

UNIVERSITÉ CHEIKH ANTA DIOP DE DAKAR



ÉCOLE DOCTORALE MATHÉMATIQUES ET INFORMATIQUE

Année : 2017

N° d'ordre : 102

THESE DE DOCTORAT UNIQUE

Présentée pour obtenir le grade de Docteur de l'université Cheikh Anta DIOP de Dakar

Mention : Informatique et Télécommunications

Spécialité : Télécommunications

par

Ousmane KHOUMA

Titre : Analyse distribuée de la morphologie des événements paroxystiques intercritiques (EPICs) dans les épilepsies pharmaco-résistantes.

Soutenue le 08/07/2017 devant le jury composé de :

Président	Pape Alioune NDIAYE	Professeur	UCAD
Rapporteur	Kidiyo KPALMA	Professeur	INSA Rennes France
Rapporteur	Oumar NIANG	Maître de conférences	EPT Thiès
Examineur	Khaly TALL	Maître de conférences	UCAD
Examineur	Cheikh A. Bamba GUEYE	Maître de conférences	UCAD
Directeur de thèse	Sidi Mohamed FARSSI	Professeur	UCAD
Co-directeur de thèse	Mamadou Lamine NDIAYE	Maître de conférences	UCAD

Dédicace

*A mon père Mamadou KHOUMA,
Que la Terre lui soit légère*

Remerciements

« Si j'ai pu voir aussi loin, c'est que j'étais debout sur des épaules de géants »

Sir Isaac Newton, Mathématicien, physicien et philosophe anglais (1643-1727)

Je suis loin d'avoir vu aussi loin que Newton. N'empêche que j'ai mes géants à qui je tiens à exprimer ma plus profonde reconnaissance.

Après avoir rendu grâce à Dieu qui m'a donné force, croyance et amour pour bien mener ce travail, mes plus sincères remerciements vont :

- ❖ Au **Directeur de l'École Supérieure Polytechnique** pour m'avoir accepté dans son établissement pour y mener mes travaux de recherches.
- ❖ Au **Directeur de l'École Doctorale Mathématiques et Informatique** pour m'avoir accepté dans l'école doctorale pour y mener mes travaux de recherches.
- ❖ A **l'ensemble des personnes**, qui par leurs conseils, leurs remarques et leurs encouragements, ont contribué à l'aboutissement de ce travail.
- ❖ A **Monsieur Sidi Mohamed FARSSI** pour avoir assuré la direction de ma thèse avec disponibilité et rigueur scientifique. Je vous exprime toute ma gratitude pour la confiance qu'il m'a accordée tout au long de mes recherches.
- ❖ A **Monsieur Mamadou Lamine NDIAYE** pour la proposition du projet de thèse et l'encadrement. Votre disponibilité, vos conseils, vos directives, vos encouragements et surtout votre rigueur tout au long de la réalisation de ce travail ont été sans faille et d'une importance capitale pour mon moral. Cher encadrant, je vous serai toujours reconnaissant et soyez assurés de ma profonde gratitude.
- ❖ A **Monsieur Idy DIOP** pour avoir assuré l'encadrement de cette thèse. Vos conseils et suggestions sont sans faille.
- ❖ A **Monsieur Khaly TALL** pour le soutien et nos échanges fructueux.
- ❖ A **l'ensemble des membres du jury** qui m'ont fait l'honneur de bien examiner mon travail :

Le **Professeur Pape Alioune NDIAYE**, pour avoir accepté de présider ce jury.

Aux **Professeurs Kidiyo KPALMA** et **Oumar NIANG**, pour avoir accepté de rapporter ce travail, pour avoir consacré du temps à la lecture de mon manuscrit, pour leurs remarques et suggestions qui m'ont permis de corriger et d'améliorer le manuscrit.

Je vous témoigne toute ma reconnaissance.

Aux **Professeurs Khaly TALL** et **Cheikh A. Bamba GUEYE** pour avoir accepté d'être examinateurs.

- ❖ Au **Curateur de l'École doctorale** pour avoir accepté d'évaluer ce travail.
- ❖ A **ma mère Aïssatou NDAO** pour son soutien incondtionnel et pour m'avoir assisté et appuyé moralement durant toutes ces longues années. Je prie pour qu'une bonne longévité lui soit accordée ainsi qu'à ma **femme Seynabou**, à mon enfant **Mouhamed KHOUMA**, à tous mes frères et sœurs.
- ❖ A tous **mes enseignants** de l'école primaire à l'université
- ❖ A tous les **enseignants et chercheurs** du département génie informatique de l'ESP.
- ❖ A **Birahime DIOUF, Madiop DIOUF, Lamine SANE, Ndiaye DIOP, Mamadou Lamine MBOUP, Ousmane SADIO, Ibrahima GAYE, Abdourahmane NDIAYE, Khadidiatou DIALLO, Kéba GUEYE** et tous les **chercheurs et doctorants** du Laboratoire d'Imagerie Médicale et de Bio-Informatique (LIMBI) et du Laboratoire Informatique Réseaux et Télécommunications (LIRT).

Table des matières

Liste des figures et tableaux	ix
Glossaires	xii
Résumé	xiii
Abstract.....	xiv
Introduction générale.....	1
Chapitre 1 : Contexte et cadre général du sujet.....	4
1.1. Introduction	4
1.2. Le cerveau : anatomie et physiologie	4
1.2.1. Les neurones.....	5
1.2.2. L'activité électrique du cerveau	5
1.3. L'épilepsie	7
1.3.1. Définition	7
1.3.2. Les causes de l'épilepsie	8
1.4. Traitements de l'épilepsie	8
1.4.1. Les traitements pharmaceutiques	8
1.4.2. Les traitements chirurgicaux	9
1.5. Les méthodes d'investigation des épilepsies.....	10
1.5.1. Les méthodes non invasives	11
1.5.2. Les méthodes invasives	13
1.6. Les zones de localisation en épilepsie.....	15
1.6.1. La zone lésionnelle.....	15
1.6.2. La zone irritative	15
1.6.3. La zone épileptogène.....	16
1.7. Les événements paroxystiques critiques et intercritiques	18
1.7.1. Les événements paroxystiques critiques (les crises)	18
1.7.2. Les événements paroxystiques intercritiques (EPICs).....	19
1.7.2.1. La formation des activités épileptiformes	20
1.7.2.2. Caractérisation des EPICs	21
1.7.2.3. Dynamique spatio-temporelle des EPICs.....	22
1.7.3. Relations entre événements paroxystiques intercritiques et critiques.....	23

1.8. Analyse du contexte local et problématique de la thèse.....	24
1.8.1. Analyse du contexte local : Sénégal.....	24
1.8.2. Problématique de la thèse.....	25
1.9. Conclusion.....	27
Chapitre 2 : Méthodes de débruitage des signaux EEG.....	28
2.1. Introduction.....	28
2.2. Signaux aléatoires et estimation.....	28
2.2.1. Signaux aléatoires.....	28
2.2.1.1. Moments statistiques.....	28
2.2.1.2. Densité spectrale de puissance.....	30
2.2.1.3. Stationnarité.....	30
2.2.2. Estimation.....	30
2.2.2.1. Estimateur.....	30
2.2.2.2. Quelques propriétés d'un estimateur.....	31
2.3. Généralités sur le filtrage des signaux.....	31
2.3.1. Réalisabilité d'un filtre.....	32
2.3.2. Structure des filtres numériques.....	33
2.3.2.1. Structure transversale (ou non récursive).....	33
2.3.2.2. Structure récursive.....	34
2.4. Etude du filtre de SSA.....	35
2.4.1. Décomposition en valeurs singulières.....	35
2.4.2. Etape de la décomposition du filtre SSA.....	37
2.4.3. Etape de reconstruction du filtre SSA.....	38
2.5. Filtrage par ondelette.....	39
2.5.1. Transformées en ondelettes continues.....	40
2.5.2. Transformées en ondelettes discrètes.....	41
2.5.3. Applications des ondelettes.....	42
2.6. Etude du filtre de Kalman.....	45
2.6.1. Historique.....	45
2.6.1. Principe du filtre de Kalman.....	46
2.6.3. Fonctionnement du filtre de Kalman.....	47
2.6.3.1. Les différentes phases du filtre de Kalman.....	47
2.6.3.2. Stabilité du filtre de Kalman.....	48

2.6.3.3 Algorithme du filtre de Kalman	49
2.6.4. Filtre de Kalman étendu	50
2.6.4.1. Equation du filtre de Kalman étendu.....	51
2.6.4.2. Algorithme du filtre de Kalman étendu.....	52
2.7. Conclusion.....	53
Chapitre 3 : Etude et détection des événements paroxystiques intercritiques	54
3.1. Introduction	54
3.1. Etat de l'art des méthodes de détection des EPICs	54
3.1.1. Les méthodes heuristiques (méthodes mimétique)	54
3.1.2. Les méthodes prédictives	55
3.1.3. Les méthodes basées sur le filtrage adaptif (matching pattern methods).....	55
3.1.4. Les méthodes basées sur l'analyse factorielle.....	55
3.1.5. Les méthodes basées sur les techniques de classification	56
3.2. Formalisme du problème.....	57
3.3. La détection basée sur l'algorithme de Page Hinkley	58
3.3.1. Approche théorique	58
3.3.2. Principe de Page Hinkley	59
3.4. La détection basée sur l'opérateur d'énergie non linéaire (SNEO)	61
3.4.1. Représentation temps-fréquence des signaux EEG.....	61
3.4.2. Opérateur d'énergie non linéaire.....	63
3.4.2.1. Energie d'un système masse-ressort et l'opérateur Teager-Kaiser	63
3.4.2.2. Algorithme de Teager-Kaiser.....	65
3.4.3. Filtrage temporel	66
3.4.4. Détection adaptative des EPICs par la méthode SNEO	67
3.5. Détection de pointes basée sur la dimension fractale.....	69
3.5.1. Généralité sur la fractale et la dimension fractale	69
3.5.1.1. Origine et concept de la fractale.....	69
3.5.1.2. La dimension fractale	70
3.5.2. Algorithmes de calcul de la dimension fractale	71
3.5.2.1. Algorithme de Higuchi.....	71
3.5.2.2. Algorithmes de Petrosian	72
3.5.2.3. Algorithme de Katz	73
3.5.3. Détection adaptative des EPICs par la méthode de dimension fractale	74

3.6. Conclusion.....	75
Chapitre 4 : Classification de la morphologie des EPICs	76
4.1. Introduction	76
4.2. Généralités sur la classification non supervisée	76
4.2.1. Les méthodes k-means	77
4.2.1.1. Méthode des centres mobiles	78
4.2.1.2. Méthode des nuées dynamiques	78
4.2.2. Les méthodes de k-médoïdes	80
4.2.2.1. La méthode PAM	80
4.2.2.2. La méthode de CLARA.....	81
4.2.2.3. La méthode CLARANS	81
4.3. Mise en forme de la morphologie des EPICs	82
4.3.1. Extraction des EPICs détectés.....	83
4.3.2. Normalisation, seuillage et segmentation des EPICs	84
4.3.3. Réorganisation des vecteurs	85
4.4. Classification des EPICs	86
4.4.1. Application des algorithmes de k-means	86
4.4.1.1. Critère d'arrêt d'une exécution des k-means.....	87
4.4.1.2. Critère de qualité d'une exécution des k-means et sortie du classificateur....	87
4.4.2. Application des algorithmes de k-médoïdes	88
4.4.2.1. Critère de qualité de la classification par la méthode SSE.....	89
4.4.2.2. Critère de qualité de la classification par la méthode de Sylvain Ferrandiz ...	89
4.4.3. Le taux de bonne classification (accuracy) et Courbes ROC.....	90
4.4.4. Détection de la présence d'une onde lente dans un EPIC	92
4.5. Les éléments caractérisant la sortie de la chaîne de traitement.....	94
4.6. Conclusion.....	94
Chapitre 5 : Evaluation et validation des résultats	95
5.1. Introduction	95
5.2. Filtrage des signaux EEG	95
5.2.1. Filtres passe-bas et passe-haut.....	96
5.2.2. Filtre SSA.....	99
5.2.3. Filtrage par ondelette.....	101
5.2.4. Filtre de Kalman.....	102

Ousmane KHOUMA

5.3. La détection des EPICs	103
5.3.1. Résultats de la détection avec l’algorithme de Page Hinkley	105
5.3.2. Résultats de la détection avec le SNEO	107
5.3.3. Résultats de la détection avec la dimension fractale	110
5.4. La classification des EPICs	115
5.5. Détection des ondes lentes	121
5.6. Validation de la classification des EPICs sur des données réelles et brutes	122
5.7. Conclusion.....	123
Conclusion générale	124
Annexe.....	127
Références	129
Publications	137

Liste des figures et tableaux

Figure 1-1 : Représentation des différentes parties de l'encéphale	5
Figure 1-2 : Schéma synoptique d'un neurone	6
Figure 1-3 : Neurone pyramidale (a) et neurone en étoile (b)	6
Figure 1-4 : Résolutions spatiales et temporelles des différentes méthodes d'exploration	10
Figure 1-5 : Le système 10–20 de la Fédération Internationale de Neurophysiologie Clinique	11
Figure 1-6 : Exemple d'enregistrement EEG	12
Figure 1-7 : Principaux rythmes extraits d'un EEG réel	12
Figure 1-8 : Matrice de capteurs placée sur le cortex	13
Figure 1-9 : Enregistrement intracérébral avec la technique SEEG	14
Figure 1-10 : Planning d'un séjour hospitalier lors d'une SEEG	14
Figure 1-11 : Dynamique de la symptomatologie clinique des épilepsies partielles	16
Figure 1-12 : Quelques événements paroxystiques intercritiques (EPICs)	20
Figure 1-13 : Hyperexcitabilité intrinsèque du neurone épileptique	21
Figure 1-14 : Morphologies de quelques EPICs	22
Figure 1-15 : Zone irritative et ensembles d'activation	23
Figure 1-16 : Transition entre les phases intercritique et critique	24
Figure 1-17 : Chaîne de traitement de signaux EEG proposée	26
Figure 2-1 : Structures de réalisation transversale	34
Figure 2-2 : Structures de réalisation récursive	34
Figure 2-3 : Exemples d'ondelettes	41
Figure 2-4 : filtres miroirs conjugués	42
Figure 2-5 : filtres miroirs conjugués : reconstitution	43
Figure 2-6 : processus de décomposition et de reconstruction	44
Figure 2-7 : Banc de filtres impliquant un filtre passe-bas et filtre passe haut	45
Figure 2-8 : Les étapes du filtre de Kalman	47
Figure 2-9 : Algorithme récursive du filtre de Kalman	49
Figure 3-1 : Détection de pointes avec l'algorithme Cusum séquentiel	60
Figure 3-2 : Représentations du signal avec quatre atomes	62
Figure 3-3 : RTF d'un signal EEG avec une distribution de pointes	62
Figure 3-4 : L'opérateur d'énergie de Teager-Kaiser	65
Figure 3-5 : Système de filtrage temporel	66
Figure 3-6 : Détection adaptative des EPICs avec le SNEO	68
Figure 3-7 : Illustration des cinq premières étapes de la construction du pentagone de Durer	70
Figure 3-8 : Principe de la construction de la courbe de Von Koch	70

Figure 3-9 : Variation de dimension fractale quand l'amplitude ou la fréquence change	71
Figure 3-10 : Illustration des fenêtres glissantes tout au long du signal.....	74
Figure 3-11 : Diagramme de détection adaptative avec la dimension fractale.....	74
Figure 4-1 : Représentation de quelques EPICs et leur gabarit.....	82
Figure 4-2 : EPICs extraits d'un signal EEG réel	83
Figure 4-3 : Algorithme de repérage des extrema	85
Figure 4-4 : Algorithme de détermination du vecteur final.....	86
Figure 4-5 : Fonctionnement de l'algorithme k-means appliqué aux EPICs.....	87
Figure 4-6 : Matrice de confusion et équations paramétriques	91
Figure 4-7 : Un graphique ROC de base montrant cinq classificateurs	92
Figure 4-8 : Points caractéristiques du modèle de détection d'onde lente	93
Figure 4-9 : Valeurs remarquables pour le calcul de ρ	93
Figure 5-1 : Filtre passe-bas avec RSB = 50 dB	96
Figure 5-2 : Filtre passe-bas avec un RSB = - 30 dB	96
Figure 5-3 : Filtre passe-haut avec un RSB = - 30 dB.....	97
Figure 5-4 : Filtre passe-haut avec un RSB = 50 dB.....	97
Figure 5-5 : Représentation RSB de sortie en fonction de RSB d'entrée du filtre passe bas.....	98
Figure 5-6 : Représentation RSB de sortie en fonction de RSB d'entrée du filtre passe haut	98
Figure 5-7 : Filtre SSA avec un RSB = 50 dB	99
Figure 5-8 : Filtre SSA avec un RSB = - 30 dB	100
Figure 5-9 : Représentation RSB de sortie en fonction de RSB d'entrée du filtre SSA	100
Figure 5-10 : Filtrage par ondelette avec un RSB = 50 dB	101
Figure 5-11 : Filtrage par ondelette avec un RSB = - 30 dB	101
Figure 5-12 : Filtre de Kalman avec un RSB = 50 dB	102
Figure 5-13 : Filtre de Kalman avec un RSB = -30 dB	102
Figure 5-14 : Représentation RSB de sortie en fonction de RSB d'entrée du filtre de Kalman	103
Figure 5-15 : Schéma de simulation de la détection des EPICs	104
Figure 5-16 : Détection des EPICs NP avec Page Hinkley	105
Figure 5-17 : Détection des EPICs PN avec Page Hinkley	105
Figure 5-18 : Courbes de performances de Page Hinkley avec des données de P1	107
Figure 5-19 : Courbes de performances de Page Hinkley avec des données de P2	107
Figure 5-20 : Détection des EPICs NP avec SNEO	108
Figure 5-21 : Détection des EPICs PN avec SNEO	108
Figure 5-22 : Courbes de performances de SNEO avec des données de P1	109
Figure 5-23 : Courbes de performances de SNEO avec des données de P2	110
Figure 5-24 : Détection des EPICs NP avec Dimension Fractale	111
Figure 5-25 : Détection des EPICs PN avec Dimension Fractale	111

Figure 5-26 : Courbes de performances de FD avec des données de P1	112
Figure 5-27 : Courbes de performances de FD avec des données de P2.....	113
Figure 5-28 : Performances des trois détecteurs avec des données de P1	113
Figure 5-29 : Zoom des performances de trois détecteurs avec les données de P1	114
Figure 5-30 : Performances des trois détecteurs avec des données de P2	114
Figure 5-31 : Zoom des performances des trois détecteurs avec les données de P2	114
Figure 5-32 : Schéma de simulation pour l'identification et la classification des EPICs.....	116
Figure 5-33 : Exemple de clustering des données aléatoires.....	117
Figure 5-34 : Clustering d'un mélange de 2 EPICs (NN et PP).....	118
Figure 5-35 : Clustering d'un mélange de 2 EPICs (P et NPO).....	118
Figure 5-36 : Clustering d'un mélange de 3 EPICs (N, PN et PP).....	118
Figure 5-37 : Performances de la classification avec l'algorithme des k-means.....	120
Figure 5-38 : Performances de la détection d'ondes lentes.....	121
Figure 5-39 : Classification moyenne des EPICs validés.....	122
Tableau 1-1 : Classification internationale des épilepsies et des syndromes épileptiques	19
Tableau 5-1 : Performances moyennes de la détection avec Page Hinkley (données de P1).....	106
Tableau 5-2 : Performances moyennes de la détection avec Page Hinkley (données de P2).....	106
Tableau 5-3 : Performances moyennes de la détection avec SNEO (données de P1).....	109
Tableau 5-4 : Performances moyennes de la détection avec SNEO (données de P2).....	109
Tableau 5-5 : Performances moyennes de la détection avec FD (données de P1)	112
Tableau 5-6 : Performances moyennes de la détection avec FD (données de P2)	112
Tableau 5-7 : Temps moyen d'exécution des trois détecteurs sur des signaux d'une heure.....	115
Tableau 5-8 : Performance de classification des mélanges de 2 EPICs (données de P1 et de P2).....	119
Tableau 5-9 : Performance de classification des mélanges de 3 EPICs (données de P1)	119
Tableau 5-10 : Performance de classification des mélanges de 3 EPICs (données de P2)	120

Glossaires

ACI : Analyse en Composantes Indépendantes
ACP : Analyse en Composantes Principales
ANN : Artificial Neural Network
AWGN : Add White Gaussian Noise
DWT : Discret Wavelet Transform
CLARA : Clustering Large Applications
CLARANS : Clustering Large Applications based upon Randomized Search
DF : Dimension fractale (FD : Fractal Dimension en anglais)
ECG : Electrocardiogramme
ECoG : Electroencéphalographie
EPICs : événements paroxystiques intercritiques
EEG : électroencéphalographie
IRM : Imagerie par Résonance Magnétique
MEG : Magnétoencéphalographie
OMS : Organisation Mondiale de la Santé
PAM : Partition Around Medoids
RIF : réponse impulsionnelle finie
RII : réponse impulsionnelle infinie
ROC : Receiver Operating Characteristics
RSB : Rapport Signal sur Bruit
SEEG : Stéréoélectroencéphalographie
SNC : système nerveux central
SNEO : Smoothed Nonlinear Energy Operator
SNP : système nerveux périphérique
SSA : Singular Spectrum Analysis
SSE : Sum Squared Error
TEMP : Tomographie d'Emission MonoPhotonique
TEP : Tomographie par Emission de Positons
TOD : Transformée en Ondelettes Dyadique.
ZE : zone épileptogène
ZI : zone irritative
ZL : zone lésionnelle

Résumé

L'épilepsie est l'une des maladies qui font plus l'objet de consultation dans les cliniques neurologiques. Pour aider les neurologues à bien diagnostiquer cette maladie, plusieurs outils technologiques ont été développés. L'électroencéphalographie (EEG) de surface ou de profondeur est un outil d'acquisition de signaux provenant des décharges électriques des zones cérébrales. Ces signaux sont souvent accompagnés des événements transitoires communément appelés événements paroxystiques intercritiques (EPICs) de courtes durées. L'analyse de ces EPICs pourrait avoir un apport substantiel sur le diagnostic et le traitement de l'épilepsie.

Dans cette thèse, nous proposons des outils de filtrage pour mettre en évidence les EPICs afin de faciliter leur détection. De ce fait, trois méthodes de détection ont été proposées. La première est basée sur l'algorithme de Page Hinkley. Les autres utilisent des modèles dynamiques basés sur un seuil adaptatif. Elles reposent respectivement sur l'utilisation de l'opérateur d'énergie non linéaire et de la dimension fractale.

Une nouvelle méthode de classification non supervisée de la morphologie des EPICs détectés est proposée. Elle est associée à l'analyse en composantes principales.

L'application de ces outils de traitement du signal pourrait apporter des éléments de réponse sur la relation (qui fait encore l'objet de beaucoup de travaux de recherche) entre la distribution spatio-temporelle des EPICs et l'arrivée des crises.

Mots clés : épilepsie, électroencéphalographie, filtrage, détection d'EPICs, analyse en composantes principales, classification non supervisée.

Abstract

Epilepsy is one of the diseases that are more subject to consultation in neurological clinics. To help neurologists to accurately diagnose this disease, several technological tools have been developed. Electroencephalography (EEG) of scalp or deep is a signal acquisition tool from electrical discharges of the brain areas. These signals are often accompanied by transient events commonly called interictal paroxystic events (IPE) of short durations. IPE Analysis could have a substantial impact on the diagnosis and the treatment of epilepsy.

In this thesis, we provide filtering tools to highlight the IPE for facilitate their detection. Therefore, three methods of detection have been proposed. The first is based on the Page Hinkley algorithm. Others use dynamic models based on an adaptive threshold. They are based respectively on the use of non-linear energy operator and fractal dimension.

A new clustering method of the spike morphology is proposed. It is associated with the principal component analysis. The latter makes us the interpretation of the distribution of IPE.

The application of these signal processing tools could provide answers on the not yet found relationship between the spatial and temporal distribution of IPE and the arrival of crises.

Keywords: epilepsy, electroencephalography, filtering, spike detection, principal components analysis, unsupervised classification.

Introduction générale

L'épilepsie est une affection neurologique qui touche une grande partie de la population mondiale. Elle est caractérisée par une décharge anormale et excessive d'une population neuronale plus ou moins importante. Cette maladie pose, encore aujourd'hui, des problèmes de traitements (médicaments) [1], et la médecine moderne rencontre encore des difficultés à traiter certains cas. En effet, certaines formes d'épilepsies dites pharmaco-résistantes sont rebelles à tous traitements médicamenteux [2]. Dans ces cas, un traitement chirurgical peut être envisagé mais son application exige une évaluation préchirurgicale complexe. Afin de trouver de nouvelles solutions thérapeutiques, les communautés scientifiques et médicales étudient, depuis des années, la façon dont les crises surviennent. Ces différentes études cherchent à :

- Identifier les signatures caractéristiques de la maladie en rapport avec les structures cérébrales concernées ;
- Identifier les modes d'interaction entre les différentes structures ;
- Etablir les relations entre les signaux observés et les signes cliniques ;
- Etablir les relations entre les périodes critiques (durant les crises) et les périodes intercritiques.

On distingue deux périodes dans le cycle de vie d'un épileptique : les périodes critiques caractérisées par les crises et les périodes intercritiques caractérisées par des événements paroxystiques intercritiques (EPICs). Les EPICs sont observés chez 1% des sujets non épileptiques et entre 60 et 90% des sujets épileptiques [3] [4]. Ils ont une occurrence très élevée par rapport à la fréquence des crises. La caractérisation clinique de ces événements repose sur leur densité, leur topographie ou leur morphologie.

Les méthodes d'investigation en épilepsie visent à déterminer l'origine et l'étendue de ces décharges, elles fournissent des données essentielles à la compréhension de la maladie. Elles peuvent être divisées en trois groupes en fonction des données qu'elles utilisent : cliniques, anatomiques et physiologiques. Les données physiologiques sont des signaux électriques provenant essentiellement des techniques d'explorations électroencéphalographiques de surface (EEG), Stéréo-électroencéphalographiques (SEEG) et Magnétoencéphalographiques (MEG).

Cette thèse s'inscrit dans le contexte d'analyse et d'interprétation des données électrophysiologiques notamment l'analyse des EPICs. Elle s'intéresse particulièrement à la morphologie des EPICs et leur densité.

L'association entre la morphologie et la densité des EPICs pourrait apporter des informations importantes sur le lien peu connu entre les événements paroxystiques critiques et intercritiques. Cette analyse pourrait contribuer à l'aide au diagnostic. Pour ce faire, nous chercherons tout d'abord à détecter les EPICs, en les séparant de l'activité de fond du signal EEG, puis on mettra en œuvre un processus de classification distinguant les événements détectés selon leurs morphologies. L'objectif à terme est de caractériser leur distribution spatio-temporelle sur toute la durée du signal et sur l'espace des capteurs.

Ce manuscrit est organisé en cinq chapitres.

Le chapitre 1 présente le contexte et le cadre général de ce travail. Il aborde les bases anatomiques et physiologiques du cerveau, la définition et les causes de l'épilepsie. Il présente aussi l'origine des bruits qui peuvent rendre difficile l'analyse et l'interprétation des données électrophysiologiques. En plus une analyse du contexte local de l'épilepsie au Sénégal sera faite.

Le chapitre 2 présente un état de l'art sur les filtres appliqués aux signaux EEG. Une généralité sur le filtrage numérique est décrite. Certains de ces filtres peuvent modifier les informations utiles contenues dans les signaux. De ce fait, nous proposons d'utiliser des filtres qui pourront conserver les informations quel que soit le niveau de bruits. Pour le prétraitement des signaux, le filtre de Kalman et le filtrage basé sur la décomposition en valeurs singulières (SSA : Singular Spectrum Analysis) sont utilisés. Le chapitre présente aussi le filtrage par décomposition en ondelettes qui peut être appliqué aux EPICs extraits après leur détection.

Dans le chapitre 3, un état d'art sur la détection des EPICs est fait. En se basant sur les méthodes existantes, nous avons choisi trois méthodes de détection [5]. La première s'est basée sur l'algorithme de Page Hinkley. Elle utilise la fonction de vraisemblance avec un seuil qui est en fonction de la valeur médiane du signal. La deuxième méthode utilise la convolution de l'opérateur d'énergie non linéaire discret de Teager – Kaiser avec une fenêtre de lissage de Bartlett (SNEO : Smoothed Nonlinear Energy Operator). La dernière s'appuie sur la détection par la dimension fractale associée à deux fenêtres glissantes. Pour les deux dernières, nous avons proposé des seuils adaptatifs qui suivent les variations des propriétés de l'activité de fond.

Le quatrième chapitre aborde l'identification de la morphologie des EPICs ainsi que leur classification. Les méthodes de classification non supervisées s'appuyant sur l'analyse en composantes principales (ACP) sont utilisées.

Le dernier chapitre applique les méthodes proposées dans une chaîne complète de traitement sur des données réelles enregistrées chez des patients souffrant d'épilepsies pharmaco-résistantes du lobe temporal. Une analyse des résultats obtenus et une validation expérimentale des résultats sont également présentées dans ce chapitre.

Chapitre 1 : Contexte et cadre général du sujet

1.1. Introduction

L'électroencéphalographie (EEG) est une des techniques d'investigation les plus utilisées pour l'étude et la mise en évidence de l'activité électrique du cerveau. Elle demeure incontournable pour le diagnostic des maladies telles que l'épilepsie. Cette maladie est une affection chronique du cerveau qui touche toutes les populations du monde. Elle se caractérise par des crises récurrentes qui sont la manifestation physique de décharges électriques excessives et soudaines, généralement brèves et répétitives, générées par une population de neurones. Les crises peuvent varier en intensité mais également en localisation et en volume, elles peuvent entraîner de brèves pertes d'attention ou de petites secousses musculaires ou même conduisent à des convulsions sévères et prolongées. Ce chapitre aborde de manière générale le contexte médical : le cerveau, l'épilepsie (définition, causes, les bases neurophysiologiques), les modalités d'exploration pour les diagnostics, les événements paroxystiques intercritiques et critiques. Il présente aussi le contexte local de l'épilepsie au Sénégal et la problématique du sujet.

1.2. Le cerveau : anatomie et physiologie

Le cerveau est l'organe le plus important du corps humain. Il est à la base du fonctionnement de l'organisme. Il nous permet de voir, sentir ou entendre, parler, marcher, analyser et comprendre le monde qui nous entoure. Pour cela, il suscite autant d'interrogations que de fascination [6].

