash, 2016) dans le cas de signaux multi-composantes, ce qui rend l'interprétation visuelle de la représentation TF plus difficile. Par conséquent, avec les avantages cités ci-dessus, la transformée en S présente un outil approprié pour notre étude.

Soit $x[n], n = 0, 1, 2, \dots, N - 1$, une série temporelle à temps discret correspondant à un signal temporel continu donné, où N désigne le nombre d'échantillons. La transformée en S de $x[n]$ calculée à un facteur de décalage temporel $k \in \{0, \dots, N - 1\}$ donné et à un point fréquentiel $m \in \{0, \dots, M - 1\}$, où M représente le nombre de points fréquentiels, est définie comme suit :

$$S[k, m] = \sum_{n=0}^{N-1} x[n] \omega[k - n, m] e^{-i2\pi \frac{m}{M} k} \quad (3.1)$$

où $\omega[k - n, m]$ est une fonction d'ondelette mère spécifique donnée par :

$$\omega[k - n, m] = \frac{|m|}{M\sqrt{2\pi}} e^{-\frac{n^2 m^2}{2M^2}} \quad (3.2)$$

La transformée en S étant appliquée à chaque événement d'intérêt, une représentation TF associée à chacun de ces événements est disponible. Notons qu'afin d'éviter l'effet de bord lié à la transformation TF, une fenêtre de Hanning de 200 ms a été préalablement appliquée à chaque événement d'intérêt. Un exemple de la représentation TF d'un FR est illustré sur la Figure 3.2.




Figure 3.2 - Exemple d'un événement HFO de type FR
(a) : représentation temporelle, (b) : représentation TF

3.3.4 Extraction des caractéristiques

Dans cette étape, qui est le cœur de notre approche, les caractéristiques sont extraites non seulement de la représentation TF conventionnelle (Boashash, 2016) de chaque événement d'intérêt mais aussi de l'image TF binarisée associée. Cette dernière permet d'utiliser des caractéristiques spécifiques dans le domaine de l'analyse et du traitement des images. L'ensemble des caractéristiques extraites permet de donner une description complète de l'événement d'intérêt dans l'espace TF. Nous détaillons dans la suite les différentes caractéristiques déduites de la représentation TF et celles extraites de l'image TF binarisée.

3.3.4.1 Caractéristiques extraites de la représentation TF

Les caractéristiques extraites de la représentation TF ont pour objectif de caractériser la variation, la distribution ainsi que la concentration de l'énergie du signal considéré dans le plan TF comme nous le verrons dans cette section :

- **Le flux Temps-Fréquence** (TF_{flux}) : une mesure de la variation de l'énergie du signal dans le plan TF. Elle est définie par :

$$TF_{flux} [l, r] = \sum_{n=0}^{N-1-l} \sum_{m=0}^{M-1-r} |\bar{S}[n+1, m+1] - \bar{S}[n, m]| \quad (3.3)$$

où $\bar{S}[k, m] = |S[k, m]|^2$. Trois directions possibles sont considérées dans cette étude pour le calcul du flux TF :

- (i) Selon l'axe des temps (*i.e.*, $l = 1, r = 0$), notée $TF_{flux1} = TF_{flux}[1,0]$;
 - (ii) Selon l'axe des fréquences (*i.e.*, $l = 0, r = 1$), notée $TF_{flux2} = TF_{flux}[0,1]$;
 - (iii) Selon les axes de temps et de fréquences (*i.e.*, $l = r = 1$), notée $TF_{flux3} = TF_{flux}[1,1]$.
- **La platitude Temps-Fréquence** ($TF_{platitude}$) : une mesure permettant de quantifier l'uniformité de la distribution de l'énergie du signal dans le plan TF. Elle est définie par :

$$TF_{platitude} = \frac{\prod_{n=0}^{N-1} \prod_{m=0}^{M-1} \bar{S}[n, m]^{\frac{1}{MN}}}{\frac{1}{MN} \sum_{n=0}^{N-1} \sum_{m=0}^{M-1} \bar{S}[n, m]} \quad (3.4)$$

Il est à noter qu'une platitude élevée indique que l'énergie est uniformément distribuée dans la représentation TF tandis qu'une platitude faible indique que l'énergie est concentrée dans des régions spécifiques (Boashash, 2016).

- **La concentration d'énergie** (EC) : une mesure permettant de quantifier la concentration de l'énergie du signal dans le plan TF. Elle est définie par :

$$EC = \left(\sum_{n=0}^{N-1} \sum_{m=0}^{M-1} \bar{S}[n, m]^{1/2} \right)^2 \quad (3.5)$$

Il est à noter que, pour les signaux dont l'énergie est répartie sur tout le plan TF, la mesure EC est élevée, alors que la valeur de cette mesure est petite pour les signaux ayant une énergie concentrée dans certaines zones (Boashash, 2016).

- **Caractéristiques statistiques** : les caractéristiques statistiques telles que la moyenne μ , l'écart-type σ , le skewness sk , le kurtosis ku et le coefficient de variation cv sont également prises en compte. Classiquement, ces caractéristiques sont employées séparément, soit dans le domaine temporel, soit dans le domaine fréquentiel (Boashash, 2016). Récemment, elles ont été étendues au domaine TF et définies respectivement par :

$$\mu = \frac{1}{MN} \sum_{n=1}^N \sum_{m=1}^M \bar{S}[n, m] \quad (3.6)$$

$$\sigma = \sqrt{\frac{1}{MN} \sum_{n=1}^N \sum_{m=1}^M (\bar{S}[n, m] - \mu)^2} \quad (3.7)$$

$$sk = \sqrt{\frac{1}{MN\sigma^2} \sum_{n=1}^N \sum_{m=1}^M (\bar{S}[n,m] - \mu)^3} \quad (3.8)$$

$$ku = \frac{1}{MN\sigma^4} \sum_{n=1}^N \sum_{m=1}^M (\bar{S}[n,m] - \mu)^4 \quad (3.9)$$

$$cv = \frac{\sigma}{\mu} \quad (3.10)$$

3.3.4.2 Caractéristiques extraites de l'image TF binarisée associée

En plus des caractéristiques extraites de la représentation TF de chaque événement d'intérêt, d'autres caractéristiques liées à l'image associée à cette dernière représentation sont également considérées. Ainsi, deux transformations de la représentation TF originale sont effectuées : (i) la binarisation et (ii) le calcul du gradient de l'image binarisée. Des caractéristiques liées à l'image sont ensuite extraites de l'image binarisée et de son image gradient comme précisé ci-dessous.

- Caractéristiques extraites de l'image binarisée

Dans cette étape, nous proposons de procéder à une segmentation par binarisation de l'image TF. Ainsi, la représentation de chaque événement d'intérêt est transformée en une image en niveaux de gris codée sur 8 bits comme illustré sur la Figure 3.3. Ensuite, l'image en niveaux de gris obtenue est binarisée à l'aide de la méthode d'Otsu (Otsu, 1979). Cette méthode permet de classifier les pixels de l'image en deux classes (noir et blanc). Les pixels appartenant à la classe « pixel blanc » sont ceux dont l'intensité est supérieure ou égale à un seuil prédéfini (Otsu, 1979). Ce seuil optimal est déterminé de telle sorte que la variance intra-classe soit minimale. Ainsi, pour chaque image binaire obtenue, désignée ici par Υ , des caractéristiques géométriques sont extraites. Ces dernières caractéristiques peuvent être calculées en utilisant le moment $M_{p,q}$ d'ordre $(p, q) \in \mathbb{N} \times \mathbb{N}$ de l'image défini par :

$$M_{p,q} = \sum_{n=0}^{N-1} \sum_{m=0}^{M-1} n^p m^q \Upsilon(n, m) \quad (3.11)$$

A partir du calcul des moments, nous obtenons les caractéristiques géométriques suivantes :

- (i) L'aire : le nombre de pixels constituant le segment dans l'image

$$Aire = M_{0,0}$$

- (ii) Le périmètre : le nombre de pixels de l'image constituant le contour du segment

$$Périmètre = (M_{3,0} + M_{1,2})^2$$

- (iii) La compacité : une mesure reflétant la forme du segment dans l'image binarisée

$$Compacité = \frac{périmètre^2}{Surface}$$

- (iv) Le centroïde : correspond respectivement aux deux coordonnées temporelles et fréquentielles du centre de chaque événement d'intérêt détecté dans l'image binarisée. Il est défini par $\left(\frac{M_{1,0}}{M_{0,0}}; \frac{M_{0,1}}{M_{0,0}}\right)$.

- Caractéristiques du gradient de l'image

Le calcul du gradient d'une image TF permet de capturer et de caractériser la forme du contour de l'événement d'intérêt. Dans notre étude, pour chaque événement d'intérêt, le gradient de l'image binaire \mathbf{Y} est calculé en convoluant cette dernière avec l'opérateur de gradient $\mathbf{h} = [-1 \ 0 \ 1]$. Cette convolution est effectuée séparément dans les directions temps et fréquence :

$$\mathbf{G}_t = \mathbf{Y} * \mathbf{h} \quad (3.12)$$

$$\mathbf{G}_f = \mathbf{Y} * \mathbf{h}^\top \quad (3.13)$$

où \mathbf{G}_t et \mathbf{G}_f sont respectivement les gradients de l'image suivant les deux axes temps et fréquence.

Ensuite, le module, Γ , du gradient obtenu (Merabet, 2013) est calculée comme suit :

$$\Gamma = \sqrt{\mathbf{G}_t^2 + \mathbf{G}_f^2} \quad (3.14)$$

Une fois l'image du gradient calculée, sa norme $L1$ est considérée comme une caractéristique quantifiant la parcimonie du contour dans l'image TF binarisée associée à l'événement d'intérêt. Cette norme est définie par :

$$\|\Gamma\|_1 = \sum_{n=0}^{N-1} \sum_{m=0}^{M-1} |\Gamma(n, m)| \quad (3.15)$$

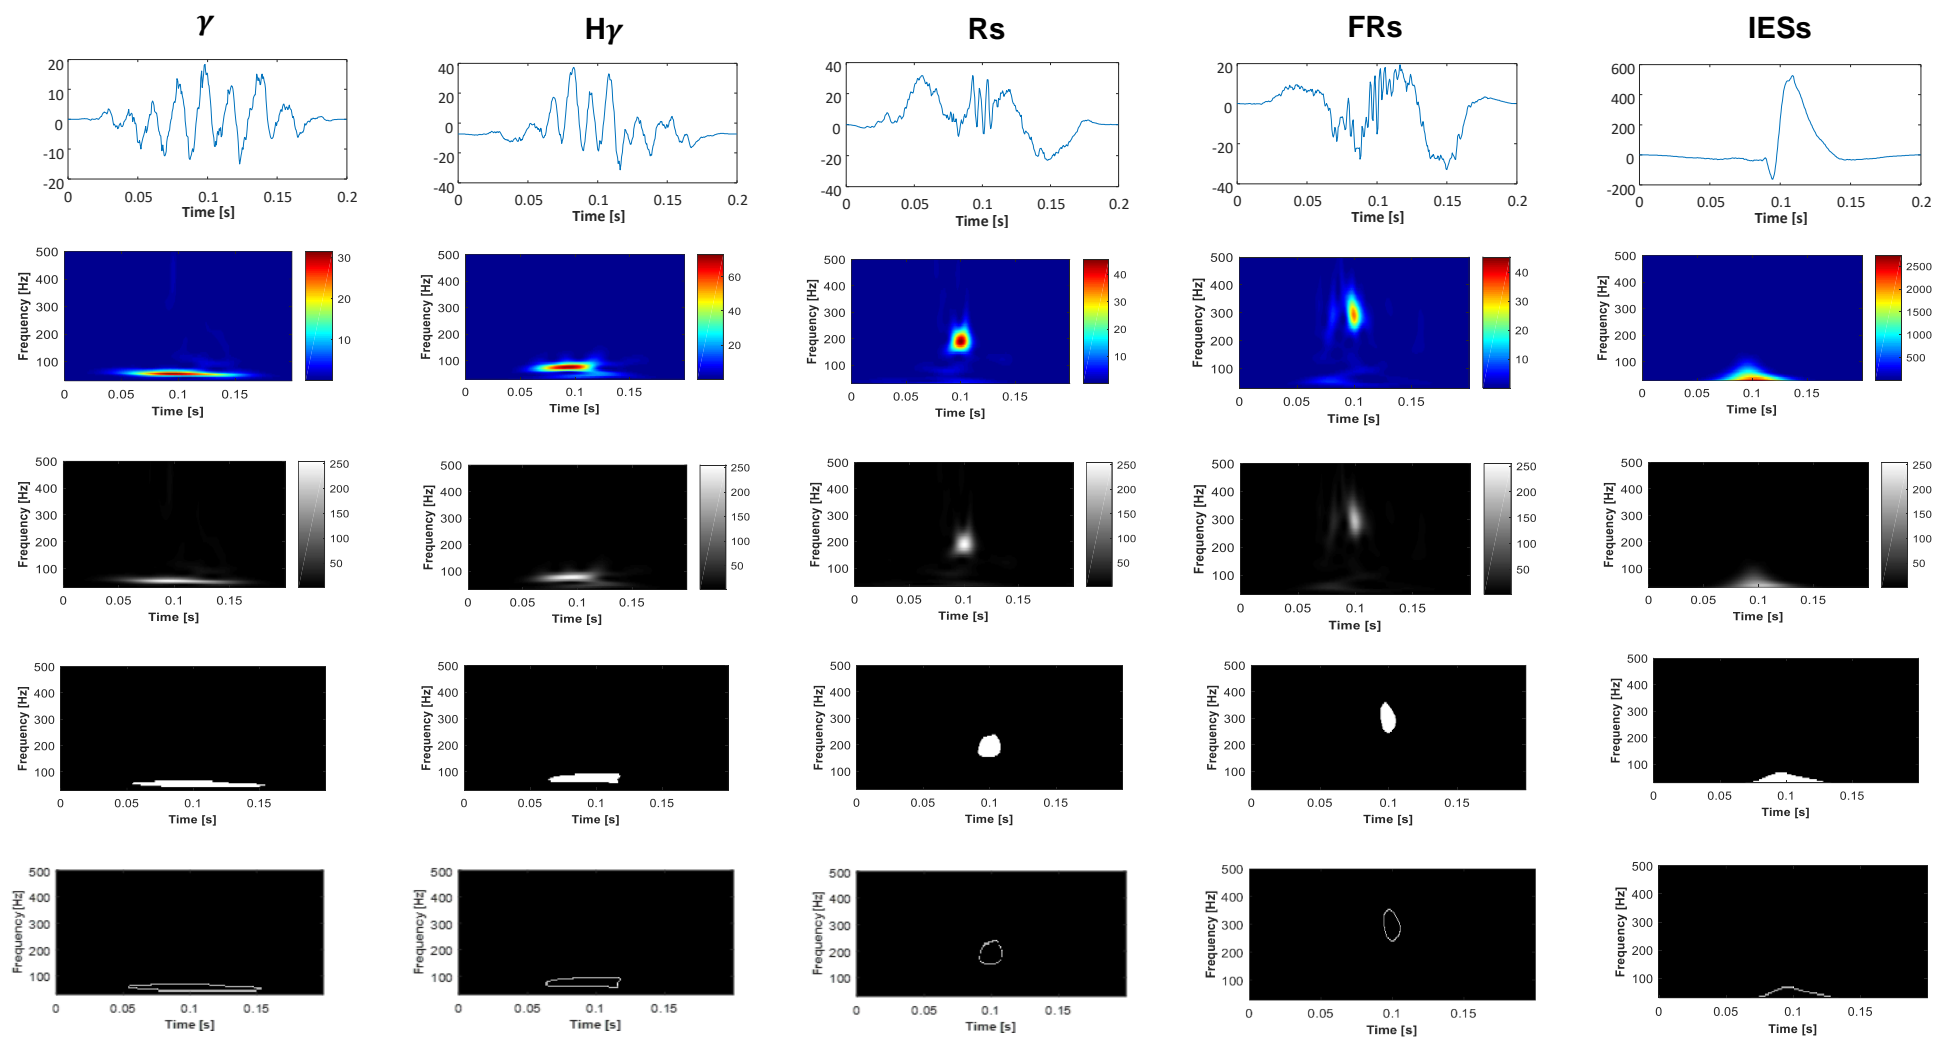


Figure 3.3 - Représentation des événements HFOs et IESs dans le domaine temporel (première ligne) (i) Plan TF (deuxième ligne), (ii) Image en niveaux de gris (troisième ligne), (iii) Image TF binarisée (quatrième ligne) et (iv) gradient de l'image (cinquième ligne)

Tableau 3.1 - Synthèse des différentes caractéristiques utilisées

Type	Nom	Formule
Caractéristiques liées à la représentation TF	Flux TF	$TF_{flux} [l, r] = \sum_{n=0}^{N-1-l} \sum_{m=0}^{M-1-r} \bar{S}[n+1, m+1] - \bar{S}[n, m] $
	Platitude TF	$TF_{Platitude} = \frac{\prod_{n=0}^{N-1} \prod_{m=0}^{M-1} \bar{S}[n, m]^{\frac{1}{MN}}}{\frac{1}{MN} \sum_{n=0}^{N-1} \sum_{m=0}^{M-1} \bar{S}[n, m]}$
	Concentration d'énergie	$EC = \left(\sum_{n=0}^{N-1} \sum_{m=0}^{M-1} \bar{S}[n, m]^{1/2} \right)^2$
	Moyenne	$\mu = \frac{1}{MN} \sum_{n=1}^N \sum_{m=1}^M \bar{S}[n, m]$
	Ecart-Type	$\sigma = \sqrt{\frac{1}{MN} \sum_{n=1}^N \sum_{m=1}^M (\bar{S}[n, m] - \mu)^2}$
	Skewness	$sk = \sqrt{\frac{1}{MN\sigma^2} \sum_{n=1}^N \sum_{m=1}^M (\bar{S}[n, m] - \mu)^3}$
	Kurtosis	$ku = \frac{1}{MN\sigma^4} \sum_{n=1}^N \sum_{m=1}^M (\bar{S}[n, m] - \mu)^4$
	Coefficient de variation	$cv = \frac{\sigma}{\mu}$
	Aire	$Surface = M_{0,0}$
	Périmètre	$Périmètre = ((M_{3,0} + M_{1,2})^2)$
Caractéristiques liées à l'image TF	Compacité	$Compacité = \frac{Périmètre^2}{Surface}$
	Centroïde	$\left(\frac{M_{1,0}}{M_{0,0}}, \frac{M_{0,1}}{M_{0,0}} \right)$
	Norme L1	$\ f\ _1 = \sum_{n=0}^{N-1} \sum_{m=0}^{M-1} f(n, m) $

Finalement, toutes ces caractéristiques (caractéristiques extraites de la représentation TF et caractéristiques liées à l'image TF binarisée associée) sont combinées dans un vecteur de caractéristiques. Ce dernier sera utilisé par la suite pour l'entraînement du classifieur.

3.3.5 Les classifieurs

Comme mentionné précédemment, quatre algorithmes de classification supervisée ont été utilisés, à savoir : SVM, KNN, RF et NB dont les principes sont brièvement rappelés dans les sous-sections suivantes.

3.3.5.1 Machine à vecteurs de support multi-classes

La machine à vecteurs de support (SVM) également nommée séparateur à vaste marge et simplifié par l'acronyme anglais SVM est un algorithme d'apprentissage supervisé introduit en 1995 (Cortes et al., 1995) et conçu pour traiter des données à grandes dimensions. Il est particulièrement adapté pour la classification binaire, c'est-à-dire pour discriminer entre deux classes de données. Il a été ensuite étendu au cas d'une classification multi-classes grâce à la stratégie « un-contre-tous » (Guermeur, 2007). La classification par SVM consiste à chercher l'hyperplan maximisant la séparabilité entre les classes dans l'espace des caractéristiques ou dans un espace transformé de ces dernières. En effet, lorsque la séparabilité entre les différentes classes n'est pas évidente dans le domaine de représentation initial des caractéristiques, une transformation par une fonction dite noyau, notée ici ϕ , est ainsi appliquée. Cette transformation permet, dans l'espace transformé, la mise en évidence des classes linéairement séparables et par conséquent une meilleure définition de l'hyperplan séparateur.