Par ailleurs, le système nerveux comprend principalement deux parties : le système nerveux central et le système nerveux périphérique. Dans le système nerveux central, nous y retrouvons l'encéphale et la moelle épinière. La boîte crânienne contient l'encéphale qui est composé du cerveau et de tous les nerfs qui y sont connectés. Concernant le système nerveux périphérique, il est composé des nerfs crâniens et spinaux [7].

Le cerveau est composé de deux hémisphères, droit et gauche. Il contient des plis formés sur la surface et il est subdivisé en lobes (Figure 1-1 [7]) : un frontal, deux temporaux, un pariétal et un occipital.

Concernant le *lobe frontal*, nous pouvons citer comme fonctions spécifiques : la parole, le langage, l'humeur, la pensée etc... Cependant, tous les mouvements et les messages

provenant du corps sont gérés par le *lobe pariétal*. Quant à la vision, elle est associée au *lobe occipital*. Enfin, la mémoire et les émotions s'associent aux *lobes temporaux*.

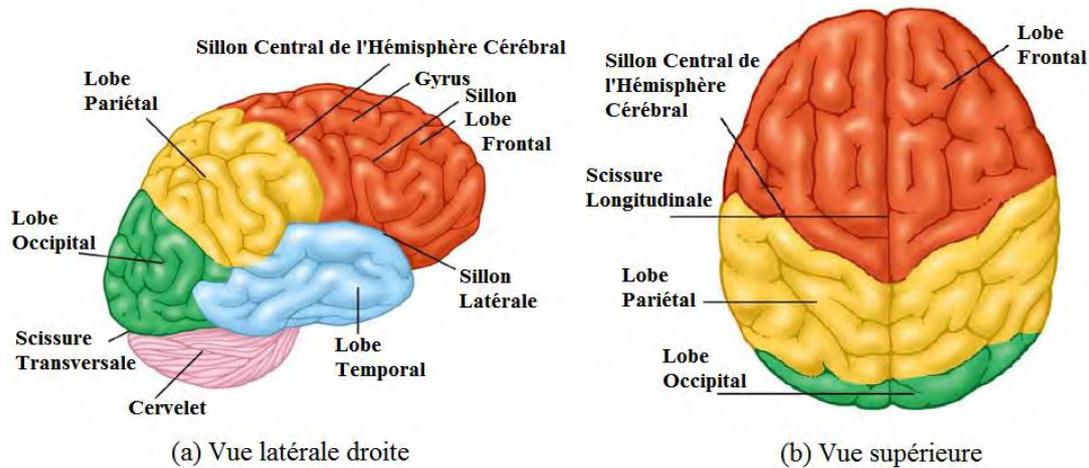


Figure 1-1 : Représentation des différentes parties de l'encéphale

Le cortex cérébral est une substance grise qui se trouve sur la surface des hémisphères. Il contient des classes de cellules très particulières et importantes appelées **neurones** [7].

1.2.1. Les neurones

Les neurones sont des cellules qui prennent en charge le traitement de l'information au sein du cerveau. On estime que le cerveau humain comprend environ 100 milliards (10^{11}) de neurones [8]. L'influx nerveux assuré par les neurones représente la génération et la transmission d'un signal.

Les principales parties d'un neurone sont : le corps cellulaire ou soma, l'axone et les dendrites. Nous trouvons dans le soma les organites. Les signaux électriques communément appelés influx nerveux (ou potentiel d'action) sont transmis par les axones. Les dendrites assurent les connexions entre neurones, à travers des liaisons nommées synapses.

La Figure 1-2 [7] [8] donne le schéma synoptique d'un neurone et ses différentes parties.

1.2.2. L'activité électrique du cerveau

La présence des synapses électriques est notée dans tout le système nerveux. Ce sont les synapses qui font circuler le courant électrique directement de façon passive d'un neurone à l'autre à travers des pores de jonctions communicantes.

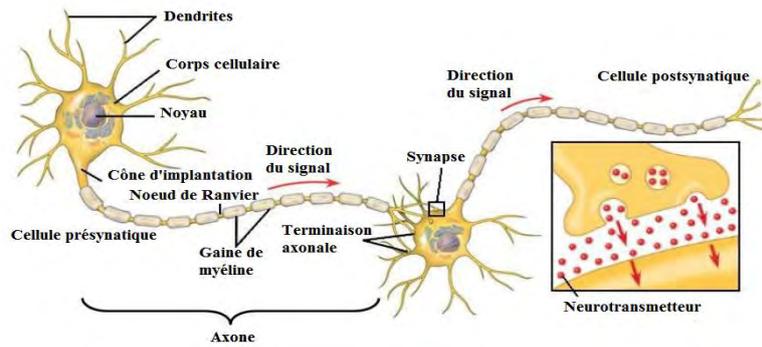


Figure 1-2 : Schéma synoptique d'un neurone

Les activités synaptiques des neurones représentent les potentiels électriques enregistrés sur la surface du scalp. Elles sont dues à l'activation simultanée d'un très grand nombre de neurones.

En effet, l'EEG de surface n'est pas produit par tous les neurones. Ce sont les cellules pyramidales, minoritaires qui en sont capables.

Les cellules pyramidales (Figure 1-3 [9]) sont disposées parallèlement les unes par rapport aux autres et perpendiculairement à la surface du manteau cortical, leur arborisation dendritique est très asymétrique avec une dendrite dite apicale¹ s'étendant dans la couche superficielle du cortex, alors que le soma (corps cellulaire) est plus profondément situé. La disposition parallèle de ces cellules pyramidales explique la génération d'un vecteur de densité de courant et caractérise la constitution du dipôle.

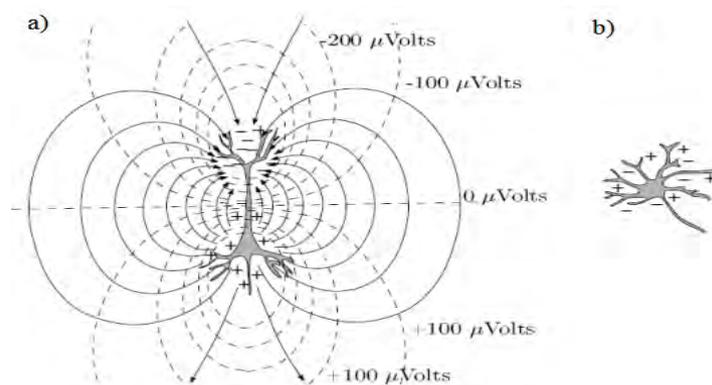


Figure 1-3 : Neurone pyramidale (a) et neurone en étoile (b)

Pour qu'une activité électrique ait une grande amplitude pour devenir visible sur les électrodes de la surface du scalp, il faut que des centaines de milliers de neurones soient

¹ Une dendrite apicale est une dendrite qui émerge de l'apex d'une cellule pyramidale

excités simultanément. Selon [7] et [10], la surface corticale minimale pour l'apparition d'un potentiel de scalp a été estimée à 6 cm².

La création d'un courant extracellulaire (trait plein) est due par l'excitation d'un neurone pyramidale. Les traits pointillés représentent les surfaces équipotentielles du champ électromagnétique.

1.3. L'épilepsie

1.3.1. Définition

Nous pouvons définir le terme épilepsie par rapport au mot grec « epilambanein », qui signifie assaillir ou saisir violemment. L'épilepsie est une des maladies qui a eu le plus d'appellations différentes au cours de l'histoire. Au V^e siècle avant J.C, les Grecs parlaient du « mal sacré ». Selon Hippocrate, il s'agissait d'un dérèglement cérébral, ce qui était une conception révolutionnaire. Chez les romains, il s'agissait du « mal de l'esclave ».

Ce n'est qu'à la fin du XIX^e siècle, après des siècles d'obscurantisme, que l'épilepsie prend enfin sa place dans la famille des maladies neurologiques. C'est à Hughlings Jackson à qui nous devons la première conception pathogénique de la crise épileptique qu'il définit en 1873, comme la survenue soudaine d'une décharge, excessive et rapide d'une population plus ou moins étendue de neurones qui constituent la substance grise de l'encéphale. Il émet aussi l'idée que le type de crise varie en fonction de la localisation et de la nature de ces décharges.

Dans le monde, environ 50 millions de personnes sont atteintes de l'épilepsie selon l'Organisation Mondiale de la Santé (OMS) [11]. Il n'existe pas de frontières géographiques, raciales ou sociales à la maladie, n'importe qui peut en être atteint à tout âge et pour les deux sexes. Une crise d'épilepsie représente l'unité conceptuelle de la maladie, elle n'est que l'expression d'un mauvais fonctionnement des neurones du cerveau [12].

Au niveau des cellules du système nerveux, la pathologie résulte de décharges électriques synchrones dans les populations de neurones, ceci dans un ou plusieurs foyers cérébraux. Ces décharges, appelées décharges paroxystiques, sont assimilées à des conséquences de perturbations dans les processus d'excitation et d'inhibition intervenant dans la transmission de l'information entre neurones. Le caractère paroxystique et le début brutal des crises sont des éléments sémiologiques les plus évocateurs de l'épilepsie.

Les décharges paroxystiques sont plus ou moins circonscrites dans le cerveau et leur propagation à une partie ou à l'ensemble des aires cérébrales définissent deux classes d'épilepsie. Les épilepsies partielles où les décharges se limitent au démarrage de la crise à un

volume restreint dans l'espace cérébral et les crises généralisées pour lesquelles les décharges paroxystiques impliquent rapidement les deux hémisphères [12].

L'épilepsie a un profond retentissement chez les sujets atteints, tant sur le plan psychique que sur le mode de vie, et chez les enfants présentant une épilepsie rebelle aux traitements médicamenteux, un retard psychomoteur plus ou moins important est à mettre en relation avec la maladie [13] [14].

1.3.2. Les causes de l'épilepsie

L'épilepsie fait partie des maladies non contagieuses. Selon l'origine de l'épilepsie, les crises partielles et les crises généralisées peuvent être *symptomatiques*, *cryptogéniques* ou *idiopathiques*.

L'épilepsie idiopathique est le type le plus courant de cette maladie. Elle concerne six personnes atteintes sur dix et il n'y pas de causes connues [11].

Si la cause de la maladie est suspicieuse mais elle n'est pas prouvée par les moyens diagnostiques, on parle d'épilepsie cryptogénique.

Lorsqu'on peut déterminer la cause, on parle d'épilepsie symptomatique. Les causes sont nombreuses et nous pouvons en citer [11] :

- Une lésion cérébrale due à des traumatismes prénatals ou périnatals ;
- Des troubles génétiques s'associant à des malformations cérébrales ;
- Un traumatisme grave à la tête ;
- Un accident vasculaire cérébral privant le cerveau d'oxygène ;
- Une infection touchant le cerveau, comme une méningite, une encéphalite ;
- Une tumeur cérébrale ;
- Etc...

1.4. Traitements de l'épilepsie

Les traitements appliqués sont de deux types : *pharmaceutiques* et *chirurgicaux*. Un traitement médicamenteux est prescrit après diagnostic de l'épilepsie. En cas d'échec (épilepsie pharmaco-résistante), un traitement chirurgical peut être envisagé.

1.4.1. Les traitements pharmaceutiques

Le traitement se fait par médicaments anti épileptiques qui agissent directement sur les trois processus mis en jeu lors du déclenchement d'une crise :

- Stabiliser la membrane des neurones ;
- Diminuer la tendance des unités motrices à former des décharges répétitives ;

- Réduire la propagation des décharges critiques.

Dans le rapport du mois de février 2017 de l'OMS [11], il est mentionné que l'épilepsie peut être facilement traitée par la prise quotidienne de médicaments dont le coût est dérisoire (5 dollars (US \$) par an.

Selon des études récentes, dans les pays à revenu faible ou intermédiaire, les médicaments anti épileptiques permettent de traiter avec succès jusqu'à 70% des enfants et des adultes chez qui une épilepsie vient d'être diagnostiquée (c'est-à-dire qu'on obtient la disparition complète des crises) [11]. Donc 30% sont résistants à la thérapie. Parmi ceux-ci, la moitié est candidate à la chirurgie.

1.4.2. Les traitements chirurgicaux

La chirurgie peut être bénéfique aux patients souffrant d'épilepsies pharmaco-résistantes. Elle est la seule option thérapeutique susceptible d'améliorer les conditions de vie de ces patients. Elle concerne principalement les patients pour lesquels la zone épileptogène (ZE) est localisée, accessible et que son opération ne touche pas les organes fonctionnels de l'organisme.

La chirurgie a deux objectifs :

- **Curatif** : l'intervention consiste en l'ablation du foyer épileptique ou d'une zone lésée. Elle ne doit pas toucher certaines zones corticales qui ont des fonctions essentielles. Ce qui limite cette solution. Elle est appliquée dans le cas des épilepsies partielles.
- **Palliatif** : l'intervention a pour objectif de sectionner les voies de transmission de la propagation de la décharge épileptique. Cette solution est notamment appliquée dans les épilepsies généralisées pour lesquelles des callosotomies sont requises.

Ainsi avant d'envisager ce type d'intervention, il est indispensable de connaître et de préciser l'épilepsie du patient (temporale, frontale, occipitale...). Trois types d'interventions peuvent être proposés :

- **La cortectomie** est limitée à une zone corticale où a été individualisé le foyer épileptogène. La cortectomie est réalisée au niveau du lobe temporal mais aussi au niveau du lobe frontal.
- **La callosotomie** est indiquée dans certaines épilepsies généralisées avec chutes et handicaps graves. Elle consiste à la résection du corps calleux ou les deux tiers.
- **L'hémisphérotomie** est réservée aux jeunes enfants présentant une épilepsie sévère associée à des lésions anatomiques importantes. Elle permet de séparer les deux hémisphères.

1.5. Les méthodes d'investigation des épilepsies

La prise en charge de l'épilepsie se fait en plusieurs étapes. Le récit de l'entourage du patient et ou l'observation durant les crises permet aux médecins d'émettre des hypothèses sur les zones cérébrales potentiellement affectées. Ces hypothèses sont confirmées ou infirmées grâce aux méthodes d'investigation en épilepsie. L'objectif est d'identifier les structures cérébrales qui initient le démarrage des crises, les zones qui sont affectées par la propagation et les zones qui sont totalement épargnées. Nous avons principalement deux méthodes d'exploration des activités cérébrales : l'imagerie et l'exploration électrophysiologique. La Figure 1-4 [15] illustre la variabilité des résolutions temporelles et spatiales parmi les méthodes d'exploration cérébrales.

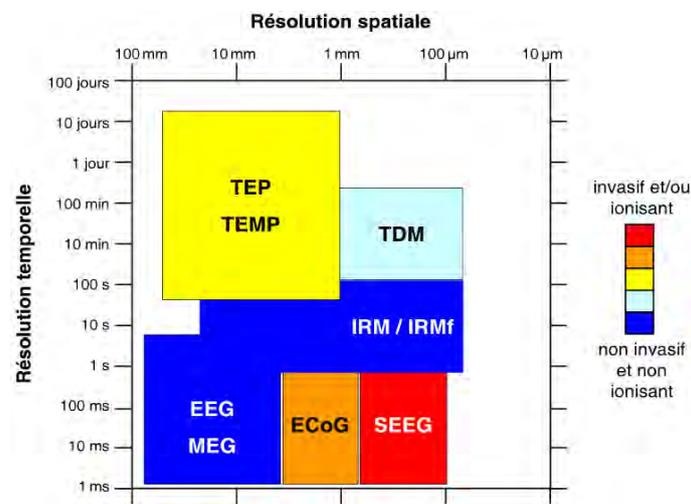


Figure 1-4 : Résolutions spatiales et temporelles des différentes méthodes d'exploration

Les méthodes TEMP (*Tomographie d'Emission Mono Photonique*) et TEP (*Tomographie par Emission de Positons*) se sont basées sur l'utilisation des traceurs radioactifs. Ces derniers permettent d'étudier les métabolismes des organes concernés. Ils apportent des informations sur la localisation des zones lésionnelles. La tomodensitométrie (TDM) associée à la technique TEP nous permet de diagnostiquer les problèmes cérébraux et cardiaques.

Pour détecter des lésions pouvant être l'origine des décharges paroxystiques, des techniques d'imagerie médicale sont appliquées. L'IRM (*Imagerie par Résonance Magnétique*) est une technique d'imagerie qui fournit des informations avec une grande précision. Les données anatomiques obtenues permettent de faire la modélisation en 3D de la tête du patient. Quant à l'IRMf (*IRM fonctionnelle*), elle permet d'observer en temps réel l'activité du cerveau.

Pour une meilleure résolution temporelle des lésions cérébrales, on peut utiliser la magnétoencéphalographie (MEG). Elle mesure les champs magnétiques des courants intra et

extracellulaires dus aux potentiels post-synaptiques. Elle est limitée par sa cherté et la difficulté de sa mise en place.

Par ailleurs, l'électrocorticographie (ECoG) est une méthode invasive où une petite fenêtre est ouverte au niveau du scalp. Elle présente une meilleure résolution spatiale car les signaux obtenus ne sont pas perturbés par la boîte crânienne.

1.5.1. Les méthodes non invasives

L'IRM, la MEG et l'électroencéphalographie (EEG) sont des méthodes d'investigation non invasives. Dans cette partie, nous nous intéressons à l'EEG. Elle est le moyen le plus utilisé surtout dans les pays à revenus faibles ou intermédiaires. Elle permet l'acquisition de signaux numériques avec une très bonne résolution et provenant d'un grand nombre d'électrodes positionnées sur le scalp. Le couplage de l'EEG avec un enregistrement vidéo permet de faire la corrélation entre les activités électriques reflétées par les signaux et les différents comportements du patient (mâchonnement, déglutition, frottement des mains, gesticulation, activités violentes de pédalage, exclamations verbales, etc.) pouvant être en relation avec des dysfonctionnements électrophysiologiques dus à l'épilepsie [15].

Les électrodes sont placées sur la surface du scalp selon une norme standard. Le système 10-20 est le plus utilisé. Les figures 1-5 et 1-6 (Figure 1-5 et Figure 1-6) [7] illustrent respectivement le système 10-20 et un exemple d'enregistrement EEG. Les potentiels au niveau des électrodes varient au cours du temps et forment des rythmes.

La morphologie des tracés dépend de l'état d'activation des neurones enregistrés et cet état d'activation va se traduire par des variations de fréquence et d'amplitude des signaux enregistrés.

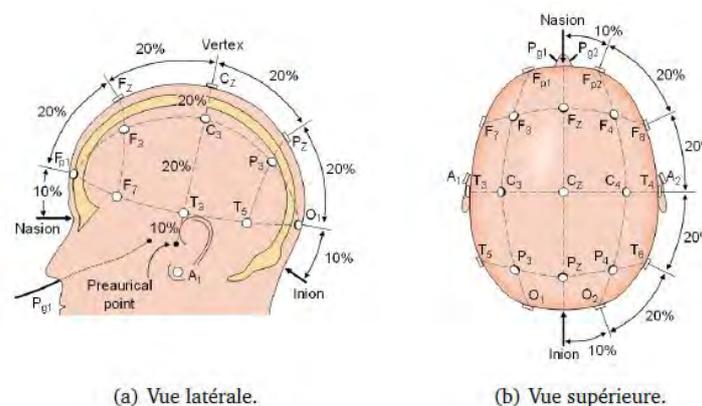


Figure 1-5 : Le système 10–20 de la Fédération Internationale de Neurophysiologie Clinique

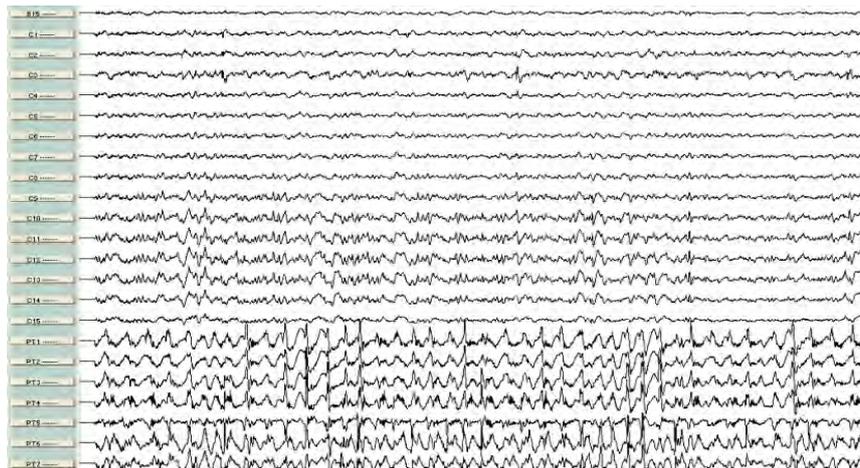


Figure 1-6 : Exemple d'enregistrement EEG

Les activités électriques cérébrales rythmiques sont classées en groupes suivant leur bande de fréquences :

- Le rythme delta (δ) contient des fréquences inférieures à 4 Hz. Il est lié au sommeil profond.
- Le rythme thêta (θ) contient des fréquences appartenant à la bande [4 Hz, 8 Hz]. Il dépend particulièrement à la mémoire, au sommeil et aux phases de concentration. Ainsi, la création d'ondes lentes est due aux rythmes δ et θ , définis par leur contenu fréquentiel très faible.
- Le rythme alpha (α) dont ses fréquences appartiennent à la bande [8 Hz, 13 Hz] est purement d'origine occipitale.
- Le rythme bêta (β) a des fréquences dans l'intervalle [13 Hz, 30 Hz].
- En fin gamma (γ) correspond aux fréquences supérieures à 30 Hz. Son amplitude est très faible et il a une petite contribution à l'EEG.

La Figure 1-7 [6] illustre les principaux rythmes de l'activité cérébrale (δ , θ , α et β).

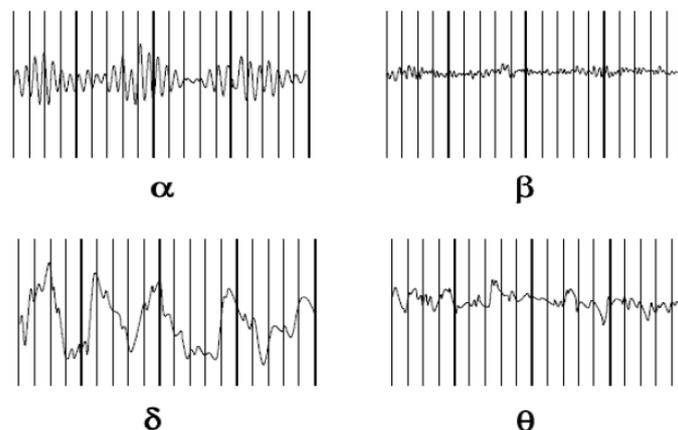


Figure 1-7 : Principaux rythmes extraits d'un EEG réel

Les principales perturbations qu'on peut trouver dans les signaux EEG peuvent être d'origine physiologique ou provenant des instruments de mesure ou encore d'autres sources externes.

Les premières perturbations sont des activités électrophysiologiques qui peuvent avoir plusieurs origines, comme des mouvements oculaires, des clignements, des activités musculaires, des activités cardiaques, etc.

1.5.2. Les méthodes invasives

Les méthodes invasives les plus connues sont : la Stéréo-électroencéphalographie (SEEG) et l'électrocorticographie (ECoG). Cette partie étudie principalement la technique SEEG.

Elle a été mise au point en France par Bancaud et Talairach à la fin des années 1950 [16] [17]. La Figure 1-8 [16] donne un exemple de matrice de capteurs (électrodes de profondeur) placée sur le cortex.

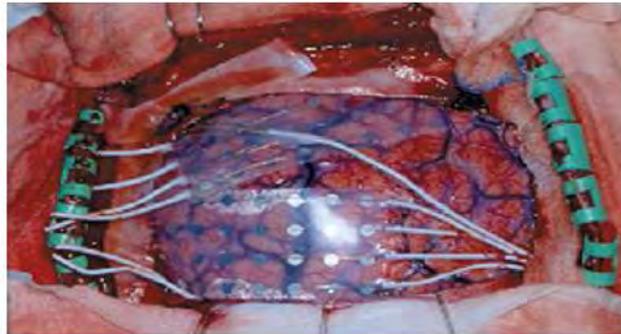


Figure 1-8 : Matrice de capteurs placée sur le cortex

L'objectif de cette méthode est de confirmer les hypothèses sur l'étendue de la zone épileptogène, et de détecter des zones de propagation des décharges en vue d'une ablation chirurgicale « sur mesure ». Elle reste la méthode de référence pour la détection de la zone de début des crises. De plus en plus considérée comme non indispensable pour la chirurgie des épilepsies méso-temporales, elle demeure obligatoire pour les localisations extra-temporales.

Pour rendre l'analyse électro-clinique des crises plus facile, il est préférable d'associer à la SEEG des enregistrements vidéo, voire des enregistrements EEG de surface. Cette analyse permet la délimitation des sites cérébraux impliqués par les décharges paroxystiques.

La SEEG utilise en moyenne cinq à dix électrodes souples cylindriques ($\varnothing = 0.8 \text{ mm}$, $L \leq 60 \text{ mm}$), chaque électrode dispose de dix à quinze capteurs de petite taille ($l = 2 \text{ mm}$) séparés par un isolant ($l = 1.5 \text{ mm}$) et chaque capteur délivre un signal SEEG (Figure 1-9 [18]). L'implantation des électrodes se fait par le neurochirurgien, sous anesthésie générale.

Le signal vectoriel résultant est enregistré sur 80 à 128 voies (selon les systèmes d'acquisition) échantillonné à 256, 512 Hz ou 1 kHz et stocké sur un support informatique lors de l'acquisition. En pratique, les patients sont généralement accueillis dans une unité d'épileptologie pendant 5 jours (Figure 1-10) [18].

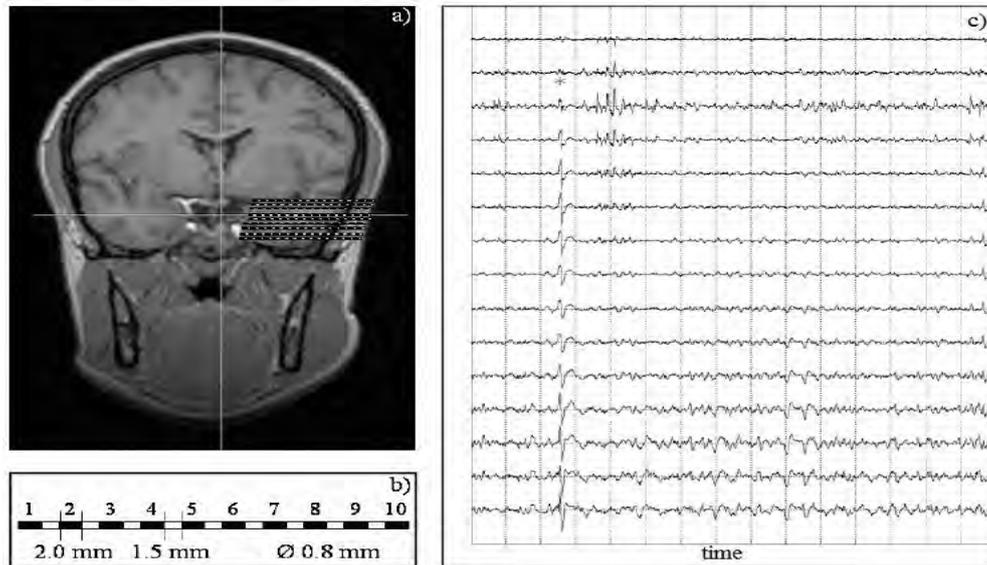


Figure 1-9 : Enregistrement intracérébral avec la technique SEEG

Dans la Figure 1-9, a), b) et c) représentent respectivement l'IRM du patient sur laquelle ont été reportées les électrodes implantées dans la région explorée, le schéma d'une électrode à plots étagés et un exemple d'enregistrement SEEG sur lequel apparaît un EPIC (*) le long d'une électrode.

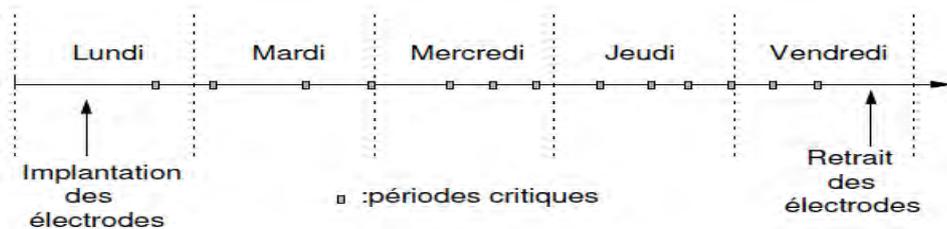


Figure 1-10 : Planning d'un séjour hospitalier lors d'une SEEG

L'intérêt principal de la SEEG, par rapport à l'EEG, est de recueillir l'activité électrique des neurones directement au contact des générateurs, ce qui permet d'enregistrer des signaux représentant une activité locale. La SEEG mesure donc l'activité épileptique de façon très focale avec une très bonne résolution spatiale dans l'axe du support d'électrodes. Elle donne des renseignements sur la profondeur de la zone épileptogène.

En effet, le bilan pré-chirurgical d'une épilepsie partielle pharmaco-résistante impose les conditions d'enregistrement [12] suivantes :

- Un nombre d'électrode minimal de 21 en montage référentiel (système 10-20), en acquisition numérisée en vue de relectures exhaustives (fréquence d'échantillonnage de 256 Hz) ;
- Un système de connexion adéquat pour des enregistrements prolongés ;
- Une surveillance spécialisée permanente pour l'observation et l'interaction cliniques per-ictales et post-ictales.

1.6. Les zones de localisation en épilepsie

Bancaud et Talairach ont défini, suivant l'aspect électrographique des signaux SEEG, trois zones correspondant respectivement à la lésion (zone lésionnelle : ZL), au siège des EPICs (zone irritative : ZI), et au siège des crises (zone épileptogène : ZE).

La zone lésionnelle est le siège d'ondes lentes monomorphes, provoqué par l'altération du tissu cérébral. La zone irritative correspond aux structures où sont observés les EPICs. Enfin, la zone épileptogène est la région d'organisation des décharges critiques. Selon ces auteurs, l'investigation préchirurgicale des épilepsies partielles doit reposer sur l'étendue de ses trois zones et sur les interactions qu'elles entretiennent.

Les anomalies intercritiques ont une valeur localisatrice controversée, les relations spatiales qu'elles entretiennent avec la zone épileptogène sont encore mal définies. Néanmoins on admet souvent que la zone irritative est plus étendue que la zone épileptogène.

1.6.1. La zone lésionnelle

Depuis la définition de Bancaud et Talairach, l'imagerie morphologique (scanner, IRM) s'est considérablement développée apportant de nouvelles informations sur la correspondance entre lésion et zone lésionnelle définie a priori comme siège des ondes lentes monomorphes, cette dernière étant généralement plus étendue spatialement [18].

1.6.2. La zone irritative

Par définition, les périodes intercritiques correspondent aux intervalles de temps séparant les crises. Bien qu'il existe probablement une expression sous-jacente de la pathologie dans l'activité électrique, les segments temporels les plus étudiés au sein des périodes critiques sont ceux correspondant aux EPICs.

La zone irritative étant définie comme le siège des EPICs, plusieurs études [18] ont montré que son organisation n'est pas celle d'un foyer mais plutôt d'un réseau de ressources d'activités paroxystiques intercritiques distribuées dans différentes structures. Par définition,

l'analyse de la dynamique spatio-temporelle des EPICs doit renseigner sur l'organisation de la zone irritative.

1.6.3. La zone épileptogène

L'analyse électro-clinique repose sur la mise en correspondance des données EEG de profondeur (expression électrique de la décharge critique) et des données vidéo (expression clinique de la décharge critique). Elle a pour objectif de déterminer les structures cérébrales impliquées et la dynamique spatio-temporelle qu'elle présente durant les crises, en distinguant deux sous-ensembles :

- Un premier groupe formé des structures impliquées à l'origine de la crise et qui correspond à la zone épileptogène ;
- Un second groupe formé des structures secondairement impliquées et qui correspond à la zone de propagation.

La zone épileptogène est constituée d'un réseau de différentes structures cérébrales distribuées spatialement et qui se synchronisent en moment donné pour générer les décharges paroxystiques critiques. Dans la perspective d'un geste chirurgical curatif optimal, c'est principalement l'organisation de la zone épileptogène qu'il faut étudier, le but étant de supprimer les sites impliqués dans l'initiation des crises ou bien les connexions entre sites, de manière à supprimer toutes transitions entre l'activité normale et l'activité paroxystique. La Figure 1-11 [12] illustre schématiquement la dynamique symptomatique clinique d'une crise partielle.

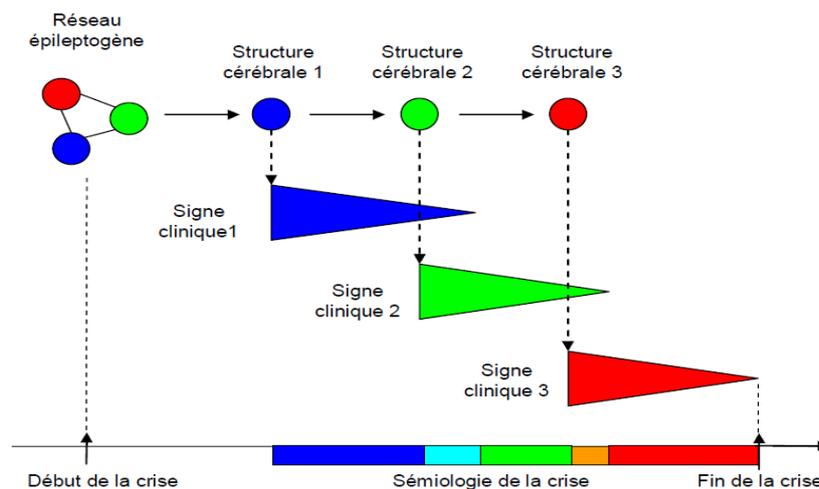


Figure 1-11 : Dynamique de la symptomatologie clinique des épilepsies partielles

Par ailleurs, la sémiologie des crises consiste en l'analyse détaillée des signes cliniques qui surviennent juste avant, pendant et après la crise. Cette analyse est capitale dans la

détermination de la zone épileptogène ainsi que les zones de propagation des décharges paroxystiques. Elle est réalisée à partir d'enregistrements vidéo (expression clinique de la décharge critique) et souvent mis en correspondance avec les données physiologiques. Un signe clinique qui survient en début de crise et qui se reproduit dans plusieurs crises est probablement en rapport avec l'origine de la décharge initiale, il peut être suivi par d'autres symptômes qui cette fois ci renseignent sur la propagation de la décharge épileptique [19].

Les travaux d'Isabelle Merlet [20] (appliqués aux épilepsies temporales) ont montré que les générateurs de pointes se distribuent spatialement de façon majoritaire au sein d'un seul lobe temporal (62,5% des cas), qu'ils peuvent suggérer des interactions entre structures temporales et extra-temporales (25% des cas) ou encore entre les deux lobes temporaux (12,5% des cas). Cette notion de sources distribuées au sein des pointes intercritiques n'est pas nouvelle car elle a été évoquée par Barth en 1984 [21]. La SEEG a fourni un apport en faveur de la mise en jeu d'un réseau au sein des paroxysmes intercritiques en mettant en évidence l'activation spatio-temporelle des générateurs intra cérébraux de pointes.

Les résultats de Merlet sont en faveur de la notion de réseau distribué nécessaire à la genèse des paroxysmes intercritiques, ce réseau pouvant dans certains cas s'étendre à d'autres zones situées à l'extérieur de la zone temporale, à des structures fortement connectées aux structures temporales. Sur certains patients, ce réseau distribué peut concerner les 2 hémisphères. Dans les épilepsies frontales, des études ont montré que ce réseau pouvait être très étendu et composé de plusieurs structures distantes interconnectées. Cette notion de réseau remet en cause la notion de structure fixe d'où démarrent les processus intercritiques car « *le réseau peut s'emballer à partir de n'importe laquelle de ses structures* » [20].

Si l'on considère que ce réseau probablement lié avec des mécanismes de plasticité synaptique, fonctionne selon le principe des processus parallèles distribués. Ces notions de processus distribués rencontrées dans les pointes intercritiques et dans les décharges critiques peuvent justifier la question que nombreux se sont posés à savoir les relations qui existe entre les pointes intercritiques et les décharges critiques.

De ce fait, l'étude comparative des événements intercritiques et critiques pourrait montrer l'existence d'une structure commune aux deux réseaux. Cependant, si dans certains cas la zone épileptogène se confond avec la zone irritative, dans d'autres cas les réseaux respectifs des pointes et des crises ne sont pas totalement superposables. Cela confirme l'existence de rapports anatomiques complexes entre zone irritative et zone épileptogène et appuie la non redondance des informations issues des enregistrements intercritiques et critiques.

1.7. Les événements paroxystiques critiques et intercritiques

1.7.1. Les événements paroxystiques critiques (les crises)

Dans le cadre de la neurologie, les crises sont causées par la survenue brutale d'une décharge électrique synchrone dans un ensemble de structure cérébrale. En plus, quand un groupe particulier de neurones envoie à différentes parties du cerveau des décharges anormales d'énergie électrique, une crise se produit. Cette décharge se propage plus ou moins rapidement et son étendu est plus ou moins important [18]. En effet la désorganisation fonctionnelle des structures affectées par les décharges provoque des manifestations cliniques qui dépendent des aires motrices, sensorielles, ou associatives impliquées.

Dans les épilepsies partielles, la décharge naît et se propage suivant des modes spatio-temporels [19] reproductibles occasionnant une séquence de signes cliniques reproductibles dont la valeur localisatrice clinique est importante. Ces crises peuvent causer des troubles de la vision, de la mémoire, du langage etc. Lorsque ce dysfonctionnement est plus diffus et atteint le cerveau de façon globale, les crises sont dites généralisées et se traduisent par des absences et surtout des convulsions plus connues sous le nom de « Grand Mal » [12].

Compte tenu de la diversité des sites cérébraux pouvant être concernés, une grande variété de signes cliniques est observée. Le cerveau est responsable du contrôle des actes moteurs, de la pensée, des sensations et des émotions, il règle également les fonctions involontaires du cœur, des poumons etc. Par conséquent, il est possible qu'aucune ou quelques-unes de ces fonctions soient entravées pendant une crise d'épilepsie.

Par contre, la sémiologie clinique et l'EEG des crises permettent de formuler des hypothèses quant à la localisation de la décharge critique. Il faut aussi noter que les crises d'un malade donné se caractérisent par une séquence chronologique de symptômes qui peuvent se modifier au cours de l'évolution de la maladie. Chaque épilepsie est un cas particulier, selon sa cause, sa fréquence, son intensité, sa sensibilité aux traitements ou à des événements extérieurs [22]. Cette grande diversité de la maladie a conduit à des essais de classifications en fonction des signes qu'elle met en jeu. On peut retenir deux grands groupes d'épilepsie, eux-mêmes subdivisés. Lorsque les décharges se produisent simultanément dans l'ensemble du cerveau, on parle de crises généralisées. Si les décharges ne prennent naissance que dans un foyer bien délimité, on parle de crise partielle. Lorsque les décharges se propagent ensuite à tout le cerveau on parle de crise secondairement généralisée. Le Tableau 1-1 [23] donne une classification internationale des épilepsies.

Tableau 1-1 : Classification internationale des épilepsies et des syndromes épileptiques

Crises généralisées	Tonique, clonique, tonico-clonique (Grand mal)
	Absences (Petit mal) <ul style="list-style-type: none"> ▪ Simples (uniquement perte de conscience), ▪ Complexes (avec de brefs mouvements automatiques, toniques)
	Syndrome de Gastaut-Lennox
	Épilepsie myoclonique juvénile
	Spasmes de l'enfant (syndrome de West)
	Crises atoniques (astasia, akinésie, parfois avec des myoclonies)
Crises partielles ou focales	Simples (sans perte de conscience) <ul style="list-style-type: none"> ▪ Motrices (tonique, clonique, tonico-clonique, Bravais-Jackson, épilepsie bénigne de l'enfance, épilepsie partielle continue), ▪ Somatosensorielles (visuelle, auditive, olfactive, gustative, vertiges), ▪ Autonomiques, ▪ Psychiques.
	Complexes (avec troubles de la conscience) <ul style="list-style-type: none"> ▪ Débutant comme une crise partielle et progressant avec troubles de la conscience, ▪ Avec troubles de la conscience dès le début de la crise.
Syndromes épileptiques particuliers	Myoclonies et crises myocloniques,
	Épilepsie réflexe,
	Aphasie acquise avec troubles convulsifs (syndrome de Landau-Kleffner),
	Convulsions fébriles et autres crises de l'enfance, Crises hystériques.

1.7.2. Les événements paroxystiques intercritiques (EPICs)

Les événements paroxystiques intercritiques (EPICs) sont caractérisés par une phase initiale brève, pointue et de fortes amplitudes, sous forme d'événements transitoires (< 1 seconde). Les EPICs peuvent être observés sur l'EEG de scalp (surface) ou de profondeur. Ils sont classés en pointes et en ondes, leur différence est que les pointes ont une durée comprise en 20 et 70 ms et les ondes pointues une durée entre 70 et 200 ms. Ils se distinguent par une amplitude significativement plus élevée que celle de l'activité de fond. Lorsque ces phases pointues sont suivies d'une onde plus lente, on parle alors de pointe-onde (« spike and wave

complex », en anglais). Une onde lente (slow wave) est d'amplitude plus faible relativement à la pointe ou à l'onde pointue et sa durée est comprise entre 200 ms et 800 ms.

La caractérisation clinique des EPICs repose sur leur densité, leur morphologie, et leur topographie (Figure 1-12 [12]). La densité horaire estimée sur un groupe standard d'électrodes SEEG (100 capteurs) varie suivant les patients de quelques centaines à plusieurs milliers par heures [18] [24]. Pour un EPIC donné, la distribution des activités épileptiques (AE) sur un sous ensemble de voies donne la topographie de cet EPIC.

La localisation des structures cérébrales sièges de la génération des différentes formes d'activités paroxystiques ont permis de définir 3 zones (lésionnelle, irritative et épileptogène) correspondant respectivement à la zone lésionnelle, au siège des EPICs, et au siège des crises.

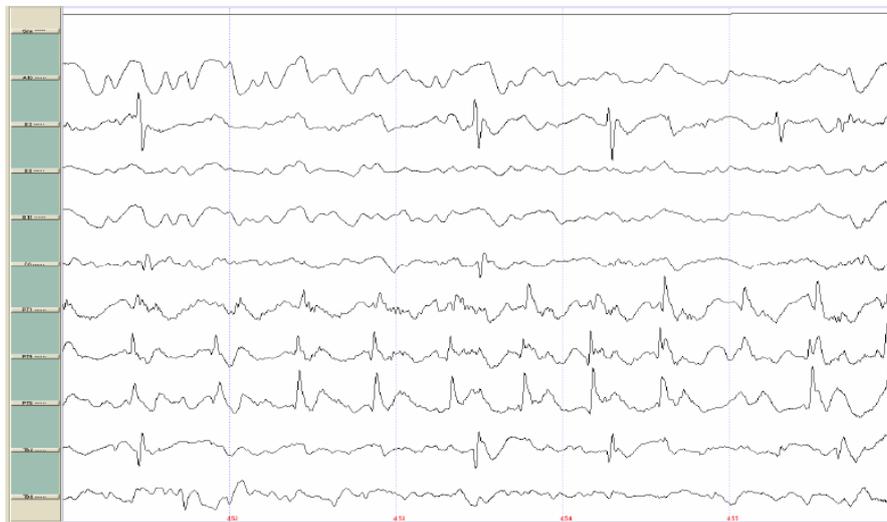


Figure 1-12 : Quelques événements paroxystiques intercritiques (EPICs)

1.7.2.1. La formation des activités épileptiformes

Au niveau de la population des neurones, celles appartenant au tissu épileptique possède deux caractéristiques particulières :

- Une caractéristique « intrinsèque » liée à des propriétés biochimiques membranaires qui les rendent hyperexcitable.
- Une caractéristique « réseau » permettant à des ensembles distants de neurones de se synchroniser par des connexions facilitées.

Au niveau cellulaire, l'hyperexcitabilité neuronale se traduit, en réponse à une excitation, par des séquences de dépolarisations paroxystiques. Les connexions anormales développées à l'origine de la synchronisation s'effectuent par le biais des synapses mais aussi par des mécanismes non synaptiques. La Figure 1-13 [18] illustre le schéma de l'effet d'une

excitation sur un neurone normal (a) et sur un neurone épileptique (b). La synchronisation d'un ensemble de neurones suffisant génère une activité épileptique (c) [18].

Sur le signal recueilli par un capteur, les dépolarisations membranaires synchrones au sein d'une population de neurones hyperexcitables vont se traduire par une activité transitoire typique souvent appelée « activité épileptique ».

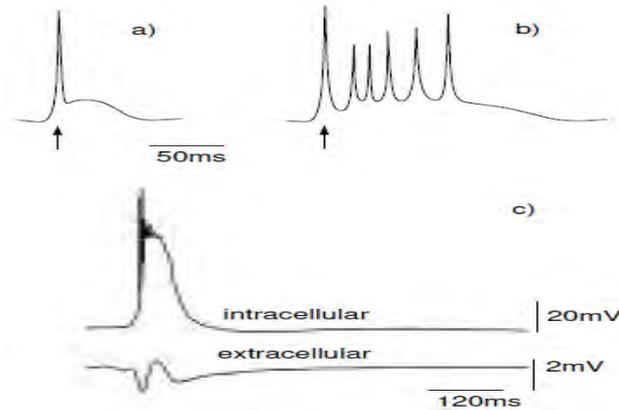


Figure 1-13 : Hyperexcitabilité intrinsèque du neurone épileptique

Dans la Figure 1-13 [18], a), b) et c) représentent respectivement *un neurone sain, un neurone épileptique et la genèse d'une activité épileptiforme extracellulaire par synchronisation d'une population de neurone épileptique.*

1.7.2.2. Caractérisation des EPICs

Un EPIC observé dans un signal EEG multivoies correspond à l'apparition sur 1 ou sur n voies, de respectivement, une ou n activités épileptiformes dont les instants de début (si $n > 1$) sont contenus dans une même fenêtre de support temporel court.

Morphologiquement les activités épileptiformes sont constituées d'une séquence de deux morphotypes élémentaires : une forme pointue bi, tri ou multiphasique et une forme monophasique plus lente. La forme pointue correspond à la dépolarisation synchrone d'une population de neurones et la forme monophasique lente correspond au régime de repolarisation. La morphologie « pointe et onde lente » (spike and slow wave) constitue un arrangement fréquent de ces deux formes élémentaires.

D'après les travaux de J. Bourien [18], les points les plus pertinents sur l'analyse des EPICs sont :

- La densité des EPICs observés en profondeur (SEEG) est supérieure à celle des EPICs observés en surface : de 0.5 à 0.8 pointes par seconde ;
- Leur morphologie est complexe, variable au cours du temps pour un même patient, et variable selon les patients ;

- La majorité des EPICs présentent tous une phase pointue monophasique, biphasique ou multiphasique ;
- La définition morphologique des EPICs varie beaucoup d'un auteur à l'autre (plus encore que dans le cas des EPICs observés sur des EEG de surface).

La Figure 1-14 donne quelques exemples de morphologie des EPICs avec leur polarisation (N, P et O désignent respectivement une phase pointue négative, positive et une onde lente).

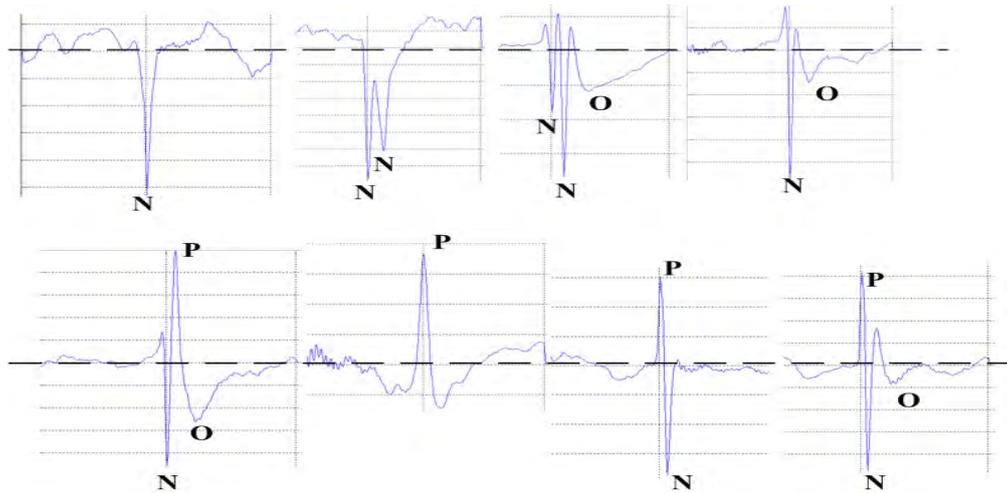


Figure 1-14 : Morphologies de quelques EPICs

1.7.2.3. Dynamique spatio-temporelle des EPICs

Les connexions anatomo-fonctionnelles, éventuellement facilitées entre certaines structures d'une région cérébrale donnée engendrent des distributions non-aléatoires des activités épileptiques dans l'espace des structures et dans le temps. Ceci amène à postuler l'existence d'une organisation sous-jacente (dépendante du patient) à identifier et à analyser (la zone irritative et modes d'activation). Cette organisation se manifeste dans les signaux EEG de profondeur par des dynamiques spatio-temporelle brèves et souvent reproductible [18]. L'inspection visuelle de l'activité intercritique repose sur un modèle d'implication inverse dans lequel :

- La co-activation fréquente d'un ensemble de structures traduit des connexions conjointes anormalement renforcées ;
- Une chronologie dans l'activation d'un des sous-ensembles de structures traduit une relation d'ordre temporel d'implication qui peut être causale.

L'analyse visuelle des données intercritiques est souvent fastidieuse. Si une co-activation est aisée à déterminer pour un expert (morphologie contrastée de l'EPIC par rapport à l'activité de fond), l'estimation de sa fréquence, en revanche, est plus difficile à effectuer. Elle

nécessite de retrouver, visuellement et sur de longues périodes d'enregistrement, les séquences d'activation similaires à celle recherchée.

Les signaux EEG de profondeur enregistrés dans 10 structures distantes (S1, ..., S10) sont présentés dans la Figure 1-15 [18]. La zone irritative contient 9 structures sur les 10 observées (pas d'AE dans S6). Des AE apparaissent de manière isolée ou par bouffées sur des sous-ensembles de voies, formant 10 EPICs. L'analyse visuelle permet de dégager 4 modes (1, 2, 3, 4) d'activation des structures sur cet ensemble d'EPICs.

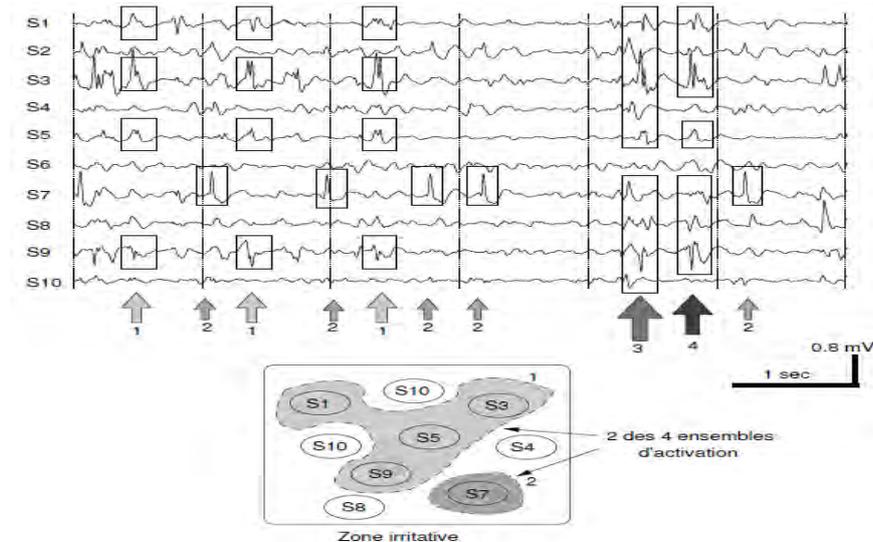


Figure 1-15 : Zone irritative et ensembles d'activation

1.7.3. Relations entre événements paroxystiques intercritiques et critiques

Les relations entre les EPICs et les crises restent mal connues bien que ces deux types d'activités paroxystiques soient pris en compte qualitativement dans l'analyse visuelle des signaux EEG [18]. Les anomalies intercritiques ont une valeur localisatrice controversée, les relations spatiales qu'elles entretiennent avec la zone épileptogène sont encore mal définies. Cependant, deux hypothèses contradictoires sont présentées dans la littérature [18] [4] :

- Les EPICs sont des événements excitateurs dégénérant les crises ;
- Les EPICs sont des événements inhibiteurs retardant la survenue des crises.

En effet, des travaux ont montré que la densité des EPICs a plutôt tendance à décroître avant les crises et à augmenter après les crises [25]. Ceci conduit à l'hypothèse d'un rôle potentiel des EPICs dans la réduction de la susceptibilité aux crises (inhibition des crises). L'altération de ce système inhibiteur, se traduisant par une diminution précritique du nombre d'EPICs, expliquerait l'apparition des crises. Après la crise, le système inhibiteur bénéficiant d'un déséquilibre favorable, par épuisement du système excitateur, retrouverait son rôle [18]. Les relations spatiales que les EPICs entretiennent avec les crises restent d'actualité car la

mise en correspondance de ces deux systèmes demeure toujours un problème. La difficulté réside dans la comparaison de processus ayant des descripteurs morphologiques et temporels différents (Figure 1-16 [12]).

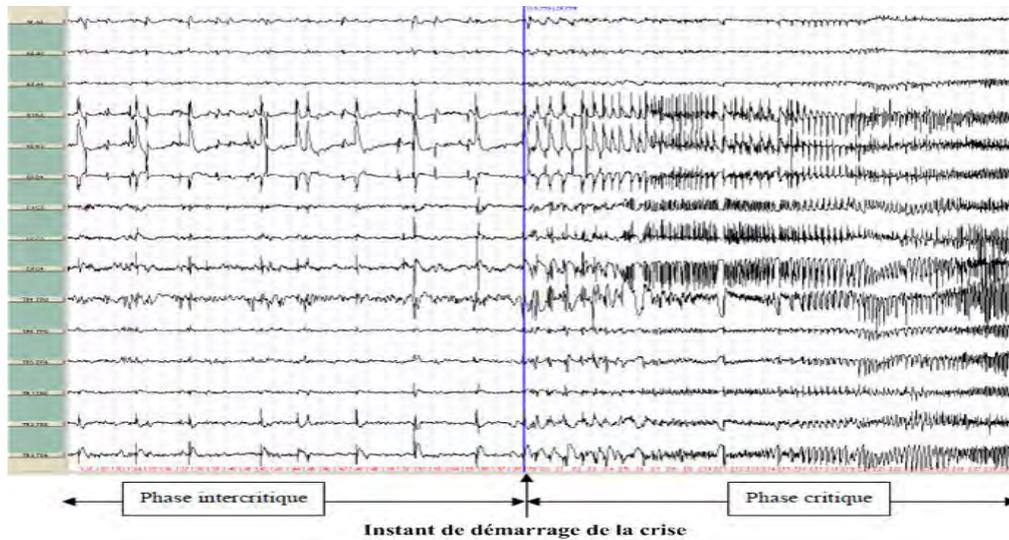


Figure 1-16 : Transition entre les phases intercritique et critique

1.8. Analyse du contexte local et problématique de la thèse

1.8.1. Analyse du contexte local : Sénégal

L'épilepsie est un problème de santé publique au Sénégal avec un taux de prévalence de 8,3 à 14 pour mille [26]. Elle concerne principalement les enfants et constitue un véritable facteur d'exclusion scolaire et sociale. La prévalence cache cependant des disparités régionales. La plupart des épileptiques ne sont pas traités du fait des interprétations socioculturelles et de l'insuffisance des ressources humaines et matérielles. Les préjugés négatifs qui entourent la maladie sont des obstacles à la bonne prise en charge des malades, leur épanouissement et leur intégration sociale [27].

Des études ont été menées sur des enfants de 3 mois à 16 ans [26] avec un sex-ratio de 1,7 en faveur des garçons. L'épilepsie était idiopathique chez 57% des enfants et non idiopathique chez 43% des patients. Les facteurs étiologiques étaient dominés par une consanguinité parentale, les anomalies de la grossesse et de l'accouchement, les infections du système nerveux central. Dans le groupe des épilepsies idiopathiques, la consanguinité parentale et l'épilepsie familiale étaient retrouvées respectivement chez 21,62% et 6,75% des enfants. Dans ce cas, 3% des enfants présentaient un trouble du langage, alors que 0,33% avaient un déficit cognitif global. Dans le groupe des épilepsies non idiopathiques, les signes associés à l'épilepsie étaient les troubles du langage (15,7%), du comportement (15%) et des déficits

moteurs (10,32%). Concernant des enfants scolarisés, 22,41% d'entre eux avaient des difficultés d'apprentissage menant parfois à des redoublements scolaires ou une exclusion.

Pour le cas des épilepsies idiopathiques, 47% des enfants présentaient une épilepsie généralisée et 53% une épilepsie partielle. Par contre, pour les épilepsies non idiopathiques, 61,06% des cas ont une épilepsie partielle et 38,94% une épilepsie généralisée. En plus, les épilepsies temporales et frontales sont les plus fréquentes.

Par ailleurs, les études sont souvent menées sur des patients qui sont suivis régulièrement par la structure en charge. Mais au Sénégal, les nombreux facteurs étiologiques font que l'épilepsie est majoritairement symptomatique [28]. En plus, les personnes présentant les épilepsies symptomatiques ne cessent de changer de médecin du fait des crises difficilement contrôlables mais aussi des handicaps associés qui rendent la prise en charge plus coûteuse, et beaucoup de familles ne viennent plus en consultation par manque de moyens. Ces patients continuent leur consultation le plus souvent chez les marabouts et autres sorciers.

Si en pratique neurologique quotidienne l'épilepsie est le deuxième motif de consultation après les céphalées, l'insuffisance en ressources humaines et matérielles rend sa prise en charge difficile. L'unique structure spécialisée public dans la prise en charge de l'épilepsie est le *service de Neurologie de l'Hôpital Fann de Dakar*.

Il y a un ratio de 1 Neurologue pour 536 000 d'habitants au Sénégal. Ce taux, même s'il est supérieur à la moyenne en Afrique au Sud du Sahara, reste largement insuffisant. Le ratio recommandé par l'OMS (Organisation Mondiale de la Santé) est 1 Neurologue pour 50.000 habitants [27].

1.8.2. Problématique de la thèse

Actuellement, le nombre exact d'épileptiques au Sénégal n'est pas connu. Cela est dû à des interprétations différentes que la population a vis-à-vis de cette maladie. Elle est présentée comme une manifestation surnaturelle dont le traitement relèverait du tradipraticien. Lorsque le guérisseur tradipraticien rencontre des difficultés à guérir cette maladie, les patients feront recours à la médecine moderne. Le service neurologique de Fann a un problème de capacité d'accueil insuffisante. En effet, le nombre de médecins spécialistes de l'épilepsie (neurochirurgiens, neurosciences) est insuffisant. Par conséquent, les médecins sont débordés par le nombre de consultation par jour, ce qui rend difficile le diagnostic. Il s'y ajoute un manque de moyens matériels (matériels d'exploration) et humains (exploitation des données d'exploration). L'exploitation des données d'investigation se limite à une inspection visuelle des tracés de l'EEG qui ne permet pas toujours d'identifier certains événements de

l'épilepsie. Ce travail s'inscrit dans le contexte d'élaboration d'outils d'aide à la décision visant à améliorer le diagnostic de l'épilepsie à travers une analyse automatique de la distribution des activités paroxystiques intercritiques et critiques.

De ce fait, nous proposons un système de traitement en partant de l'acquisition des données jusqu'à l'identification de la morphologie de l'EPIC (pointe) en passant par le filtrage et la détection des EPICs. La Figure 1-17 représente les différentes étapes de la chaîne de traitement d'aide au diagnostic de l'épilepsie [29].