A titre illustratif, supposons, dans le cas d'une classification binaire, que les données d'apprentissage sont constituées de (i) N vecteurs $x_i, 1 \leq i \leq N$, des caractéristiques extraites à partir des événements d'intérêt et (ii) de leurs N annotations (labels), $y_i \in \{-1, +1\} \forall i \in \{1, \dots, N\}$, associées. Ces données d'apprentissage ont pour objectif d'apprendre un classifieur $f(x)$ tel que :

$$f(x) = w^\top \phi(x) + b \quad (3.16)$$

où w est un vecteur de poids, $\phi(x)$ un vecteur de caractéristiques transformées et b un biais. En effet, l'algorithme SVM consiste à trouver l'hyperplan séparateur en résolvant le problème d'optimisation suivant :

$$\begin{aligned} & \underset{w, b}{\operatorname{argmax}} \underset{i}{\operatorname{argmin}} \operatorname{dist}(x_i, w, b) \\ \text{s. t. } & y_i(w^\top \phi(x) + b) \geq 0, \quad \forall i \in \{1, \dots, N\} \end{aligned} \quad (3.17)$$

avec $\operatorname{dist}(x_i, w, b)$ la distance Euclidienne entre le point $\phi(x)$ dans l'espace des caractéristiques considérées et l'hyperplan défini par $w^\top \phi(x) + b = 0$. Le rôle de la contrainte figurant dans le problème d'optimisation est de privilégier une frontière de décision garantissant une classification correcte de toutes les données d'apprentissage. A l'issue de cet apprentissage, la réponse de f à un nouveau vecteur x_q sera égale à $\operatorname{sign}(f(x_q))$ où sign est la fonction signe.

Concernant notre étude, le noyau de fonction radiale (RBF : radial basis function) gaussien est utilisé. La fonction RBF est définie comme $\exp(-\beta\|x_i - x_j\|_2^2)$ où x_i et x_j ($i \neq j$) sont deux vecteurs de caractéristiques de deux exemples différents de la base d'apprentissage et β dénote la largeur de la fonction RBF. Afin d'éviter un possible phénomène de sur-apprentissage/sous-apprentissage du modèle, la technique de régularisation des poids, w , est utilisée. Une telle procédure se traduit par un terme de régularisation, par exemple de type norme $L2$, à rajouter à la fonction de coût du problème (3.17). Il convient de noter que l'ajout d'un terme de régularisation suscite un choix judicieux du paramètre de régularisation associé, notée C dans ce manuscrit. Une stratégie sur le choix des paramètres β et C sera présentée dans le chapitre 4.

3.3.5.2 Algorithme des K -plus proches voisins

L'algorithme des k -plus proches voisins (KNN) est un algorithme d'apprentissage automatique supervisé, à la fois simple et puissant pour des tâches de classification et régression. Cette méthode a été introduite pour la première fois en 1951 par Fix et Hodges (Silverman et al., 1989). Ensuite, de nombreuses extensions de ces méthodes ont été publiées (Tibshirani et al., 2008). Dans le contexte de classification, l'algorithme KNN prédit la classe de l'exemple courant comme étant la classe la plus souvent représentée parmi les k exemples d'apprentissage définis dans un voisinage de l'exemple étudié. En d'autres termes, la classe prédite d'un exemple donné correspond au « vote de la majorité » des k exemples définis dans un voisinage de l'exemple courant.

Plus précisément, supposons à titre illustratif le cas d'une classification binaire et définissons une fonction cible $g(x) = y$ qui associe un exemple x_i (vecteur de caractéristiques) d'apprentissage à l'une des deux classes (i.e. $y \in \{-1, 1\}$). Supposons ensuite que l'ensemble $\mathcal{D}_i^K = \{(x_i^1, y_i^1), \dots, (x_i^K, y_i^K)\}$ des K -plus proches voisins à x_i est défini selon une métrique donnée telle que la distance Euclidienne définie par :

$$d(x_i, x_n) = \sqrt{\sum_{l=1}^m (x_i(l) - x_n(l))^2} \quad \forall n \in \{1, \dots, N\} \quad (3.18)$$

La classification de l'exemple x_i par l'algorithme KNN peut être alors formulée comme étant la solution du problème d'optimisation suivant :

$$y_i = \operatorname{argmax}_{y \in \{-1, +1\}} \sum_{i=1}^K \delta(y, g(x_i)) \quad (3.19)$$

où la fonction Kronecker Delta, δ , est donnée par :

$$\delta(a, b) = \begin{cases} 1, & \text{si } a = b \\ 0, & \text{si } a \neq b \end{cases} \quad (3.20)$$

3.3.5.3 La forêt aléatoire

La forêt aléatoire (RF) est une technique de régression et de classification supervisée introduite en 2001 (Breiman, 2001). Plus précisément, c'est une collection de $K \in \mathbb{N} \setminus \{0\}$ arbres de décision structurée, chaque arbre caractérisé par un vecteur aléatoire θ_k $k = \{1, \dots, K\}$. Chaque vecteur θ_k est généré de manière indépendante des vecteurs précédents $\theta_1, \theta_2, \dots, \theta_{k-1}$. De ce fait, les K vecteurs $\theta_1, \theta_2, \dots, \theta_K$ sont supposés indépendants et identiquement distribués. Supposons que $y_{q,k} = f_k(x_q, \theta_{q,k})$ soit la classe prédite par le k ème arbre à partir d'un exemple d'entrée x_q grâce à un classifieur associé f_k , la classe prédite par la forêt aléatoire est alors obtenue par une procédure d'agrégation par vote :

$$y_q^{RF} = \text{vote majoritaire } \{y_{q,1}, \dots, y_{q,K}\}$$

Il convient de noter que le processus de classification du k ème arbre de décision consiste essentiellement à partitionner l'espace des caractéristiques en un ensemble de M régions $R_k^m, m \in \{1, \dots, M\}$ (nœuds, feuilles) et y définir un modèle simple de réponse associé que nous notons ici par $p_{k,c}^m$. Cette procédure de partitionnement est séquentielle. Plus précisément, l'espace des caractéristiques est dans un premier temps partitionné en deux régions et chaque région est ensuite partitionnée en sous régions et ainsi de suite. Ce partitionnement s'arrête lorsqu'un meilleur compromis entre la taille de l'arbre et la performance de classification est atteinte. Concernant le modèle de réponse $p_{k,c}^m$, il est défini comme étant la proportion de la classe c (ex. $c \in \{-1, +1\}$) dans le cas d'une classification binaire) dans la région R_k^m et il est donné par (Tibshirani et al., 2008) :

$$p_{k,c}^m = \frac{1}{N_k^m} \sum_{x_{k,l}^m \in R_k^m} I(y_l = c) \quad (3.21)$$

où N_k^m est le nombre d'exemples $x_{k,l}^m, l \in \{1, \dots, N_k^m\}$ dans la région R_k^m et I est la fonction indicatrice. Par conséquent, la classe prédite $c_{k,q}^m$ de l'exemple de $x_{k,q}^m$, introduit à l'entrée de la région R_k^m , est obtenue en résolvant le problème d'optimisation suivant (Tibshirani et al., 2008) :

$$c_{k,q}^m = \underset{c}{\operatorname{argmax}} p_{k,c}^m \quad (3.22)$$

Ensuite, la classe $y_{k,q}$ prédite à l'échelle du k ème arbre de décision est donnée par :

$$y_{k,q} = \sum_{m=1}^M c_{k,q}^m I(x_q \in R_m) \quad (3.23)$$

3.3.5.4 Le classifieur naïf bayésien

Le classifieur naïf bayésien (NB : naive Bayes) (Lewis, 1998) est une approche probabiliste de classification. Elle est essentiellement fondée sur l'hypothèse de l'indépendance conditionnelle entre les vecteurs des caractéristiques de la base d'apprentissage. Plus précisément, ces derniers vecteurs sont supposés indépendants lorsqu'ils sont conditionnés par une classe donnée. Cette hypothèse est formalisée mathématiquement pour un vecteur donné x_q par :

$$p(x_q|y) = \prod_{i=1}^m p(x_q(i)|y) \quad (3.24)$$

Il convient ici de mentionner qu'une telle hypothèse d'indépendance conditionnelle n'est généralement pas vérifiée en pratique d'où le terme "naïf". Par conséquent, la classe prédite d'un exemple x_q donné est obtenue en maximisant la probabilité *a posteriori* de la classe (*i.e.* label) :

$$y_q = \operatorname{argmax}_{y \in \{-1, +1\}} p(y|x_q) = \frac{\prod_{i=1}^m p(x_q(i)|y) p(y)}{P(x_q)} \quad (3.25)$$

Notons ici que le problème d'optimisation ci-dessus concerne le cas d'une classification binaire mais une généralisation au cas d'une classification multi-classes (plus que deux classes) est immédiate. Il convient de noter aussi qu'il existe trois implémentations couramment utilisées du classifieur NB selon le choix de la distribution $P(x_q(i)|y)$: gaussienne, multinomiale ou de Bernoulli.

3.3.6 Synthèse

Dans cette première partie, nous avons proposé une première approche qui est basée sur la combinaison de caractéristiques extraites directement de la représentation TF avec celles liées à l'image TF binarisée associée (Krikid et al., 2022). Cette approche présente une première exploration de l'intérêt de combiner différentes caractéristiques TF extraites de deux domaines de représentations différents à savoir le plan TF et son image TF binarisée associée dans le cadre de la multi-classification des HFOs. Par la suite, nous avons poursuivi nos recherches en nous intéressant aux techniques d'apprentissage profond et nous présentons ci-après notre deuxième approche de multi-classification basée sur le CNN.

3.4. Approche 2 – Multi-classification de HFOs basée sur l'apprentissage profond

L'approche ML présentée précédemment est basée sur l'extraction manuelle de différentes caractéristiques liées à la représentation TF et à l'image TF binarisée associée. Toutefois, l'extraction manuelle de ces caractéristiques s'avère être une tâche relativement complexe car elle nécessite, pour certaines caractéristiques, de considérer plusieurs étapes intermédiaires de calculs. En outre, le choix des caractéristiques et leur pertinence dépendent fortement de

l'expertise du traiteur de données. Cela présente des limitations majeures pour l'approche ML. Par conséquent, nous nous sommes tournés vers une approche d'apprentissage profond pour remédier à ces limitations.

L'apprentissage profond (DL) suscite depuis quelques années beaucoup d'intérêt au vu de ses résultats encourageants dans différents champs d'application. L'avantage principal du DL est de remplacer l'investigation manuelle des caractéristiques par une extraction automatique à partir de données brutes. Motivé par une telle particularité, notre choix de la technique DL pour remédier à la limitation de l'approche ML était évident. De plus, convaincus par la pertinence d'une classification basée sur l'association entre la représentation TF des HFOs et les images TF correspondant, nous avons choisi de poursuivre cette deuxième partie de thèse en considérant une approche de DL basée sur ces dernières images TF. Dans ce cas, le problème de la classification des HFOs est considéré comme étant un problème de reconnaissance d'images. Parmi les différentes architectures proposées de réseaux de neurones pour le traitement d'images telles que les cellules LSTM (long short-term memory) (Hochreiter et al., 1997), les RNNs (Werbos, 1990) ou encore les CNNs, nous avons opté pour cette dernière architecture. Ce choix est justifié par les bonnes performances rapportées du CNN dans différents domaines d'application tels que le traitement d'images (par exemple, classification, détection et reconnaissance d'objets, etc.) (Simonyan et al., 2015; Szegedy et al., 2014) et la classification des signaux EEG (Madhavan et al., 2020; Gupta et al., 2021). Le CNN évite avec succès la nécessité d'un processus d'extraction et de sélection de caractéristiques en offrant une capacité à extraire des caractéristiques permettant une caractérisation riche des images d'entrée. Tous ces avantages nous amènent dans ce manuscrit à utiliser le CNN pour la classification des HFOs et les IESs. Un organigramme de l'approche proposée est présenté à la Figure 3.4. De plus, une description détaillée de chaque étape de cet organigramme est donnée dans les différentes sous-sections ci-après.

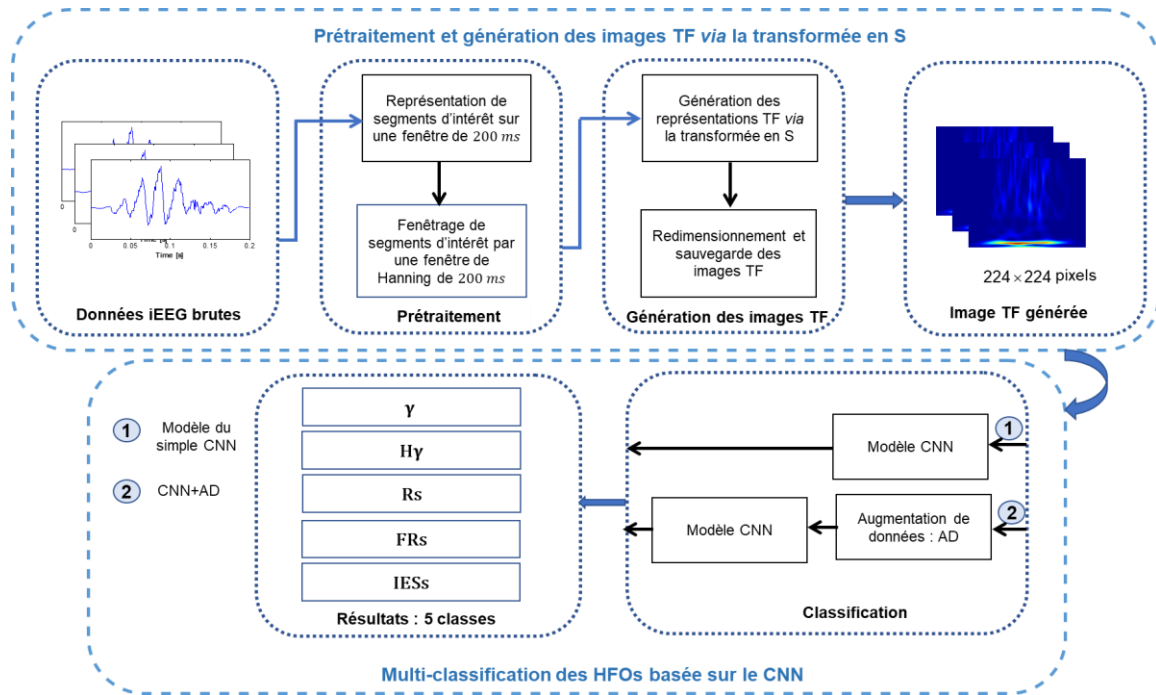


Figure 3.4 - Organigramme du *framework* proposé pour la multi-classification des HFOs basée sur le CNN

3.4.1 Prétraitement et génération des images TF via la transformée en S

Cette étape de prétraitement est identique à celle évoquée dans la section 3.3.2 et consiste à représenter les événements d'intérêt annotés dans notre base de données sur des fenêtres temporelles de 200 ms. Ensuite, la transformée en S (Stockwell, 2007) est utilisée pour la génération de la représentation TF pour chaque type d'événement (i.e. γ , $H\gamma$, R_s , FR_s et IES_s). Les images TF ont une taille d'origine de 400×500 pixels. La taille de ces images TF est ensuite réduite à 224×224 comme couramment utilisée dans la littérature (Shuvo et al., 2020; Aslan, 2022) afin d'accélérer l'apprentissage du modèle sans que cela n'altère significativement la qualité des images.

3.4.2 Multi-classification des HFOs via le CNN

Dans cette section, la deuxième approche proposée pour la multi-classification des HFOs et IES_s basée sur le CNN est présentée. Dans ce travail, la taille de notre base de données SEEG (décrite dans la section 3.2) est limitée. Ceci engendre potentiellement un problème de sous-apprentissage/sur-apprentissage du modèle et par conséquent une dégradation de sa performance de classification. Afin de remédier à ce problème, la technique d'AD est une solution possible (Salamon et al., 2017). L'AD consiste à générer, par différentes transformations appliquées aux données disponibles, de nouvelles données qui seront par la suite ajoutées aux données initiales. Par conséquent, la taille de la base finale de données est significativement supérieure à celle des données initiales. Dans le but d'évaluer l'apport de l'AD sur la qualité de classification, nous investiguons deux schémas différents de classification par CNN, sans et avec AD comme illustré sur la Figure 3.4. Il convient de noter

que la procédure de l'AD n'a, à notre connaissance, jamais été auparavant mise en œuvre dans le contexte de la multi-classification des HFOs et IESs.

3.4.2.1 Schéma 1 : multi-classification des HFOs basée CNN sans augmentation de données

L'architecture proposée du modèle CNN, comme illustré sur la Figure 3.5, comprend une couche d'entrée correspondant aux images d'entrée à 3 canaux (RGB) de dimensions 224×224 . Les images d'entrée sont passées à travers quatre blocs de couches profondes de convolution. Chaque bloc comprend quatre couches successives : convolution, normalisation par lot (BN : batch normalisation :), activation par la fonction ReLU et Pooling 2D.

Concernant la couche de convolution, chaque image à l'entrée de cette couche est convoluée avec un filtre de taille 3×3 avec un pas de convolution bien défini : 1 pour conv1, 2 pour conv2-conv4. En plus, l'ajout des zéros autour de l'image d'entrée (padding en anglais) a été adopté dans notre architecture. Ensuite, les sorties de toutes ces couches sont aplaties avant de les appliquer au processus de classification. Pour la partie classification, notre architecture comprend deux couches entièrement connectées (FC : fully connected) notées respectivement « FC1 » et « FC2 ». Ces couches sont ensuite suivies par une couche de dropout avec un taux égal à 0,5. Le dropout (Srivastava et al., 2014) consiste à « déconnecter » temporairement des neurones pris aléatoirement à chaque itération afin de diminuer le nombre de paramètres du réseau et de mettre à jour un nombre réduit de poids. Les autres neurones doivent donc compenser cette absence. Cette technique a pour objectif de rendre le réseau de neurones plus robuste au phénomène de surapprentissage. Enfin, une couche de sortie Softmax est ajoutée pour prédire la classe finale.

Concernant la fonction d'activation utilisée, la fonction ReLU a été appliquée à la sortie de chaque couche d'activation. L'étape de Max pooling utilisée après l'activation par la fonction ReLU réduit la dimensionnalité spatiale des cartes des caractéristiques extraites et aide à extraire les caractéristiques les plus informatives. La couche de normalisation par lot (BN) (Ioffe et al., 2015) est placée entre la couche de convolution et la couche d'activation ReLU. Le rôle de cette couche BN est (i) de normaliser la carte des caractéristiques afin que le modèle CNN devienne plus efficace même avec un petit nombre de paramètres et (ii) d'accélérer le processus d'apprentissage.




Figure 3.5 - Schéma 1 : architecture du modèle CNN

3.4.2.2 Schéma 2 : multi-classification de HFOs basée CNN avec augmentation des données

Généralement, une des principales limites à l'application de modèles d'apprentissage profond tels que le CNN est la quantité limitée de données. Plus la taille des données d'entraînement est importante, meilleure est la précision du modèle. Globalement, obtenir un volume assez important de données est toujours une question critique lorsqu'il s'agit de données médicales comme les enregistrements SEEG. Pour faire face à cette contrainte forte, l'AD est une procédure communément pratiquée dans le domaine de l'apprentissage profond et, par conséquent, elle est adoptée ici.

L'AD est une technique permettant, comme mentionné précédemment, d'augmenter la taille de données utilisées pour entraîner le modèle en ajoutant davantage d'exemples synthétiques à l'ensemble des données d'entraînement (Salamon et al., 2017). Cette technique consiste concrètement à appliquer certaines transformations sur l'ensemble initial d'apprentissage afin de créer de nouveaux exemples artificiels (synthétiques) sans modifier la nature de la classe à détecter. La technique de l'AD permet alors d'augmenter artificiellement la taille de l'ensemble d'apprentissage sans avoir besoin d'acquérir de nouvelles données et par conséquent obtenir une meilleure généralisation du modèle. Plusieurs études ont récemment montré que la performance du système de classification peut être améliorée grâce à la technique de l'AD (Zhang et al., 2020; Ssekidde et al., 2021; He et al., 2021). Dans le cadre de la classification des HFOs, la procédure d'AD a été, à notre connaissance, uniquement utilisée dans l'étude de Nadalin *et al.* (Nadalin et al., 2021) dans le contexte de classification binaire (Rs et spikes).