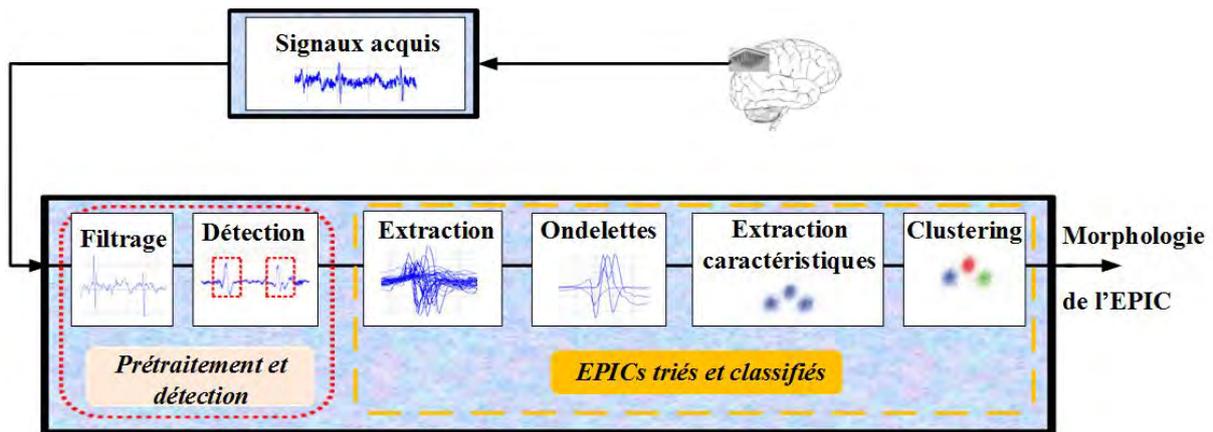


Figure 1-17 : Chaîne de traitement de signaux EEG proposée

Le fonctionnement de chaque module de la chaîne de traitement de l'information sera détaillé de façon claire dans le document et dans l'ordre chronologique du traitement.

Les signaux acquis au niveau des capteurs sont accompagnés de bruits d'origine différente. Il est donc nécessaire de diminuer voire supprimer ces bruits qui pourront entraîner des erreurs sur le traitement des données. Nous utiliserons les filtres SSA et de Kalman pour faire ce travail.

Après cette étape (Figure 1-17), nous pouvons appliquer les trois détecteurs proposés pour déterminer les instants d'occurrence des EPICs. De ce fait, nous utilisons les instants de détection pour pouvoir extraire tous les EPICs. Chaque EPIC extrait est soumis à un filtrage par décomposition d'ondelettes (DWT : Discret Wavelet Transform) pour éliminer les variations lentes des EPICs et de retenir uniquement les parties pointues. Selon les caractéristiques morphologiques des EPICs, nous pouvons les classer avec les méthodes de classification non supervisée associées à l'analyse en composantes principales.

1.9. Conclusion

Nous avons abordé dans ce chapitre une description du cerveau et ses activités électriques. Ces dernières peuvent être en rapport avec les crises épileptiques. Elles sont dues à des décharges paroxystiques critiques ou intercritiques selon le volume d'espace cérébrale concerné. Nous avons aussi présenté les différentes zones de localisation en épilepsie. Ce chapitre expose aussi le traitement de l'épilepsie. Le traitement pharmaceutique est la première méthode à être utilisée. Dans le cas où la maladie résiste à ce traitement, il est possible de faire recours à la chirurgie de l'épilepsie. Cette dernière nécessite une prise en charge très lourde et ne se pratique que dans les pays développés. Dans ce chapitre, nous avons présenté le cadre et le contexte général de ce travail. Le cas spécifique du Sénégal a été aussi abordé. Nous avons positionné la problématique de ce travail autour du développement d'outils d'aide au diagnostic à travers le filtrage, la détection des événements paroxystiques intercritiques, l'identification de leur morphologie et leur classification. Le chapitre 2 aborde le filtrage des signaux électroencéphalographiques.

Chapitre 2 : Méthodes de débruitage des signaux EEG

2.1. Introduction

En conditions réelles, l'enregistrement d'EEG de surface ou de profondeur est toujours perturbé par des artefacts, ce qui rend difficile l'analyse des événements paroxystiques critiques et intercritiques. On constate couramment des synchronisations d'artefacts, qui peuvent engendrer des erreurs d'interprétation médicale. Donc il est nécessaire de diminuer voire éliminer les bruits pour un meilleur traitement des données. Par ailleurs, il existe un grand nombre de filtres en traitement du signal. Vu la structure des signaux EEG, nous allons étudier des filtres qui permettent de mettre en évidence les événements transitoires. Nous présentons dans ce chapitre trois types de filtres. Après la présentation des signaux aléatoires et les filtres numériques, ce chapitre aborde d'abord le filtre basé sur la décomposition en valeurs singulières (SSA), ensuite l'application des ondelettes et enfin le filtre de Kalman.

2.2. Signaux aléatoires et estimation

On appelle signal une fonction qui représente l'évolution dans le temps d'une quantité physique comme la tension (exprimée en Volts (V)) ou le courant (exprimé en Ampères (A)). La représentation mathématique d'un signal se fait au moyen d'une fonction de la variable indépendante t ou f , où t et f représentent respectivement le temps et la fréquence. On désigne par exemple un signal par la notation $x(t)$ ou $X(f)$ [30].

2.2.1. Signaux aléatoires

Beaucoup de signaux dans le monde réel contiennent des parties non stationnaires (par exemple les signaux EEG). Ces signaux doivent obéir une loi de probabilité [31].

Un signal aléatoire $x(t, w)$ peut être déterminé à l'aide d'une fonction à deux variables (le temps t et w qui suit une loi de probabilité) [32].

La fonction $x(t, w)$ est variable aléatoire si t est fixe. Elle devient un échantillon du signal dans le cas où w est fixe. Par contre pour les deux variables fixées, la fonction $x(t, w)$ devient un nombre.

2.2.1.1. Moments statistiques

Dans cette partie, nous étudions certaines propriétés de la statistique dont on aura besoin pour décrire le comportement des signaux non stationnaires.

▪ **Espérance Mathématique**

L'espérance mathématique ou le moment statistique représente la moyenne des événements possibles dans un ensemble donné. La fonction correspondante peut être un signal continu ou discret et elle est toujours en fonction du temps [33].

✓ Si le signal aléatoire est continu, nous avons :

$$E(x(t)) = \int_{\Omega} x(t, w)p(w)dw \quad (2-1)$$

Où la fonction $E(x(t))$ est l'espérance mathématique et $p(w)$ la densité de probabilité dans l'espace des probabilités Ω .

✓ Dans le cas où le signal aléatoire prend ses valeurs dans un ensemble discret à N valeurs, nous obtenons :

$$E(x(k)) = \sum_{i=1}^N x_i(k)p_i \quad (2-2)$$

Où p_i est la probabilité de l'élément x_i .

Un signal aléatoire est stationnaire d'ordre 1 si l'espérance mathématique ne dépend pas du temps. Il est aléatoire centré dans le cas où l'espérance mathématique est nulle.

Les deux propriétés principales de l'espérance mathématique sont [34] :

- L'espérance est une fonction linéaire :

$$\forall \alpha, \beta \in \mathbb{R}, E[\alpha x + \beta y] = \alpha E[x] + \beta E[y] \quad (2-3)$$

- Si les deux variables x et y sont indépendantes, alors :

$$E[x, y] = E[x]E[y] \quad (2-4)$$

▪ **Variance**

La formule générale de la variance est :

$$\sigma^2 = E[x^2] - E(x)^2 = E[(x - E(x))^2] \quad (2-5)$$

Elle est égale à la puissance dans le cas des signaux aléatoires centrés et elle est déterminée par la relation suivante :

$$\sigma^2 = E[x^2] = p \quad (2-6)$$

La variance est importante dans la mesure où elle permet de caractériser la distribution des amplitudes du signal par rapport à sa valeur moyenne.

▪ Fonction d'autocorrélation

En statistique, l'autocorrélation R_x correspond aux produits des échantillons du signal pris à des instants t_1 et t_2 . Les équations (2-7) et (2-8) nous donnent respectivement l'autocorrélation pour un signal continu et discret :

$$R_x(t_1, t_2) = E[x(t_1)x^*(t_2)] \quad (2-7)$$

$$R_x(n, k) = E[x_n x_k^*] \quad (2-8)$$

2.2.1.2. Densité spectrale de puissance

La densité spectrale de puissance d'un signal aléatoire $x(t)$ que l'on note $S_x(f)$, est définie par la transformée de Fourier de sa fonction d'autocorrélation $R_x(\tau)$ [30]. Nous avons respectivement les expressions de la densité spectrale de puissance pour un signal continu (équation 2-9) ou discret (équation 2-10).

Soit $\tau = t_1 - t_2$

$$S_x(f) = TF[R_x(\tau)] = \int_{-\infty}^{+\infty} R_x(\tau) e^{-j2\pi n f} d\tau \quad (2-9)$$

$$S_x(f) = \sum_{n=-\infty}^{+\infty} x(n) e^{-j2\pi n f} \quad (2-10)$$

2.2.1.3. Stationnarité

On parle de signal stationnaire si toutes ses propriétés statistiques sont invariantes par translation de l'origine du temps [30].

Dans le cas où l'espérance mathématique est une constante $E(x(t)) = \beta$, le signal aléatoire est stationnaire à l'ordre 2. La fonction d'autocorrélation associée ne dépend que de la valeur τ ($R_x(t, \tau) = R_x(\tau)$).

2.2.2. Estimation

Pour évaluer des paramètres inconnus, en statistique, on doit les estimer. L'estimation est une branche de la statistique qui permet, à partir de mesures effectuées sur un système, d'estimer les valeurs de différents paramètres de ce système.

2.2.2.1. Estimateur

Un estimateur T de paramètre inconnu θ d'un modèle ou d'une loi de probabilité est une fonction qui fait correspondre à une suite d'observation (y_1, y_2, \dots, y_n) issues du modèle ou de la loi de probabilité, la valeur $\hat{\theta}$ que l'on nomme estimé ou estimation [34].

$$T = \hat{\theta}_n = f(y_1, y_2, \dots, y_n) \quad (2-11)$$

Un estimateur ne doit jamais dépendre de θ ; il ne dépend que des observations empiriques.

2.2.2.2. Quelques propriétés d'un estimateur

Pour évaluer un estimateur, on utilise un certain nombre de paramètres :

▪ Biais d'un estimateur

Le biais de l'estimateur T de θ est donné par la relation suivante [35] :

$$B(T) = E(T) - \theta \quad (2-12)$$

Si le biais est nul, on dit que l'estimateur est sans biais.

▪ Variance d'un estimateur

Pour obtenir des précisions sur l'estimateur, on utilise la variance de l'estimateur, $Var(\hat{\theta})$. Plus elle est faible, plus l'estimateur sera précis [36].

$$Var(\hat{\theta}) = E(\hat{\theta} - E(\hat{\theta}))^2 \quad (2-13)$$

▪ Convergence

La convergence est une propriété importante d'un estimateur. Elle doit être toujours vérifiée. Dans le cas où la taille des échantillons tend vers l'infini, l'estimateur doit se rapprocher du paramètre qu'il estime.

Nous pouvons avoir plusieurs définitions importantes concernant la convergence. Nous pouvons citer :

- ✓ L'estimateur T est convergent en probabilité si :

$$\forall \epsilon > 0 \lim_{n \rightarrow \infty} P(|T - \theta| > \epsilon) = 0 \quad (2-14)$$

Ceci peut se traduire quand $T = \theta$, $n \rightarrow \infty$.

- ✓ L'estimateur T est convergent en moyenne quadratique si :

$$\lim_{n \rightarrow \infty} (Var(T)) = 0 \quad (2-15)$$

Avec n la taille de l'échantillon.

2. 3. Généralités sur le filtrage des signaux

Un bruit est un phénomène perturbateur gênant la transmission ou l'interprétation d'un signal. De ce fait, le filtrage est une opération courante et très importante en traitement du signal. Les signaux acquis au moyen des capteurs sont, dans la majorité des cas, entachés des signaux indésirables, appelés bruit électronique, qui tendent à perturber, voire noyer complètement le signal utile à acquérir.

Le filtrage a pour but essentiel, d'améliorer la qualité du signal en rejetant la composante perturbatrice tout en conservant la partie porteuse de l'information utile [37].

On classe les filtres en deux grandes familles :

- Les **filtres analogiques** réalisés à partir des composants passifs ou actifs ;
- Les **filtres numériques** réalisés à partir des structures intégrées microprogrammables.

2.3.1. Réalisabilité d'un filtre

Pour qu'un filtre numérique soit réalisable, il doit vérifier les trois conditions suivantes :

▪ Invariance dans le temps

Un filtre numérique est invariant dans le temps s'il reproduit à sa sortie le même décalage temporel appliqué sur son signal d'entrée.

$$y(n) = f(x(n)) \Rightarrow y(n - p) = f(x(n - p)) \quad (2-16)$$

▪ Causalité

Un système est dit causal si la valeur de la sortie y à l'instant t ne dépend que des valeurs aux instants antérieurs à t , t inclus.

La causalité peut se traduire par l'expression suivante [37] :

$$h(n) = 0 \quad \text{pour } n < 0 \quad (2-17)$$

Où $h(n)$ est la réponse impulsionnelle du système. Elle représente une description du système dans l'espace des temps.

▪ Stabilité

Un système discret est stable si tout signal d'entrée arbitraire $x[n]$ d'amplitude finie ($|x[n]|_{max} \leq A \in \mathbb{R}$) produit en sortie un signal $y[n]$ d'amplitude finie ($|y[n]|_{max} \leq B \in \mathbb{R}$) [37].

La notion de stabilité des filtres est l'un des critères les plus importants à prendre en compte lors de la conception d'un filtre numérique. En effet, si le filtre se révèle instable, il n'aura aucune utilité pratique et peut même se révéler nocif.

✓ Théorème 2.1

Un filtre numérique de réponse impulsionnelle $\{h(n), n = 1, 2, 3 \dots\}$ est dit stable si et seulement si la somme de tous les échantillons de sa réponse impulsionnelle est finie.

$$\sum_{n=0}^{+\infty} |h(n)| < +\infty \quad (2-18)$$

✓ Théorème 2.2

Un filtre numérique causal de fonction de transfert $H(z)$ est stable si et seulement si tous les pôles de $H(z)$ sont d'amplitude inférieur à 1. Ceci est équivalent à dire que tous les pôles sont à l'intérieur du cercle unité dans le plan des z (z est un nombre complexe).

La fonction de transfert $H(z)$ constitue la réponse en fréquence du système avec $z = e^{-j2\pi f}$.

2.3.2. Structure des filtres numériques

On distingue deux types de réalisation de filtre numérique : la structure transversale et la structure récursive. Ces réalisations sont effectuées à partir de circuits numériques de base comme les sommateurs, les multiplieurs, etc.

2.3.2.1. Structure transversale (ou non récursive)

Cette réalisation est dite non récursive ou transversale car elle ne fait apparaître aucun bouclage de la sortie sur l'entrée (la sortie ne dépend que des entrées aux instants précédents). Elle est associée exclusivement aux filtres à réponse impulsionnelle fini (RIF) [37]. C'est essentiellement la partie numérateur de la fonction de transfert $H(z)$.

La sortie temporelle du filtre est définie par l'équation aux différences suivante :

$$y(n) = \sum_{i=0}^N b_i x(n-i) = b_0 x(n) + b_1 x(n-1) + \dots + b_N x(n-N) \quad (2-19)$$

Où $x(n)$, b_i et $N + 1$ représentent respectivement le signal d'entrée, les coefficients du filtre et le nombre de termes de l'équation.

La fonction de transfert $H(z)$ est définie par :

$$H(z) = \sum_{i=0}^N b_i z^{-i} \quad (2-20)$$

Pour la réalisation de ce filtre, il suffit d'effectuer un nombre fini de multiplications et d'additions. Le nombre de multiplication est égal à (N) et le nombre d'addition à $(N - 1)$.

Deux types de modèles sont alors possibles : la structure directe et la structure transposée. Elles sont représentées par la Figure 2-1.

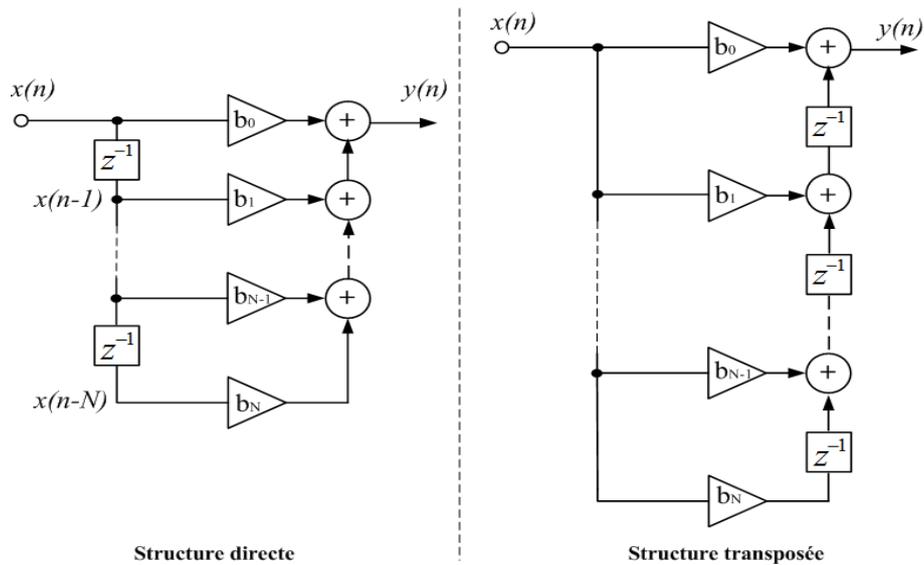


Figure 2-1 : Structures de réalisation transversale

Ces structures ne possèdent pas de boucle de retour, elles sont inconditionnellement stables.

2.3.2.2. Structure réursive

Elle correspond au cas où la sortie dépend de l'entrée et des sorties précédentes. C'est essentiellement le cas des filtres à réponse impulsionnelle infinie (RII) [37].

La sortie temporelle du filtre est définie par l'équation aux différences suivante :

$$y(n) = \sum_{i=0}^N b_i x(n-i) - \sum_{i=0}^M a_i y(n-i) \quad (2-21)$$

La fonction de transfert en z est donnée par :

$$H(z) = \frac{\sum_{i=0}^N b_i z^{-i}}{1 + \sum_{i=0}^M a_i z^{-i}} \quad (2-22)$$

On distingue alors la structure directe et celle en cascade.

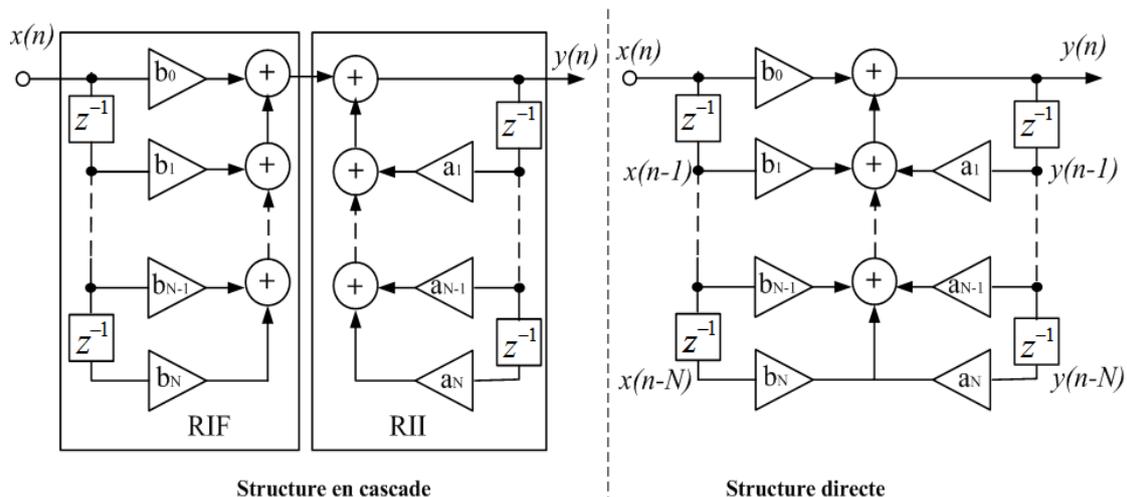


Figure 2-2 : Structures de réalisation réursive

Ces filtres numériques sont très utilisés en traitement des signaux biomédicaux. Mais ils peuvent présenter une limite lorsque le signal est fortement bruité. Ils peuvent modifier les événements paroxystiques intercritiques dans les signaux EEG. Dans la suite, nous présentons des filtres, qui de par leurs caractéristiques, s'adaptent aux données d'entrée.

2.4. Etude du filtre de SSA

Le filtre SSA (Singular Spectrum Analysis) ou analyse spectrale singulière s'est avéré être une méthode flexible pour l'analyse des données. Plusieurs applications sont rapportées dans divers domaines tels que le changement climatique [38] et des phénomènes géographiques [39] [40], du traitement minéral [41] et des applications en télécommunications [42] [43].

2.4.1. Décomposition en valeurs singulières

La décomposition en valeurs singulières (*SVD : Singular Value Decomposition*) regroupe plusieurs domaines scientifiques. Elle vient combler les limites de la décomposition en valeurs propres. Cette dernière s'applique uniquement sur certaines matrices carrées [44].

De ce fait, la décomposition en valeurs singulières concerne toutes les matrices sans restriction. Elle permet aussi de généraliser la diagonalisation dans le cas des matrices rectangulaires.

Pour une matrice A de taille $m \times n$, il existe deux matrices carrées orthogonales U et V de tailles respectives $m \times m$ et $n \times n$ telles que :

$$A = U\Sigma V^T \quad (2-23)$$

Où Σ une matrice de taille $m \times n$ diagonale avec coefficients réels et positifs [45].

Cette matrice contient les éléments $\sigma_1, \sigma_2, \dots, \sigma_k$, appelés valeurs singulières de A telles que $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_k \geq 0$ où $k = \text{minimale} \{m, n\}$.

Par ailleurs, les vecteurs singuliers droit et gauche de la matrice A sont respectivement les k premières colonnes de $U = (u_1, u_2, \dots, u_m)$ et $V = (v_1, v_2, \dots, v_n)$.

La matrice Σ peut avoir des structures différentes [46] :

- Dans le cas où $k = m$ ($m < n$), nous obtenons la structure ci-dessous :

$$\Sigma = \left(\begin{array}{ccc|c} \sigma_1 & & & 0 \\ & \sigma_2 & & \\ & & \ddots & \\ & & & \sigma_k \\ \hline & & & 0 \end{array} \right) = (\Sigma_k, 0) \quad (2-24)$$

En effet, nous pouvons simplifier l'écriture de la décomposition de la matrice A par [47] :

$$A = U(\Sigma_k, 0) \begin{pmatrix} V_1^T \\ V_2^T \end{pmatrix} \quad (2-25)$$

Le bloc V_2^T est multiplié par 0, ce qui nous permet d'obtenir la relation suivante :

$$A = U \Sigma_k V_1^T \quad (2-26)$$

Où U et Σ_k des matrices carrées de taille $m \times m$. La taille de la matrice V_1^T est égale à $m \times n$.

- Pour $k = n$ ($n < m$), nous avons la structure suivante :

$$\Sigma = \begin{pmatrix} \sigma_1 & & & & \\ & \sigma_2 & & & \\ & & \ddots & & \\ & & & \sigma_k & \\ \hline & & & & 0 \end{pmatrix} = \begin{pmatrix} \Sigma_k \\ 0 \end{pmatrix} \quad (2-27)$$

Pour ce cas, nous obtenons aussi une écriture simplifiée de A .

$$A = (U_1, U_2) \begin{pmatrix} \Sigma_k \\ 0 \end{pmatrix} V^T \quad (2-28)$$

Pour cette expression, le bloc U_2 est aussi multiplié par 0, ce qui donne l'expression réduite de la matrice A .

$$A = U_1 \Sigma_k V^T \quad (2-29)$$

Où les matrices Σ_k et V sont carrées de taille $n \times n$. La taille de la matrice U_1 est égale à $m \times n$.

Les équations (2-26) et (2-29) sont appelées décomposition réduite en valeurs singulières de la matrice A . Cette forme réduite est très importante en pratique. Il est aussi très intéressant de transformer ces équations réduites en une somme de matrices de rang 1. Les équations (2-26) et (2-29) deviennent alors [47]

$$A = \sum_{i=1}^k \sigma_i u_i v_i^T \quad (2-30)$$

- Pour le cas où la matrice A est carrée ($m = n$), toutes les autres matrices de la décomposition sont aussi carrées.

Par ailleurs, la détermination théorique des valeurs singulières et vecteurs singuliers associés semble très difficile. De ce fait, on se ramène à la résolution de problèmes aux valeurs propres et vecteurs propres des matrices AA^T et $A^T A$.

Soit A , une matrice de taille $m \times n$ avec $m > n$, en multipliant les deux membres de l'équation (2-23) par A^T , nous obtenons l'équation suivante :

$$A^T A = V \Sigma^T U^T U \Sigma V^T \quad (2-31)$$

Comme la matrice U est orthogonale, $U^T U = I$ (I : une matrice identité). Nous obtenons alors l'équation suivante :

$$A^T A = V \Sigma^2 V^T \quad (2-32)$$

La matrice $A^T A$ est une matrice carrée de taille $n \times n$. Elle est donc diagonalisable dans une base orthonormale de vecteurs propres. Sa décomposition en valeurs propres est :

$$A^T A = V \Pi V^T \quad (2-33)$$

Où $\Pi = \Sigma^2$.

Ainsi, les valeurs singulières de la matrice A représentent la racine carrée des valeurs propres λ_i ($\sigma_i = \sqrt{\lambda_i}$). Enfin, le couple (Π, V) représente la décomposition en valeurs propres de la matrice $A^T A$.

De manière similaire, le couple (Π, U) représente la décomposition en valeurs propres de la matrice AA^T .

Par conséquent, nous pouvons noter que les diagonalisations de $A^T A$ et AA^T déterminent respectivement les vecteurs singuliers V et U .

Par ailleurs, le filtre SSA est décrit principalement en deux étapes avec des formules mathématiques correspondantes. A la première étape ; la donnée est décomposée et à la deuxième étape, nous reconstruisons la donnée originale. Nous utilisons la partie reconstruite (qui est sans bruit) pour prédire de nouveaux points du signal.

2.4.2. Etape de la décomposition du filtre SSA

Cette étape est composée de deux parties essentielles incluant l'insertion et la décomposition en valeurs singulières. Dans l'étape d'insertion, la série chronologique « s » représentant le signal EEG est mappée de « k » vecteurs retardés de taille « l » [48].

$$X_i = [S_{i-1}, S_i, \dots, S_{i+l-2}]^T, \quad 1 \leq i \leq k \quad (2-34)$$

Où $k = r - l + 1$, l représente la largeur de la fenêtre ($1 \leq l \leq r$) et $[\]^T$ représente la matrice transposée. La taille de la fenêtre appropriée dépend totalement de l'application et de l'information préalable sur les signaux d'intérêt. La matrice de trajectoire de la série « s » est construite en insérant chaque \mathbf{X}_i à la $i^{\text{ème}}$ colonne d'une matrice $l \times k$.

$$\mathbf{X} = [x_1, x_2, \dots, x_k] = \begin{bmatrix} S_0 & S_1 & S_2 & \cdots & S_{k-1} \\ S_1 & S_2 & S_3 & \cdots & S_k \\ S_2 & S_3 & S_4 & \cdots & S_{k+1} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ S_{l-1} & S_l & S_{l+1} & \cdots & S_{r-1} \end{bmatrix} \quad (2-35)$$

Notons que la matrice de trajectoire est une matrice de Hankel, c'est-à-dire tous les éléments de ses diagonales sont sous la forme $i + j = \text{constante}$.

En effet, la SVD de la matrice de trajectoire est calculée et représentée comme la somme des matrices élémentaires bi-orthogonales de rang 1. En considérant les valeurs propres et les vecteurs propres correspondant de $S = \mathbf{X}\mathbf{X}^T$ sont $\lambda_1, \lambda_2, \dots, \lambda_l$ et e_1, e_2, \dots, e_l respectivement. Si $V_i = \mathbf{X}^T e_i / \sqrt{\lambda_i}$, alors la SVD de la matrice de trajectoire peut être écrite par :

$$\mathbf{X} = \mathbf{X}_1 + \mathbf{X}_2 + \cdots + \mathbf{X}_d \quad (2-36)$$

Où $d = \text{argmax}_i(\lambda_i > 0)$ et $\mathbf{X}_i = \sqrt{\lambda_i} e_i V_i^T$. Le $i^{\text{ème}}$ triplet de la décomposition SVD comporte les V_i , e_i et λ_i . La projection de la série chronologique sur la direction de chaque vecteur donne la composante principale temporelle correspondant.

2.4.3. Etape de reconstruction du filtre SSA

Cette partie a deux étapes : regroupement et diagonalisation.

- Regroupement moyen : cette étape divise l'ensemble en indice $\{1, 2, \dots, d\}$ pour m ensembles disjoints I_1, I_2, \dots, I_m . Pour chaque groupe $I_j = \{i_{j1}, i_{j2}, \dots, i_{jp}\}$, nous avons $\mathbf{X}_{I_j} = \{X_{j1}, X_{j2}, \dots, X_{jp}\}$.

Le groupement des triplets avec l'expansion de toutes les matrices \mathbf{X}_{I_j} est déterminé par la relation suivante :

$$\mathbf{X} = \mathbf{X}_{I_1} + \mathbf{X}_{I_2} + \cdots + \mathbf{X}_{I_d} \quad (2-37)$$

Il n'existe pas de règle générale de regroupement. Pour chaque application, la règle de regroupement dépend du problème et de la contribution des signaux et du bruit.

- Diagonalisation moyenne : dans la dernière étape de l'analyse, chaque regroupement est transformé en une série de longueur r . Pour une matrice Y de taille $l \times k$, le $q^{\text{ème}}$ élément de la série chronologique g_q , est calculé à l'aide de la moyenne des éléments de la matrice au-dessus de la diagonale $i + j = q + 2$, où i et j sont respectivement les indices de la ligne et de la colonne de Y .

Le concept de séparabilité est une partie importante de la méthodologie SSA. Supposons que \mathbf{s} soit la somme de deux séries \mathbf{s}_1 et \mathbf{s}_2 , c'est-à-dire $\mathbf{s} = \mathbf{s}_1 + \mathbf{s}_2$. La séparabilité signifie que les termes de la matrice de la SVD de \mathbf{X} peuvent être divisés en deux groupes disjoints. Les deux groupes sont représentés respectivement par les matrices de trajectoire \mathbf{X}_1 et \mathbf{X}_2 [49]. Une condition nécessaire pour la séparabilité des sources, est la discontinuité de leur spectre de fréquences. La séparabilité exacte ne peut pas être réalisée pour les signaux du monde réel ; par conséquent, seule la séparabilité approximative peut être envisagée.

Les triplets résultant du filtre SSA contiennent également des informations sur le contenu en fréquence des données. S'il existe une composante périodique dans les données, elle sera renvoyée à la sortie du SSA comme une paire de valeurs propres (presque) égales. Par ailleurs, les pics les plus élevés dans la transformation de Fourier des vecteurs propres correspondants sont liés à la fréquence de la composante périodique. Ces caractéristiques du filtre SSA sont utilisées pour construire des filtres pilotés par les données [50].