Concernant notre étude, les transformations suivantes sont appliquées, de manière aléatoire, en amont aux images TF d'entraînement : le retournement (« flipping » en anglais), la rotation, l'ajout d'un bruit gaussien à moyenne nulle avec un écart-type $\sigma = 0.05$ (voir Figure 3.6). Une fois que les images TF augmentées sont générées, elles sont mélangées avec les images originales. Finalement, le nouvel ensemble d'images est introduit à l'architecture proposée du CNN (voir Figure 3.7).




Figure 3.6 - Exemple d'images augmentées pour chaque classe (γ , $H\gamma$, Rs, FRs et IESs)
 (a) image TF originale, (b) retournement, (c) rotation, (d) ajout d'un bruit gaussien




Figure 3.7 - Schéma 2 : architecture du CNN avec l'augmentation des données

3.5. Conclusion

Dans ce chapitre, deux nouvelles approches ont été proposées pour la multi-classification des HFOs et IESs. Nous avons introduit dans un premier temps une approche basée ML et dans un second temps une approche basée DL. L'approche basée ML repose sur la combinaison entre les caractéristiques extraites directement du plan TF des événements d'intérêt avec celles liées à l'image TF binarisée associée. L'objectif principal est de fournir une description complète et riche des événements HFOs dans le plan TF. Concernant l'approche basée DL, elle a été proposée pour remédier à un inconvénient majeur des approches ML à savoir le choix manuel souvent subjectif des caractéristiques. Nous avons également procédé à une étape d'AD dans le cadre de l'approche DL pour lutter contre la taille limitée de la base de données. Cette étape d'AD permet une augmentation artificielle du nombre d'images TF de tous les événements HFOs et IESs. Les résultats de ces deux approches sur données réelles et bruitées, ainsi que les discussions qui en découlent, sont présentés dans le chapitre suivant.

Chapitre 4. Expérimentations

4.1. Introduction

Dans le chapitre précédent, la méthodologie des deux approches proposées dans le cadre de cette thèse permettant la classification automatique des HFOs et IESs a été détaillée. Nous commencerons le présent chapitre par une brève description des différents outils de développement, conduisant à la mise en pratique de ces approches, puis des métriques de performances retenues. Nous évaluerons ensuite, dans un premier temps, les performances de classification de la première approche que nous comparerons à celles d'approches issues de la littérature. Nous analyserons, dans un second temps, les performances de la seconde approche que nous comparerons à celles de la première méthode et ce sur la même base de données.

4.2. Outils de développement

Toutes les expériences et simulations ont été réalisées à l'aide de l'environnement MATLAB (Mathworks Inc., Natick, MA) pour le traitement de la base de données SEEG, et du langage Python³ pour l'étape de classification grâce à la bibliothèque scikit-learn⁴. Les différentes simulations ont été exécutées sur un processeur Intel(R) Xeon(R), 2,7 GHz (2 processeurs) avec 32 Go de mémoire. Le paragraphe suivant présente quelques détails sur les *frameworks* utilisés pour développer nos approches.

Python est un langage de programmation interprété et de haut niveau permettant d'assurer une programmation structurée, orientée objet et fonctionnelle. Les plateformes utilisées pour le développement de modèles ML et DL sont : (i) Tensorflow⁵ qui est un environnement complet et flexible d'outils et de bibliothèques faciles à utiliser ; (ii) Keras⁶ qui présente une bibliothèque open source permettant d'interagir avec des algorithmes de réseaux de neurones ; (iii) Open CV (Open Computer Vision)⁷ qui présente une bibliothèque graphique libre, conçue principalement pour le traitement d'images y compris des vidéos en temps réel.

4.3. Analyse des performances des approches proposées

Pour évaluer les performances des approches proposées, quatre métriques couramment utilisées dans le contexte de l'apprentissage automatique ont été considérées dans cette étude, à savoir la sensibilité (SEN : sensitivity :), la spécificité (SPE : specificity :), la précision (ACC : accuracy) et le F1-score. Ces métriques sont définies respectivement par les équations suivantes :

$$SEN = \frac{TP}{(TP + FN)} \quad (4.1)$$

³ <https://www.python.org/>

⁴ <https://scikit-learn.org>

⁵ <https://www.tensorflow.org/>

⁶ <https://keras.io/>

⁷ <https://opencv.org/>

$$SPE = \frac{TN}{(TN + FP)} \quad (4.2)$$

$$ACC = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (4.3)$$

$$F1 - score = \frac{2TP}{(2TP + FP + TN)} \quad (4.4)$$

où

TP représente les vrais positifs (*i.e.* les échantillons classés correctement comme positifs).

TN représente les vrais négatifs (*i.e.* les échantillons classés correctement comme négatifs).

FN représente les faux négatifs (*i.e.* les échantillons classés faussement comme négatifs).

FP représente les faux positifs (*i.e.* les échantillons classés faussement comme positifs).

De plus, les métriques SEN et SPE sont utilisées pour définir la courbe ROC (receiver operating characteristic) où l'aire sous cette courbe, notée AUC (area under the curve), est une mesure de la pertinence du modèle appris. Plus précisément, l'AUC de la courbe ROC est la mesure de la capacité d'un classifieur à faire la distinction entre les classes. Ainsi, plus la valeur AUC est élevée, meilleures sont les performances du modèle dans la séparabilité. Autrement dit, il indique dans quelle mesure le modèle est capable de distinguer entre les classes. Une illustration de la courbe ROC et de l'AUC est donnée à la Figure 4.1.

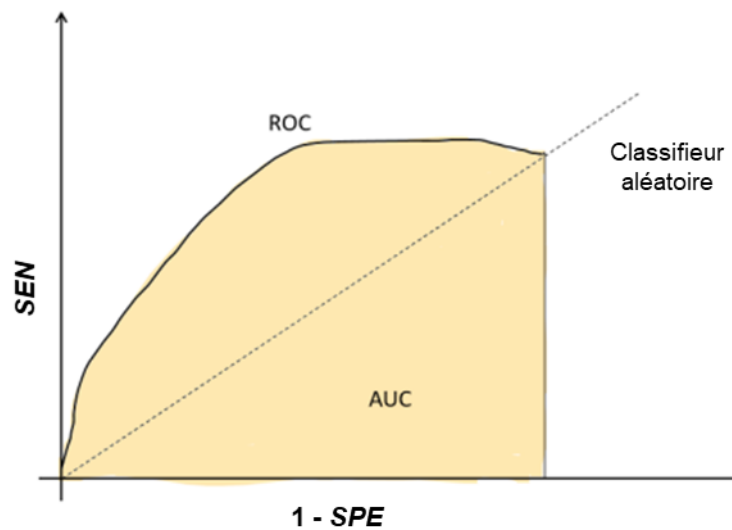


Figure 4.1 - Exemple typique d'une courbe ROC

4.4. Approche 1 : classification des HFOs basée sur des caractéristiques TF

Comme évoqué dans le chapitre 3, la première approche proposée a été conçue pour la classification de HFOs et IESs via un modèle ML. Cette approche est basée sur la combinaison des caractéristiques TF extraites de la représentation TF avec celles liées à l'image TF

binarisée associée. Un aperçu de l'architecture fonctionnelle utilisée pour les expérimentations de notre approche est donné sur la Figure 4.2. Cette figure présente les différentes étapes de classification et d'évaluation. La première étape consiste à acquérir les données SEEG suivie par une étape de prétraitement des données (détaillée dans le chapitre 3, section 3.3.2). S'ensuivent une étape de génération de la représentation TF et une étape de binarisation pour extraire les caractéristiques. Ces caractéristiques seront combinées pour former un seul vecteur de caractéristiques comportant à la fois des caractéristiques extraites de la représentation TF et celles liées à l'image binarisée associée. Par la suite, une répartition de 70% et 30% a été effectuée respectivement pour la création des bases d'apprentissage et de test. Une fois cette répartition effectuée, l'apprentissage et l'optimisation des hyperparamètres des différents algorithmes (*i.e.* KNN, RF, NB et SVM) sont opérés sur les données d'apprentissage. Finalement, l'approche proposée est testée sur les données de test et évaluée.

Les expérimentations réalisées ainsi que les résultats de classification obtenus sont détaillés dans les sous-sections suivantes.

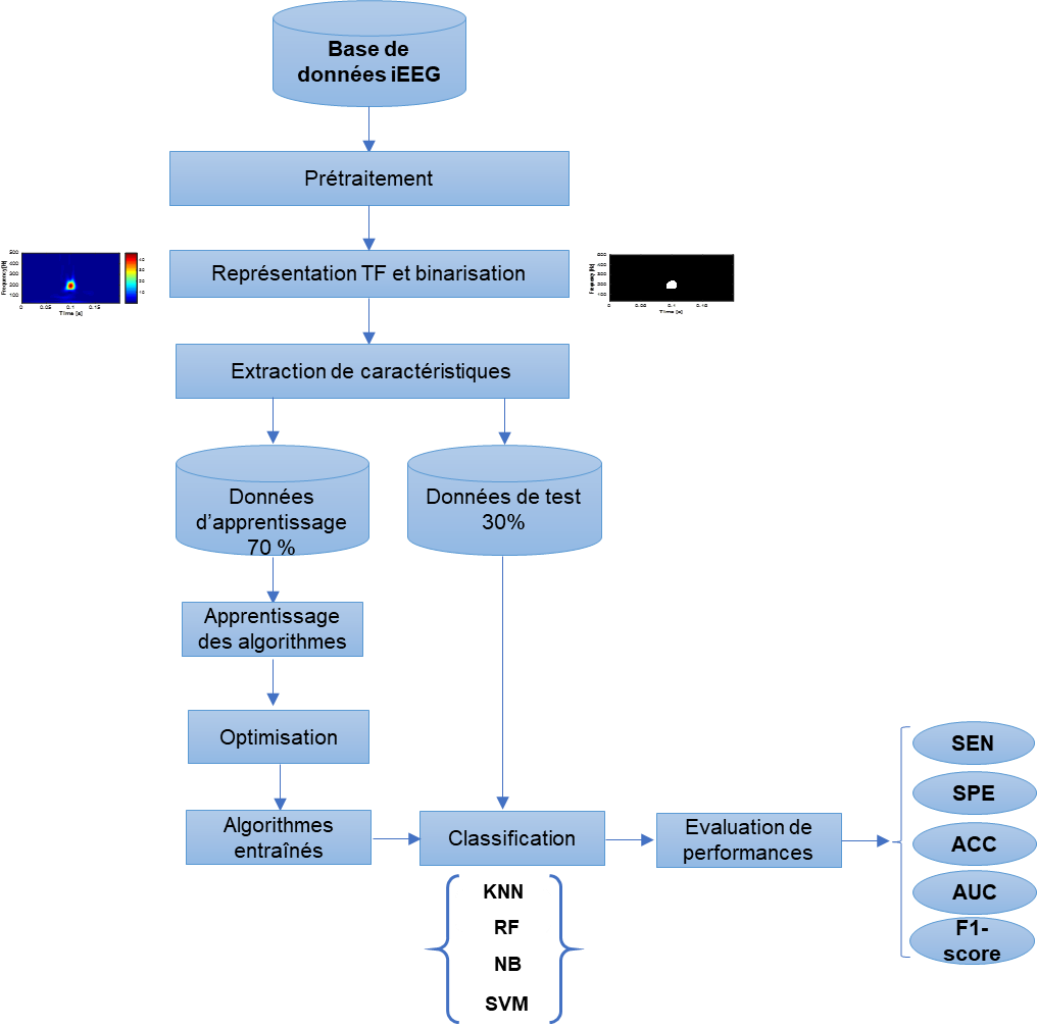


Figure 4.2 - Architecture fonctionnelle de l'approche 1

4.4.1 Protocole expérimental

Dans cette section, nous commençons par l'analyse de différentes caractéristiques utilisées (caractéristiques TF extraites de la représentation en S et celles liées à l'image TF binarisée associée). Puis, nous passons à l'étape de sélection des hyperparamètres optimaux de chaque classifieur.

4.4.1.1 Analyse des caractéristiques utilisées

Afin d'analyser la pertinence des caractéristiques choisies, nous avons établi des diagrammes en violon (violin⁸ plots) pour visualiser la distribution de ces caractéristiques. Le diagramme en violon est un type de visualisation des données quantitatives combinant les caractéristiques de la boîte à moustaches et de l'estimateur de densité par noyau. Le diagramme en violon est donc semblable à la boîte à moustaches, mais il affiche également la densité de probabilité des données associée aux différentes caractéristiques. Il comprend généralement un marqueur pour la médiane et l'écart interquartile. Ainsi, pour une comparaison fiable entre les différents diagrammes en violon, une procédure de normalisation min-max a été appliquée à toutes les caractéristiques calculées. Cette méthode de normalisation met sur une même échelle toutes les caractéristiques de manière à ce qu'elles soient bornées entre 0 et 1. La normalisation min-max est exprimée par l'équation suivante :

$$x_{norm} = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (4.5)$$

où x est la valeur originale de la variable et x_{norm} est la nouvelle valeur normalisée de la variable.

La Figure 4.3 présente des diagrammes en violon permettant de visualiser la distribution de toutes les caractéristiques calculées (*i.e.* flux TF, platitude TF, EC, μ , σ , sk, ku, cv, aire, périmètre, centroïde TF et norme $L1$). Comme nous pouvons le constater sur cette figure, la distribution statistique des caractéristiques utilisées pour chaque événement d'intérêt (γ , $H\gamma$, Rs, FRs et IESs) est différente en termes d'informations statistiques (médiane, quartile...). Cela montre une bonne séparation entre les différentes classes.

Intéressons-nous maintenant à la distribution statistique des caractéristiques pour chaque événement d'intérêt. La Figure 4.3 (a) permet de visualiser les caractéristiques pour l'événement γ . Clairement, nous remarquons une distribution différente pour chaque type de caractéristique. Toutefois, une distribution quasi-similaire a été remarquée pour les caractéristiques statistiques telles que la moyenne μ et l'écart-type σ . La Figure 4.3 (b) représente la distribution des caractéristiques pour $H\gamma$ qui montre également une diversité des aspects de toutes les caractéristiques surtout celles liées à l'image (aire, périmètre, compacité et centroïde TF et la norme $L1$). La distribution des caractéristiques pour le reste des événements (*i.e.* Rs, FRs et IESs) est visible respectivement sur les Figures 4.3 (c), (d), (e) qui montrent également une différence de distribution suivant les caractéristiques utilisées.

Globalement, nous pouvons conclure, à partir de la Figure 4.3, que la distribution statistique des caractéristiques utilisées pour chaque segment d'intérêt (γ , $H\gamma$, Rs, FRs et IESs) est différente suivant les classes ce qui confirme bien leur pouvoir discriminatoire. Il ne semble, du reste, pas exister de redondance entre les caractéristiques choisies.

⁸ <http://seaborn.pydata.org/generated/seaborn.violinplot.html?highlight=violin#seaborn.violinplot>

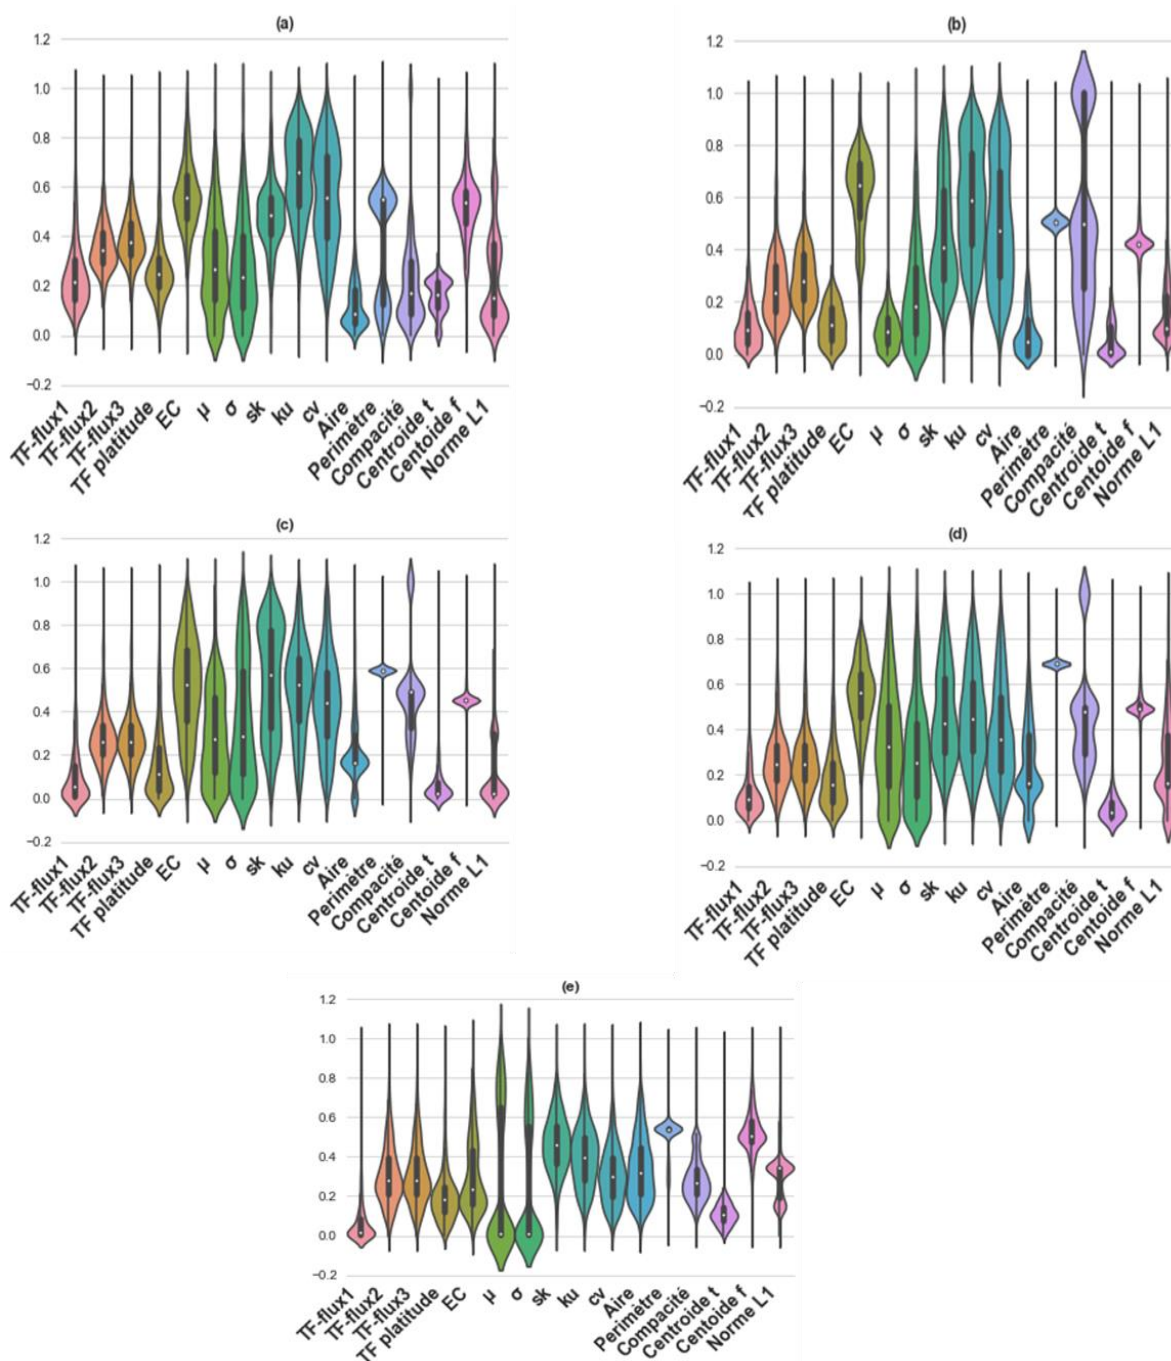


Figure 4.3 - Diagramme en violon des caractéristiques choisies pour les cinq classes :
 (a) : γ , (b) : Hy, (c) : Rs, (d) : FRs, (e) : IESs

Après cette analyse des différentes caractéristiques choisies, nous passons dans la section suivante à l'étape de sélection des hyperparamètres de différents classifieurs.