2.5. Filtrage par ondelette

Pour un bon traitement des signaux déterministes, il est nécessaire de passer par l'analyse de Fourier [51]. C'est l'analyse de Fourier qui nous permet de faire le traitement convenable des signaux déterministes car elle apporte des compléments aux informations temporelles des signaux [52]. Elle répondait aux besoins des chercheurs, ingénieurs pour ne citer que cela. Mais elle a vite montré ses limites pour le cas des signaux transitoires. Dans le monde réel, presque tous les signaux sont de nature non stationnaire (transitoire) et nous pouvons citer : le domaine de la géophysique et de la sismologie, le domaine de la biomédicale (électroencéphalogramme (EEG), électrocardiogramme (ECG)) etc.

De ce fait, il fallait que la communauté scientifique trouvât des solutions à ce problème. C'est ainsi que Haar a eu l'idée de proposer pour la première fois en 1910 la transformation en ondelette [53]. Après la proposition de Haar, beaucoup de travaux se sont succédés pour résoudre aussi l'équation de l'analyse de Fourier. Jean Morlet fut le premier à avoir proposé le nom d'ondelettes. Il effectuait des recherches géologiques pour la découverte du pétrole. Pour analyser ses données, Morlet utilisait une technique adaptative consistant à déterminer la localisation de l'information tout en obtenant son contenu fréquentiel. Ce qui donne l'importance de la transformation en ondelettes [52].

Par conséquent, la transformation en ondelettes est un outil très puissant qui permet de découper les signaux en composantes fréquentielles suivant une résolution en échelle.

2.5.1. Transformées en ondelettes continues

Les ondelettes sont des fonctions à partir desquelles il est possible d'analyser (extraire des éléments remarquables, caractéristiques) et de représenter un signal (décomposition dans une base).

Dans l'espace des signaux d'énergie finie noté $L^2(\mathbb{R})$, la transformée en ondelettes continues (TOC) d'une fonction f est définie par :

$$T(a, b) = \int_{-\infty}^{+\infty} f(t) \psi_{a,b}^*(t) dt \quad (2-38)$$

La fonction $\Psi_{a,b}$ appelée ondelette est définie par :

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{-b}{a}\right) \quad (a, b \in \mathbb{R}, a \neq 0) \quad (2-39)$$

Dans cette définition, les indices a et b ont respectivement un rôle de dilatation et de décalage temporel à partir d'une fonction ψ , dite ondelette mère, dont les propriétés restent à définir.

Le facteur de normalisation $\frac{1}{\sqrt{a}}$ assure la conservation de la norme pour les ondelettes, soit :

$$\|\Psi_{a,b}(t)\| = \|\psi(t)\| \quad (2-40)$$

Le produit scalaire de f avec $\psi_{a,b}$ permet de mesurer les similitudes entre f et l'ondelette mère dilatée d'un facteur a et translatée d'un temps b .

L'ondelette mère ψ et sa transformée de Fourier $TF(\psi)$ doivent vérifier un certain nombre de propriétés.

Soit $\psi : \mathbb{R} \rightarrow \mathbb{R}$, $\psi(t) \in L^2$, vérifiant la condition d'admissibilité [54] :

$$C_\psi = 2\pi \int_{-\infty}^{+\infty} |TF(\psi)|^2 \frac{d\omega}{\omega} < +\infty \quad (2-41)$$

Cette formule représente le spectre à décroissance rapide. Cette condition permet d'analyser le signal, puis de le reconstruire sans perte d'information. En outre la transformée de Fourier de l'ondelette à la fréquence nulle (pour $\omega = 0$) doit être nulle.

Par ailleurs, la conservation d'énergie entre la fonction et sa transformée assure la possibilité de reconstruction parfaite. La propriété de conservation d'énergie se traduit par :

$$|f(t)|^2 = \frac{1}{C_\psi} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} |TOC_f(a, b)|^2 \frac{1}{a^2} da db \quad (2-42)$$

La reconstruction de f à partir de sa TOC s'écrit :

$$f(t) = \frac{1}{C_\psi} \int_0^{+\infty} \int_{-\infty}^{+\infty} |TOC_f(a,b)|^2 \psi_{a,b}(t) \frac{1}{a^2} da db \quad (2-43)$$

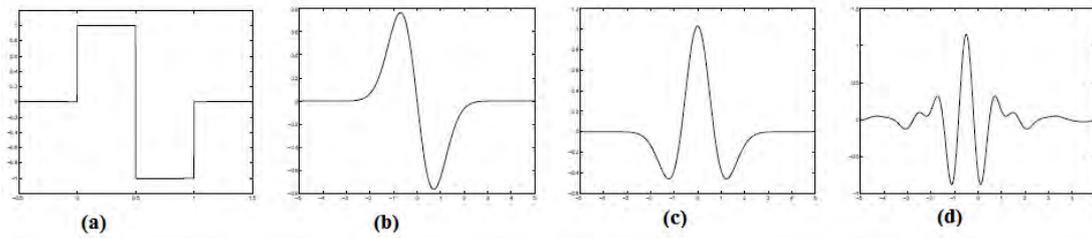


Figure 2-3 : Exemples d'ondelettes

(a) Ondelette de Haar, (b) Ondelette dérivée première de Gaussienne, (c) Ondelette Sombbrero, égale à $-\Delta G$ (dérivée seconde de Gaussienne), (d) Ondelette de Meyer [54].

2.5.2. Transformées en ondelettes discrètes

La transformée en ondelettes continues est très redondante. Il suffit en pratique d'avoir quelques coefficients pour couvrir entièrement le plan temps-échelle. On discrétise ainsi la représentation continue en échantillonnant à la fois le paramètre d'échelle a et le paramètre de translation temporelle b . Un échantillonnage judicieux de ces grandeurs doit : garantir la reconstruction du signal analysé, en trouvant un juste compromis entre redondance et perte d'information, et utiliser au mieux les caractéristiques propres aux fonctions analysantes $\psi_{a,b}$ et aux signaux que l'on désire étudier.

C'est pourquoi on choisit un échantillonnage logarithmique uniforme des paramètres et non pas un échantillonnage linéaire. La grille d'échantillonnage est la suivante :

$$\{(a,b) = (a_0^m, nb_0 a_0^m); a_0 > 1, b_0 > 0; n, m \in \mathbb{Z}\} \quad (2-44)$$

Où m et n représentent les indices d'échelle et de temps, et l'ondelette qui lui est associée est :

$$\psi_{m,n}(t) = a_0^{-\frac{m}{2}} \psi * (a_0^{-m}t - nb_0) \quad (2-45)$$

Le problème de la discrétisation est alors reporté sur la transformation de l'intégrale en une somme double sur les indices m et n . ($\langle \cdot, \cdot \rangle$ désigne le produit scalaire dans L^2).

$$A\|f\|^2 \leq \sum_{m,n} |\langle \psi_{m,n}, f \rangle|^2 \leq B\|f\|^2 \quad (2-46)$$

Pour la reconstruction du signal, une condition suffisante est d'avoir l'égalité des bornes A et B . Dans ce cas, la valeur commune des bornes est un indice de redondance lié à l'échantillonnage. La transformée en ondelettes discrète se formalise comme suit :

$$\text{TOD}_{m,n}[f(t)] = a_0 \frac{-m}{2} \int_{-\infty}^{+\infty} f(t) \psi * (a_0^{-m}t - nb_0) dt \quad (n, m \in \mathbb{Z}) \quad (2-47)$$

Où TOD signifie *Transformée en Ondelettes Dyadique*. La formule de reconstruction s'écrit :

$$f(t) = \sum_m \sum_n \langle f, \psi *_{m,n} \rangle \psi_{m,n}(t) = \sum_m \sum_n \text{TOD}_{m,n}[f(t)] \cdot \psi_{m,n}(t) \quad (2-48)$$

On choisit fréquemment les valeurs $a_0 = 2$ et $b_0 = 1$, ce qui conduit à une échelle logarithmique formant un réseau appelé réseau dyadique. Ce choix a conduit à proposer des algorithmes rapides de décomposition en ondelettes discrète grâce à l'utilisation d'opérateurs de décimation et d'interpolation d'un facteur 2.

2.5.3. Applications des ondelettes

Les domaines d'applications dans lesquels les ondelettes ont sans doute eu l'impact le plus important sont entre autres la compression d'images, le débruitage, l'analyse des phénomènes fractals ...

Nous nous intéressons dans cette partie au filtrage utilisant les *ondelettes orthogonales*. De ce fait, nous définissons g (passe-haut) et h (passe-bas) deux filtres miroirs conjugués.

Les filtres miroirs conjugués sont un cas particulier des bancs de filtres à reconstruction parfaite. La nature dyadique de l'approximation multi résolution est étroitement liée à la possibilité d'opérer des sous-échantillonnages élémentaires du signal par suppression d'un terme sur deux, et des sur-échantillonnages élémentaires par insertion d'un zéro tous les deux coefficients.

Le calcul des coefficients $a_1[n]$ et $d_1[n]$ d'un signal dans V_j et W_j (sous-espace vectoriel) à partir de ses coefficients $a_0[n]$ dans V_{j-1} se fait par application des filtres miroirs conjugués puis un sous-échantillonnage :

$$a_1[n] = a_0 * h_1[2n] \text{ et } d_1[n] = a_0 * g_1[2n] \quad (2-49)$$

En posant $h_1[n] = h[-n]$ et $g_1[n] = g[-n]$.

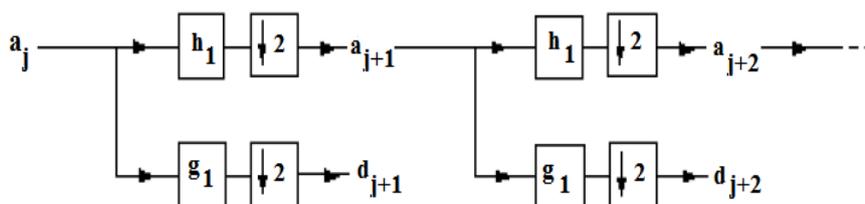


Figure 2-4 : filtres miroirs conjugués

Pour cela, nous définissons une fonction d'échelle par ϕ :

Il existe $\phi \in V_0$ (sous-espace vectoriel) telle que la famille $\{\phi(-k), k \in \mathbb{Z}\}$ forme une base de Riesz de V_0 . D'où cette ϕ représente la fonction d'échelle de l'Analyse multirésolution de $L^2(\mathbb{R})$ [55].

Les coefficients de h sont donnés par l'équation d'échelle.

$$\frac{1}{\sqrt{2}}\phi\left(\frac{t}{2}\right) = \sum_{n=-\infty}^{+\infty} h[n]\phi(t-n) \quad (2-50)$$

Dans le domaine fréquentiel, nous avons :

$$\hat{\phi}(\omega) = \prod_{p=1}^{+\infty} \frac{\hat{h}(2^{-p}\omega)}{\sqrt{2}} \hat{\phi}(0) \quad (2-51)$$

Les coefficients de g sont donnés par l'équation d'échelle sur l'ondelette :

$$\frac{1}{\sqrt{2}}\psi\left(\frac{t}{2}\right) = \sum_{n=-\infty}^{+\infty} g[n]\phi(t-n) \quad (2-52)$$

Soit, dans le domaine fréquentiel :

$$\hat{\psi}(\omega) = \frac{1}{\sqrt{2}}\hat{g}\left(\frac{\omega}{2}\right)\hat{\psi}\left(\frac{\omega}{2}\right) \quad (2-53)$$

En pratique, cette récurrence est initialisée en assimilant les échantillons du signal aux coefficients de résolution la plus fine.

Inversement, la reconstruction de $a_0[n]$ à partir de $a_1[n]$ et de $d_0[n]$ à partir de $d_1[n]$ se fait en insérant un zéro entre chaque échantillon puis en faisant la somme des convolutions avec h et g :

$$a_0[n] = z(a_1) * h[n] + z(d_1) * g[n] \quad (2-54)$$

Où l'opérateur z représente l'insertion de zéro.

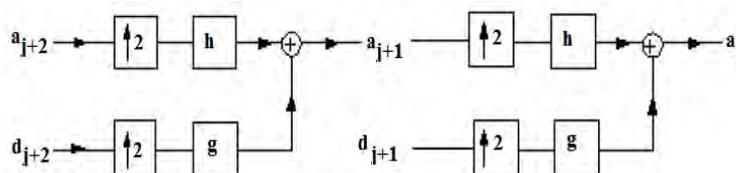


Figure 2-5 : filtres miroirs conjugués : reconstitution

L'évaluation des diverses ondelettes et fonctions d'échelles se fait comme dans le cas orthogonal. La construction d'ondelettes orthogonales revient donc à la synthèse de filtres miroirs conjugués possédant une propriété de stabilité [56]. On s'intéressera au cas particulier des filtres à réponse impulsionnelle finie, i.e., aux ondelettes à support compact.

Cependant, un banc de filtre à reconstitution parfaite décompose un signal par filtrage et sous-échantillonnage. Un banc de filtres (discrets) sous-échantillonnés à deux canaux fait le produit de convolution d'un signal a_0 avec un filtre passe-bas $h_1[n] = h[-n]$ et un filtre passe-haut $g_1[n] = g[-n]$ (équation 2-54). Ainsi, l'obtention du signal reconstitué a_2 se fait en appliquant un filtre passe-bas dual h_2 et un filtre passe haut dual g_2 aux signaux dilatés par insertion de zéros. En insérant un zéro sur tous les deux échantillons, nous obtenons un signal noté $y(x)$ et l'équation obtenue est :

$$a_2[n] = y(a_1) * h_2[n] + y(d_1) * g_2[n] \quad (2-55)$$

La Figure 2-6 donne le processus de décomposition et de reconstruction.

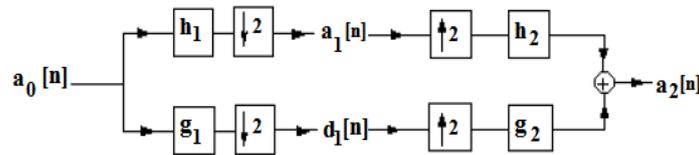


Figure 2-6 : processus de décomposition et de reconstruction

Un banc de filtres est à reconstruction parfaite lorsque $a_2 = a_0$. En effet, nous pouvons parler de filtre miroir dans le cas des égalités suivantes : $h = h_2$ et $g = g_2$.

De manière générale, on utilise l'algorithme à trous de Mallat pour calculer rapidement les coefficients d'ondelettes de la TOD (Transformée en Ondelettes Dyadique), grâce à des convolutions discrètes.

- Coefficients d'approximation

$$a_j[n] = \left\langle f, \frac{1}{\sqrt{2^j}} \phi \left(\frac{-2^j n}{2^j} \right) \right\rangle \quad (2-56)$$

- Coefficient de détails

$$d_j[n] = \left\langle f, \frac{1}{\sqrt{2^j}} \psi \left(\frac{-2^j n}{2^j} \right) \right\rangle \quad (2-57)$$

De même, pour des filtres h et g , nous pouvons obtenir respectivement les filtres h_j et g_j par insertion de $2^j - 1$ zéros entre deux coefficients de h et g . A partir des coefficients a_0 , les coefficients $(a_j)_{j \geq 0}$ et $(d_j)_{j \geq 0}$ définis ci-dessus peuvent être obtenus récursivement d'après les formules de décomposition suivantes :

$$a_{j+1} = a_j * h_j \quad (2-58)$$

$$d_{j+1} = a_j * g_j \quad (2-59)$$

L'application de ces formules se représente par un banc de filtres impliquant un filtre passe-bas h , correspondant à la fonction échelle ϕ et un filtre passe-haut g , correspondant à l'ondelette ψ (Figure 2-7).

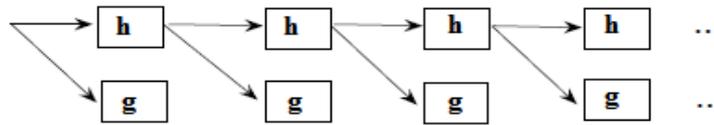


Figure 2-7 : Banc de filtres impliquant un filtre passe-bas et filtre passe haut

2.6. Etude du filtre de Kalman

Le filtre de Kalman [57] fait partie de la famille des filtres récursifs. Il fait l'estimation de l'état d'un système dynamique à partir d'une information connue sur l'évolution de cet état et de mesures réelles.

Ce filtre est très utilisé, même recommandé lorsque les données estimées sont imprécises c'est-à-dire qu'on peut les comparer à un signal bruité [58].

Le filtre de Kalman est appliqué dans une très large gamme de domaines technologiques tels que le traitement du signal, l'automatique, le radar et les systèmes de communication. On peut le retrouver également en dehors du domaine du traitement du signal, par exemple en météorologie et en océanographie, en finance et en navigation [59].

Dans le cas où nous voulons filtrer ou prédire les états d'un système dynamique et linéaire, on peut utiliser le filtre de Kalman.

2.6.1. Historique

Le filtre de Kalman vient de Rudolf Kalman qui est né en 1930. Il étudiait le comportement des solutions des équations du second degré dans les domaines de l'électronique et l'automatique. Il a soutenu sa thèse en 1957. Après sa thèse, il travaillait en 1958 au Research Institute for Advanced Studies à Baltimore. C'est à ce moment qu'il eut l'idée d'employer le formalisme des équations d'état au filtre de Wiener, ce qui lui permit de construire l'estimateur que nous connaissons aujourd'hui.

En 1960, après la visite de Kalman à la NASA, un des responsables, F. Schmidt comprit la possibilité d'appliquer les résultats de Kalman pour le projet « Apollo » pour estimer et commander les trajectoires [60]. Schmidt travailla sur le sujet et on peut dire que ce fut la première réelle implantation du filtre.

Les applications du filtre de Kalman sur des objets nécessitent la linéarisation des systèmes non linéaires. Le passage de cette étape a conduit aujourd'hui d'avoir une amélioration du filtre qu'on appelle filtre de Kalman étendu.

2.6.1. Principe du filtre de Kalman

Pour pouvoir estimer l'état courant d'un système dynamique, on doit tenir compte de l'estimation de l'état précédent et des mesures actuelles. Le principe du filtre de Kalman peut être modélisé suivant des variables d'état basé sur deux équations :

- L'équation de modélisation du processus aléatoire x_k (vecteur d'état) discret, dite équation d'état ou équation de transition.
- L'équation d'observation (ou équation de mesure) du processus y_k (vecteur de mesure).

Les équations de base du filtre de Kalman sont :

$$\begin{cases} x_{k+1} = A_k x_k + B_k u_k + w_k & w_k \Rightarrow \mathcal{N}(0, Q_k) \\ y_k = H_k x_k + v_k & v_k \Rightarrow \mathcal{N}(0, R_k) \end{cases} \quad (2-60)$$

Avec :

x_k Vecteur d'état à l'instant k qui inclut les quantités à estimer, de taille $n \times 1$.

A_k Matrice de transition. Elle décrit l'évolution du vecteur d'état de l'instant $k-1$ à l'instant k de taille $n \times n$.

B_k Matrice de commande à l'instant k dépend de la modélisation du système.

H_k Matrice d'observation (mesure). Elle est en fait le lien entre les paramètres du système et les mesures de taille $m \times n$.

u_k Vecteur représentant les commandes appliquées au système à l'instant k .

w_k Bruit de modélisation lié à l'incertitude que l'on a sur le modèle de processus.

Q_k Matrice de variances-covariances du bruit de processus à l'instant k .

y_k Vecteur de mesure à l'instant k de taille $m \times 1$.

v_k Bruit de mesure, de taille $m \times 1$.

R_k Matrice de variances-covariances du bruit de mesure à l'instant k .

Les bruits sont considérés comme blancs, gaussiens, centrés, indépendants entre eux et indépendants de l'état du système. On a alors :

$$E(w_k) = 0 \text{ et } E(v_k) = 0 \quad \forall k \quad (2-61)$$

$$E(x_0 w_i^T) = 0 \text{ et } E(x_0 v_i^T) = 0 \quad \forall k \quad (2-62)$$

$$E(w_k v_i^T) = 0. \quad \forall k, i \quad (2-63)$$

$$E(w_k w_i^T) = Q_k \delta_{ik} \quad (2-64)$$

$$E(v_k v_i^T) = R_k \delta_{ik} \quad (2-65)$$

2.6.3. Fonctionnement du filtre de Kalman

2.6.3.1. Les différentes phases du filtre de Kalman

Pour minimiser la variance de l'erreur d'estimation, on doit utiliser une estimation optimale. Elle consiste à trouver la meilleure estimation \hat{x}_k de l'état x_k .

$$e_k = x_k - \hat{x}_k \quad (2-66)$$

$$P_k = E[e_k e_k^T] \quad (2-67)$$

La prédiction et la mise à jour constituent les différentes phases du filtre Kalman.

La prédiction représente la première phase du filtre de Kalman. Elle utilise l'état estimé de l'instant précédent pour produire une autre estimation (instant courant). Concernant la phase de mise à jour, les observations de l'instant courant sont utilisées pour corriger l'état prédit dans le but d'obtenir une estimation plus précise.

La Figure 2-8 nous donne les différentes phases du filtre Kalman [61].

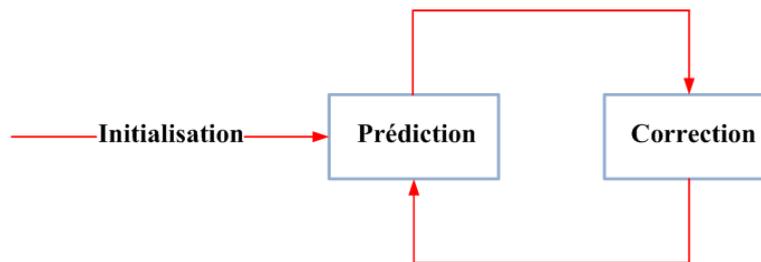


Figure 2-8 : Les étapes du filtre de Kalman

- La phase de prédiction

On considère l'instant k où on dispose d'une estimation initiale fondée sur la connaissance du processus et des mesures jusqu'à l'instant précédent, c'est-à-dire $k - 1$, cette estimation est appelée estimation à priori.

Si on note $\hat{x}_{k|k-1}$ l'estimation d'état, l'erreur à priori s'écrit sous la forme suivante :

$$e_{k|k-1} = x_k - \hat{x}_{k|k-1} \quad (2-68)$$

De fait, l'équation (2-71) donne la matrice de la covariance de l'erreur à priori.

$$P_{k|k-1} = E[e_{k|k-1} (e_{k|k-1})^T] = E[(x_k - \hat{x}_{k|k-1})(x_k - \hat{x}_{k|k-1})^T] \quad (2-69)$$

Enfin, les équations de la phase de prédiction sont représentées par les expressions suivantes :

$$\begin{cases} \hat{x}_{k|k-1} = A_{k-1} \hat{x}_{k-1|k-1} + B_{k-1} u_{k-1} \\ P_{k|k-1} = A_{k-1} P_{k-1|k-1} A_{k-1} + Q_{k-1} \end{cases} \quad (2-70)$$

- La phase de la mise à jour (Correction)

La correction de l'estimation à priori $\hat{x}_{k|k-1}$ et l'obtention de l'estimation à posteriori $\hat{x}_{k|k}$ sont faites à l'aide de la mesure y_k .

L'erreur à posteriori est donnée par la relation suivante :

$$e_{k|k} = x_k - \hat{x}_{k|k} \quad (2-71)$$

La matrice de covariance de l'erreur à posteriori est donnée par l'équation (2-72) :

$$P_{k|k} = E[e_{k|k} (e_{k|k})^T] = E[(x_k - \hat{x}_{k|k})(x_k - \hat{x}_{k|k})^T] \quad (2-72)$$

Les équations de la phase de correction sont :

$$\begin{cases} \hat{x}_{k|k} = \hat{x}_{k|k-1} + G_k(y_k - H_k \hat{x}_{k|k-1}) \\ P_{k|k} = (I - H_k G_k) P_{k|k-1} \end{cases} \quad (2-73)$$

Le paramètre G_k est le gain de Kalman optimal.

I : est la matrice identité de même taille que $P_{k|k-1}$.

2.6.3.2. Stabilité du filtre de Kalman

L'étude de la stabilité d'un filtre est très importante. Le filtre de Kalman a un gain qui varie dans le temps. L'étude de sa stabilité découle de l'équation de mise à jour. Cette dernière est donnée par la relation suivante :

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + G_k(y_k - H_k \hat{x}_{k|k-1}) \quad (2-74)$$

Avec :

$$\hat{x}_{k|k-1} = A_{k-1} \hat{x}_{k-1|k-1} \quad (2-75)$$

On obtient enfin l'expression suivante :

$$\hat{x}_{k|k} = A_{k-1} \hat{x}_{k-1|k-1} + G_k(y_k - H_k A_{k-1} \hat{x}_{k-1|k-1}) \quad (2-76)$$

$$\hat{x}_{k|k} = (A_{k-1} - A_{k-1} G_k H_k) \hat{x}_{k-1|k-1} + G_k y_k \quad (2-77)$$

Pour la représentation dans le domaine de représentation en z , on obtient les équations suivantes :

$$\hat{x}_{k|k}(z) = (A_{k-1} - A_{k-1} G_k H_k) z^{-1} \hat{x}_{k|k}(z) + G_k y_k(z) \quad (2-78)$$

$$(z - (A_{k-1} - A_{k-1} G_k H_k)) \hat{x}_{k|k}(z) = z G_k y_k(z) \quad (2-79)$$

$$\hat{x}_{k|k}(z) = \frac{zG_k y_k(z)}{(z - (A_{k-1} - A_{k-1}G_k H_k))} \quad (2-80)$$

En remplaçant $A_{k-1} - A_{k-1}G_k H_k$ par p on obtient :

$$\hat{x}_{k|k}(z) = \frac{zG_k y_k(z)}{(z - p)} \quad (2-81)$$

Comme tout filtre numérique, la stabilité est toujours liée aux pôles qui sont les racines du dénominateur.

Le filtre de Kalman est alors stable si les valeurs absolues des $A_{k-1} - A_{k-1}G_k H_k$ sont inférieures à 1.

2.6.3.3 Algorithme du filtre de Kalman

La combinaison des observations y_k avec l'information fournie par le modèle x_k nous permet d'obtenir l'état optimal du système.

La Figure 2-9 nous donne les différentes étapes de l'algorithme qui permettent d'obtenir un état estimé à chaque instant [62].

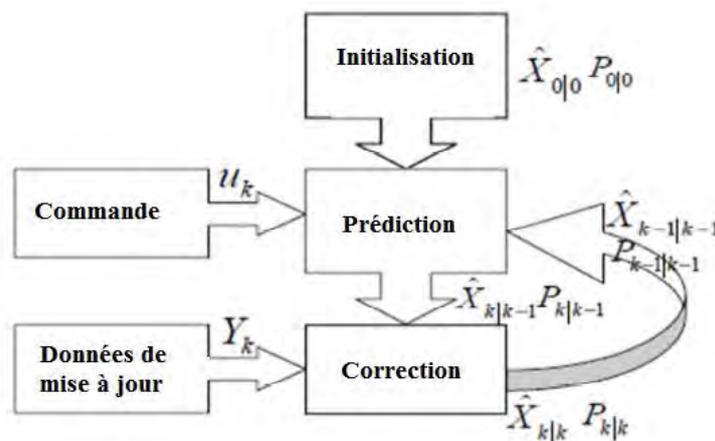


Figure 2-9 : Algorithme récursif du filtre de Kalman

Les différentes étapes de l'algorithme sont :

- Initialisation

Plusieurs paramètres doivent être déterminés dans cette partie : *les valeurs initiales du vecteur d'état \hat{x}_0 , la matrice de variances-covariances de l'erreur d'estimation P_0 , la matrice de variances-covariances du bruit de processus Q_0 et la matrice de variances-covariances du bruit de mesure R_0* [34].

$$\hat{x}_0 = E[x_0] \quad (2-82)$$

$$P_0 = E[(x_0 - \hat{x}_0)(x_0 - \hat{x}_0)^T] \quad (2-83)$$

$$Q_0 = E[(w - \bar{w})(w - \bar{w})^T] \quad (2-84)$$

$$R_0 = E[(v - \bar{v})(v - \bar{v})^T] \quad (2-85)$$

- Calcul de l'estimé $\hat{x}_{k|k-1}$ et de la matrice de covariance $P_{k|k-1}$ à partir des mesures disponibles à l'instant $k - 1$.

$$\hat{x}_{k|k-1} = A_{k-1}\hat{x}_{k-1|k-1} + B_{k-1}u_{k-1} \quad (2-86)$$

$$P_{k|k-1} = A_{k-1}P_{k-1}A_{k-1}^T + Q_{k-1} \quad (2-87)$$

- Calcul du gain de Kalman :

$$K_k = P_{k|k-1} H_k^T (H_k P_{k|k-1} H_k^T + R_k)^{-1} \quad (2-88)$$

- Mise à jour de l'estimation $\hat{x}_{k|k}$ (équation 2.74)
- Calcul de matrice covariance de l'erreur $P_{k|k}$ (équation 2.73)
- Préparation du pas suivant :

$$\hat{x}_{k+1|k} = A_k \hat{x}_{k|k} + B_k u_k \quad (2-89)$$

$$P_{k+1|k} = A_k P_k A_k^T + Q_k \quad (2-90)$$

2.6.4. Filtre de Kalman étendu

La première approche du filtre de Kalman était destinée aux systèmes linéaires. Mais dans la plupart des cas, on rencontre des systèmes non linéaires.

L'aspect non linéaire des phénomènes physiques rendait inefficace le filtre de Kalman classique. Il y a alors nécessité de l'améliorer pour qu'il puisse s'adapter aux différentes données étudiées.

Pour pouvoir rendre linéaire les systèmes qui ne le sont pas, une approche basée sur le développement de Taylor autour de l'état estimé a été appliquée. On se ramène dans ce cas au filtrage de Kalman linéaire classique. Et cette technique d'amélioration est connue sous l'appellation de filtre de Kalman étendu (EKF).

Ainsi nous obtenons les équations d'état et de mesure dans le cas des phénomènes non linéaires :

$$\begin{cases} x_{k+1} = f(x_k, w_k, u_k, k) & w_k \Rightarrow \mathcal{N}(0, Q_k) \\ y_k = h(x_k, v_k, k) & v_k \Rightarrow \mathcal{N}(0, R_k) \end{cases} \quad (2-91)$$

Où les fonctions f et h représentent respectivement la fonction d'évolution d'état et la fonction de mesure.

Les variables w et v sont des bruits blancs gaussiens de moyenne nulle et de variances respectives Q et R .