4.4.1.2 Sélection des hyperparamètres des classifieurs

Lors de l'apprentissage d'un modèle, on fait la différence entre les paramètres internes du modèle dont la valeur est déterminée pendant l'apprentissage et les hyperparamètres, dont la

valeur doit être fixée avant l'apprentissage pour assurer une évaluation fiable de chaque ensemble de données particulier. De plus, il a été démontré dans (Elgeldawi et al., 2021) que le résultat de classification peut être amélioré en modifiant les hyperparamètres.

Comme nous l'avons indiqué dans le chapitre précédent (section 3.3.5), nous avons choisi quatre classifieurs pour l'étape de classification à savoir le KNN, RF, NB et SVM. En fait, l'optimisation des hyperparamètres vise à améliorer l'efficacité d'un algorithme et à éviter tout problème de sur/sous apprentissage. De ce fait, il convient de bien choisir ces hyperparamètres. Pour ce faire, une approche itérative a été choisie pour leur optimisation lors de la phase d'apprentissage. Dans ce travail, la méthode de recherche sur grille (ou « Grid search ») a été utilisée comme technique de réglage afin de calculer les valeurs optimales des hyperparamètres par une recherche exhaustive. Pour ce faire, nous avons utilisé la librairie « `sklearn.model_selection.GridSearchCV` » dans l'environnement Python. La recherche par grille est déterministe, c'est-à-dire qu'elle effectue une recherche exhaustive dans un espace de paramètres prédéfini $S = \{0,1,2,3, \dots, n\}$ dans le but de trouver la valeur de l'hyperparamètre S qui permet d'obtenir la meilleure précision. Cette méthode est coûteuse en temps et en ressources computationnelles, mais elle donne généralement de bons résultats. Ainsi, le modèle sera entraîné pour chaque combinaison à chaque fois. La combinaison qui atteint la précision la plus élevée sera choisie en utilisant une validation croisée à 5-blocs. Il est à noter que cette étape a été appliquée seulement sur les données d'entraînement. Le Tableau 4.1 résume les différents hyperparamètres sélectionnés après la procédure de validation croisée pour les différents classifieurs KNN, RF, NB et SVM.

Tableau 4.1 - Valeurs des hyperparamètres utilisés pour les différents classifieurs

KNN	
Nombre de voisins (k)	5
Type de distance	Minkowski
RF	
Nombre d'arbres de decision	10
Profondeur d'arbres	3
NB	
Estimateur	Gaussien
Variance_smoothing	1e-7
SVM	
Noyau	RBF
Facteur de pénalité C	1
Largeur β	0,1

Après avoir sélectionné les différents hyperparamètres des classifieurs, nous analysons dans la section suivante les résultats de classification de l'approche proposée en utilisant les quatre classifieurs. Ensuite, une étude statistique nous permettra de comparer leurs performances et par conséquent de sélectionner le meilleur classifieur parmi les quatre initialement choisis.

4.4.2 Choix du meilleur modèle : analyse et résultats

Nous présentons ci-dessous les différentes étapes effectuées durant la procédure de classification. Ainsi, nous procédons aux étapes suivantes :

- Diviser les données (voir Figure 4.2) en deux ensembles : un ensemble d'entraînement (70%) et un ensemble de test (30%).
- Évaluer la performance du modèle retenu pour chaque classifieur sur les données de test en termes de SEN, SPE, ACC, AUC et F1-score.
- Comparer statistiquement les différents classifieurs.

Notons que les étapes précédentes ont été répétées sur 100 essais où, à chaque essai, les ensembles d'entraînement et de test sont mélangés.

Nous présentons dans cette section les résultats obtenus en appliquant le système de classification proposé, dans un premier temps, sur des signaux réels et, dans un deuxième temps, sur des signaux bruités.

4.4.2.1 Cas des données réelles

La Figure 4.4 illustre les résultats de classification pour tous les classifieurs (avec les hyperparamètres sélectionnés) sur les données réelles en termes de SEN, SEP, ACC, AUC et F1-score.

Les boîtes à moustaches de la Figure 4.4 rapportent les performances de chaque classifieur calculées sur 100 essais. Pour chaque boîte, la marque centrale est la médiane, les bords de la boîte sont les 25e et 75e centiles. Cette figure montre clairement que les performances de l'approche proposée, lorsque le classifieur SVM est utilisé, sont généralement supérieures à celles obtenues avec les classifieurs KNN, NB et RF. Plus particulièrement, l'approche proposée utilisant l'algorithme SVM a obtenu des scores en termes de SEN, SPE, ACC, AUC et F1-score les plus élevés avec des valeurs égales à 0,800, 0,940, 0,930, 0,951 et 0,859 respectivement. Il convient de noter, d'après les Figures 4.4 (b) et (c), que, si les classifieurs RF et NB sont moins performants que le classifieur SVM, ils présentent néanmoins des performances comparables notamment en termes de SPE qui varie dans la plage [0,751 – 0,850] pour ces deux classifieurs. Il convient de noter également d'après la Figure 4.4 (a), que les classifieurs KNN et RF affichent les performances les plus faibles surtout en termes de SEN pour laquelle ils présentent une valeur maximale ne dépassant pas 0,700. De même, le classifieur KNN montre un F1-score relativement faible en comparaison des autres classifieurs avec une valeur maximale égale à 0,752 (cf. Figure 4.4 (e)). En résumé, les résultats obtenus et présentés sur la Figure 4.4 témoignent d'une meilleure performance quand le classifieur SVM est employé.

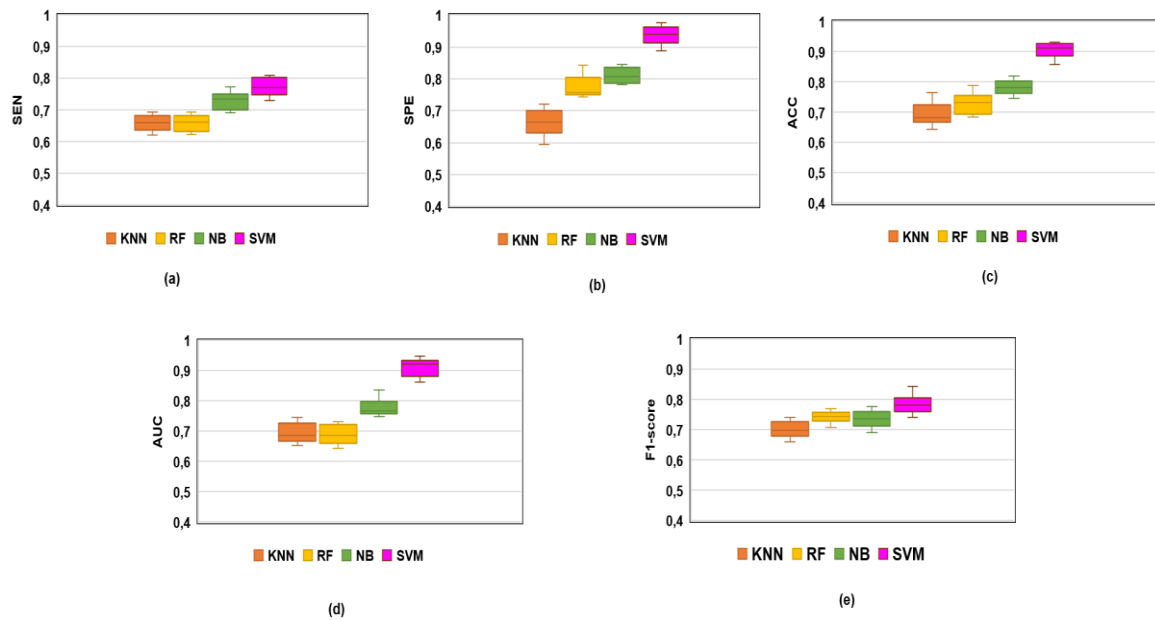



Figure 4.4 - Boîte à moustaches des performances de l'approche proposée en utilisant les classifieurs SVM, RF, KNN et NB. (a) : SEN, (b) : SPE, (c) : ACC, (d) : AUC, (e) : F1-score. Cas des données réelles


4.4.2.2 Cas des données bruitées

En plus des données réelles, nous souhaitons évaluer les performances de l'approche proposée sur des données bruitées (décrites dans la section 3.2.2 du chapitre 3) en utilisant les mêmes classifieurs que précédemment.


Les résultats de classification sur les données bruitées en termes de SEN, SPE, ACC, AUC et F1-score sont donnés sur la Figure 4.5 pour six valeurs de SNR (-10, -5, 0, +5, +10, +15 dB). D'après cette figure, à classifieur donné, la méthode proposée atteste généralement de bonnes performances quelle que soit la valeur du SNR. De manière non surprenante, l'approche proposée témoigne de performances légèrement plus faibles pour de faibles SNR (*i.e.* -5 et -10 dB) en comparaison aux valeurs de SNR élevées. Par exemple, pour une valeur du SNR élevée (SNR = +15 dB), d'après les Figures 4.5 (a) et (c), l'approche proposée présente de bonnes performances avec des valeurs de SEN et ACC qui dépassent 0,9 pour tous les classifieurs. Au contraire, pour un faible SNR (*i.e.* -10 ou -5 dB), nous pouvons remarquer une légère diminution des performances de l'approche proposée pour tous les classifieurs, cela dû probablement au fait que, pour un faible SNR, les segments d'intérêt sont noyés dans les activités de fond où leur amplitude est très comparable à celles-ci. Cela a assurément une influence sur les représentations TF associées à chaque événement d'intérêt. Donc, plus le SNR est élevé, meilleure est la représentation TF en termes de résolution. Pour des valeurs faibles de SNR (*i.e.* -10 ou -5 dB), la SEN pour tous les classifieurs ne dépasse pas 0,870 sauf dans le cas du classifieur SVM qui révèle une sensibilité entre 0,963 et 0,990 et une précision entre 0,984 et 0,994. Notons ici que l'algorithme KNN donne les performances les plus faibles.




(a)



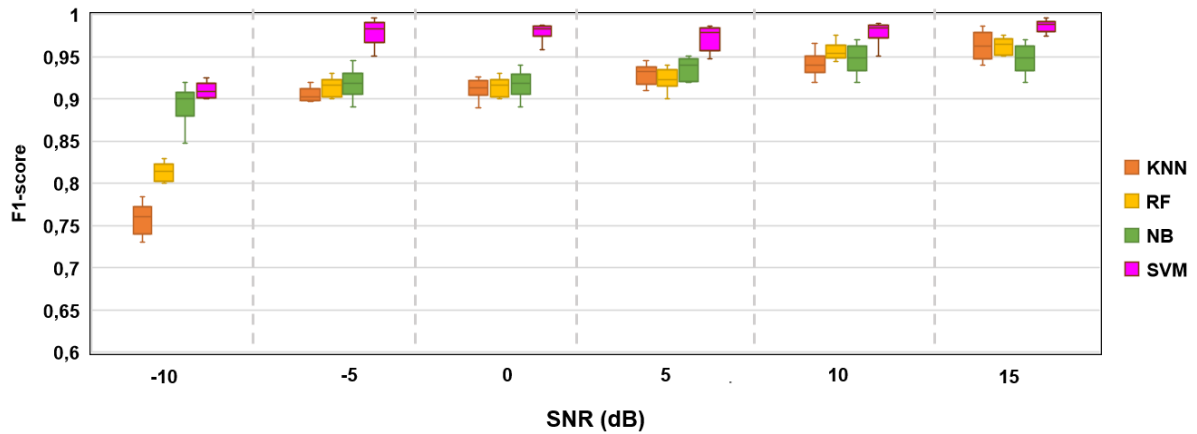
(b)



(c)



(d)



(e)

Figure 4.5 - Boîte à moustaches des performances de l'approche proposée en utilisant les classifieurs SVM, RF, KNN and NB pour différentes valeurs de SNR : (a) : SEN, (b) : SPE, (c) : ACC, (d) : AUC, (e) : F1-score. Cas des données bruitées

Au vu des résultats à la fois sur données réelles et bruitées, l'approche proposée se révèle performante pour une classification fiable des HFOs, notamment en adoptant le classifieur SVM. De plus, l'étude sur les données bruitées a montré sa bonne robustesse au bruit.

Par conséquent, parmi les différents modèles testés, nous retiendrons par la suite le classifieur SVM puisqu'il conduit aux meilleures performances de classification.

4.4.3 Comparaison avec l'état de l'art

Dans cette section, nous proposons une étude comparative des performances entre l'approche proposée en utilisant le classifieur SVM (Krikid et al., 2022) et des approches connues de la littérature telles que celles issues de (Matsumoto et al., 2013; Chaibi et al., 2014; Sciaraffa et al., 2020). Ces dernières approches sont basées sur des caractéristiques temporelles et/ou fréquentielles et des caractéristiques TF. Notons ici que toutes les approches considérées dans cette étude ont été évaluées sur la même base de données

(réelles et bruitées). Le Tableau 4.2 récapitule les approches de l'état de l'art utilisées pour la comparaison.

Tableau 4.2 - Approches de l'état de l'art testées pour comparaison

Etude	Caractéristiques
(Matsumoto et al., 2013)	Fréquence Durée
(Chaibi et al., 2014)	Moyenne / Ecart type Energy du Teager Densité spectrale du puissance
(Sciaraffa et al., 2020)	Energie RMS Energie STLL Energie STE Energie du Teager

4.4.3.1 Cas des données réelles

La Figure 4.6 rapporte les résultats de classification moyenne (au regard des différentes classes (γ , $H\gamma$, Rs, FRs, IESs)) obtenus par l'approche proposée et par celles issues de l'état de l'art sur les données SEEG réelles. Il convient de noter que les résultats de classification ont été moyennés sur 100 essais en modifiant les ensembles d'entraînement et de test à chaque essai. Il ressort de la Figure 4.6 que l'approche proposée fournit de meilleures performances en la comparant aux approches de l'état de l'art quelle que soit la métrique testée. Par exemple, notre approche montre des taux de classification de 0,765, 0,941, 0,906, 0,926 et 0,768 pour SEN, SPE, ACC AUC et F1-score respectivement, alors que des valeurs plus faibles égales à 0,529, 0,811, 0,852, 0,807 et 0,704 respectivement sont obtenues avec la méthode développée dans (Sciaraffa et al., 2020). De même, les méthodes issues de (Matsumoto et al., 2013) et (Chaibi et al., 2014) montrent une performance inférieure comparée à notre approche. De plus, la Figure 4.6 montre clairement que la méthode (Matsumoto et al., 2013) est la moins performante avec une faible sensibilité (0,500).

En conclusion, en nous basant sur les résultats illustrés sur la Figure 4.6, nous voyons nettement que notre approche obtient de meilleurs résultats que les approches issues de la littérature. Ceci confirme la pertinence de notre choix de caractéristiques, qui combine les caractéristiques extraites de la représentation TF avec celles liées à l'image TF binarisée associée, dans la caractérisation de l'aspect non stationnaire des événements HFOs. Si les approches de l'état de l'art présentent de bonnes valeurs en termes d'ACC entre 0,792 et 0,852, elles obtiennent de faibles valeurs de SEN, valeurs qui ne dépassent pas 0,529. Cela montre l'incapacité de ces approches à décrire les différents patterns caractérisant les événements HFOs. En revanche, notre méthode construit un vecteur de caractéristiques qui fournit une description complète des événements HFOs grâce aux techniques de traitement d'images à savoir la méthode d'Otsu pour extraire des caractéristiques liées à la forme géométrique des événements dans l'espace TF, ce qui conduit à une valeur de SPE élevée de notre approche qui dépasse 0,900.




Figure 4.6 - Performances de la classification des HFOs entre l'approche proposée utilisant le classifieur SVM et des approches issues de la littérature en termes de SEN, SPE, ACC, AUC, F1-score. Cas des données réelles

4.4.3.2 Cas des données bruitées

La validation sur données réelles étant réalisée et s'avérant très satisfaisante, nous avons ensuite évalué notre approche sur données bruitées.

La Figure 4.7 représente les performances des différentes approches en termes de SEN, SPE, ACC, AUC et F1-score en fonction de valeurs de SNR, *i.e.* -10, -5, 0, +5, +10, et +15 dB. D'après cette figure, nous constatons une meilleure performance de classification de l'approche proposée utilisant le classifieur SVM comparée aux méthodes conventionnelles (Matsumoto et al., 2013; Chaibi et al., 2014; Sciaraffa et al., 2020) pour les différentes valeurs de SNR testées. En regardant plus en détail les Figures 4.7 (a), (b), (c) (d) et (e), les performances de classification de ces approches et la nôtre dépassent globalement 0,7 pour SEN, SPE, ACC, AUC et F1-score. Plus particulièrement, les approches de Chaibi *et al.* et de Sciaraffa *et al.* sont plus performantes que l'approche de Matsumoto *et al.* avec un rapport SEN/ACC plus avantageux. Une bonne SEN est indispensable parce que cela justifie que peu de vrais positifs sont omis. De même, une valeur élevée d'ACC reflète la capacité du modèle à distinguer les différentes classes. Toutefois, si nous comparons les performances de toutes les approches pour un faible SNR (*i.e.* -10, -5, 0 dB), contrairement aux différentes approches conventionnelles, notre approche présente une réelle robustesse. Par exemple, tandis que l'approche de Sciaraffa *et al.* montre, pour un SNR égal à -10 dB, des valeurs de 0,854, 0,752, 0,711, 0,800 et 0,800 pour SEN, SPE, ACC, AUC et F1-score, respectivement, notre approche conduit à des valeurs de 0,978, 0,998, 0,983, 0,994 et 0,980 pour les mêmes critères. Elle présente, de même, des scores de classification plus élevés que les approches introduites dans (Matsumoto et al., 2013) et (Chaibi et al., 2014). Pour des valeurs de SNR au-dessus de 0 dB, les approches conventionnelles et la nôtre montrent de bons comportements en termes de SEN, SPE, ACC, AUC et SPE, comportements globalement d'autant meilleurs que le SNR augmente. Il convient d'observer qu'entre les valeurs faibles et élevées du SNR, notre approche présente des valeurs de SEN, SPE, ACC, et AUC très élevées et stables, à l'exception d'une très légère chute de l'AUC passant de de 0,997 à 0,922 pour un SNR de 0 dB.

Pour synthétiser, en nous appuyant sur les Figures 4.6 et 4.7, nous pouvons conclure que l'approche proposée présente de bonnes performances sur données réelles et bruitées. Rappelons que les deux bases de données utilisées dans ce manuscrit sont différentes comme décrites dans la section 3.2 du chapitre 3. Si de meilleures performances de l'approche proposée sont obtenues dans le cas de données bruitées, ceci peut s'expliquer par le fait que cette base contient davantage d'événements d'intérêt, permettant un meilleur apprentissage du modèle de classification.




Figure 4.7 - Performances de la classification des HFOs entre l'approche proposée utilisant le classifieur SVM et des approches de l'état de l'art en termes de (a) : SEN, (b) : SPE, (c) : ACC, (d) : AUC, (e) : F1-score. Cas des données bruitées

4.5. Approche 2 : multi-classification de HFOs basée sur l'apprentissage profond

4.5.1 Protocole expérimental

Dans cette section, nous présentons les différentes expérimentations réalisées pour tester notre seconde approche basée sur l'apprentissage profond et plus particulièrement sur le CNN. Une architecture fonctionnelle de l'approche proposée est illustrée sur la Figure 4.8. Le but de cette approche est d'entraîner tout d'abord le modèle CNN pour classifier par la suite les événements d'intérêt à partir de leurs images TF.




Figure 4.8 - Architecture fonctionnelle pour les expérimentations de l'approche 2

Pour construire le modèle CNN, il faut sélectionner différents hyperparamètres nécessaires à l'apprentissage du modèle. Pour ce faire, nous avons retenu les hyperparamètres résumés dans le Tableau 4.3. L'entropie croisée (cross entropy) a été utilisée comme fonction de coût et l'algorithme de descente du gradient stochastique avec momentum (SGDM : stochastic gradient descent with momentum) a été adopté comme solveur du problème d'optimisation posé. Le coefficient du momentum est égal à 0,8. En outre, pour garantir la stabilité de l'apprentissage, il est indispensable de fixer le coefficient d'apprentissage (learning rate).

Après plusieurs essais effectués, nous avons fixé un coefficient d'apprentissage égal à 0,1. Finalement, la taille de lot (batch size) était fixée à 32.

Le modèle proposé a été entraîné sur 100 époques (epochs). Nous notons à ce niveau que la différence entre l'époque et l'itération est que l'époque décrit le nombre de fois que l'algorithme d'apprentissage reçoit l'ensemble des données tandis que l'itération décrit le nombre de fois qu'un lot particulier de données passe à travers l'algorithme d'apprentissage. A ce titre, la technique de validation croisée K -blocs (avec $K = 5$) a été utilisée pour éviter le problème de surapprentissage (overfitting). Plus particulièrement, l'ensemble de données a été divisé de manière aléatoire en cinq sous-ensembles ($K1, K2, K3, K4$ et $K5$). Quatre de ces sous-ensembles ont été utilisés pour la phase d'apprentissage du modèle CNN tandis que le sous-ensemble restant a été utilisé dans la phase de test. De plus, les données d'apprentissage ont été divisées avec un rapport 80:20 pour l'apprentissage et la validation respectivement comme recommandé dans (Lai et al., 2019). Enfin, les résultats de la procédure de validation croisée à 5 blocs ont été moyennés pour calculer les valeurs de SEN, SPE, ACC, AUC et F1-score pour chaque classe. Indiquons que les étapes précédentes ont été répétées sur 25 essais où, à chaque essai, les ensembles d'entraînement et de test ont été mélangés.

Tableau 4.3 - Valeurs des hyperparamètres pour l'apprentissage du modèle CNN proposé

Hyperparamètre	Valeur
Optimiseur	SGDM
Momentum	0,8
Coefficient d'apprentissage	0,1
Fonction de coût	Entropie croisée
Taille du lot	32
Époques	100

4.5.2 Evaluation des performances du modèle CNN : cas de données réelles

Dans cette section, les deux phases d'évaluation du modèle CNN sur les données réelles à savoir la phase d'apprentissage-validation et la phase de test sont détaillées. De plus, l'impact de l'augmentation des données sur la performance du modèle est également présenté.

4.5.2.1 Apprentissage du CNN sans augmentation de données

La Figure 4.9 montre l'évolution de la fonction de coût (Figure 4.9 (a)) et la précision (Figure 4.9 (b)) en fonction du nombre d'époques. D'après cette figure, on remarque que le modèle proposé ne présente pas de phénomène de surapprentissage (overfitting). Après 100 époques, comme illustré sur la Figure 4.9 (a), la fonction de coût atteint dans les deux phases (apprentissage et validation) 0,309 alors que le taux de précision tend vers 0,897 pour les deux phases, comme illustré sur la Figure 4.9 (b).




Figure 4.9 - Le modèle CNN sans augmentation de données :
(a) taux d'erreur, (b) taux de précision

4.5.2.2 Apprentissage du CNN avec augmentation de données

La Figure 4.10 montre l'évolution de la fonction de coût (Figure 4.10 (a)) et la précision (Figure 4.10 (b)) en fonction du nombre d'époques. Comme précédemment, on observe que le modèle proposé ne présente pas de phénomène de surapprentissage (overfitting). Plus précisément, la Figure 4.10 (a) montre que la fonction de coût dans la phase de validation devient minimale pour atteindre 0,248 dans la dernière époque. De plus, le CNN avec augmentation des données (AD) montre une légère augmentation de la précision, avec une valeur de 0,901, lors de la phase de validation comme illustré sur la Figure. 4.10 (b) comparé à la valeur de précision sans AD (0,897).




Figure 4.10 - Le modèle CNN avec augmentation de données :
(a) taux d'erreur, (b) taux de précision.

D'après les résultats d'apprentissage et de validation obtenus pour le CNN avec ou sans augmentation de données, les courbes de la fonction de coût diminuent avec les époques. De même, les courbes de précision montrent une augmentation au fur et à mesure que le nombre d'époques augmente. Par conséquent, nous pouvons conclure que, dans la phase d'apprentissage, le CNN proposé ne présente aucun problème de surapprentissage sur l'ensemble de données d'images TF.

4.5.2.3 Performance de classification du CNN sans augmentation de données

Le Tableau 4.4 présente les performances de classification du modèle CNN sans augmentation de données pour les différentes classes en termes de SEN, SPE, ACC, AUC et F1-score. Nous pouvons observer que le modèle CNN proposé montre une bonne performance de classification pour toutes les classes (γ , $H\gamma$, Rs, FRs, IESs). En particulier, la classe FRs montre globalement des performances nettement supérieures à celles des autres

classes. Plus précisément, les critères SEN, SPE, ACC et AUC présentent des valeurs égales à 0,933, 0,998, 0,999 et 0,954, respectivement. En revanche, la meilleure performance en termes de F1-score correspondant à la valeur 0,895 est obtenue pour la classe $H\gamma$.

En ce qui concerne la performance moyenne, le modèle basé sur le CNN atteint des performances (moyenne(SD)) égales à 0,886(0,032), 0,982(0,006), 0,904(0,030), 0,938(0,007) et 0,806(0,003) pour SEN, SPE, ACC, AUC et F1-score respectivement.

Tableau 4.4 - Performances de classification du modèle CNN sans augmentation de données

Classe	SEN	SPE	ACC	AUC	F1-score
γ	0,789	0,974	0,849	0,932	0,728
$H\gamma$	0,894	0,982	0,872	0,944	0,895
Rs	0,889	0,992	0,894	0,894	0,784
FRs	0,933	0,998	0,999	0,954	0,814
IESs	0,929	0,966	0,906	0,966	0,811
Moyenne(SD)	0,886(0,032)	0,982(0,006)	0,904(0,030)	0,938(0,007)	0,806(0,003)

4.5.2.4 Impact de l'augmentation de données sur la performance du modèle CNN

Pour étudier le comportement global du modèle CNN proposé sans ou avec augmentation de données, nous présentons dans la Figure 4.11 les résultats de la classification de l'approche proposée sans et avec augmentation de données en termes du SEN, SPE, ACC, AUC et F1-score. D'après cette figure, nous remarquons que le modèle CNN proposé avec AD montre des performances de classification relativement plus élevées en termes de SEN, ACC, F1-score et AUC par rapport au cas où aucune étape d'AD n'est ajoutée. En revanche, en termes de SPE, aucune amélioration n'a été observée pour le modèle CNN avec AD par rapport à celui proposé sans augmentation de données. Par ailleurs, la Figure 4.11 montre qu'une très bonne précision (0,935) a été obtenue dans le cas du modèle CNN avec augmentation de données.

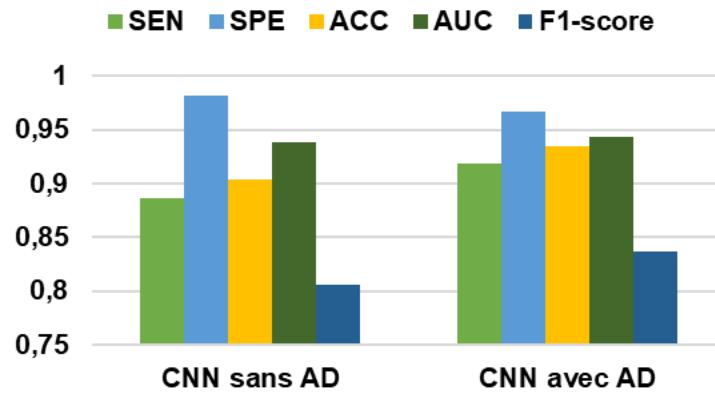


Figure 4.11 - Performance de classification des HFOs du modèle CNN proposé sans et avec AD

4.5.2.5 Etude comparative

Une étude comparative entre l'approche proposée ici avec AD et l'approche ML évoquée précédemment (Krikid et al., 2022) a été réalisée. Pour une comparaison fiable, la même base de données SEEG a été utilisée pour l'ensemble des approches considérées dans cette étude.

Les scores de SEN, SPE, ACC, AUC et F1-score pour chaque algorithme ont été moyennés et illustrés sur la Figure 4.12. D'après cette figure, l'approche basée ML a fourni une performance de classification inférieure au regard de tous les critères de performance en comparaison du modèle CNN. Cela peut s'expliquer par le fait que, contrairement aux modèles CNN où les caractéristiques pertinentes sont automatiquement extraites, les méthodes de ML s'appuient fortement sur une présélection manuelle des caractéristiques pertinentes. De plus, comparé à tous les algorithmes considérés, le modèle CNN proposé avec AD a atteint l'ACC la plus élevée avec une valeur égale à 0,935.




Figure 4.12 - Comparaison des performances du modèle CNN proposé (avec AD) avec l'algorithme SVM

4.5.3 Evaluation des performances du modèle CNN : cas de données bruitées

Dans cette section, les deux phases d'évaluation du modèle CNN sur les données bruitées à savoir la phase d'apprentissage-validation et la phase de test sont détaillées.

4.5.3.1 Apprentissage du modèle sans augmentation de données

La Figure 4.13 montre l'évolution de la fonction de coût (Figures 4.13 (a) et (b)) et le taux de précision (Figures 4.13 (c) et (d)) en fonction du nombre d'époques et pour chaque valeur de SNR pour l'apprentissage et la validation respectivement.

D'après la Figure 4.13, nous remarquons que le modèle proposé ne présente pas de phénomène de surapprentissage (overfitting) pour les deux phases (apprentissage et validation) quelle que soit la valeur du SNR. Si nous évaluons le comportement du modèle lors de la phase de validation, nous remarquons d'après la Figure 4.13 (b) que la fonction de coût converge rapidement dans le cas des SNR élevés (*i.e.* 10 dB et 15 dB) pour atteindre une valeur après 100 époques égale à 0,015 pour un SNR de 15 dB. En revanche, la valeur de la fonction de coût reste plus élevée pour de faibles SNR, de l'ordre de 0,256 pour un SNR de -10 dB). Ceci étant, d'après la Figure 4.13 (d), une valeur de précision supérieure à 0,9 a pu être atteinte quel que soit le SNR.




Figure 4.13 - Le modèle CNN sans AD :
(a) fonction de coût en phase d'apprentissage, (b) fonction de coût en phase de validation, (c) taux de précision en phase d'apprentissage et (d) taux de précision en phase de validation

4.5.3.2 Apprentissage du modèle avec augmentation de données

La Figure 4.14 montre l'évolution de la fonction de coût (Figures 4.14 (a) et (b)) et le taux de précision (Figures 4.14 (c) et (d)) en fonction du nombre d'époques et pour chaque valeur de SNR pour l'apprentissage et la validation respectivement.

D'après la Figure 4.14, nous remarquons que le modèle proposé ne présente pas de phénomène de surapprentissage (overfitting) pour les deux phases (apprentissage et validation) et ce quel que soit le SNR. Si nous évaluons le comportement du modèle lors de la phase de validation, nous remarquons d'après la Figure 4.14 (b) que la fonction de coût converge rapidement dans le cas des SNR élevés (*i.e.* 10 dB et 15 dB) pour atteindre, après 100 époques, une valeur de 0.019 pour un SNR de 15 dB. Pour des valeurs de SNR faibles, la fonction de coût tend vers 0,092. Cette valeur montre l'impact positif de l'AD sur la robustesse du modèle. En outre, d'après la Figure 4.14 (d), une valeur de précision supérieure à 0.995 a été atteinte pour toutes les valeurs de SNR.

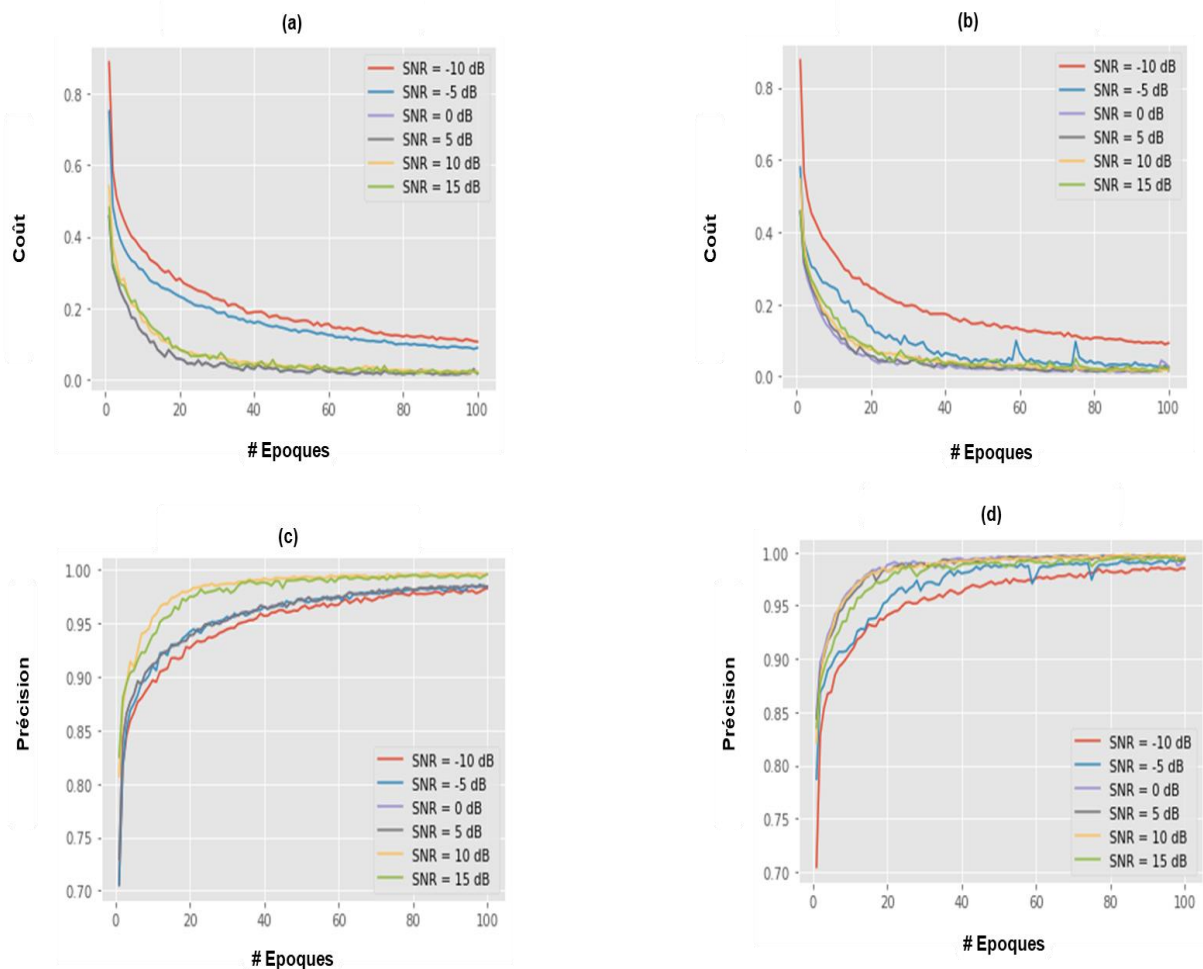


Figure 4.14 – Le modèle CNN avec AD :
(a) Fonction de coût en phase d'apprentissage, (b) fonction de coût en phase de validation, (c)taux de précision en phase d'apprentissage et (d) taux de précision en phase de validation

4.5.3.3 Performance globale

Pour étudier le comportement global du modèle CNN proposé sans ou avec augmentation de données, nous présentons dans le Tableau 4.5 les résultats de la classification de l'approche proposée sur les données de test. D'après ce tableau, nous remarquons que le modèle CNN proposé sans ou avec AD montre généralement de bonnes performances de classification quel que soit le critère utilisé et quel que soit le SNR. Les meilleures performances de classification sont mises en évidence (en gras). Par ailleurs, l'approche proposée présente relativement de meilleures performances dans le cas où l'AD a été appliquée. Par exemple, les précisions varient dans ce cas de 0,898 à 0,996 ce qui montre la robustesse de l'approche proposée en présence de bruit.

Tableau 4.5 - Performances de classification du modèle CNN sans et avec augmentation de données : cas de données bruitées

Modèle	SNR (dB)	SEN	SPE	ACC	AUC	F1-score
CNN sans AD	-10	0,896	0,900	0,896	0,930	0,895
	-5	0,920	0,905	0,899	0,951	0,922
	0	0,936	0,916	0,924	0,972	0,900
	+5	0,954	0,946	0,957	0,955	0,903
	+10	0,981	0,977	0,978	0,972	0,991
	+15	0,989	0,986	0,985	0,983	0,990
CNN avec AD	-10	0,899	0,980	0,898	0,991	0,982
	-5	0,911	0,990	0,928	0,988	0,982
	0	0,980	0,992	0,956	0,988	0,989
	+5	0,982	0,989	0,974	0,996	0,970
	+10	0,986	0,990	0,987	0,992	0,990
	+15	0,991	0,991	0,996	0,990	0,990

4.5.3.4 Etude comparative

Une étude comparative entre l'approche proposée basée CNN avec AD et l'approche ML évoquée précédemment (Krikid et al., 2022) a été réalisée. Pour une comparaison fiable, la même base de données bruitées a été utilisée pour l'ensemble des approches considérées dans cette étude.

Les scores de SEN, SPE, ACC, AUC et F1-score pour chaque algorithme ont été moyennés et illustrés dans le Tableau 4.6. Comme nous pouvons le constater, l'approche basée CNN avec AD conduit à une performance de classification légèrement inférieure au regard de tous les critères de performance en comparaison du modèle SVM dans le cas où le SNR est inférieur à 0 dB. En revanche, Pour une valeur du SNR élevée (*i.e.* SNR = 15 dB), nous constatons une amélioration de performance de l'approche basée CNN en termes de SEN (0,991) et ACC (0,996).

Tableau 4.6 - Comparaison des performances du modèle CNN proposé (avec AD) avec l'algorithme SVM

Modèle	SNR (dB)	SEN	SPE	ACC	AUC	F1-score
SVM	-10	0,990	0,996	0,995	0,993	0,900
	-5	0,983	0,990	0,988	0,997	0,982
	0	0,984	0,995	0,992	0,922	0,984
	+5	0,985	0,995	0,988	0,995	0,983
	+10	0,991	0,997	0,992	0,992	0,991
	+15	0,990	0,996	0,995	0,993	0,990
CNN avec AD	-10	0,899	0,980	0,898	0,991	0,982
	-5	0,911	0,990	0,928	0,988	0,982
	0	0,980	0,992	0,956	0,988	0,989
	+5	0,982	0,989	0,974	0,996	0,970
	+10	0,986	0,990	0,987	0,992	0,990
	+15	0,991	0,991	0,996	0,990	0,990

4.6. Discussion générale

Dans cette section, nous récapitulons les différents résultats obtenus par les deux approches développées pour la classification des HFOs et IESs.

La première approche proposée est basée sur l'extraction manuelle des caractéristiques pour alimenter différents classifieurs, et notamment le classifieur SVM. Cette approche montre une bonne performance sur les données réelles et bruitées comme rapporté dans la section 4.4. En outre, notre approche a montré sa supériorité vis-à-vis des approches de l'état de l'art (Matsumoto et al., 2013; Chaibi, 2014; Sciaraffa et al., 2020). Pour ce qui est de la deuxième approche, les caractéristiques discriminantes requises pour classer les événements d'intérêt (γ , $H\gamma$, R_s , FR_s , IESs) ont été automatiquement extraites des images TF par la transformée en S. Ces caractéristiques ont été introduites par la suite comme entrée dans le modèle CNN. Comme le montre la Figure 4.11, le modèle basé sur le CNN offre de meilleures performances de classification en termes de SEN, SPE, ACC, AUC et F1-score. Bien souvent, pour réduire l'éventuel surapprentissage causé par le manque de données, l'AD est récemment devenue un outil très utilisé dans de nombreux domaines dont l'objectif principal est de générer artificiellement de nouvelles données en appliquant des transformations sur les données initiales. Les résultats expérimentaux (Figure 4.11) ont montré le très bon comportement du modèle basé sur le CNN en termes de SEN, SPE, ACC, AUC et F1-score lorsque l'AD est utilisée. Cela prouve que l'augmentation artificielle de la quantité de données peut améliorer la généralisation du modèle ainsi que ses performances globales. Afin de prouver l'efficacité du modèle CNN proposé dans ses deux versions, nous avons comparé sa performance avec l'approche basée sur le ML (Krikid et al., 2022). D'après la Figure 4.12, un bon comportement du modèle CNN avec AD a été confirmé par rapport à celui basé sur le ML (Krikid et al., 2022). Ceci est probablement dû au fait que les classifieurs standards sont basés sur l'extraction manuelle de caractéristiques, qui présente une procédure subjective. Le modèle CNN a également été testé sur les données bruitées sans et avec augmentation de données,

montrant sa robustesse, notamment dans ce second cas (en termes de fonction de coût et de précision).