2.6.4.1. Equation du filtre de Kalman étendu

Le développement en série de Taylor des équations (2-91) peut se mettre sous la forme suivante :

$$\begin{cases} x_{k+1} \approx f(\hat{x}_k, w_k, k) + A_k(x_k - \hat{x}_k) + F_k(w_k - \hat{w}_k) \\ y_k \approx h(\hat{x}_k, v_k, k) + H_k(x_k - \hat{x}_k) + Z_k(V_k - \hat{V}_k) \end{cases} \quad (2-92)$$

Comme les vecteurs de bruit v_k et w_k ont, par hypothèse, une moyenne nulle, l'approximation des équations (2-92) est obtenue en considérant les estimés des bruits comme nuls [63] :

Alors on a :

$$\begin{cases} x_{k+1} \approx f(\hat{x}_k, 0, k) + A_k(x_k - \hat{x}_k) + F_k(w_k) \\ y_k \approx h(\hat{x}_k, 0, k) + H_k(x_k - \hat{x}_k) + Z_k(V_k) \end{cases} \quad (2-93)$$

Avec :

A_k : Matrice Jacobienne des dérivées partielles du modèle dynamique f par rapport à x :

$$A_k = \left. \frac{\partial f}{\partial x} \right|_{x=\hat{x}_k} \quad (2-94)$$

F_k : Matrice Jacobienne des dérivées partielles du modèle dynamique f par rapport à w :

$$F_k = \left. \frac{\partial f}{\partial w} \right|_{w=\hat{w}_k} \quad (2-95)$$

H_k : Matrice Jacobienne des dérivées partielles du modèle de mesure h par rapport à x :

$$H_k = \left. \frac{\partial h}{\partial x} \right|_{x=\hat{x}_k} \quad (2-96)$$

Z_k : Matrice Jacobienne des dérivées partielles du modèle de mesure h par rapport à v :

$$Z_k = \left. \frac{\partial h}{\partial v} \right|_{v=\hat{v}_k} \quad (2-97)$$

A partir de là, les équations de prédiction et de correction deviennent :

- Equations de prédiction :

$$\hat{x}_{k|k-1} = f(\hat{x}_{k|k-1}, 0) \quad (2-98)$$

$$P_{k|k-1} = A_{k-1}P_{k-1|k-1}A_{k-1}^T + F_{k-1}Q_{k-1}F_{k-1}^T \quad (2-99)$$

- Equations de correction :

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + G_k (y_k - h(\hat{x}_{k|k-1}, 0)) \quad (2-100)$$

$$K_k = P_{k|k-1}H_k^T (H_k P_{k|k-1}H_k^T + Z_k R_k Z_k^T)^{-1} \quad (2-101)$$

$$P_{k|k} = (I - G_k H_k)P_{k|k-1} \quad (2-102)$$

2.6.4.2. Algorithme du filtre de Kalman étendu

Les différentes étapes de l'algorithme de Kalman étendu sont [64][65] :

- Initialisation du processus

Dans cette partie, nous retrouvons les mêmes équations que le filtre de Kalman classique (équations 2-82, 2-83, 2-84 et 2-85).

- Calcul des matrices Jacobiennes de la fonction f autour de l'état précédent ($k - 1$).

$$A_{k-1} = \left. \frac{\partial f_{k-1}}{\partial x} \right|_{\hat{x}_{k-1|k-1}} \quad (2-103)$$

$$F_{k-1} = \left. \frac{\partial f_{k-1}}{\partial w} \right|_{\hat{x}_{k-1|k-1}} \quad (2-104)$$

- Prédiction de l'état à l'instant k par le calcul de l'estimé $\hat{x}_{k-1|k-1}$ et de la matrice covariance $P_{k-1|k-1}$ à partir des mesures disponibles à l'instant $k - 1$:

Les équations (2-98 et 2-99) de prédiction sont utilisées dans cette partie.

- Calcul des matrices Jacobiennes de la fonction non linéaire h :

$$H_k = \left. \frac{\partial h_{k-1}}{\partial x} \right|_{\hat{x}_{k-1|k-1}} \quad (2-105)$$

$$G_k = \left. \frac{\partial h_{k-1}}{\partial v} \right|_{\hat{x}_{k-1|k-1}} \quad (2-106)$$

- Correction de l'estimation par la mesure :

Les équations (2-100, 2-101 et 2-102) sont utilisées aussi pour faire cette correction.

- Bouclage sur l'étape 2...

2.7. Conclusion

Lors de l'acquisition des données EEG, plusieurs bruits d'origine différente peuvent s'ajouter au signal. L'objectif principal de ce chapitre est de trouver des filtres qui sont adaptés à ces signaux. Dans un premier temps, un rappel sur les généralités des filtres numériques a été fait, suivi des filtres qui ont été choisis dans une large gamme. Le filtre SSA se repose essentiellement sur la décomposition en valeurs singulières des données d'entrée. Alors que le filtrage par ondelette s'appuie sur des systèmes multi-résolutions et multi-échelles pour atténuer les bruits et mettre en évidence les EPICs. Le dernier filtre est un outil de filtrage de type stochastique qui est le filtre de Kalman. Après la phase d'initialisation, ce filtre utilise fondamentalement la prédiction et la correction pour trouver l'information exacte filtrée.

Chapitre 3 : Etude et détection des événements paroxystiques intercritiques

3.1. Introduction

La détection des événements paroxystiques intercritiques fait l'objet de nombreux travaux de recherche. L'occurrence de ces événements est très importante devant la fréquence des crises épileptiques. Plusieurs études [7] [66] [67] [68] cherchent à évaluer les relations entre les EPICs et les crises. Ces différents travaux passent nécessairement par la détection de ces événements. La détection des EPICs n'est pas un problème simple, elle est toujours considérée comme un problème difficile dans le domaine du traitement des signaux EEG. D'une part, ces signaux sont hautement non-stationnaires, et d'autre part, les événements que l'on cherche à détecter peuvent avoir des formes variées. Elle est considérée utile car il est parfois difficile, voire impossible pour un expert de relever des pointes plus petites qu'une certaine amplitude par la seule inspection visuelle des tracés. C'est une problématique très abordée dans la littérature scientifique, et les méthodes proposées sont très variées. Plusieurs méthodes de détection semblent donner de « bons » résultats, mais il faut rester prudent quant à leur objectivité car il n'existe pas de standard, pas de référence absolue sur la définition d'un EPIC, sur les indices de mesure de performances et sur les références utilisées pour évaluer les méthodes (experts). Ce chapitre présente une étude succincte de l'état d'art des méthodes de détection existantes. De ce fait, nous proposons trois méthodes de détection dont la première est basée sur l'algorithme de Page Hinkley, la deuxième sur l'utilisation de l'opérateur non linéaire d'énergie et la dernière sur la dimension fractale [5].

3.1. Etat de l'art des méthodes de détection des EPICs

On peut dire que la détection des EPICs permet de prendre des décisions sur la présence ou pas d'un événement. Une différence doit être faite entre la pointe et l'activité de fond du signal. C'est pourquoi il est nécessaire d'appliquer un filtre avant d'utiliser une méthode de détection pour éviter de manquer des événements ou de détecter des parties qui ne sont pas des EPICs.

Par rapport aux différentes méthodes appliquées à la détection, nous pouvons les classer en cinq (5) catégories selon leur critère de détection.

3.1.1. Les méthodes heuristiques (méthodes mimétique)

Les experts ou les neurologues décomposent le plus souvent le signal EEG pour identifier les différentes pointes. Les méthodes heuristiques qui sont très utilisées dans la littérature, se

sont basées sur les décompositions utilisées par les experts [69] [70] [71]. Elles passent par la caractérisation en morceaux des signaux EEG par attributs distincts comme la pente, la durée, l'amplitude du signal. Après une décision doit être prise pour déterminer la présence ou non d'une pointe dans les morceaux.

3.1.2. Les méthodes prédictives

Les méthodes prédictives sont basées sur l'utilisation des modèles paramétriques linéaires (Autorégressifs : AR) et non linéaires [72]. Les modèles autorégressifs considèrent l'activité de fond du signal EEG comme la sortie d'un filtre dont ses paramètres (ordre, pôles...) seront estimés. En effet, Tzallas et ses co-auteurs [73] ont présenté une nouvelle technique basée sur un modèle autorégressif variable dans le temps qui s'est servi de la non-stationnarité des signaux EEG [74]. Dans ce cas, les paramètres autorégressifs sont estimés à l'aide d'un filtre de Kalman. Ainsi, les pointes sont détectées lorsqu'un changement est observé dans l'espace de ces paramètres.

3.1.3. Les méthodes basées sur le filtrage adaptif (matching pattern methods)

Les méthodes à filtres adaptifs permettent de séparer l'activité de fond et les composantes des EPICs tout en conservant leur morphologie. Elles caractérisent les bandes de fréquences, les représentations temps-fréquence et la morphologie des pointes [75]. De ce fait, elles définissent les gabarits des événements recherchés. Ces gabarits sont utilisés pour filtrer les signaux afin de faire la différence entre les EPICs et l'activité de fond. Le signal obtenu après filtrage va changer en présence de tout événement ressemblant au gabarit [76]. Enfin, la fonction de seuillage est utilisée pour prendre des décisions sur la présence ou pas d'une pointe.

3.1.4. Les méthodes basées sur l'analyse factorielle

Ces méthodes de détection s'appuient principalement sur l'analyse en composantes indépendantes (ACI) des EPICs. Elles sont très utilisées pour détecter les pointes dans des signaux multicanaux. Pour ce faire, l'ACI est appliquée aux données spatio-temporelles et aux composants qui ressemblent à des activités épileptiques anormales validées par un neurologue ou un expert [77] [78]. C'est ainsi que Kobayashi [79] a proposé deux démonstrations basées sur des modèles et des données réelles de l'utilisation de l'ACI pour isoler les pointes des données multicanales des signaux EEG [74].

3.1.5. Les méthodes basées sur les techniques de classification

Cette partie regroupe une large gamme de méthodes de détection. Certaines méthodes utilisent les techniques de clustering comme K-means, Fuzzy C-means et d'autres s'appuient sur des techniques de classification supervisées (les réseaux de neurones ou les machines à vecteurs de support). Concernant les méthodes de clustering, elles interviennent sur le groupement des différents éléments des signaux EEG afin d'identifier les EPICs [80]. Le groupement est fait à l'aide des algorithmes des K-means [81] et Fuzzy C-means [82]. Cependant, l'algorithme K-means a été employé non seulement pour le groupement des pointes mais aussi d'autres types de morphologie d'ondes passagères [83]. Pour les réseaux de neurones (ANNs : Artificial Neural Network), le comportement de la collection de neurones doit être simulé. Cette simulation se base d'abord sur l'apprentissage des données brutes [84] [85] pour détecter les EPICs. Les données utilisées concernent principalement la durée, la pente, la finesse et l'amplitude des pointes [86] [87]. En plus certains auteurs utilisent aussi d'autres techniques de classification supervisées comme les machines à vecteur de support (SVM : Support Vector Machine) [88]. Le SVM s'appuie sur l'ajustement de la position du séparateur (ligne, plan, hyper plan) entre les modèles de vraies et de fausses pointes en se basant sur la distance des données aberrantes. Hormis ces méthodes de détection, il s'y ajoute les techniques de fouille de données (data mining) [89]. Concernant cette dernière technique, la morphologie des EPICs n'est pas précisée.

Toutefois, la problématique de la détection des événements paroxystiques intercritiques (EPICs) est confrontée à de nombreuses difficultés et questionnements.

Quels sont les meilleurs critères et méthodes de détection des EPICs ?

Quel est le taux de bonnes détections des méthodes utilisées ?

Quel est le taux de fausses détections des méthodes utilisées ?

Quelles sont les durées des différents événements détectés ?

Quelles sont les différentes structures cérébrales génératrices de ces événements ?

À partir des questions précédentes, il ressort clairement dans le problème de détection de pointes, qu'*un équilibre doit être obtenu entre la sensibilité élevée et la sélectivité élevée*. Il est facile d'ajuster des paramètres de méthode pour obtenir tous les EPICs présents dans les signaux enregistrés chez un patient donné. Cette situation est souvent accompagnée d'un grand nombre de fausses détections [90]. Alternativement, il est aussi facile d'avoir une méthode avec des taux de fausses détections très bas, mais ceci serait accompagné d'un grand nombre d'événements manqués. *Il est préférable d'avoir une sensibilité élevée qui permettrait*

de maximiser la détection des vrais EPICs. La suppression des fausses détections induites par la sensibilité pourrait être faite par un spécialiste (neurophysiologiste) [90] [91].

Par ailleurs, il n'existe pas une méthode de détection de pointes qui fait le consensus dans la communauté scientifique. Les résultats d'une méthode peuvent présenter des variations pour un même patient et pour des patients différents.

De ce fait, nous proposons dans cette thèse trois détecteurs basés sur des méthodes existantes [18] [76] [92] [93], mais modifiées pour répondre au problème posé. **Ces détections se sont basées respectivement sur l'algorithme de Page Hinkley, sur l'opérateur d'énergie non linéaire (SNEO) et sur la dimension fractale (FD).**

3.2. Formalisme du problème

Soient $X(t)$ une matrice composée de vecteurs lignes $x_k(t), k \in \{0, 1, \dots, N_{lignes} - 1\}$ et $t \in \{0, 1, \dots, N_{ech} - 1\}$, \hat{x} désigne l'estimée de x et x^T désigne la transposée de la matrice x .

Considérons un enregistrement EEG à temps discret de N_{ech} échantillons :

$V(t) = [v_0(t), v_1(t), \dots, v_{N_v-1}(t)]^T$ où N_v représente le nombre de voies de l'enregistrement, t représente l'échantillon temporel. Chaque ligne de la matrice $V(t)$, $v_k(t), k \in \{0, \dots, N_v - 1\}$ représente un signal monovoie, c'est-à-dire une observation enregistrée par le capteur k .

Le signal vectoriel $V(t)$ peut être représenté de la manière suivante :

$$\begin{bmatrix} v_0(t) \\ v_1(t) \\ \dots \\ \dots \\ v_{N_v-1}(t) \end{bmatrix} = \begin{bmatrix} \sum_{i=0}^{N_0^{EPICs}-1} e_{0,i}(t - \tau_{0,i}) \\ \sum_{i=0}^{N_1^{EPICs}-1} e_{1,i}(t - \tau_{1,i}) \\ \dots \\ \sum_{i=0}^{N_{N_v-1}^{EPICs}-1} e_{N_v-1,i}(t - \tau_{N_v-1,i}) \end{bmatrix} + \begin{bmatrix} b_0(t) \\ b_1(t) \\ \dots \\ \dots \\ b_{N_v-1}(t) \end{bmatrix} \quad (3-1)$$

Où $v_k(t)$ est la superposition :

- d'un nombre d'EPICs N_k^{EPICs} dépendant de k (le nombre d'EPICs dépend de la zone cérébrale observée et donc du capteur k : $e_{k,i}(t - \tau_{k,i}), i \in \{0, 1, \dots, N_k^{EPICs} - 1\}$ où $\tau_{k,i}$ est l'instant d'occurrence de l'EPIC i de la voie k).
- d'une activité de fond $b_k(t)$ qui sépare les activités épileptiformes et dont le contenu fréquentiel dépend de la position du capteur à l'intérieur du cerveau, de la proximité temporelle des crises et de l'état de vigilance du patient (concentré, assoupi, endormi

profondément, etc.). Ce signal d'amplitude homogène représente le « rythme » (*voir la partie 1.5.1 du document*). On considère que le bruit de mesure est inclus dans cette activité.

L'objectif est de détecter dans chaque signal $v_k(t)$ les N_k^{EPICs} (différents pour chaque voie k) EPICs $e_{k,i}(t)$ en calculant les estimées de leurs instants d'occurrence $\hat{t}_{k,i}$. En plus, on va estimer pour chaque EPIC $e_{k,i}(t)$ identifié, son amplitude maximale $\hat{a}_{k,i}^{MAX}$ de sa phase pointue et la durée de la phase pointue $\hat{\delta}t_{k,i}^{Pte}$.

3.3. La détection basée sur l'algorithme de Page Hinkley

La prise de décision est assurée par la méthode des sommes cumulées dite CUSUM (pour Cumulative Sum) initialement proposé par Page [94]. Elle a été approfondie par Hinkley quinze ans plus tard [95], ce qui lui vaut aussi le nom d'algorithme de Page-Hinkley. Il s'agit d'un algorithme récursif basé sur la fonction de vraisemblance. Cet algorithme est optimal pour la détection d'un changement brusque, comme un saut de moyenne, dans un bruit blanc.

3.3.1. Approche théorique

On considère un vecteur $\varepsilon(t), t \in \{0, \dots, N-1\}$, dont les N échantillons sont des variables aléatoires gaussiennes centrées indépendantes, et un vecteur d'observation $w(t)$ avec $t \in \{0, \dots, N-1\}$, pouvant prendre deux valeurs différentes selon l'hypothèse vérifiée (H_0 pour « pas de rupture dans le signal » et H_1 pour « rupture dans le signal ») [5]:

$$\begin{cases} H_0: w(t) = \mu_0 + \varepsilon(t), & t \in \{0, \dots, N-1\} \\ H_1: \begin{cases} w(t) = \mu_0 + \varepsilon(t), & t \in \{0, \dots, r-1\} \\ w(t) = \mu_1 + \varepsilon(t), & t \in \{r, \dots, N-1\} \end{cases} \end{cases} \quad (3-2)$$

Où μ_0 et μ_1 sont les valeurs moyennes du vecteur d'observation avant et après l'instant de rupture r (on s'intéresse ici au cas $\mu_1 > \mu_0$).

Le rapport de vraisemblance s'écrit :

$$\Lambda(r) = \frac{p(w|H_1)}{p(w|H_0)} \quad (3-3)$$

Puisque le vecteur d'observation w a des composantes gaussiennes, on peut écrire :

$$\Lambda(r) = \frac{\prod_{t=0}^{r-1} p(w|H_0) \cdot \prod_{t=r}^{N-1} p(w|H_1)}{\prod_{t=0}^{N-1} p(w|H_0)} = \prod_{t=r}^{N-1} \frac{p(w|H_1)}{p(w|H_0)} \quad (3-4)$$

En développant et en prenant le logarithme népérien de $\Lambda(r)$ on obtient aisément :

$$\ln(\Lambda(r)) = \frac{\mu_1 - \mu_0}{\sigma^2} \cdot \sum_{t=r}^{N-1} \left(w(t) - \frac{\mu_1 + \mu_0}{2} \right) = \frac{\nu}{\sigma^2} \cdot S_r^{N-1}(\mu_0, \nu) \quad (3-5)$$

$$\text{Avec } \begin{cases} S_r^{N-1}(\mu_0, \nu) = \sum_{t=r}^{N-1} \left(w(t) - \mu_0 - \frac{\nu}{2} \right) \\ \nu = \mu_1 - \mu_0 \end{cases}$$

L'instant de rupture r étant inconnu, nous allons maximiser le rapport de vraisemblance pour estimer sa valeur (estimateur du maximum de vraisemblance) :

$$\hat{r}_{MV} = \arg \max_{1 \leq r \leq N-1} [S_r^{N-1}(\mu_0, \nu)] \quad (3-6)$$

En fixant un seuil de détection S , la règle de décision s'écrit :

$$\ln(\Lambda(\hat{r}_V)) = \max_{1 \leq r \leq N-1} [S_r^{N-1}(\mu_0, \nu)]_{H_1 > S}^{H_0 \leq S} \quad (3-7)$$

En fin, on remarque que :

$$S_r^{N-1}(\mu_0, \nu) = S_0^{N-1}(\mu_0, \nu) - S_0^{r-1}(\mu_0, \nu) \quad (3-8)$$

C'est pourquoi on peut réécrire la règle de décision sous la forme :

$$\ln(\Lambda(\hat{r}_{MV})) = S_0^{N-1}(\mu_0, \nu) - \min_{1 \leq r \leq N-1} [S_0^{r-1}(\mu_0, \nu)]_{H_1 > S}^{H_0 \leq S} \quad (3-9)$$

L'élément $S_0^{N-1}(\mu_0, \nu) = \sum_{t=0}^{N-1} \left(w(t) - \mu_0 - \frac{\nu}{2} \right)$ est appelé somme cumulée, d'où le nom « CuSum ». Pour simplifier les notations, on le désigne simplement par $Cusum_0^{N-1}$.

3.3.2. Principe de Page Hinkley

Dans notre cas, il faut détecter plusieurs ruptures de type $\mu_1 > \mu_0$ dans le signal EEG : nous devons donc adapter la méthode comme la propose [18]. Il introduit pour cela un temps de gel G après chaque détection, afin de réapprendre correctement la valeur moyenne μ_0 de l'activité de fond suivant un EPIC. Le principe de fonctionnement de l'algorithme de Page Hinkley séquentiel est résumé de la manière suivante :

- 1) On estime μ_0 sur une 1^{ère} fenêtre de durée h qui se déplace d'un échantillon à chaque pas.
- 2) A chaque pas, la durée d de la 2^{ème} fenêtre augmente d'un échantillon, tant qu'il n'y pas de

$$\text{détection, on génère } \begin{cases} Cusum_0^{d-1} = \sum_{t=0}^{d-1} \left(w(t) - \mu_0 - \frac{\nu}{2} \right) \\ m_{d-1} = \min_{1 \leq k \leq d-1} Cusum_0^k \end{cases} \text{ et on met à jour la valeur } \mu_0.$$

- 3) Il y a détection lorsque : $Cusum_0^{d-1} - m_{d-1} \geq S$.
- 4) On gèle l'algorithme pendant G échantillons puis on reprend à 1).

La Figure 3-1 donne les différentes étapes de l'algorithme de Page Hinkley.

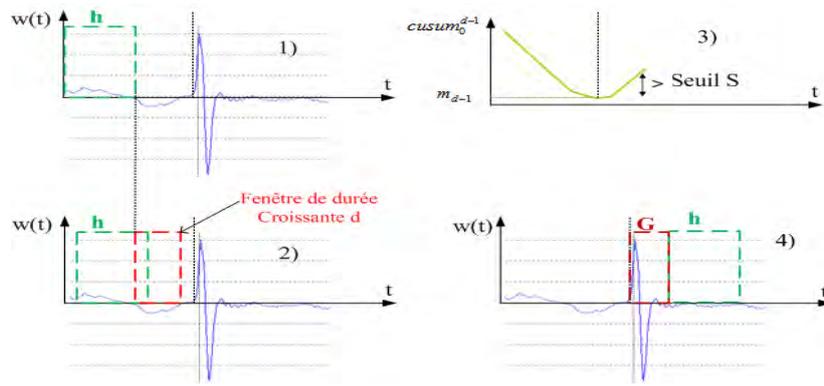


Figure 3-1 : Détection de pointes avec l'algorithme Cusum séquentiel

Par conséquent, l'algorithme 1 donne de manière brève le pseudo code de Page Hinkley.

Algorithme 1 : Algorithme de Page-Hinkley

Entrée : le signal $v(0 : n - 1)$ de n échantillons ; le saut de valeur moyenne ν ; le seuil de détection s ; l'horizon d'analyse h ; temps de gel G ;

Sortie : les nbDetect instants de ruptures InstRupt ($0 : \text{nbDetect}-1$) ;

$d = 0 ; \mu_0 = 0 ; \text{cusum} = 0 ; \text{min} = v(0) ; \text{instRupt} = 0 ; \text{nbDetect} = 0$ % initialisation %

tant que $d \leq n - h$

 detection = 0 ;

$\mu_0 = \text{moyenne}(v(d : d + h - 1))$ % estimation de μ_0 initiale %

$t+ = h ; \text{min} = v(t) ;$

tant que detection = 0 et $t \leq n - h$

$\text{cusum} += v(t) - \mu_0 - \frac{\nu}{2} ;$ % calcul de la somme cumulée %

si ($\text{cusum} < \text{min}$)

$\text{min} = \text{cusum} ; \text{instRupt} = t ;$ % mise à jour du min et de sa date %

fin si

$\mu_0- = v(t - h)/h ; \mu_0+ = v(t)/h ;$ % mise à jour de μ_0 sur l'horizon h %

si $\text{cusum} - \text{min} > s$ % \Rightarrow détection %

 detection = 1 % passage à 1 afin de sortir de la boucle tant que %

$d = \text{instRupt} + G ;$ % application d'un temps de gel à partir de l'instant de rupture %

$\text{cusum} = 0 ;$ % réinitialisation de la somme cumulée %

$\text{InstRupt}(\text{nbDtect}) = \text{instRupt} ;$ % mémorisation de l'instant de rupture %

$\text{nbDtect} += 1 ;$ % incrémentation du nombre de détection %

fin si

$t = t + 1 ;$

fin tant que

fin tant que

Certains paramètres de l'algorithme doivent être réglés selon les connaissances a priori que nous avons sur le signal observé, d'autres peuvent être directement estimés sur le signal observé :

- ✓ μ_0 : la moyenne du signal « au repos » est le plus souvent estimée sur une fenêtre de durée h ;
- ✓ h : dans notre cas, nous devons choisir une valeur inférieure à la durée séparant 2 EPICs consécutifs ;
- ✓ ν : généralement choisi comme étant égal à l'amplitude minimale de la rupture recherchée. Dans notre cas, ν peut être choisi en fonction du RSB (rapport entre l'énergie des EPICs et l'énergie de l'activité de fond). En effet, en introduisant $RSB = \frac{\mu_1}{\mu_0}$ on peut écrire $\nu = \mu_1 - \mu_0 = \mu_0(RSB - 1)$. Il faut toutefois remarquer que si on veut une valeur fixe de ν tout au long de l'exécution de l'algorithme séquentiel, il faut utiliser un estimateur de μ_0 sur toute la durée du signal d'entrée. Nous avons choisi la valeur médiane, et on obtient ainsi : $\nu = \text{médiane}(\text{signal}(t)).(RSB - 1)$. Nous pouvons fixer empiriquement la valeur du RSB mais l'utilisateur pourra la régler à sa guise pour ajuster la sensibilité et la sélectivité du détecteur.
- ✓ S : le seuil de détection. Ce paramètre permet de régler le décalage entre l'instant correspondant à un minimum local de la somme cumulée et l'instant de détection. Intuitivement ce paramètre dépend de la durée d'un palier haut du signal à traiter. Nous avons choisi de fixer S proportionnellement à ν : $S = \text{CoeffSeuilDetect}.\nu$
- ✓ G : le temps de gel.

3.4. La détection basée sur l'opérateur d'énergie non linéaire (SNEO)

3.4.1. Représentation temps-fréquence des signaux EEG

Un signal quelconque peut être représenté soit dans le domaine temporel ou fréquentiel. L'analyse fréquentielle est un outil très puissant pour comprendre certains phénomènes caractérisant le spectre des signaux. Il est aussi intéressant de voir une autre représentation spectrale des signaux. C'est ainsi qu'un troisième élément est introduit pour faire évoluer la représentation fréquentielle des signaux : c'est la représentation temps-fréquence (RTF). Elle est devenue une discipline scientifique grâce aux travaux fondamentaux de Ville et de Wigner [96] sur les représentations temps-fréquences (RTF) [97].

La RTF fait la correspondance entre une fonction à une variable (le temps t) avec une autre fonction à deux variables (le temps t et la fréquence f). Elle permet de déterminer les niveaux d'énergie du signal dans le plan temps-fréquence [98].

La classe des RTF la plus utilisée est celle de Cohen [99]. Et l'expression générique de la classe de Cohen pour un signal temporel $x(t)$ est la suivante :

$$C_x(t, f, \Pi) = \iint \Pi(u - t, \xi - f) W_x(u, f) du d\xi \quad (3-10)$$

où $W_x(u, f)$ est la Distribution de Wigner-Ville (WVD) et la fonction Π est le noyau de la représentation temps-fréquence. Et les propriétés $C_x(t, f, \Pi)$ dépendent du noyau Π .

$$W_x(u, f) = \int x\left(u + \frac{\tau}{2}\right) \cdot x^*\left(u - \frac{\tau}{2}\right) e^{-j2\pi\tau f} d\tau \quad (3-11)$$

Il y a plusieurs distributions qui appartiennent à la classe de Cohen et nous pouvons citer : le spectrogramme, la WVD la distribution de Choi- Williams... [96].

La Figure 3-2 [97] donne un exemple de représentations (temps, fréquence et RTF idéalisée) d'un signal.

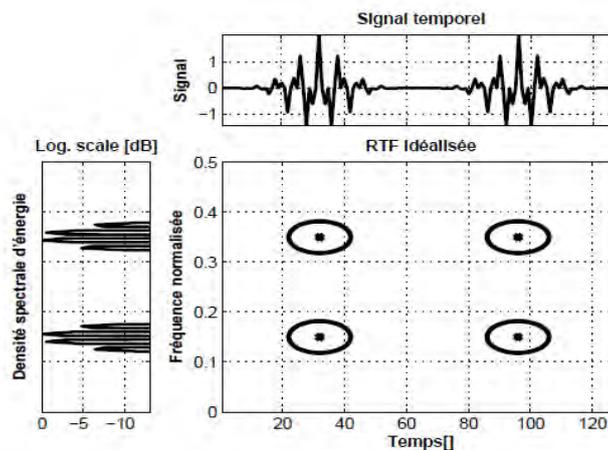


Figure 3-2 : Représentations du signal avec quatre atomes

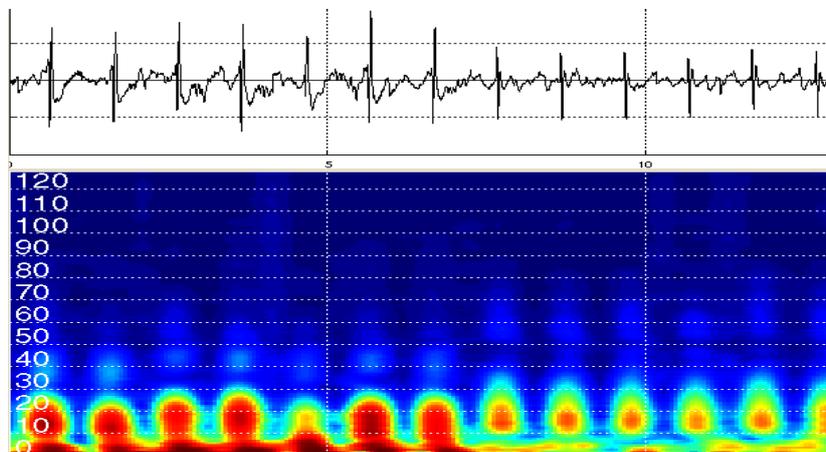


Figure 3-3 : RTF d'un signal EEG avec une distribution de pointes

Pour les signaux EEG, la présence d'une pointe dans le signal nous donne une forte concentration d'énergie. La Figure 3-3 nous donne la RTF d'un signal EEG. En analysant la structure temps-fréquence des pointes, nous remarquons que la partie pointue de l'événement est caractérisée par un spectre fréquentiel s'étendant plus ou moins de 10 à 30 Hz.