Si les approches proposées présentent de bonnes performances dans le cas de données réelles ou bruitées, une légère différence dans les résultats obtenus peut être remarquée. Cette différence peut être expliquée par le fait que la base de données bruitées est plus riche que la base de données réelles, ce qui peut potentiellement permettre un meilleur apprentissage.

4.7. Conclusion

Dans ce chapitre, nous avons présenté les résultats de classification des HFOs et IESs suivant deux nouvelles approches (ML et DL).

Pour l'approche 1 (basée sur le ML), une évaluation des performances sur des données réelles et bruitées a été effectuée. Grâce aux caractéristiques TF proposées, les expérimentations conduites ont montré sa bonne performance de classification, et notamment sa supériorité vis-à-vis d'approches conventionnelles.

Concernant l'approche 2 (basée sur le CNN), un bon comportement de cette approche en termes de SEN, SPE, ACC, AUC et F1-score a été confirmé sur des signaux SEEG réels et sur les données bruitées. Nous avons testé la deuxième approche suivant deux versions : sans et avec AD. Une amélioration des performances du modèle a été observée dans le cas où l'AD est appliquée. Cette technique permet de compenser la taille limitée de notre ensemble de données qui ne sont parfois pas facilement disponibles et par conséquent d'augmenter la performance du CNN.

Finalement, une étude comparative a été menée pour tester l'efficacité du modèle CNN proposé par rapport à la méthode ML basée sur le SVM sur chaque base de données (réelles et bruitées). Les résultats ont montré le bon comportement du modèle CNN dans ses deux versions par rapport à la méthode basée sur le ML.

Conclusion & perspectives

Conclusion

L'épilepsie, maladie neurologique et chronique du système nerveux, a un impact profond sur la qualité de vie des patients. Dans le cas d'épilepsies pharmaco-résistantes, pour lesquelles la chirurgie est une solution envisageable, la région cérébrale responsable de la génération des crises doit absolument être bien localisée, rendant nécessaire l'étude de biomarqueurs fiables en vue de localiser la ZE.

Au cours des deux dernières décennies, la recherche autour des HFOs et des IESs a émergé et s'est largement développée due à leur importance dans le diagnostic de l'épilepsie et plus particulièrement dans la localisation de la ZE (Roehri et al., 2019). De nombreuses études ont montré que la résection chirurgicale des tissus cérébraux associés à ces biomarqueurs menait à un bilan post-chirurgical plus favorable, comparativement à la résection de n'importe quel autre tissu (Höller et al., 2015; Thomschewski et al., 2019). Dans ce manuscrit, nous avons présenté nos contributions sur l'identification et la classification des biomarqueurs épileptiques (*i.e.* HFOs et IESs) en nous basant sur des techniques d'intelligence artificielle.

La méthodologie de traitement développée au cours de cette thèse a conduit à deux nouvelles approches de classification des biomarqueurs épileptiques (*i.e.* HFOs et IESs), et ce à partir de caractéristiques extraites des images TF. Les deux contributions mises en œuvre sont basées sur les techniques d'apprentissage automatique et d'apprentissage profond.

L'idée clé de la première contribution a consisté à introduire une combinaison des caractéristiques extraites à partir de la représentation TF avec celles liées à l'image TF binarisée associée. Cette combinaison a permis de caractériser la signature des HFOs dans l'espace TF. Nous avons ainsi développé une approche originale par rapport à celles issues de la littérature. Comme détaillé dans le chapitre 3, les HFOs et les IESs que l'on cherche à classifier sont caractérisées par un aspect *blobaire* (Jmail, 2012) très particulier dans l'espace TF. Nous avons exploré cette information structurelle pour une caractérisation complète de ces événements cérébraux. Nous avons envisagé à la fois des caractéristiques TF brutes comme le flux TF, la platitude TF permettant de caractériser l'énergie de l'événement d'intérêt dans le plan TF avec des caractéristiques inspirées de techniques de traitement d'images notamment la binarisation et le gradient d'image.

Concernant notre seconde contribution, nous avons exploré le CNN pour extraire automatiquement les caractéristiques des images TF. Par ailleurs, la classification des HFOs et des IESs en utilisant le CNN permet d'aborder le problème sous un angle différent : de la recherche manuelle des caractéristiques à l'extraction automatique de caractéristiques discriminantes et informatives. Le principe général de cette approche consiste tout d'abord en une étape de préparation des images TF de taille 224×224 à l'étape de classification *via* le CNN. Par la suite, le CNN prend en entrée les images TF dont les différentes caractéristiques sont extraites et mémorisées grâce à plusieurs étapes de traitement comprenant des filtres, ou noyaux convolutifs. L'algorithme est capable d'extraire les caractéristiques globales et locales de chaque événement d'intérêt en vue de sa classification en différentes catégories

(*i.e.* γ , $H\gamma$, Rs, FRs et IESs). Bien souvent, il est essentiel de disposer d'une large base de données contenant les différents événements d'intérêt pour une bonne performance du modèle CNN et éviter le surapprentissage. Or, cliniquement, les données SEEG sont souvent limitées. Par conséquent, une grande quantité de données peut être obtenue en augmentant les données enregistrées de plusieurs patients afin que le modèle puisse être bien pré-entraîné. En outre, l'AD est une procédure permettant la génération de nouvelles données d'apprentissage dans le but d'améliorer la précision et la robustesse des classificateurs. Dans notre travail, nous avons utilisé des méthodes d'AD couramment utilisées dans le traitement d'images *i.e.* rotation, retournement, et ajout de bruit gaussien afin de tester leur impact sur la performance du système.

Les résultats obtenus par nos deux approches sur des données réelles et bruitées ont attesté de leurs bonnes performances en termes de SEN, SPE, ACC, AUC et F1-score.

Dans le cas de la première approche, divers algorithmes de classification (*i.e.* SVM, KNN, NB et RF) ont été testés sur deux bases différentes (réelles et bruitées) montrant un bon comportement de l'algorithme SVM. Concernant les résultats de classification sur les données réelles, l'approche proposée, utilisant ce dernier algorithme, présente des résultats encourageants (environ 0,7 pour SEN et F1-score et 0,9 pour SPE, ACC et AUC). Sur les données bruitées, l'approche proposée démontre sa robustesse au bruit pour atteindre des résultats de classification qui dépassent 0,9 pour tous les critères mentionnés.

Pour la deuxième approche, le CNN a été entraîné et testé pour classifier les différents événements d'intérêt. Les résultats de classification pour les deux cas de figures sans et avec augmentation de données) dépassent 0,8 pour SEN, SPE, ACC, AUC et F1-score et sont d'autant plus élevés lorsque l'augmentation de données (AD) est adoptée. A ce titre, une amélioration sur la performance globale du CNN a été démontrée sur les données réelles, soit 0,919 pour SEN et 0,935 pour ACC. Cela prouve bien la valeur ajoutée de cette technique sur la performance du modèle CNN qui permet d'améliorer l'apprentissage de ce dernier. De plus, le bon comportement du modèle CNN proposé a été confirmé pour les données bruitées sans et avec augmentation de données. L'approche proposée démontre sa robustesse surtout pour des valeurs de SNR élevées (*i.e.* 15 dB) pour atteindre des résultats de classification égales à 0,991 et 0,996 en termes de SEN et ACC respectivement dans le cas d'AD.

Perspectives

Les perspectives pour aller plus loin dans la classification de biomarqueurs épileptiques (*i.e.* HFOs et IESs) de la ZE sont nombreuses. Tout d'abord, il semble crucial de disposer davantage de données SEEG expertisées par des neurologues pour tester les performances des méthodes proposées à plus grande échelle et juger leur intérêt clinique.

Dans le contexte de l'apprentissage profond, il paraîtrait intéressant de tester des architectures d'apprentissage par transfert (TL) telles que le VGG16 (Li et al., 2018) et ResNet (Biswas et al., 2019) afin de pouvoir faire face au manque de données, problème fréquent en apprentissage. De plus, ces architectures permettraient la conservation des connaissances acquises à partir des modèles préentraînés et en les appliquant à un problème différent mais connexe pour avoir un modèle CNN plus robuste. Par ailleurs, le TL a été déjà utilisé dans le contexte de classification binaire des HFOs mais pas pour la multi-classification.

Une autre perspective concernant les méthodes d'AD, au-delà des méthodes actuelles (*i.e.* rotation, ajout du bruit), consisterait à tester par exemple les GANs. Ces derniers sont des algorithmes qui permettent de générer des échantillons plus réalistes. D'ailleurs, cette technique d'AD a montré son efficacité dans le domaine de classification des signaux EEG comme la reconnaissance des émotions (Kalashami et al., 2022) et la prédiction de la maladie de Parkinson (Kaur et al., 2021).

Naturellement, il serait intéressant aussi d'étudier la possibilité de proposer un modèle « hybride » qui combine les deux approches développées dans cette thèse en (i) utilisant le CNN comme extracteur de caractéristiques discriminantes et le SVM comme classifieur, (ii) combinant les caractéristiques extraites manuellement (caractéristiques extraites de la représentation TF et celles liées à l'image binarisée associée) et automatiquement (extraites du CNN) à la fois. Ces caractéristiques peuvent être concaténées pour produire un nouveau vecteur de caractéristiques plus riche.

Comme autre perspective à ce travail, nous pensons à l'utilisation du modèle CNN entraîné comme un « détecteur-classifieur » des événements d'intérêt. Ce modèle serait utilisé pour chercher des HFOs (γ , $H\gamma$, Rs, FRs) et des IESs dans une séquence complète d'enregistrements SEEG. Autrement dit, il s'agirait de parcourir le signal SEEG automatiquement en utilisant des fenêtres glissantes de 200 ms et par la suite le CNN entraîné pourrait analyser les images TF générées pour les classifier.

Bibliographie

- Alvarado-Rojas, C., Huberfeld, G., Baulac, M., Clemenceau, S., Charpier, S., Miles, R., Menendez de la Prida, L. and Le Van Quyen, M., Two Different Mechanisms Associated with Ripple-like Oscillations (100-250 Hz) in the Human Epileptic Subiculum in Vitro, *Annals of Neurology*, vol. **77**, no. 2, pp. 281–90, February 2015. DOI: 10.1002/ana.24324
- Amiri, M., Lina, J.-M., Pizzo, F. and Gotman, J., High Frequency Oscillations and Spikes: Separating Real HFOs from False Oscillations, *Clinical Neurophysiology: Official Journal of the International Federation of Clinical Neurophysiology*, vol. **127**, no. 1, pp. 187–96, January 2016. DOI: 10.1016/j.clinph.2015.04.290
- Aslan, M., CNN Based Efficient Approach for Emotion Recognition, *Journal of King Saud University - Computer and Information Sciences*, vol. **34**, no. 9, pp. 7335–46, October 1, 2022. DOI: 10.1016/j.jksuci.2021.08.021
- Axmacher, N., Elger, C. E. and Fell, J., Ripples in the Medial Temporal Lobe Are Relevant for Human Memory Consolidation, *Brain: A Journal of Neurology*, vol. **131**, no. Pt 7, pp. 1806–17, July 2008. DOI: 10.1093/brain/awn103
- Ayala, G. F., Dichter, M., Gumnit, R. J., Matsumoto, H. and Spencer, W. A., Genesis of Epileptic Interictal Spikes. New Knowledge of Cortical Feedback Systems Suggests a Neurophysiological Explanation of Brief Paroxysms, *Brain Research*, vol. **52**, pp. 1–17, March 30, 1973. DOI: 10.1016/0006-8993(73)90647-1
- Bartolomei, F., Lagarde, S., Wendling, F., McGonigal, A., Jirsa, V., Guye, M. and Bénar, C., Defining Epileptogenic Networks: Contribution of SEEG and Signal Analysis, *Epilepsia*, vol. **58**, no. 7, pp. 1131–47, July 2017. DOI: 10.1111/epi.13791
- Bartolomei, F., Trébuchon, A., Bonini, F., Lambert, I., Gavaret, M., Woodman, M., Giusiano, B., Wendling, F. and Bénar, C., What Is the Concordance between the Seizure Onset Zone and the Irritative Zone? A SEEG Quantified Study, *Clinical Neurophysiology*, vol. **127**, no. 2, pp. 1157–62, February 1, 2016. DOI: 10.1016/j.clinph.2015.10.029
- Bénar, C. G., Chauvière, L., Bartolomei, F. and Wendling, F., Pitfalls of High-Pass Filtering for Detecting Epileptic Oscillations: A Technical Note on “False” Ripples, *Clinical Neurophysiology: Official Journal of the International Federation of Clinical Neurophysiology*, vol. **121**, no. 3, pp. 301–10, March 2010. DOI: 10.1016/j.clinph.2009.10.019
- Bernardo, D., Nariai, H., Hussain, S. A., Sankar, R., Salamon, N., Krueger, D. A., Sahin, M., Northrup, H., Bebin, E. M. and Wu, J. Y., Visual and Semi-Automatic Non-Invasive Detection of Interictal Fast Ripples: A Potential Biomarker of Epilepsy in Children with Tuberous Sclerosis Complex, *Clinical Neurophysiology*, vol. **129**, no. 7, pp. 1458–66, July 1, 2018. DOI: 10.1016/j.clinph.2018.03.010
- Biro, G., Kachenoura, A., Albera, L., Bénar, C. and Wendling, F., Automatic Detection of Fast Ripples, *Journal of Neuroscience Methods*, vol. **213**, no. 2, pp. 236–49, March 15, 2013. DOI: 10.1016/j.jneumeth.2012.12.013

- Biswas, A., Al Nazi, Z., and Abir, T. A., Invasive Ductal Carcinoma Detection by A Gated Recurrent Unit Network with Self Attention, *2019 4th International Conference on Electrical Information and Communication Technology (EICT), 2019 4th International Conference on Electrical Information and Communication Technology (EICT)*, pp. 1–6, 2019.
- Blanco, J. A., Stead, M., Krieger, A., Viventi, J., Marsh, W. R., Lee, K. H., Worrell, G. A. and Litt, B., Unsupervised Classification of High-Frequency Oscillations in Human Neocortical Epilepsy and Control Patients, *Journal of Neurophysiology*, vol. **104**, no. 5, pp. 2900–2912, November 2010. DOI: 10.1152/jn.01082.2009
- Boashash, B. Ed., Copyright, in *Time-Frequency Signal Analysis and Processing (Second Edition)*, Oxford: Academic Press, accessed October 20, 2022, from <https://www.sciencedirect.com/science/article/pii/B9780123984999099878>, p. iv, 2016.
- Boëx, C., Vulliémoz, S., Spinelli, L., Foletti, G. B., Pollo, C. and Seeck, M., Stimulation électrique intracrânienne dans le traitement de l'épilepsie, p. 5, 2006.
- Bragin, A., Mody, I., Wilson, C. L. and Engel, J., Local Generation of Fast Ripples in Epileptic Brain, *The Journal of Neuroscience: The Official Journal of the Society for Neuroscience*, vol. **22**, no. 5, pp. 2012–21, March 1, 2002.
- Breiman, L., Random Forests, *Machine Learning*, vol. **45**, no. 1, pp. 5–32, October 1, 2001. DOI: 10.1023/A:1010933404324
- Burnos, S., Hilfiker, P., Sürücü, O., Scholkmann, F., Krayenbühl, N., Grunwald, T. and Sarthain, J., Human Intracranial High Frequency Oscillations (HFOs) Detected by Automatic Time-Frequency Analysis, *PloS One*, vol. **9**, no. 4, p. e94381, 2014. DOI: 10.1371/journal.pone.0094381
- Caparos, M., Analyse automatique des crises d'épilepsie du lobe temporal à partir des EEG de surface, Phdthesis, Institut National Polytechnique de Lorraine - INPL, 2006.
- Chaibi, S., Lajnef, T., Sakka, Z., Samet, M. and Kachouri, A., A Comparaison of Methods for Detection of High Frequency Oscillations (HFOs) in Human Intacerberal EEG Recordings, *American Journal of Signal Processing*, vol. **3**, no. 2, pp. 25–34, 2013.
- Chaibi, S., Lajnef, T., Sakka, Z., Samet, M. and Kachouri, A., A Reliable Approach to Distinguish between Transient with and without HFOs Using TQWT and MCA, *Journal of Neuroscience Methods*, vol. **232**, pp. 36–46, July 1, 2014. DOI: 10.1016/j.jneumeth.2014.04.025
- Chaibi, S., Lajnef, T., Samet, M., Jerbi, K., and Kachouri, A., Detection of High Frequency Oscillations (HFOs) in the 80-500 Hz Range in Epilepsy Recordings Using Decision Tree Analysis, 2014.
- Chander, R., Algorithms to detect High Frequency Oscillations in human intracerebral electroencephalogram, , These de doctorat, Canada, 2007.
- Charupanit, K. and Lopour, B. A., A Simple Statistical Method for the Automatic Detection of Ripples in Human Intracranial EEG, *Brain Topography*, vol. **30**, no. 6, pp. 724–38, November 2017. DOI: 10.1007/s10548-017-0579-6

- Cimbálník, J., Hewitt, A., Worrell, G. and Stead, M., The CS Algorithm: A Novel Method for High Frequency Oscillation Detection in EEG, *Journal of Neuroscience Methods*, vol. **293**, pp. 6–16, January 1, 2018. DOI: 10.1016/j.jneumeth.2017.08.023
- Ciresan, D., Giusti, A., Gambardella, L., and Schmidhuber, J., Deep Neural Networks Segment Neuronal Membranes in Electron Microscopy Images, *Advances in Neural Information Processing Systems*, Curran Associates, Inc., vol. **25**, 2012.
- Cortes, C. and Vapnik, V., Support-Vector Networks, *Machine Learning*, vol. **20**, no. 3, pp. 273–97, September 1995. DOI: 10.1007/BF00994018
- Cozzone, P. J., Vion-Dury, J. and Confort-Gouny, S., L'imagerie et la spectroscopie par résonance magnétique nucléaire du cerveau: une nouvelle approche de la physiopathologie cérébrale, *Annales Françaises d'Anesthésie et de Réanimation*, vol. **11**, no. 6, pp. 666–71, January 1, 1992. DOI: 10.1016/S0750-7658(05)80787-7
- Crépon, B., Navarro, V., Hasboun, D., Clemenceau, S., Martinerie, J., Baulac, M., Adam, C. and Le Van Quyen, M., Mapping Interictal Oscillations Greater than 200 Hz Recorded with Intracranial Macroelectrodes in Human Epilepsy, *Brain: A Journal of Neurology*, vol. **133**, no. Pt 1, pp. 33–45, January 2010. DOI: 10.1093/brain/awp277
- Deslauriers-Gauthier, S., Classification des pointes épileptiques en électro-magnéto-encéphalographie, Masters, École de technologie supérieure, 2010.
- Donos, C., Mîndruță, I. and Barborica, A., Unsupervised Detection of High-Frequency Oscillations Using Time-Frequency Maps and Computer Vision, *Frontiers in Neuroscience*, vol. **14**, p. 183, March 23, 2020. DOI: 10.3389/fnins.2020.00183
- Doshi, C., Methods for Detecting High-Frequency Oscillations in Ongoing Brain Signals: Application to the Determination of Epileptic Seizure Onset Zones, *Master's Theses (2009 -)*, from https://epublications.marquette.edu/theses_open/100, July 1, 2011.
- Du, Y., Sun, B., Lu, R., Zhang, C. and Wu, H., A Method for Detecting High-Frequency Oscillations Using Semi-Supervised k-Means and Mean Shift Clustering, *Neurocomputing*, vol. **350**, pp. 102–7, July 20, 2019. DOI: 10.1016/j.neucom.2019.03.055
- Dümpelmann, M., Jacobs, J., Kerber, K. and Schulze-Bonhage, A., Automatic 80–250Hz “Ripple” High Frequency Oscillation Detection in Invasive Subdural Grid and Strip Recordings in Epilepsy by a Radial Basis Function Neural Network, *Clinical Neurophysiology*, vol. **123**, no. 9, pp. 1721–31, September 1, 2012. DOI: 10.1016/j.clinph.2012.02.072
- Elgeldawi, E., Sayed, A., Galal, A. R. and Zaki, A. M., Hyperparameter Tuning for Machine Learning Algorithms Used for Arabic Sentiment Analysis, *Informatics*, vol. **8**, no. 4, p. 79, November 17, 2021. DOI: 10.3390/informatics8040079
- Ellenrieder, N. von, Dubeau, F., Gotman, J. and Frauscher, B., Physiological and Pathological High-Frequency Oscillations Have Distinct Sleep-Homeostatic Properties, *NeuroImage. Clinical*, vol. **14**, pp. 566–73, 2017. DOI: 10.1016/j.nicl.2017.02.018
- Fedele, T., Burnos, S., Boran, E., Kraysenbühl, N., Hilfiker, P., Grunwald, T. and Sarnthein, J., Resection of High Frequency Oscillations Predicts Seizure Outcome in the Individual Patient, *Scientific Reports*, vol. **7**, no. 1, p. 13836, October 23, 2017. DOI: 10.1038/s41598-017-13064-1