3.4.2. Opérateur d'énergie non linéaire

Teager et Kaiser sont les premiers à montrer les problèmes rencontrés sur la modélisation linéaire de la voix [97] [100]. Ils ont pu démontrer la non linéarité de la parole en se basant sur la courbe d'énergie nécessaire à la production de la parole. Ils ont encore montré que les fréquences de résonances contenues dans le conduit vocal du signal de parole peuvent varier rapidement en fréquence et en amplitude [100].

Pour trouver l'énergie qui permet de créer le signal de la parole, Kaiser a eu l'idée d'étudier deux fréquences différentes. Il considère deux signaux de fréquences respectives 10 Hz et 100 Hz. Il considère que ces deux signaux peuvent avoir la même énergie mais l'énergie fournie par le système pour créer le signal à 100 Hz est plus importante que celle de 10 Hz [102].

Pour confirmer son idée, il considère un système d'oscillateur harmonique. Dans ce système, il a montré que l'énergie nécessaire pour créer le signal oscillant est proportionnelle au carré du produit de l'amplitude et de la fréquence du signal.

Avec ce système, il a proposé un algorithme d'estimation d'énergie appelé opérateur d'énergie de Teager-Kaiser [102].

3.4.2.1. Energie d'un système masse-ressort et l'opérateur Teager-Kaiser

Dans cette partie, nous allons utiliser l'exemple d'un système formé par une masse et un ressort de raideur k pour trouver l'opérateur de Teager-Kaiser. En se basant sur le principe fondamental de la dynamique, nous obtenons l'équation différentielle suivante :

$$\frac{d^2x(t)}{dt^2} + \frac{k}{m}x(t) = 0 \quad (3-12)$$

L'équation (3-12) décrit une équation différentielle du second ordre du système masse-ressort. La valeur k est constante. Ce modèle est un oscillateur harmonique non amorti. La fonction $x(t)$ représente la position de la masse à l'instant t . La solution générale de l'équation différentielle est une fonction sinusoïdale (cosinus) donnée par la relation suivante :

$$x(t) = A \cos(\Omega t + \phi) \quad (3-13)$$

où A est l'amplitude des oscillations, $\Omega_0 = \sqrt{\frac{k}{m}}$ la pulsation propre d'oscillation (fréquence angulaire), et ϕ est la phase initiale.

L'énergie mécanique ou l'énergie totale E_x du système masse-ressort est la somme de l'énergie potentielle du ressort et de l'énergie cinétique de la masse :

$$E_x = \frac{1}{2} kx^2 + \frac{1}{2} mv^2 \quad (3-14)$$

En remplaçant la vitesse $v = dx/dt$ et la position $x(t) = A \cos(\Omega t + \phi)$ dans l'équation (3-14) nous obtenons la relation suivante :

$$E_x = \frac{1}{2} m\Omega^2 A^2 \quad (3-15)$$

$$E_x \simeq \Omega^2 A^2 \quad (3-16)$$

Ainsi, l'équation (3-16) nous montre que l'énergie totale est proportionnelle au carré de l'amplitude et de la pulsation des oscillations [104].

Nous pouvons ainsi donner la définition de l'opérateur d'énergie [97] comme suit :

L'opérateur d'énergie de Teager-Kaiser (TKEO) $\Psi_{\mathbb{R}}[x(t)]$ d'un signal $x(t)$ à valeurs réelles est défini dans le domaine continu par :

$$\Psi_{\mathbb{R}}[x(t)] = \left(\frac{dx(t)}{dt}\right)^2 - x(t) \frac{d^2x(t)}{dt^2} \quad (3-17)$$

En réécrivant l'équation (3-17) nous obtenons la relation suivante :

$$\Psi_{\mathbb{R}}(x) = \dot{x}^2 - x\ddot{x} \quad (3-18)$$

avec $x \equiv x(t)$, $\dot{x} \equiv dx(t)/dt$ et $\ddot{x} \equiv d^2x(t)/dt^2$ et en considérant la variable indépendante t comme implicite.

L'opérateur TKEO associé au mouvement de l'oscillateur harmonique est alors :

$$\begin{aligned} \Psi_{\mathbb{R}}[x(t)] &= (-A\omega \sin(\omega t))^2 - A \cos(\omega t)(-\omega^2 A \cos(t)) \\ &= A^2 \omega^2 (\sin^2(\omega t) + \cos^2(\omega t)) \\ &= A^2 \omega^2 \end{aligned}$$

L'énergie de l'oscillateur harmonique peut donc s'écrire :

$$\underbrace{E_x}_{\text{Energie du processus}} = \underbrace{\frac{1}{2} m}_{\text{coefficient de proportionnalité}} \cdot \underbrace{\Psi_{\mathbb{R}}[x(t)]}_{\text{Opérateur d'énergie de Teager-Kaiser}} \quad (3-19)$$

La Figure 3-4 [97] donne l'opérateur d'énergie de Teager-Kaiser dépiste l'énergie fournie par la source sinusoïdale qui engendre le signal $x(t)$.

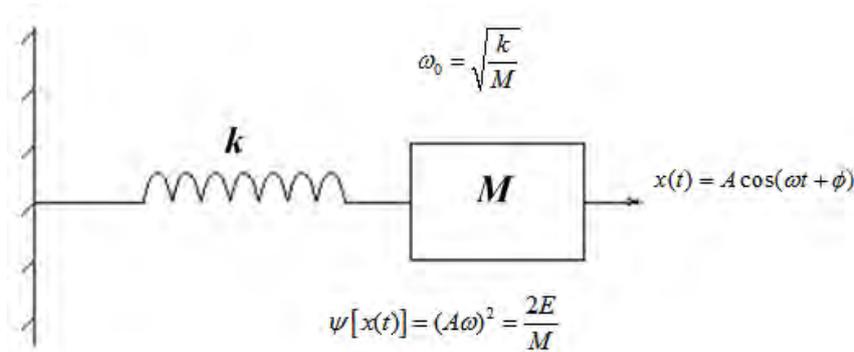


Figure 3-4 : L'opérateur d'énergie de Teager-Kaiser

L'opérateur TKEO aussi appelé opérateur *NEO* (*Nonlinear Energy Operator*) permet de décrire les propriétés locales d'un signal réel $x(t)$, de même grandeur qu'une énergie. Cet opérateur est en fonction du signal et de ses dérivées premières et secondes [104]. Une mise en forme informatique ne pose pas de problème puisque son expression est peu complexe. Enfin, il possède naturellement une très bonne résolution temporelle.

3.4.2.2. Algorithme de Teager-Kaiser

Nous intéressons dans cette section au signal discret de l'oscillateur harmonique. Considérons x_n les échantillons du signal $x(t)$ représentant le mouvement de l'oscillateur. La solution peut s'écrire sous la forme suivante :

$$x_n = A \cos(\Omega n + \phi) \quad (3-20)$$

Où $\Omega = 2\pi f/F_e$ est la pulsation numérique, f la fréquence du signal et F_e la fréquence d'échantillonnage. Nous supposons que l'échantillonnage est régulier. Dans l'équation 3.20, nous avons trois inconnues ou paramètres (A, Ω, ϕ). Pour résoudre l'équation, nous avons besoin de trois échantillons du signal. Prenons les échantillons suivants : x_{n-1} , x_n et x_{n+1} :

En appliquant les relations trigonométriques suivantes, nous avons :

$$\cos(\alpha + \beta) \cos(\alpha - \beta) = \frac{1}{2} [\cos(2\alpha) + \cos(2\beta)] \quad (3-21)$$

$$\cos(2\alpha) = 1 - 2\sin^2(\alpha) \quad (3-22)$$

Nous obtenons :

$$x_{n+1}x_{n-1} = A^2 \cos[(n+1)\Omega + \phi] \cos[(n-1)\Omega + \phi] \quad (3-23)$$

$$x_{n+1}x_{n-1} = x_n^2 - A^2 \sin^2(\Omega) \quad (3-24)$$

Finalement nous avons :

$$A^2 \sin^2(\Omega) = x_n^2 - x_{n+1}x_{n-1} \quad (3-25)$$

Ainsi $\sin \Omega \approx \Omega$ pour des faibles valeurs de Ω . Si nous considérons $\Omega < \pi/4 = 0.7854$, c'est-à-dire $f/F_e < 1/8$, l'erreur commise en approximant $\sin \Omega$ par Ω est de $\frac{\Omega}{\sin \Omega} = \frac{\pi/4}{\sqrt{2}/2} \approx 11\%$ et ce qui permet de réécrire l'équation (3-25) :

$$A^2 \Omega^2 \approx x_n^2 - x_{n+1}x_{n-1} \quad (3-26)$$

L'équation 3.26 donne une mesure de l'énergie du signal $x(t)$ dont la fréquence d'échantillonnage est telle que $F_e > 8f$. Donc pour bien échantillonner le signal, la fréquence F_e doit être au moins égale à 8 fois la fréquence maximale du signal. Ainsi, la relation 3.27 est vue comme un algorithme de calcul de l'énergie d'un signal mono-composante :

$$E_n = x_n^2 - x_{n+1}x_{n-1} = A^2 \sin^2(\Omega) \approx A^2 \Omega^2 \quad (3-27)$$

où E_n est la sortie de l'algorithme et x_n est le signal à traiter. Nous constatons que l'équation (3-27) est indépendante de la phase initiale de l'oscillation. En plus pour cet algorithme, le changement de x_n en x_{-n} ou de n en $-n$ ne change pas la valeur de l'énergie du signal.

Par conséquent, l'opérateur discret de Teager – Kaiser $\psi_{\mathbb{R}}[x(n)]$ s'écrit sous la forme :

$$\psi_{\mathbb{R}}[x(n)] = x^2(n) - x(n-1)x(n+1) \quad (3-28)$$

Par ailleurs, la détection d'EPICs utilisant l'opérateur d'énergie non linéaire de Teager – Kaiser est toujours accompagnée du filtrage dans le domaine temporel.

3.4.3. Filtrage temporel

Le filtrage est un outil essentiel dans le domaine du traitement du signal. Il peut être utilisé dans plusieurs contextes applicatifs. Il est souvent utilisé dans le domaine fréquentiel pour atténuer, séparer ou extraire des fréquences dans une bande.

Dans le domaine temporel, le signal de sortie $s(t)$ (Figure 3-5) est le produit de convolution du signal d'entrée $e(t)$ et la réponse impulsionnelle du filtre $g_{\text{fen}}(t)$ [105] :

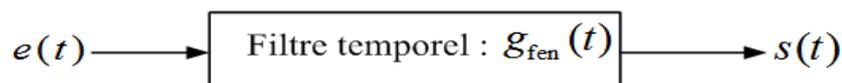
$$s(t) = g_{\text{fen}}(t) * e(t) \quad (3-29)$$


Figure 3-5 : Système de filtrage temporel

De nombreuses études ont été réalisées afin d'obtenir des fenêtres temporelles $g_{\text{fen}}(t)$ minimisant la déformation (*Smoothing Windows*), c'est-à-dire possédant un spectre plus proche des caractéristiques souhaitées. Ainsi, la première fenêtre utilisée a été la fenêtre « triangulaire » ou fenêtre de Bartlett qui a pour équation :

$$g_{\text{fen}}(t) = \begin{cases} \Lambda_{\tau}(t) & \text{pour } |t| \leq \frac{\tau}{2} \\ 0 & \text{pour } |t| > \frac{\tau}{2} \end{cases} \quad (3-30)$$

Avec :

$$\Lambda_{\tau}(t) = \begin{cases} 1 - |t| & \text{pour } |t| \leq 1 \\ 0 & \text{pour } |t| > 0 \end{cases} \quad (3-31)$$

Le spectre de cette fenêtre est obtenu à l'aide du produit de convolution entre deux signaux « portes » ou rectangulaires identiques.

$$\Lambda_{\tau}(t) = \frac{2}{\tau} [\Pi_{\tau/2}(t) * \Pi_{\tau/2}(t)] \quad (3-32)$$

La fonction « porte » est définie par :

$$\Pi_{\tau}(t) = \begin{cases} 1 & \text{pour } |t| \leq \frac{\tau}{2} \\ 0 & \text{pour } |t| > \frac{\tau}{2} \end{cases} \quad (3-33)$$

La transformée de Fourier de la fonction $\Lambda_{\tau}(t)$ est donnée par :

$$\Lambda_{\tau}(t) \xrightarrow{F} \frac{\tau}{2} \left[\frac{\sin(\pi(\tau/2)f)}{\pi(\tau/2)f} \right]^2 \quad (3-34)$$

D'autres fenêtres plus complexes dans leurs expressions mathématiques et surtout dans le calcul du spectre sont utilisées en fonction de leurs caractéristiques [105]. Mais dans cette partie nous nous intéressons uniquement à la fenêtre triangulaire (**fenêtre de Bartlett**).

3.4.4. Détection adaptative des EPICs par la méthode SNEO

Dans cette partie, nous utilisons l'opérateur discret de Teager – Kaiser $\psi_{\mathbb{R}}[x(n)]$ (équation 3.28) ou NEO pour mesurer les instances d'énergie du signal. Ainsi l'opérateur peut détecter des changements pour des amplitudes instantanées (A) ou des fréquences instantanées (Ω) d'un signal (équation 3-26). C'est un analyseur temps-fréquence qui peut considérer simultanément l'amplitude et la fréquence des informations instantanées du signal d'entrée.

Par conséquent NEO est utilisé pour amplifier les activités dans un signal. Cependant NEO est sensible aux bruits et a un problème de la croissance des termes de l'opérateur [106]. La méthode SNEO (Smoothed Nonlinear Energy Operator) [107] a été proposée pour détecter des EPICs dans les signaux EEG en faisant le produit de convolution de $\psi_{\mathbb{R}}[x(n)]$ avec une fenêtre de domaine temporel (équation (3-35)).

$$\psi_S[x(n)] = w(n) * \psi_{\mathbb{R}}[x(n)] \quad (3-35)$$

Où * représente le produit de convolution et $w(n)$ la fenêtre de lissage. Le choix du type de fenêtre et de sa largeur est très important pour réaliser la réduction suffisante d'interférences sans beaucoup perdre sa résolution temporelle qui est très utile pour la détection des pointes. Dans l'ordre de réaliser ce but, la fonction de la fenêtre de Bartlett avec l'implémentation d'un filtre numérique ont été sélectionnées pour surmonter la complexité de l'algorithme dans la mesure du possible.

Avec une fenêtre de largeur L , l'équation 3-35 devient alors :

$$\psi_S[x(n)] = \sum_{k=0}^{L-1} w(k)\psi_{\mathbb{R}}[x(n-k)] \quad (3-36)$$

La Figure 3-6 donne les étapes de la détection de pointes basée sur le SNEO avec un bloc adaptatif pour le seuil de détection [108].

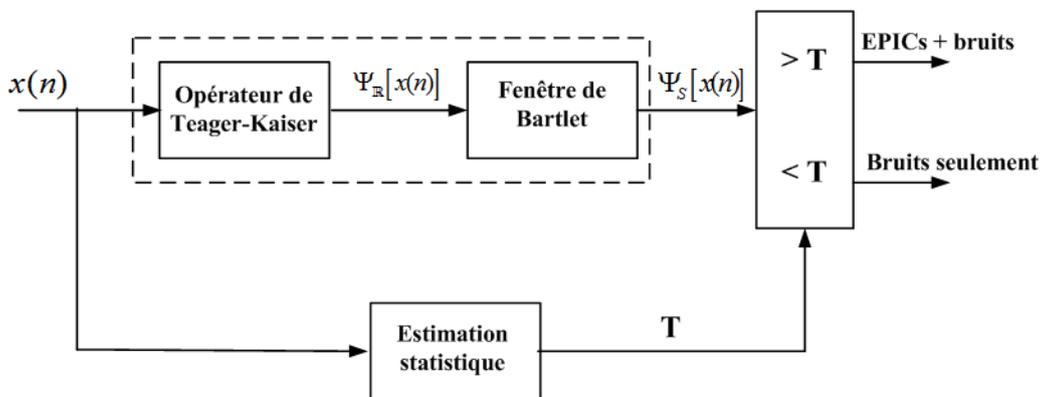


Figure 3-6 : Détection adaptative des EPICs avec le SNEO

L'objectif principal du détecteur est de décider s'il y a présence d'une pointe dans le bruit du fond (activité de fond) ou s'il y a du bruit seulement. Les valeurs de $\psi_S[x(n)]$ sont continuellement comparées à un seuil T . Par rapport à l'étape de la décision, une pointe est présente si $\psi_S[x(n)] > T$, sinon le signal est considéré contenir uniquement du bruit. Le seuil est le point focal à la détection adaptative. Seule la densité de probabilité sous l'hypothèse nulle et la probabilité de fausse alarme (P_{fa}) sont nécessaires. Comme l'opérateur Teager-Kaiser est non linéaire, la densité de probabilité ne peut pas être évaluée de manière ferme.

En statistique, plusieurs approches ont été proposées pour contourner cette limitation. Cependant, conformément à la nécessité de simplicité, une approche paramétrique est adoptée.

Ainsi, comme le bruit est un processus aléatoire, la sortie du diagramme (Figure 3-6) est aussi un processus aléatoire ayant comme valeur moyenne μ et écart-type σ (équation 2-5). Le seuil peut donc être estimé par l'équation suivante :

$$T = \mu + p\sigma \quad (3-37)$$

Où T est le seuil de détection adaptatif pour déterminer la présence d'une pointe et le multiplicateur p dépend de P_{fa} [107]. En pratique, les paramètres p et P_{fa} sont définis par l'utilisateur. En effet dans un algorithme typiquement de détection de pointes, en prenant une valeur faible de p , P_{fa} et la probabilité de détection P_d augmente en même temps, par contre, en choisissant une grande valeur, les deux vont diminuer aussi.

La valeur moyenne est déterminée par l'équation 3-38 :

$$\mu = \frac{1}{N} \sum_{n=1}^N \psi_s[x(n)] \quad (3-38)$$

Où N est le nombre d'échantillons.

3.5. Détection de pointes basée sur la dimension fractale

3.5.1. Généralité sur la fractale et la dimension fractale

Il existe derrière la géométrie fractale une curiosité depuis longtemps et une théorie mathématique depuis peu, qui sont des outils précieux pour analyser, comprendre et même prévoir divers phénomènes naturels ou industriels.

Ainsi la dimension fractale est le complément qui manquait à la dimension euclidienne et à la symétrie cristalline. Comme l'a fait remarquer Mandelbrot [109], les nuages ne sont pas des sphères, ni les montages des cônes, ni les îles des cercles et leur description nécessite une géométrisation adaptée [110].

3.5.1.1. Origine et concept de la fractale

Depuis très longtemps, l'homme a été fasciné par les formes géométriques particulières qu'il observa dans la nature et qu'il créa pour décorer ses habitations, ses vêtements, ou encore ses lieux de culte. Au XIX^{ème} siècle, elles sont considérées comme des « curiosités » mathématiques jusqu'au milieu du XX^{ème} siècle. Elles n'acquièrent un statut à part entière que dans les années 1970, grâce au mathématicien franco-américain, *Benoît Mandelbrot* (1924-2010), qui en fait l'objet d'une nouvelle discipline mathématique : la géométrie fractale, rendue populaire par son ouvrage « *les objets fractals : forme, hasard et dimension* » [109].

Par ailleurs, les objets fractals peuvent se définir comme des structures obtenues par l'itération d'un algorithme géométrique sur une figure géométrique particulière appelée **initiateur** qui constitue le rang **0**. L'initiateur est donc la figure sur laquelle on effectue la toute première modification permettant de commencer le tracé. Cette modification géométrique que l'on effectue sur la figure de rang **n** pour obtenir la figure suivante de rang

n+1 nommée **générateur**. Nous appliquons à l'infini les transformations choisies à l'objet de départ (Figure 3-7) [110].

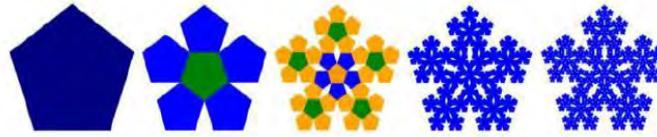


Figure 3-7 : Illustration des cinq premières étapes de la construction du pentagone de Durer

Le mathématicien suédois Niels Fabian Helge Von Koch (1870-1924) fait partie des premiers à travailler sur les fractales. Les travaux de Von Koch ont contribué à l'étude des fractales. La construction des fractales est simple. C'est une courbe composée de segments identiques de même longueur et dont la longueur totale peut tendre vers l'infini. Elle est obtenue par itération à partir d'un segment de longueur « a ». Nous devons premièrement prendre un objet initiateur, une ligne par exemple.

Puis on l'itère avec un générateur qui transformera l'initiateur. Le générateur pour la courbe de Von Koch peut s'expliquer de cette façon : pour chaque initiateur (ligne) il faut retirer le deuxième tiers de la ligne et mettre à la place deux lignes de la même longueur que l'on a retirée, puis les placer pour former un angle. Cette dernière étape s'appelle itération et sa répétition produit la courbe de Von Koch. Dans la représentation de la Figure 3-8, on peut voir l'évolution de cette courbe, elle est construite depuis l'initiateur $n = 0$ jusqu'à la cinquième itération $n = 5$ [110].

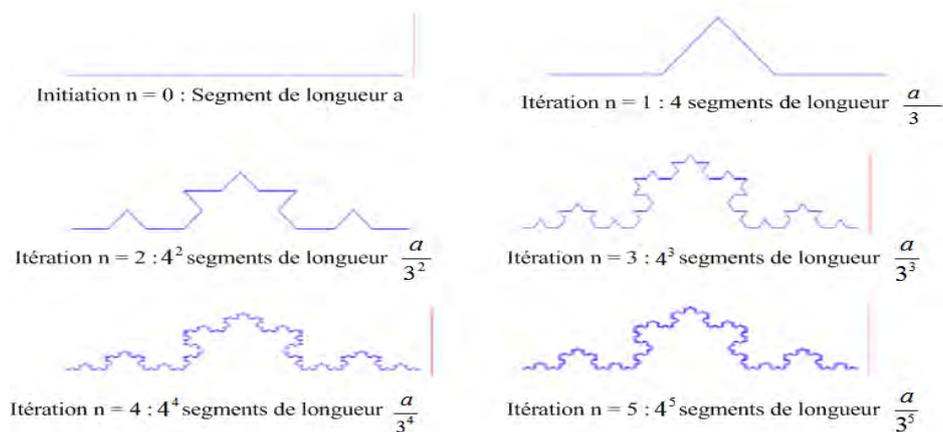


Figure 3-8 : Principe de la construction de la courbe de Von Koch

3.5.1.2. La dimension fractale

La dimension fractale (FD) est une mesure physique qui donne une idée sur la complexité géométrique du signal. Une ligne par exemple c'est un objet 1D, un carré c'est un objet 2D.

La dimension d'une série temporelle se situe quelque part entre 1 et 2 ; elle est plus compliquée qu'une simple ligne et n'arrive jamais à couvrir la dimension d'un carré.

Ainsi, FD est une mesure dynamique non linéaire des séries temporelles et est récemment devenue populaire dans l'analyse des signaux biomédicaux tels que l'EEG [111]. Si l'amplitude et la fréquence d'un signal changent, la dimension de FD changera (Figure 3-9) [48].

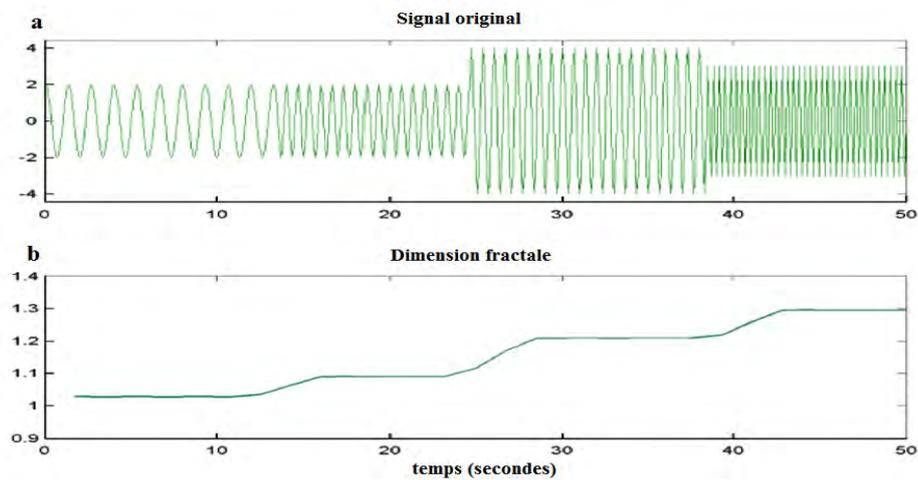


Figure 3-9 : Variation de dimension fractale quand l'amplitude ou la fréquence change

Le signal synthétique utilisé ici comprend quatre segments, le premier et le second segment ont la même amplitude ; la fréquence de la première partie est toutefois différente de celle de la seconde partie. Dans le troisième segment, l'amplitude est différente de celle du second segment. L'amplitude et la fréquence dans le quatrième segment sont différentes de celles du troisième segment. Dans ce cas, nous constatons que si deux époques adjacentes d'un signal ont des amplitudes et / ou des fréquences différentes, la FD varie.

3.5.2. Algorithmes de calcul de la dimension fractale

Il y a plusieurs méthodes pour calculer la FD d'un signal tel que les méthodes de Higuchi, Petrosian, Katz etc. Étant donné que la FD est estimée directement à partir du signal variant dans le temps, il a un faible coût de calcul. Les algorithmes les plus utilisés dans la littérature sont présentés dans cette partie.

3.5.2.1. Algorithme de Higuchi

On considère $x(1), x(2), \dots, x(N)$ la séquence chronologique qui doit être analysée. Nous construisons de nouvelles séries chronologiques x_m^k comme suit :

$$x_m^k = \left\{ x(m), x(m+k), x(m+2k), \dots, x\left(m + \left\lfloor \frac{N-m}{k} \right\rfloor k\right) \right\} \quad (3-39)$$

Pour $m = 1, 2, \dots, k$. Les nombres m et k indiquent respectivement la valeur initialement temporelle et l'intervalle de temps discret entre les points (délais), et l'opérateur $[a]$ désigne la partie entière de a . Pour chacune des courbes des séries chronologiques construites, la longueur moyenne $L_m(k)$ est calculée par :

$$L_m(k) = \frac{\sum_{i=1}^{\lfloor (N-m)/k \rfloor * k} |x(m+ik) - x(m+(i-1)k)| (n-1)}{\lfloor \frac{N-m}{k} \rfloor k} \quad (3-40)$$

Où N est la longueur totale de la séquence de données x et $\lfloor (N-m)/k \rfloor$ est un facteur de normalisation. Une longueur moyenne est calculée pour toutes les séries chronologiques ayant le même délai k , comme la moyenne des longueurs k $L_m(k)$ pour $m = 1, 2, \dots, k$. Cette procédure est répétée pour chaque k compris entre 1 à k_{max} , une somme de longueurs moyennes $L(k)$ pour chaque k est donnée par l'équation suivante :

$$L(k) = \sum_{m=1}^k L_m(k) \quad (3-41)$$

La longueur totale moyenne pour l'échelle k , $L(k)$, est proportionnelle k^{-D} , où $D = \frac{\ln(L(k))}{\ln(1/k)}$ est la dimension fractale par la méthode de Higuchi [112], le meilleur ajustement de la pente des moindres carrés est l'estimation de la dimension fractale.

3.5.2.2. Algorithmes de Petrosian

Petrosian utilise une estimation rapide de la dimension fractale. Cependant, cette estimation est vraiment la FD d'une séquence binaire. Plusieurs variantes de l'algorithme existent et ils sont notés par des lettres A , B , C et D [113]. Ces algorithmes se distinguent principalement par la façon dont la séquence binaire est créée. La méthode A génère la séquence binaire en attribuant des « 1 » lorsque la valeur de la forme d'onde est supérieure à la moyenne des données de la fenêtre en cours d'exécution, et « 0 » lorsqu'elle est inférieure à la moyenne. Dans la méthode B , la séquence binaire est formée en attribuant une valeur « 1 » à chaque fois que la forme d'onde est en dehors de la bande du moyen, plus et moins l'écart-type, et en attribuant « 0 » pour le cas contraire. La Méthode C construit la séquence binaire en soustrayant des échantillons consécutifs sur l'enregistrement du signal. A partir de cette séquence de soustractions, la séquence binaire est créée par l'attribution +1 ou -1 selon que le résultat de la soustraction est positif ou négatif, respectivement. Dans la méthode D , les différences entre des valeurs de forme d'onde consécutives reçoivent la valeur « 1 » ou « 0 », selon que la différence dépasse ou non l'écart-type du signal.

Une variante de cette méthode consiste à utiliser à priori un seuil d'amplitude choisi qui est différent de l'écart-type, est désigné comme la méthode de Petrosian. La FD de l'une des séquences binaires précédentes est alors calculée par :

$$D = \frac{\log_{10} n}{\log_{10} n + \log_{10} \left(\frac{n}{n + 0.4N_{\Delta}} \right)} \quad (3-42)$$

Où n est la longueur de la séquence (nombre de points), et N_{Δ} est le nombre de changements de signe dans la séquence binaire générée.

3.5.2.3. Algorithme de Katz

Contrairement à la méthode de Petrosian, le calcul de la dimension fractale par l'algorithme de Katz [114] est un peu plus lent, mais elle est dérivée directement de la forme d'onde, ce qui élimine l'étape de prétraitement de la création d'une séquence binaire. La FD de la courbe peut être définie par l'équation suivante :

$$D = \frac{\log_{10}(L)}{\log_{10}(d)} \quad (3-43)$$

Où L est la longueur totale de la courbe ou la somme des distances entre les points consécutifs et d est le diamètre estimé comme la distance entre le premier point de la série chronologique et le point qui a la plus grande distance.

L'expression mathématique de d est donnée par l'équation suivante :

$$d = \max(\text{distance}(1, i)) \quad (3-44)$$

Compte tenu de la distance entre chaque point de la séquence et le premier, le point i est celui qui maximise la distance par rapport au premier point.