- Firpi, H., Smart, O., Worrell, G., Marsh, E., Dlugos, D. and Litt, B., High-Frequency Oscillations Detected in Epileptic Networks Using Swarmed Neural-Network Features, *Annals of Biomedical Engineering*, vol. **35**, no. 9, pp. 1573–84, September 2007. DOI: 10.1007/s10439-007-9333-7
- Fiscon, G., Weitschek, E., Cialini, A., Felici, G., Bertolazzi, P., De Salvo, S., Bramanti, A., Bramanti, P. and De Cola, M. C., Combining EEG Signal Processing with Supervised Methods for Alzheimer's Patients Classification, *BMC Medical Informatics and Decision Making*, vol. **18**, no. 1, p. 35, December 2018. DOI: 10.1186/s12911-018-0613-y
- Fisher, R. S., Boas, W. van E., Blume, W., Elger, C., Genton, P., Lee, P. and Engel Jr., J., Epileptic Seizures and Epilepsy: Definitions Proposed by the International League Against Epilepsy (ILAE) and the International Bureau for Epilepsy (IBE), *Epilepsia*, vol. **46**, no. 4, pp. 470–72, 2005. DOI: 10.1111/j.0013-9580.2005.66104.x
- Fisher, R. S., Cross, J. H., D'Souza, C., French, J. A., Haut, S. R., Higurashi, N., Hirsch, E., et al., Instruction Manual for the ILAE 2017 Operational Classification of Seizure Types, *Epilepsia*, vol. **58**, no. 4, pp. 531–42, April 2017. DOI: 10.1111/epi.13671
- Gardner, A. B., Worrell, G. A., Marsh, E., Dlugos, D. and Litt, B., Human and Automated Detection of High-Frequency Oscillations in Clinical Intracranial EEG Recordings, *Clinical Neurophysiology: Official Journal of the International Federation of Clinical Neurophysiology*, vol. **118**, no. 5, pp. 1134–43, May 2007. DOI: 10.1016/j.clinph.2006.12.019
- Gardy, L., Détection automatique multi-échelle et de grande envergure d'oscillations intracérébrales pathologiques dans l'épilepsie par réseaux de neurones artificiels, Phdthesis, Université Paul Sabatier - Toulouse III, 2021.
- Gardy, L., Détection automatique multi-échelle et de grande envergure d'oscillations intracérébrales pathologiques dans l'épilepsie par réseaux de neurones artificiels, p. 267, n.d.
- George, R., Salinsky, M., Kuzniecky, R., Rosenfeld, W., Bergen, D., Tarver, W. B. and Wernicke, J. F., Vagus Nerve Stimulation for Treatment of Partial Seizures: 3. Long-Term Follow-up on First 67 Patients Exiting a Controlled Study. First International Vagus Nerve Stimulation Study Group, *Epilepsia*, vol. **35**, no. 3, pp. 637–43, June 1994. DOI: 10.1111/j.1528-1157.1994.tb02484.x
- Ghasemzadeh, P., Kalbkhani, H. and Shayesteh, M. G., Sleep Stages Classification from EEG Signal Based on Stockwell Transform, *IET Signal Processing*, vol. **13**, no. 2, pp. 242–52, 2019. DOI: 10.1049/iet-spr.2018.5032
- Gliske, S. V., Irwin, Z. T., Davis, K. A., Sahaya, K., Chestek, C. and Stacey, W. C., Universal Automated High Frequency Oscillation Detector for Real-Time, Long Term EEG, *Clinical Neurophysiology: Official Journal of the International Federation of Clinical Neurophysiology*, vol. **127**, no. 2, pp. 1057–66, February 2016. DOI: 10.1016/j.clinph.2015.07.016
- Gotman, J. and Gloor, P., Automatic Recognition and Quantification of Interictal Epileptic Activity in the Human Scalp EEG, *Electroencephalography and Clinical Neurophysiology*, vol. **41**, no. 5, pp. 513–29, November 1976. DOI: 10.1016/0013-4694(76)90063-8

- Grouiller, F., Cartographie fonctionnelle du cerveau épileptique lors des évaluations préchirurgicales, Phdthesis, Université Joseph-Fourier - Grenoble I, 2008.
- Guermeur, Y., SVM Multiclasses, Théorie et Applications, Thesis, Université Henri Poincaré - Nancy I, 2007.
- Gupta, V. and Pachori, R. B., FBDM Based Time-Frequency Representation for Sleep Stages Classification Using EEG Signals, *Biomedical Signal Processing and Control*, vol. **64**, p. 102265, February 1, 2021. DOI: 10.1016/j.bspc.2020.102265
- He, C., Liu, J., Zhu, Y. and Du, W., Data Augmentation for Deep Neural Networks Model in EEG Classification Task: A Review, *Frontiers in Human Neuroscience*, vol. **15**, accessed October 20, 2022, from <https://www.frontiersin.org/articles/10.3389/fnhum.2021.765525>, 2021.
- Hébert, C., Matrices de microélectrodes tout diamant et composite diamant / nanotubes de carbone pour la neurophysiologie : du matériau aux composants d'interface, Phdthesis, Université de Grenoble, 2012.
- Hochreiter, S. and Schmidhuber, J., Long Short-Term Memory, *Neural Computation*, vol. **9**, no. 8, pp. 1735–80, November 15, 1997. DOI: 10.1162/neco.1997.9.8.1735
- Höller, Y., Kutil, R., Klaffenböck, L., Thomschewski, A., Höller, P. M., Bathke, A. C., Jacobs, J., Taylor, A. C., Nardone, R. and Trinka, E., High-Frequency Oscillations in Epilepsy and Surgical Outcome. A Meta-Analysis, *Frontiers in Human Neuroscience*, vol. **9**, p. 574, 2015. DOI: 10.3389/fnhum.2015.00574
- Ioffe, S., and Szegedy, C., Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, March 2, 2015.
- Jacobs, J., Staba, R., Asano, E., Otsubo, H., Wu, J. Y., Zijlmans, M., Mohamed, I., et al., High-Frequency Oscillations (HFOs) in Clinical Epilepsy, *Progress in Neurobiology*, vol. **98**, no. 3, pp. 302–15, September 2012. DOI: 10.1016/j.pneurobio.2012.03.001
- Jacobs, Julia, Zijlmans, M., Zelmann, R., Chatillon, C.-E., Hall, J., Olivier, A., Dubeau, F. and Gotman, J., High-Frequency Electroencephalographic Oscillations Correlate with Outcome of Epilepsy Surgery, *Annals of Neurology*, vol. **67**, no. 2, pp. 209–20, February 2010a. DOI: 10.1002/ana.21847
- Jacobs, Julia, Zijlmans, M., Zelmann, R., Chatillon, C.-E., Hall, J., Olivier, A., Dubeau, F. and Gotman, J., High-Frequency Electroencephalographic Oscillations Correlate with Outcome of Epilepsy Surgery, *Annals of Neurology*, vol. **67**, no. 2, pp. 209–20, February 2010b. DOI: 10.1002/ana.21847
- Jadhav, P., Rajguru, G., Datta, D. and Mukhopadhyay, S., Automatic Sleep Stage Classification Using Time–Frequency Images of CWT and Transfer Learning Using Convolution Neural Network, *Biocybernetics and Biomedical Engineering*, vol. **40**, no. 1, pp. 494–504, January 1, 2020. DOI: 10.1016/j.bbe.2020.01.010
- Jiang, C., Li, X., Yan, J., Yu, T., Wang, X., Ren, Z., Li, D., et al., Determining the Quantitative Threshold of High-Frequency Oscillation Distribution to Delineate the Epileptogenic Zone by Automated Detection, *Frontiers in Neurology*, vol. **9**, p. 889, 2018. DOI: 10.3389/fneur.2018.00889

- Jirsch, J. D., Urrestarazu, E., LeVan, P., Olivier, A., Dubeau, F. and Gotman, J., High-Frequency Oscillations during Human Focal Seizures, *Brain: A Journal of Neurology*, vol. **129**, no. Pt 6, pp. 1593–1608, June 2006. DOI: 10.1093/brain/awl085
- Jmail, N., Séparation Des Activités Cérébrales Phasiques et Oscillatoires En MEG, EEG et EEG Intracérébral
- Jmail, N., Gavaret, M., Wendling, F., Kachouri, A., Hamadi, G., Badier, J.-M. and Bénar, C.-G., A Comparison of Methods for Separation of Transient and Oscillatory Signals in EEG, *Journal of Neuroscience Methods*, vol. **199**, no. 2, pp. 273–89, August 15, 2011. DOI: 10.1016/j.jneumeth.2011.04.028
- Jrad, N., Kachenoura, A., Merlet, I., Bartolomei, F., Nica, A., Biraben, A. and Wendling, F., Automatic Detection and Classification of High-Frequency Oscillations in Depth-EEG Signals, *IEEE Transactions on Biomedical Engineering*, vol. **64**, no. 9, pp. 2230–40, September 2017. DOI: 10.1109/TBME.2016.2633391
- Kahane, P., Landré, E., Minotti, L., Francione, S. and Ryvlin, P., The Bancaud and Talairach View on the Epileptogenic Zone: A Working Hypothesis, *Epileptic Disorders: International Epilepsy Journal with Videotape*, vol. **8 Suppl 2**, pp. S16-26, August 2006.
- Kalashami, M. P., Pedram, M. M. and Sadr, H., EEG Feature Extraction and Data Augmentation in Emotion Recognition, *Computational Intelligence and Neuroscience*, vol. **2022**, p. e7028517, March 28, 2022. DOI: 10.1155/2022/7028517
- Kaur, P., Mammogram Image Nucleus Segmentation and Classification Using Convolution Neural Network Classifier, p. 12, 2016.
- Kaur, S., Aggarwal, H. and Rani, R., Diagnosis of Parkinson's Disease Using Deep CNN with Transfer Learning and Data Augmentation, *Multimedia Tools and Applications*, vol. **80**, no. 7, pp. 10113–39, March 2021. DOI: 10.1007/s11042-020-10114-1
- Khalilov, I., Le Van Quyen, M., Gozlan, H. and Ben-Ari, Y., Epileptogenic Actions of GABA and Fast Oscillations in the Developing Hippocampus, *Neuron*, vol. **48**, no. 5, pp. 787–96, December 8, 2005. DOI: 10.1016/j.neuron.2005.09.026
- Krikid, F., Chaibi, S., Karfoul, A., Kachouri, A., and Jeannès, R. L. B., A Comparative Study between Three Epileptic High Frequency Oscillations Detection Strategies, *2020 17th International Multi-Conference on Systems, Signals & Devices (SSD), 2020 17th International Multi-Conference on Systems, Signals & Devices (SSD)*, pp. 631–35, 2020.
- Krikid, F., Karfoul, A., Chaibi, S., Kachenoura, A., Nica, A., Kachouri, A. and Le Bouquin Jeannès, R., Classification of High Frequency Oscillations in Intracranial EEG Signals Based on Coupled Time-Frequency and Image-Related Features, *Biomedical Signal Processing and Control*, vol. **73**, p. 103418, March 1, 2022. DOI: 10.1016/j.bspc.2021.103418
- Krishnan, P. T., and Balasubramanian, P., Automated EEG Seizure Detection Based on S-Transform, *2016 IEEE International Conference on Computational Intelligence and Computing Research (ICCIC), 2016 IEEE International Conference on Computational Intelligence and Computing Research (ICCIC)*, pp. 1–5, 2016.
- Lachner-Piza, D., Jacobs, J., Bruder, J. C., Schulze-Bonhage, A., Stieglitz, T. and Dümpelmann, M., Automatic Detection of High-Frequency-Oscillations and Their Sub-

- Groups Co-Occurring with Interictal-Epileptic-Spikes, *Journal of Neural Engineering*, vol. **17**, no. 1, p. 016030, January 2020. DOI: 10.1088/1741-2552/ab4560
- Lai, D., Zhang, X., Ma, K., Chen, Z., Chen, W., Zhang, H., Yuan, H. and Ding, L., Automated Detection of High Frequency Oscillations in Intracranial EEG Using the Combination of Short-Time Energy and Convolutional Neural Networks, *IEEE Access*, vol. **7**, pp. 82501–11, 2019. DOI: 10.1109/ACCESS.2019.2923281
- LeCun, Y., Bengio, Y. and Hinton, G., Deep Learning, *Nature*, vol. **521**, no. 7553, pp. 436–44, May 2015. DOI: 10.1038/nature14539
- Lewis, D. D., Naive (Bayes) at Forty: The Independence Assumption in Information Retrieval, *Machine Learning: ECML-98*, Berlin, Heidelberg: Springer, pp. 4–15, 1998.
- Li, Q., Cai, W., Wang, X., Zhou, Y., Feng, D. D., and Chen, M., Medical Image Classification with Convolutional Neural Network, *2014 13th International Conference on Control Automation Robotics & Vision (ICARCV), 2014 13th International Conference on Control Automation Robotics & Vision (ICARCV)*, pp. 844–48, 2014.
- Li, X., Grandvalet, Y., and Davoine, F., Explicit Inductive Bias for Transfer Learning with Convolutional Networks, *35th International Conference on Machine Learning (ICML 2018)*, Stockholm, Sweden, vol. **80**, pp. 2825–34, 2018.
- Liu, S., Ince, N. F., Sabanci, A., Aydoseli, A., Aras, Y., Sencer, A., Bebek, N., Sha, Z., and Gurses, C., Detection of High Frequency Oscillations in Epilepsy with K-Means Clustering Method, *2015 7th International IEEE/EMBS Conference on Neural Engineering (NER), 2015 7th International IEEE/EMBS Conference on Neural Engineering (NER)*, pp. 934–37, 2015.
- Liu, S., Sha, Z., Sencer, A., Aydoseli, A., Bebek, N., Abosch, A., Henry, T., Gurses, C. and Ince, N. F., Exploring the Time–Frequency Content of High Frequency Oscillations for Automated Identification of Seizure Onset Zone in Epilepsy, *Journal of Neural Engineering*, vol. **13**, no. 2, p. 026026, February 2016. DOI: 10.1088/1741-2560/13/2/026026
- Liu, X., Deng, Z. and Yang, Y., Recent Progress in Semantic Image Segmentation, *Artificial Intelligence Review*, vol. **52**, no. 2, pp. 1089–1106, August 2019. DOI: 10.1007/s10462-018-9641-3
- Liu, Z., Wei, P., Wang, Y., Yang, Y., Dai, Y., Cao, G., Kang, G., Shan, Y., Liu, D. and Xie, Y., Automatic Detection of High-Frequency Oscillations Based on an End-to-End Bi-Branch Neural Network and Clinical Cross-Validation, *Computational Intelligence and Neuroscience*, vol. **2021**, p. e7532241, December 28, 2021. DOI: 10.1155/2021/7532241
- López-Cuevas, A., Castillo-Toledo, B., Medina-Ceja, L., Ventura-Mejía, C. and Pardo-Peña, K., An Algorithm for On-Line Detection of High Frequency Oscillations Related to Epilepsy, *Computer Methods and Programs in Biomedicine*, vol. **110**, no. 3, pp. 354–60, June 1, 2013. DOI: 10.1016/j.cmpb.2013.01.014
- Lüders, H. O., Najm, I., Nair, D., Widdess-Walsh, P. and Bingman, W., The Epileptogenic Zone: General Principles, *Epileptic Disorders: International Epilepsy Journal with Videotape*, vol. **8 Suppl 2**, pp. S1-9, August 2006.

- Madhavan, S., Tripathy, R. K. and Pachori, R. B., Time-Frequency Domain Deep Convolutional Neural Network for the Classification of Focal and Non-Focal EEG Signals, *IEEE Sensors Journal*, vol. **20**, no. 6, pp. 3078–86, March 2020. DOI: 10.1109/JSEN.2019.2956072
- Mandhouj, B., Cherni, M. A. and Sayadi, M., An Automated Classification of EEG Signals Based on Spectrogram and CNN for Epilepsy Diagnosis, *Analog Integrated Circuits and Signal Processing*, vol. **108**, no. 1, pp. 101–10, July 1, 2021. DOI: 10.1007/s10470-021-01805-2
- Matsumoto, A., Brinkmann, B. H., Matthew Stead, S., Matsumoto, J., Kucewicz, M. T., Marsh, W. R., Meyer, F. and Worrell, G., Pathological and Physiological High-Frequency Oscillations in Focal Human Epilepsy, *Journal of Neurophysiology*, vol. **110**, no. 8, pp. 1958–64, October 2013. DOI: 10.1152/jn.00341.2013
- Melani, F., Zelmann, R., Dubeau, F. and Gotman, J., Occurrence of Scalp-Fast Oscillations among Patients with Different Spiking Rate and Their Role as Epileptogenicity Marker, *Epilepsy Research*, vol. **106**, no. 3, pp. 345–56, October 1, 2013. DOI: 10.1016/j.eplepsyres.2013.06.003
- Merabet, Y. E., Segmentation d'images couleur par combinaison LPE-régions/LPE-contours et fusion de régions. Application à la segmentation de toitures à partir d'orthophotoplans, Phdthesis, Université de Technologie de Belfort-Montbéliard ; Université Ibn Tofail. Faculté des sciences de Kénitra, 2013.
- Migliorelli, C., Bachiller, A., Alonso, J. F., Romero, S., Aparicio, J., Van, J. J.-L., Mañanas, M. A. and Antonio-Arce, V. S., SGM: A Novel Time-Frequency Algorithm Based on Unsupervised Learning Improves High-Frequency Oscillation Detection in Epilepsy, *Journal of Neural Engineering*, vol. **17**, no. 2, p. 026032, April 2020. DOI: 10.1088/1741-2552/ab8345
- Moghim, N. and Corne, D. W., Predicting Epileptic Seizures in Advance, *PloS One*, vol. **9**, no. 6, p. e99334, 2014. DOI: 10.1371/journal.pone.0099334
- Nadalin, J. K., Eden, U. T., Han, X., Richardson, R. M., Chu, C. J. and Kramer, M. A., Application of a Convolutional Neural Network for Fully-Automated Detection of Spike Ripples in the Scalp Electroencephalogram, *Journal of Neuroscience Methods*, vol. **360**, p. 109239, August 1, 2021. DOI: 10.1016/j.jneumeth.2021.109239
- Nair, D. R., Mohamed, A., Burgess, R. and Lüders, H., A Critical Review of the Different Conceptual Hypotheses Framing Human Focal Epilepsy, *Epileptic Disorders: International Epilepsy Journal with Videotape*, vol. **6**, no. 2, pp. 77–83, June 2004.
- Otsu, N., A Threshold Selection Method from Gray-Level Histograms, *IEEE Transactions on Systems, Man, and Cybernetics*, vol. **9**, no. 1, pp. 62–66, January 1979. DOI: 10.1109/TSMC.1979.4310076
- Pail, M., Halánek, J., Daniel, P., Kuba, R., Tyrlíková, I., Chrastina, J., Jurák, P., Rektor, I. and Brázdil, M., Intracerebrally Recorded High Frequency Oscillations: Simple Visual Assessment versus Automated Detection, *Clinical Neurophysiology*, vol. **124**, no. 10, pp. 1935–42, October 1, 2013. DOI: 10.1016/j.clinph.2013.03.032
- Park, S.-C., Lee, S. K., Che, H. and Chung, C. K., Ictal High-Gamma Oscillation (60–99Hz) in Intracranial Electroencephalography and Postoperative Seizure Outcome in

- Neocortical Epilepsy, *Clinical Neurophysiology*, vol. **123**, no. 6, pp. 1100–1110, June 1, 2012. DOI: 10.1016/j.clinph.2012.01.008
- Parvizi, J. and Kastner, S., Promises and Limitations of Human Intracranial Electroencephalography, *Nature Neuroscience*, vol. **21**, no. 4, pp. 474–83, April 2018. DOI: 10.1038/s41593-018-0108-2
- Rashed-Al-Mahfuz, Md., Moni, M. A., Uddin, S., Alyami, S. A., Summers, M. A. and Eapen, V., A Deep Convolutional Neural Network Method to Detect Seizures and Characteristic Frequencies Using Epileptic Electroencephalogram (EEG) Data, *IEEE Journal of Translational Engineering in Health and Medicine*, vol. **9**, pp. 1–12, 2021. DOI: 10.1109/JTEHM.2021.3050925
- Remakanthakurup Sindhu, K., Staba, R. and Lopour, B. A., Trends in the Use of Automated Algorithms for the Detection of High-Frequency Oscillations Associated with Human Epilepsy, *Epilepsia*, vol. **61**, no. 8, pp. 1553–69, 2020. DOI: 10.1111/epi.16622
- Ren, S., Gliske, S. V., Brang, D. and Stacey, W. C., Redaction of False High Frequency Oscillations Due to Muscle Artifact Improves Specificity to Epileptic Tissue, *Clinical Neurophysiology*, vol. **130**, no. 6, pp. 976–85, June 1, 2019. DOI: 10.1016/j.clinph.2019.03.028
- Roehri, N. and Bartolomei, F., Are High-Frequency Oscillations Better Biomarkers of the Epileptogenic Zone than Spikes?, *Current Opinion in Neurology*, vol. **32**, no. 2, pp. 213–19, 2019. DOI: 10.1097/WCO.0000000000000663
- Roehri, N., Lina, J.-M., Mosher, J. C., Bartolomei, F. and Benar, C.-G., Time-Frequency Strategies for Increasing High-Frequency Oscillation Detectability in Intracerebral EEG, *IEEE Transactions on Bio-Medical Engineering*, vol. **63**, no. 12, pp. 2595–2606, December 2016. DOI: 10.1109/TBME.2016.2556425
- Salamon, J. and Bello, J. P., Deep Convolutional Neural Networks and Data Augmentation for Environmental Sound Classification, *IEEE Signal Processing Letters*, vol. **24**, no. 3, pp. 279–83, March 2017. DOI: 10.1109/LSP.2017.2657381
- Schulze-Bonhage, A., Feldwisch-Drentrup, H. and Ihle, M., The Role of High-Quality EEG Databases in the Improvement and Assessment of Seizure Prediction Methods, *Epilepsy & Behavior*, vol. **22**, pp. S88–93, December 1, 2011. DOI: 10.1016/j.yebeh.2011.08.030
- Sciaraffa, N., Klados, M. A., Borghini, G., Di Flumeri, G., Babiloni, F. and Aricò, P., Double-Step Machine Learning Based Procedure for HFOs Detection and Classification, *Brain Sciences*, vol. **10**, no. 4, p. E220, April 8, 2020. DOI: 10.3390/brainsci10040220
- Seron, X. and Jeannerod, M., *Neuropsychologie humaine*, Sprimont, Belgique: Mardaga, pp. 615, 1998.
- Shuvo, S. B., Ali, S. N., Swapnil, S. I., Hasan, T., and Bhuiyan, M. I. H., A Lightweight CNN Model for Detecting Respiratory Diseases from Lung Auscultation Sounds Using EMD-CWT-Based Hybrid Scalogram, September 8, 2020.
- Silverman, B. W. and Jones, M. C., E. Fix and J.L. Hodges (1951): An Important Contribution to Nonparametric Discriminant Analysis and Density Estimation: Commentary on Fix and Hodges (1951), *International Statistical Review / Revue Internationale de Statistique*, vol. **57**, no. 3, pp. 233–38, 1989. DOI: 10.2307/1403796

- Simonyan, K., and Zisserman, A., Very Deep Convolutional Networks for Large-Scale Image Recognition, April 10, 2015.
- Sinapin, M. N., L'intelligence Artificielle : Entre Opportunités et Risques Légitimes, *Oriane 2020 : 18e Colloque Francophone Sur Le Risque*, Bayonne, France, 2020.
- Soleimani, M., Vahidi, A. and Vaseghi, B., Two-Dimensional Stockwell Transform and Deep Convolutional Neural Network for Multi-Class Diagnosis of Pathological Brain, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. **29**, pp. 163–72, 2021. DOI: 10.1109/TNSRE.2020.3040627
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R., Dropout: A Simple Way to Prevent Neural Networks from Overfitting, p. 30, n.d.
- Ssekidde, P., Steven Eyobu, O., Han, D. S. and Oyana, T. J., Augmented CWT Features for Deep Learning-Based Indoor Localization Using WiFi RSSI Data, *Applied Sciences*, vol. **11**, no. 4, p. 1806, January 2021. DOI: 10.3390/app11041806
- Staba, R. J., Wilson, C. L., Bragin, A., Fried, I. and Engel, J., Quantitative Analysis of High-Frequency Oscillations (80-500 Hz) Recorded in Human Epileptic Hippocampus and Entorhinal Cortex, *Journal of Neurophysiology*, vol. **88**, no. 4, pp. 1743–52, October 2002. DOI: 10.1152/jn.2002.88.4.1743
- Staley, K. J. and Dudek, F. E., Interictal Spikes and Epileptogenesis, *Epilepsy Currents*, vol. **6**, no. 6, pp. 199–202, November 2006. DOI: 10.1111/j.1535-7511.2006.00145.x
- Stockwell, R. G., A Basis for Efficient Representation of the S-Transform, *Digital Signal Processing*, vol. **17**, no. 1, pp. 371–93, January 1, 2007. DOI: 10.1016/j.dsp.2006.04.006
- Stockwell, R. G., Mansinha, L. and Lowe, R. P., Localization of the Complex Spectrum: The S Transform, *IEEE Transactions on Signal Processing*, vol. **44**, no. 4, pp. 998–1001, April 1996. DOI: 10.1109/78.492555
- Suárez-Paniagua, V. and Segura-Bedmar, I., Evaluation of Pooling Operations in Convolutional Architectures for Drug-Drug Interaction Extraction, *BMC Bioinformatics*, vol. **19**, no. 8, p. 209, June 13, 2018. DOI: 10.1186/s12859-018-2195-1
- Sultana, F., Sufian, A. and Dutta, P., Evolution of Image Segmentation Using Deep Convolutional Neural Network: A Survey, *Knowledge-Based Systems*, vol. **201–202**, p. 106062, August 2020. DOI: 10.1016/j.knosys.2020.106062
- Sun, F. T. and Morrell, M. J., The RNS System: Responsive Cortical Stimulation for the Treatment of Refractory Partial Epilepsy, *Expert Review of Medical Devices*, vol. **11**, no. 6, pp. 563–72, November 2014. DOI: 10.1586/17434440.2014.947274
- Sun, J., Cao, R., Zhou, M., Hussain, W., Wang, B., Xue, J. and Xiang, J., A Hybrid Deep Neural Network for Classification of Schizophrenia Using EEG Data, *Scientific Reports*, vol. **11**, no. 1, p. 4706, February 25, 2021. DOI: 10.1038/s41598-021-83350-6
- Suzuki, T., Fast Learning Rate of Deep Learning via a Kernel Perspective, May 29, 2017.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A., Going Deeper with Convolutions, September 16, 2014.

- Takayanagi, Y., Takayama, Y., Iijima, K., Iwasaki, M. and Ono, Y., Efficient Detection of High-Frequency Biomarker Signals of Epilepsy by a Transfer-Learning-Based Convolutional Neural Network, *Advanced Biomedical Engineering*, vol. **10**, no. 0, pp. 158–65, 2021. DOI: 10.14326/abe.10.158
- Thomschewski, A., Hincapié, A.-S. and Frauscher, B., Localization of the Epileptogenic Zone Using High Frequency Oscillations, *Frontiers in Neurology*, vol. **10**, accessed October 20, 2022, from <https://www.frontiersin.org/articles/10.3389/fneur.2019.00094>, 2019.
- Tibshirani, S. and Friedman, H., Valerie and Patrick Hastie, p. 764, n.d.
- Uhlhaas, P. J., Pipa, G., Neuenschwander, S., Wibral, M. and Singer, W., A New Look at Gamma? High- (>60 Hz) γ -Band Activity in Cortical Networks: Function, Mechanisms and Impairment, *Progress in Biophysics and Molecular Biology*, vol. **105**, no. 1–2, pp. 14–28, March 2011. DOI: 10.1016/j.pbiomolbio.2010.10.004
- Velez-Perez, H., Localisation et Caractérisation Du Déroulement de La Crise d'épilepsie Temporelle, Theses, Institut National Polytechnique de Lorraine - INPL, 2010.
- Wan, T., Wu, M., Wan, X., and Du, Y., Automatic Detection of High Frequency Oscillations Based on Fuzzy Entropy and Fuzzy Neural Network, *2016 35th Chinese Control Conference (CCC), 2016 35th Chinese Control Conference (CCC)*, pp. 5027–32, 2016.
- Wang, S., Wang, I. Z., Bulacio, J. C., Mosher, J. C., Gonzalez-Martinez, J., Alexopoulos, A. V., Najm, I. M. and So, N. K., Ripple Classification Helps to Localize the Seizure-Onset Zone in Neocortical Epilepsy, *Epilepsia*, vol. **54**, no. 2, pp. 370–76, February 2013. DOI: 10.1111/j.1528-1167.2012.03721.x
- Watkins, C. J. C. H. and Dayan, P., Q-Learning, *Machine Learning*, vol. **8**, no. 3, pp. 279–92, May 1, 1992. DOI: 10.1007/BF00992698
- Wendling, F., Bartolomei, F., Mina, F., Huneau, C. and Benquet, P., Interictal Spikes, Fast Ripples and Seizures in Partial Epilepsies - Combining Multi-Level Computational Models with Experimental Data., *European Journal of Neuroscience*, vol. **36**, no. 2, pp. 2164–77, July 2012. DOI: 10.1111/j.1460-9568.2012.08039.x
- Wendling, F., Chauvel, P., Biraben, A. and Bartolomei, F., From Intracerebral EEG Signals to Brain Connectivity: Identification of Epileptogenic Networks in Partial Epilepsy, *Frontiers in Systems Neuroscience*, vol. **4**, accessed October 9, 2022, from <https://www.frontiersin.org/articles/10.3389/fnsys.2010.00154>, 2010.
- Werbos, P. J., Backpropagation through Time: What It Does and How to Do It, *Proceedings of the IEEE*, vol. **78**, no. 10, pp. 1550–60, October 1990. DOI: 10.1109/5.58337
- Westen, D., *Psychologie: pensée, cerveau et culture*, De Boeck Université, pp. 1250, 2000.
- Williams, R. W. and Herrup, K., The Control of Neuron Number, *Annual Review of Neuroscience*, vol. **11**, no. 1, pp. 423–53, 1988. DOI: 10.1146/annurev.ne.11.030188.002231
- Worrell, G. A., Gardner, A. B., Stead, S. M., Hu, S., Goerss, S., Cascino, G. J., Meyer, F. B., Marsh, R. and Litt, B., High-Frequency Oscillations in Human Temporal Lobe: Simultaneous Microwire and Clinical Macroelectrode Recordings, *Brain: A Journal of Neurology*, vol. **131**, no. Pt 4, pp. 928–37, April 2008. DOI: 10.1093/brain/awn006

- Yan, P. Z., Wang, F., Kwok, N., Allen, B. B., Keros, S. and Grinspan, Z., Automated Spectrographic Seizure Detection Using Convolutional Neural Networks, *Seizure*, vol. **71**, pp. 124–31, October 1, 2019. DOI: 10.1016/j.seizure.2019.07.009
- Yazdanpour-Naeini, R., Automatic Detection of High Frequency Oscillations of Neural Signals in Epileptic Patients, Masters, Concordia University, 2012.
- Yildiz, A., Zan, H. and Said, S., Classification and Analysis of Epileptic EEG Recordings Using Convolutional Neural Network and Class Activation Mapping, *Biomedical Signal Processing and Control*, vol. **68**, p. 102720, July 1, 2021. DOI: 10.1016/j.bspc.2021.102720
- Zelmann, R., Mari, F., Jacobs, J., Zijlmans, M., Dubeau, F. and Gotman, J., A Comparison between Detectors of High Frequency Oscillations, *Clinical Neurophysiology: Official Journal of the International Federation of Clinical Neurophysiology*, vol. **123**, no. 1, pp. 106–16, January 2012. DOI: 10.1016/j.clinph.2011.06.006
- Zelmann, Rina, Zijlmans, M., Jacobs, J., Châtillon, C.-E. and Gotman, J., Improving the Identification of High Frequency Oscillations, *Clinical Neurophysiology: Official Journal of the International Federation of Clinical Neurophysiology*, vol. **120**, no. 8, pp. 1457–64, August 2009. DOI: 10.1016/j.clinph.2009.05.029
- Zhang, K., Xu, G., Han, Z., Ma, K., Zheng, X., Chen, L., Duan, N. and Zhang, S., Data Augmentation for Motor Imagery Signal Classification Based on a Hybrid Neural Network, *Sensors*, vol. **20**, no. 16, p. 4485, January 2020. DOI: 10.3390/s20164485
- Zhao, B., Hu, W., Zhang, C., Wang, X., Wang, Y., Liu, C., Mo, J., et al., Integrated Automatic Detection, Classification and Imaging of High Frequency Oscillations With Stereoelectroencephalography, *Frontiers in Neuroscience*, vol. **14**, accessed October 20, 2022, from <https://www.frontiersin.org/articles/10.3389/fnins.2020.00546>, 2020.
- Zijlmans, M., Jacobs, J., Kahn, Y. U., Zelmann, R., Dubeau, F. and Gotman, J., Ictal and Interictal High Frequency Oscillations in Patients with Focal Epilepsy, *Clinical Neurophysiology: Official Journal of the International Federation of Clinical Neurophysiology*, vol. **122**, no. 4, pp. 664–71, April 2011. DOI: 10.1016/j.clinph.2010.09.021
- Zijlmans, M., Jiruska, P., Zelmann, R., Leijten, F. S. S., Jefferys, J. G. R. and Gotman, J., High-Frequency Oscillations as a New Biomarker in Epilepsy, *Annals of Neurology*, vol. **71**, no. 2, pp. 169–78, February 2012. DOI: 10.1002/ana.22548
- Zijlmans, M., Worrell, G. A., Dümpelmann, M., Stieglitz, T., Barborica, A., Heers, M., Ikeda, A., Usui, N. and Le Van Quyen, M., How to Record High-Frequency Oscillations in Epilepsy: A Practical Guideline, *Epilepsia*, vol. **58**, no. 8, pp. 1305–15, 2017. DOI: 10.1111/epi.13814
- Zuo, R., Wei, J., Li, X., Li, C., Zhao, C., Ren, Z., Liang, Y., et al., Automated Detection of High-Frequency Oscillations in Epilepsy Based on a Convolutional Neural Network, *Frontiers in Computational Neuroscience*, vol. **13**, p. 6, February 12, 2019. DOI: 10.3389/fncom.2019.00006

Publications

Revues internationales :

F. Krikid, A. Karfoul, S. Chaibi, A. Kachenoura, A. Nica, A. Kachouri and R. Le Bouquin Jeannès, Classification of High Frequency Oscillations in intracranial EEG signals based on coupled time-frequency and image-related features, *Biomed. Signal Process. Control*, 73(3), 2022.

F. Krikid, A. Karfoul, S. Chaibi, A. Kachenoura, A. Nica, A. Kachouri and R. Le Bouquin Jeannès, Multi-Classification of High Frequency Oscillations in intracranial EEG signals based on CNN and data augmentation, *Neural computing and applications*, en soumission.

Conférences internationales :

F. Krikid, A. Karfoul, A. Kachouri and R. Le Bouquin Jeannès, Multi-Classification of epileptic High Frequency Oscillations using a Time-Frequency image-based CNN, accepted in 19th *IEEE International Multi-Conference on Systems, Signals & Devices (SSD)*, 2022.

S. Chaibi, C. Mahjoub, **F. Krikid**, A. Karfoul, R. Le Bouquin Jeannès and A. Kachouri, Pitfalls of spikes filtering for detecting High Frequency Oscillations (HFOs), *18th International Multi-Conference on Systems, Signals & Devices (SSD)*, 2021.

F. Krikid, S. Chaibi, A. Karfoul, A. Kachouri and R. Le Bouquin Jeannès, A comparative study between three epileptic high frequency oscillations detection strategies', *17th IEEE International Multi-Conference on Systems, Signals & Devices (SSD)*, 2020.

F. Krikid, A. Karfoul, A. Kachouri and R. Le Bouquin Jeannès, Classification of Epileptic High Frequency Oscillations using Machine Learning Algorithms, *Applications Médicales de l'Informatique : Nouvelles Approches (AMINA)*, 17, 18 et 19 Décembre 2020, Monastir, Tunisia.

S. Chaibi, **F. Krikid**, C. Mahjoub, T. Lajnef, R. Le Bouquin Jeannès and A. Kachouri, Detection of Epileptic High Frequency Oscillations Using Support Vector Machines, *5th International Conference on Advanced Technologies for Signal and Image Processing (ATSIP)*, 2020.

C. Mahjoub, S. Chaibi, **F. Krikid**, A. Nica, R. Le Bouquin Jeannès and A. Kachouri, Epileptic seizure detection using Multivariate Empirical Mode Decomposition and Support Vector Machines, *IEEE International Conference on Design & Test of Integrated Micro & Nano-Systems (DTS)*, 2020.

Titre : Classification des oscillations hautes fréquences dans le déroulement des crises épileptiques

Mots clés : Epilepsie, oscillations hautes fréquences, SEEG, image temps-fréquence, apprentissage automatique/profond, augmentation de données.

Résumé : Les oscillations hautes fréquences et les pointes épileptiques interictales sont des biomarqueurs fiables et précis pour localiser la zone épileptogène en cas d'exploration électroencéphalographique intracrânienne. Elles ont aussi un impact profond pour comprendre le mécanisme de l'épilepsie. Ainsi, la détermination des attributs discriminants permettant de caractériser et de catégoriser ces biomarqueurs est une étape déterminante dans le processus de la localisation de ladite zone. Dans un tel contexte, deux contributions sont proposées dans ce travail de thèse. La première est basée sur un apprentissage automatique et plus particulièrement sur la combinaison de caractéristiques extraites de la représentation

temps-fréquence et de celles extraites de l'image temps-fréquence binarisée associée. La deuxième approche consiste à exploiter des réseaux de neurones convolutifs pour l'extraction automatique des caractéristiques discriminantes à partir des images temps-fréquence. Dans ce contexte, pour enrichir notre base de données, nous avons considéré la technique d'augmentation de données. Les résultats de classification obtenus sur des données réelles et bruitées montrent l'efficacité et la robustesse de nos approches vis-à-vis des approches issues de la littérature.

Title : Classification of high frequency oscillations in epileptic seizures

Keywords : Epilepsy, high frequency oscillations, SEEG, time-frequency image, machine/deep learning, data augmentation

Abstract : High-Frequency Oscillations and interictal epileptic spikes are reliable and precise biomarkers for the identification of the epileptogenic zone and consequently to understand epilepsy using intracranial electroencephalographic recordings. Thus, extracting relevant discriminative features to reliably characterize and categorize these biomarkers is crucial. In this context, two contributions are proposed in this work. The first one is a machine learning based approach that relies on the combination (coupling) between features extracted from the time-frequency representation of the events of interest and

those extracted from the associated binarized time-frequency images. The second approach is based on deep learning and more particularly on convolutional neural networks. This approach allows to automatically extract relevant global and local features from time-frequency images associated to the events of interest. To cope with the issue of the limited size of the database at hand, the data augmentation strategy is employed. Classification results obtained on real and noisy data show the efficiency and the robustness of the proposed approaches compared to state-of-the-art methods.