De ce fait, la FD compare le nombre actuel des unités qui composent une courbe avec le nombre minimal des unités nécessaires pour reproduire un motif de même étendue spatiale. La FD est calculée par cette manière dépendra des unités de mesure utilisées. Si les unités sont différentes, alors sont aussi les dimensions fractales. L'approche de Katz résout ce problème en créant une unité générale : l'étape de la moyenne ou de la distance moyenne entre les points successifs, a . En normalisant les distances dans l'équation 3-43, nous obtenons :

$$D = \frac{\log_{10}(L/a)}{\log_{10}(d/a)} \quad (3-45)$$

En définissant n comme la taille des *pas* dans la série chronologique ou le nombre des étapes de la courbe, alors $n = L/a$, l'équation 3-45 devient :

$$D = \frac{\log_{10}(n)}{\log_{10}(d/L) + \log_{10}(n)} \quad (3-46)$$

D'où, l'équation 3-46 nous donne l'approche de Katz pour calculer la dimension fractale.

Ainsi, le choix d'un algorithme dépend de la sensibilité et de la rapidité d'exécution. Dans notre cas, l'algorithme de Katz répond mieux à notre besoin puisque qu'il n'effectue pas des traitements préliminaires avant de calculer la dimension fractale.

3.5.3. Détection adaptative des EPICs par la méthode de dimension fractale

Dans cette méthode de détection de pointes, deux fenêtres glissent tout au long du signal (Figure 3-10) [48]. Pour chaque fenêtre, la FD est calculée avec l'algorithme de Katz pour trouver les pointes du signal.

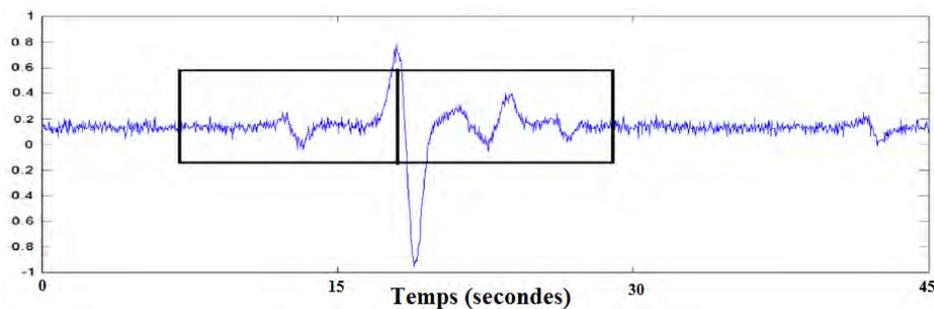


Figure 3-10 : Illustration des fenêtres glissantes tout au long du signal

Les variations de la FD sont calculées par :

$$G_t = |FD_{t+1} - FD_t| \text{ avec } t = 1, 2, \dots, L - 1 \quad (3-47)$$

Où t est la position de la fenêtre d'analyse et L est la largeur des fenêtres.

Ici le seuil est adaptatif et il est défini comme la valeur moyenne dans la distribution. Quand les maxima de G sont plus grands que le seuil, ces temps sont choisis comme les localisations des pointes dans le signal.

La Figure 3-11 donne les étapes de la détection adaptative avec la méthode de dimension fractale [29].

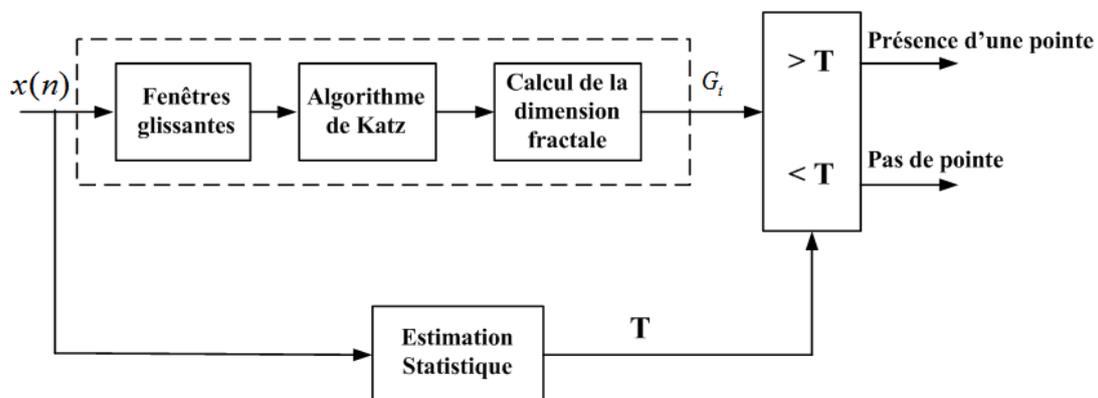


Figure 3-11 : Diagramme de détection adaptative avec la dimension fractale

Le bloc estimation statistique permet de déterminer le seuil adaptatif par rapport au signal d'entrée. Nous utilisons la même procédure d'obtention du seuil que le SNEO.

3.6. Conclusion

La détection des événements paroxystiques intercritiques dans les signaux EEG est une problématique importante dans les outils d'aide au diagnostic. C'est une thématique de recherche récurrente en épilepsie, elle constitue une voie privilégiée pour adresser la question essentielle des relations qui existent entre les EPICs et les crises. Dans ce chapitre, nous avons fait une étude brève des différentes catégories de méthodes de détection. De ce fait, nous avons proposé trois méthodes de détection. La première s'est basée sur l'algorithme de Page Hinkley qui utilise la fonction de vraisemblance pour déterminer les ruptures dans un signal EEG. L'utilisation optimale de cet algorithme nécessite l'ajustement de certains paramètres pour avoir un bon compromis entre une bonne sensibilité et une bonne sélectivité. Donc cette méthode demande une connaissance de base des signaux EEG. Fort de ce constat, nous avons proposé une méthode de calcul du seuil de détection qui dépend de la médiane du signal et du rapport signal sur bruit. Ensuite, la deuxième méthode utilise un opérateur non linéaire d'énergie avec une fenêtre glissante pour prendre une décision sur la présence ou pas d'un EPIC. Avant de prendre une décision, nous avons proposé un calcul de seuil adaptatif basé sur l'estimation statistique robuste et une comparaison est faite à la sortie de la chaîne de détection. Enfin, la dernière méthode repose sur le calcul de la dimension fractale qui utilise l'algorithme de Katz. Pour cette méthode, deux fenêtres glissantes sont utilisées afin de calculer leur FD. Le résultat obtenu est comparé à un seuil de détection adaptatif pour déterminer la localisation exacte des pointes dans la série chronologique. Le seuil adaptatif est aussi calculé par rapport à la distribution du signal d'entrée. Après la détection des pointes, il est important de passer à la classification de la morphologie des EPICs. Le chapitre 4 décrit la méthodologie utilisée pour une bonne classification.

Chapitre 4 : Classification de la morphologie des EPICs

4.1. Introduction

L'analyse des EPICs s'appuie souvent sur la densité, la topographie ou encore la morphologie. Nous nous intéressons ici à l'analyse de la morphologie des EPICs. Après les étapes de prétraitement et de détection des EPICs, il est important d'extraire la pointe et de déterminer sa morphologie grâce à la classification. Cette dernière est une étape que l'on retrouve de façon récurrente dans le domaine biomédical. En effet, les biologistes et médecins sont régulièrement amenés à établir un diagnostic, ce qui revient généralement à attribuer une classe générale y au phénomène x observé. En apprentissage statistique, on distingue deux grandes familles d'algorithmes de classification. En effet, la classification supervisée consiste à apprendre une règle de classification à partir de données préalablement annotées, c'est-à-dire auxquelles un « expert » a attribué une classe parmi un ensemble (prédéfini) de classes. La classification non-supervisée cherche à réaliser la même tâche, mais en n'ayant recours qu'à des données non-annotées, c'est-à-dire sans connaissance a priori sur l'ensemble des classes. En d'autres termes, un algorithme de classification non-supervisée n'aura que l'ensemble d'objets x en entrée. Dans cette thèse, nous nous intéressons essentiellement à la dernière classification. L'objectif à terme est de caractériser la distribution spatio-temporelle des EPICs sur toute la durée du signal et sur l'espace des capteurs tout en tenant compte de leur forme. Des éléments de réponse sur cette distribution nous permettraient de caractériser le lien encore peu connu entre la distribution spatio-temporelle des EPICs et l'arrivée des crises, apportant ainsi un complément significatif dans le diagnostic des épilepsies.

4.2. Généralités sur la classification non supervisée

Pour cette méthode de classification, les algorithmes construisent directement un ensemble d'individus en k classes. Etant donné le nombre k de classes requises, ces algorithmes génèrent des éléments initiaux, puis cherchent à l'« améliorer » en réattribuant les individus d'une classe à l'autre. La méthode classique et qui reste la plus utilisée est celle des *k-means* [115] et les nombreuses variations qui en découlent. Les classes sont représentées par leur « centroïde », qui correspond à la moyenne de l'ensemble des moyens contenus dans la classe. Dans sa version la plus classique, l'algorithme consiste à sélectionner aléatoirement k individus initiaux qui représentent les centroïdes initiaux. Un individu est assigné au cluster pour lequel la distance entre l'individu et le centroïde est minimale. Les centroïdes sont alors

recalculés et l'on passe à l'itération suivante. La fonction « objectif » traditionnellement utilisée est :

$$F = \sum_{i=1}^k \sum_{x \in C_i} d(x, m_i) \quad (4-1)$$

Où m_i représentent les centroïdes courants et x l'objet à classifier.

Il existe plusieurs méthodes de calcul de distance et nous pouvons citer :

- La distance « city block », ou encore distance de Manhattan :

$$d_{CB}(x_1(k), x_2(k)) = \sum_{k=1}^N |x_1(k) - x_2(k)| \quad (4-2)$$

- La distance euclidienne :

$$d_{EU}(x_1(k), x_2(k)) = \sqrt{\sum_{k=1}^N (x_1(k) - x_2(k))^2} \quad (4-3)$$

- La distance square Euclidean :

$$d_{SEU}(x_1(k), x_2(k)) = \sum_{k=1}^N (x_1(k) - x_2(k))^2 \quad (4-4)$$

4.2.1. Les méthodes k-means

Les méthodes des k-means sont très utilisées dans la classification non supervisée des éléments. Elles permettent de grouper un ensemble de n individus en k centres appelés centres de gravité : ce sont les classes. Les différentes classes n'ont pas besoin d'être définies à priori. La distance entre les éléments à classifier doit être minimisée :

$$\min \left(\sum_{r=1}^k \sum_{x_i \in C_r} (x_i - g_r)^2 \right) \quad (4-5)$$

Où C_r , x_i et g_r représentent respectivement la classe numéro r , individus dans une classe et le centre de classe C_r . L'algorithme des k-means s'effectue ainsi de manière générale :

-
- (1) On Choisit aléatoirement k individus dits centres des classes. Ils représentent les centres initiaux. Ils sont aussi provisoires.
 - (2) Chaque individu est affecté à une seule classe avec le centre le plus proche.
 - (3) On calcule le centre de gravité des différentes classes. C'est une mise à jour pour obtenir de nouveaux centres.
 - (4) Enfin, on répète les étapes (2) et (3) jusqu'à la stabilité des centres
-

Il existe plusieurs méthodes utilisant l'algorithme des k-means, nous pouvons citer : la méthode des centres mobiles et la méthode des nuées dynamiques.

4.2.1.1. Méthode des centres mobiles

La méthode des centres mobiles s'appuie sur la construction en k centres tirés au hasard de l'ensemble d'individus. Chaque individu de l'ensemble doit être affecté à un centre le plus proche. Après le calcul des centres de gravités, de nouveaux centres sont obtenus.

L'auteur de cette méthode est Forgy en 1965 [116]. L'algorithme des centres mobiles est utilisé lorsqu'on connaît le nombre de classe a priori. Les étapes de cet algorithme sont :

-
- (1) On tire au hasard k individus. Ils représentent les centres des classes initiales.
 - (2) On répartit tous les individus en k classes $\{C_1, \dots, C_k\}$. Chaque individu est affecté au centre le plus proche.
 - (3) On détermine les centres de gravité des différentes classes pour obtenir de nouveaux centres.
 - (4) On doit répéter les étapes (2) et (3) jusqu'à la stabilisation de l'algorithme c'est-à-dire, si on a deux itérations successives qui donnent le même résultat.
-

L'inconvénient de cette méthode est que la sortie de l'algorithme dépend fortement à l'initialisation des centres. On observe toujours une différence entre les résultats de deux exécutions.

L'autre méthode utilisant aussi les K-means est celle des nuées dynamiques.

4.2.1.2. Méthode des nuées dynamiques

Pour la méthode des nuées dynamiques, on doit aussi rechercher un sous-ensemble en k (k fixé) classes d'un ensemble de n individus.

Nous présentons ici le principe général des algorithmes des nuées dynamiques tel qu'il a été déterminé par [117] et [118].

On considère une population d'individus I . Elle est représentable sur \mathbb{R} et forme un nuage de n points. L'idée est de constituer un sous-ensemble en k classes sur I . Pour une classe donnée, elle est toujours représentée par son centre, appelé noyau.

Pour cet algorithme, on s'appuie sur deux fonctions de base définies de la manière suivante :

- Une application f est définie pour représenter l'ensemble des classes d'un sous-ensemble dans un ensemble de représentation ;
- Une autre application g qui a une famille d'individus de l'ensemble de représentation, associe un sous-ensemble.

Si $C = \{C_1, C_2, \dots, C_k\}$ est un ensemble des classes, l'application f va associer cet ensemble à un ensemble de noyau $N = \{N_1, N_2, \dots, N_k\}$ par la relation $f(C) = N$ et N_j noyau de C_j .

De la même manière, pour une famille de noyau $N = \{N_1, N_2, \dots, N_k\}$, l'application g associe à cette famille à un sous-ensemble C par $C = g(N)$, où C_j est la classe associée à N_j .

Enfin, l'équation (4-6) donne un critère qui permet de mesurer l'adéquation d'une famille de noyaux à un sous-ensemble :

$$H(C, N) = \sum_{j=1}^k h(C_j, N_j) \quad (4-6)$$

Les fonctions H, g, h ne sont pas définis indépendamment :

- Pour C donné, f associe la famille de noyaux N qui minimise H .
- Pour N donné, g associe le sous-ensemble C qui minimise H .

Comme les centres mobiles, cet algorithme donne aussi des résultats différents pour deux exécutions. Le plus souvent, on prend les résultats les plus stables.

En connaissant le nombre k de classes, l'algorithme est donné ainsi [118] :

i le nombre maximum d'itérations désiré

$j = 1$ Début

- (1) Donner une famille de noyau N_0
- (2) Déduire par g une famille de classe C_0 (un sous-ensemble)
- (3) Calculer la valeur de $H(C_0, N_0)$
- (4) A l'aide de h déterminer une nouvelle famille de noyaux N_1 telle que :

$$H(C_0, N_1) \leq H(C_0, N_0)$$

- (5) Calculer $g(N_1) = C_1$ tel que :

$$H(C_1, N_1) \leq H(C_0, N_1)$$

$j = j+1$

Jusqu'à $j = i$

FIN

L'algorithme de k -means présente plusieurs avantages et nous pouvons citer :

- Grande simplicité ;
- La complexité algorithmique est en $O(nt)$ où t est le nombre d'itération, avec $t \ll n$ habituellement ;
- Interprétation facile des classes. Elles sont naturellement représentées par les centres ou centroïdes.

Cependant, pour les inconvénients, nous pouvons aussi citer :

- Définition de la moyenne entre les données ;
- Le calcul des moyennes est très sensible aux données aberrantes ;
- Détermination à priori du nombre de clusters k ;
- Le résultat de la classification est très dépendant du choix des centroïdes initiaux.

Par ailleurs, les méthodes des k-means sont très sensibles face aux données aberrantes. Pour résoudre ce problème, un autre type d'algorithme a été développé, à savoir les *k-médoïdes*. Contrairement aux k-means, chaque classe des méthodes *k-médoïdes* est représentée par un de ses membres appelé *médoïde*. Après un tirage aléatoire de *k-médoïdes*, initiaux, l'algorithme doit déterminer tous les couples d'individus tels que l'un est un médoïde et l'autre un non-médoïde. Il fait l'évaluation sur l'échange des deux objets. L'échange qui minimise toujours la distance entre les deux objets est déterminé. Une nouvelle itération doit être faite. Enfin, chaque individu est affecté à la classe du médoïde le plus proche.

4.2.2. Les méthodes de k-médoïdes

Les méthodes des k-médoïdes permettent de choisir un individu de l'ensemble comme centre appelé médoïde. Ce dernier doit être l'élément du groupe qui possède la distance moyenne la plus faible avec les autres individus de l'ensemble.

Nous allons présenter quelques méthodes basées sur les k-médoïdes.

4.2.2.1. La méthode PAM

La méthode PAM (Partition Around Medoids) est définie en prenant dans chaque classe un élément qui va représenter le médoïde. On choisit d'abord un ensemble de médoïdes, on affecte chaque individu au médoïde le plus proche et enfin de manière itérative, on remplace chaque médoïde par un autre si cela permet de réduire la distance.

L'algorithme de la méthode PAM est représenté comme suit avec un nombre k de classes [118] :

-
- (1) On sélectionne aléatoirement k représentants M_1, M_2, \dots, M_K
 - (2) On Calcule le coût global CG_{ih} d'une permutation pour chaque paire (M_i, O_h) où M_i est le représentant d'une classe et O_h un autre objet ($CG_{ih} = \sum_j (dist(i, h) - dist(i, j))$) c'est le gain en distance globale que l'on va avoir en remplaçant h par i)
 - (3) On sélectionne la paire (M_i, O_h) pour laquelle CG_{ih} est minimal
 - (4) Si le coût différentiel CG_{ih} pour la paire sélectionnée est négatif, alors on échange les rôles de M_i et O_h et on retourne en (2)
 - (5) Retourner les classes correspondant aux représentants M_1, M_2, \dots, M_K
-

L'avantage de cet algorithme est sa robustesse en présence de bruit dans les données à classifier. Mais son inconvénient se trouve dans la complexité des calculs ($O[k(n - k)^2]$). Avec cette complexité, il est seulement efficace pour des données de petites tailles.

4.2.2.2. La méthode de CLARA

Pour résoudre le problème posé par la méthode PAM, Kaufman et Rousseeuw ont proposé l'algorithme de CLARA (Clustering Large Applications). Dans l'algorithme CLARA, on utilise aussi la méthode PAM pour améliorer les résultats obtenus. L'expérience montre qu'en pratique 5 échantillons, de taille $40 + 2k$ points [120], suffisent pour obtenir des résultats satisfaisants. L'algorithme se déroule ainsi pour un nombre k de classes :

Début

Pour $i = 1$ à 5

Répéter

- (1) Tirer un échantillon de $40 + 2.k$ objets
- (2) Appliquer PAM sur l'échantillon
- (3) Calculer la qualité du sous-ensemble engendré par l'ensemble des données
- (4) Si la qualité trouvée est la plus faible déjà déterminée
- (5) Mémoriser les représentants déterminés à l'étape 3

FIN

4.2.2.3. La méthode CLARANS

En 1994, *Ng* et *Han* ont introduit une nouvelle méthode qui s'appelle CLARANS (Clustering Large Applications based upon Randomized Search) [120]. Elle se base sur la construction d'un graphe $G_{n,k}$ dont chaque sommet (ou nœud) est représenté par un groupe de l'ensemble des individus de taille k : $\{R_{m1}, \dots, R_{mk}\}$. On dit que deux sommets sont voisins s'il y a un seul représentant qui fait la différence. L'algorithme de CLARANS est défini ainsi :

Début

- (1) Fixer les paramètres *NUMLOCAL* et *MAXNEIGHBOR*, puis initialiser I à 1 et *MINCOST* au coût maximal possible où :

NUMLOCAL est le nombre de minimaux locaux

MAXNEIGHBOR est le nombre de maximum de voisins d'un sommet de graphe.

- (2) Choisir aléatoirement un nœud X du graphe à explorer
- (3) $J = 1$
- (4) Considérer un voisin Y et X et calculer le coût différentiel $TC_{X \rightarrow Y}$

- (5) Si $(TC_{X \rightarrow Y} < 0)$, alors $X = Y$ et retourne en 3)
- (6) Sinon, $J = J + 1$
- (7) Si $(J < MAXNEIGHBOR)$, alors retourner en 4)
- (8) Si $MINCOST > COST(X)$, alors $MINCOST = COST(X)$ et $BEST = X$
- (9) $I = I + 1$. Si $(I < NUMLOCAL)$, retourner en 2)
- (10) Sinon, retourner la solution correspondant à BEST

FIN

La méthode CLARANS est plus avantageux que PAM et CLARA car elle donne de meilleurs résultats. Son inconvénient se réside au niveau du choix des paramètres. En plus, elle présente une complexité de $O(k.n^2)$.

Ces méthodes de k-médoïdes peuvent donner des résultats satisfaisant face à un ensemble qui contient des données erronées. Mais leur complexité pour chaque itération est estimée à $O(k(n - k)^2)$ avec la nécessité de spécifier le nombre de clusters k .

Après cette présentation de différentes méthodes de classification, nous allons maintenant préparer les pointes en vue d'une bonne classification morphologique.

4.3. Mise en forme de la morphologie des EPICs

L'idée est d'affecter à chaque EPIC détecté une classe C_j , $j \in \{0, \dots, N_c - 1\}$ selon sa forme. Chaque classe C_j est représentée par son gabarit g_j (figure 4.1). L'identification du gabarit g_j d'un EPIC donné se fait en deux phases. La première phase permet d'identifier la partie pointue de l'EPIC. La deuxième phase permettra de détecter la présence ou l'absence d'onde lente dans la morphologie de l'EPIC [119].

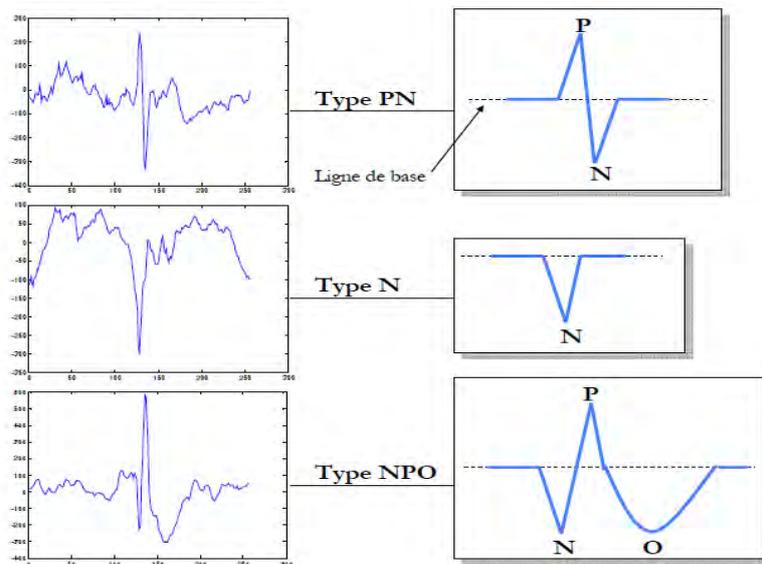


Figure 4-1 : Représentation de quelques EPICs et leur gabarit

4.3.1. Extraction des EPICs détectés

Les ondelettes sont utilisées non seulement pour éliminer le bruit présent dans un signal mais aussi elles permettent de mettre en évidence les événements. Dans notre cas, nous utilisons les ondelettes après la phase de détection pour pouvoir bien extraire les EPICs. De ce fait, une fenêtre d'extraction est ouverte autour de l'instant d'occurrence de chaque EPIC : en utilisant les informations à priori sur la durée moyenne des EPICs. Nous avons choisi une fenêtre de largeur $nbPtsDWT = 128$ échantillons, soit 0.5 seconde pour des données échantillonnées à 256 Hz.

On obtient alors une matrice $E_{pré-extrait}^k(t)$. La matrice contient des événements pré-extraits définis par : $e_{pré-ext_i}^k(t)$ avec $i \in \{0, 1, \dots, N_k^{EPIC} - 1\}$ et $k \in \{0, 1, \dots, N_v - 1\}$ et $t \in \{0, 1, \dots, nbPtsDWT\}$, l'événement est représenté par :

$$e_{pré-ext_i}^k(t) = v_k(t) \times \prod_{[\hat{\tau}_{k,i}-a, \hat{\tau}_{k,i}+b]}(t) \quad (4-7)$$

$\prod_{[\hat{\tau}_{k,i}-a, \hat{\tau}_{k,i}+b]}(t)$ est fonction porte. Les valeurs de a et b représentent respectivement le nombre d'échantillons avant et après l'instant de détection. Nous avons choisi des valeurs pour bien encadrer l'EPIC ($a = 32$, $b = 95$). Nous allons appliquer l'ondelette mère de Daubechies 6 à la matrice obtenue après son extraction. La Figure 4-2 donne une représentation de 42 EPICs extraits [29].

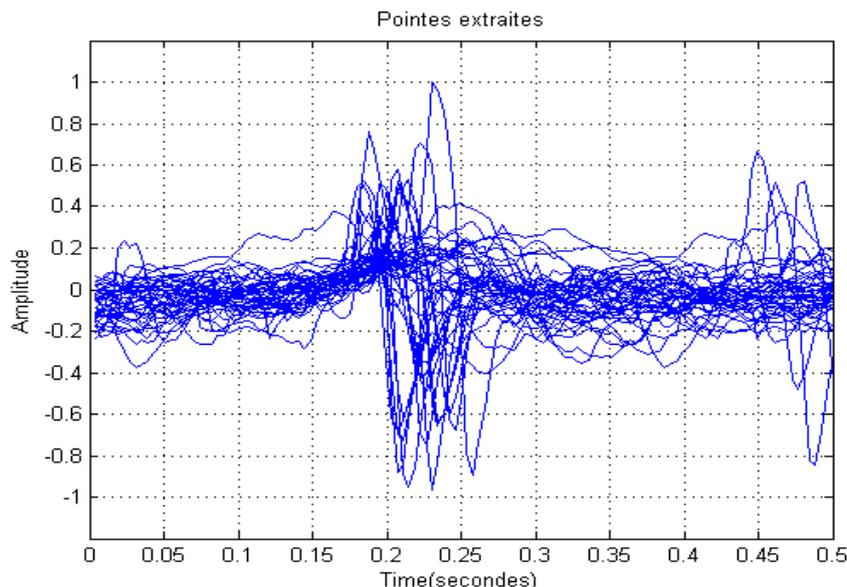


Figure 4-2 : EPICs extraits d'un signal EEG réel

Dans notre cas, nous construisons pour chaque EPIC :

- La partie « pointue » d'une part, le vecteur $spike_{pré-ext_i}^k(t)$ avec, approximation de $e_{pré-ext_i}^k(t)$ en gardant uniquement les niveaux de détails $\{1, 2, 3\}$ de la décomposition.
- La partie « lente » d'autre part, le vecteur $slow_{pré-ext_i}^k(t)$, approximation de $e_{pré-ext_i}^k(t)$ en gardant uniquement les niveaux de détails $\{5,6\}$ de la décomposition DWT.
- Simplifier les EPICs extraits (réduction du nombre de points), afin de favoriser la rapidité de traitement ;
- Faire ressortir la morphologie de ces événements, en se rapprochant le plus possible des gabarits ;
- Recaler les événements les uns par rapport aux autres de manière à pouvoir les comparer simplement lors de l'étape de classification.

4.3.2. Normalisation, seuillage et segmentation des EPICs

D'abord nous normalisons simplement le vecteur obtenu entre -1 et 1, par rapport à son maximum. On obtient alors les $spike_{norme_i}^k(t)$.

Ensuite, le seuillage nous permettra d'assimiler la valeur des composantes des vecteurs $spike_{norme_i}^k(t)$ à un taux d'appartenance à une classe ; il y a ici 2 cas possibles pour chaque échantillon : « fait partie de la forme de la pointe (gabarit) » ou « ne fait pas partie de la forme de la pointe ». Si nous choisissons une valeur « *taux_appartenance* », toutes les composantes du vecteur dont la valeur absolue est inférieure à ce taux seront mis à 0. C'est un paramètre très important car il influe beaucoup sur la forme finale du vecteur $spike_{norme_i}^k(t)$.

Enfin, la phase de segmentation consiste à transformer les vecteurs temporels $spike_{norme_i}^k(t)$, en une suite de $N_{extrema}$ extrema. En rappel, la variabilité temporelle des EPICs selon les patients et selon les zones cérébrales considérées. Nous conservons ainsi les changements de polarité de la pointe tout en supprimant cette variabilité temporelle. Pour repérer les extrema, nous avons implémenté un algorithme glissant (équivalent à une recherche des zéros dans la dérivée du signal) analysant des triplets d'échantillons. La Figure 4-3 nous donne la représentation de cet algorithme.

On considère un signal échantillonné quelconque $x(t), t \in \{0, \dots, N - 1\}$. On fait varier t de 1 à $N - 1$ et on teste à chaque pas :

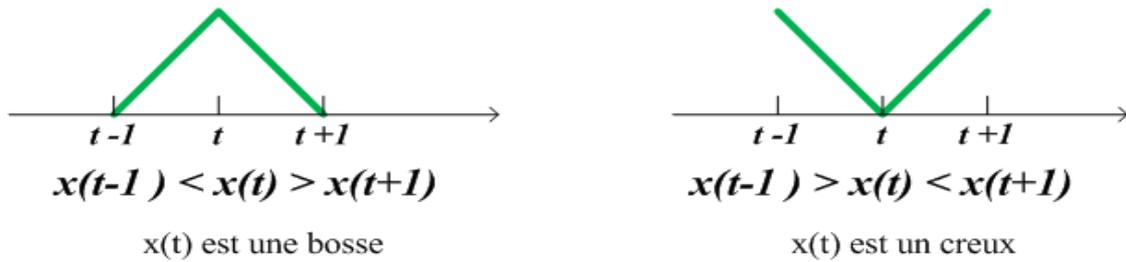


Figure 4-3 : Algorithme de repérage des extrema

En conservant uniquement les échantillons qui sont des extrema, c'est-à-dire qui ont été identifiés comme étant un creux ou une bosse, on obtient les vecteurs $spike_{extrema_i}^k(n)$ avec $n \in \{0, 1, \dots, N_{extrema} - 1\}$. On conserve dans un autre vecteur $instant_{extrema_i}^k(n)$ l'information temporelle de chaque extrema, afin de pouvoir extraire des informations supplémentaires plus tard dans le traitement [119].

4.3.3. Réorganisation des vecteurs

L'objectif principal de cette partie est de ne garder que les composantes strictement nécessaires à la description de la morphologie d'une pointe, après les étapes précédentes. Nous avons implémenté un algorithme (Figure 4-4) [119] qui effectue cette opération de manière intelligente, en lui donnant quelques règles simples pour traiter les cas particuliers des poly-pointes et des doubles détections dans une même fenêtre d'extraction.

- On parcourt le vecteur jusqu'à sa première composante non nulle et on commence à enregistrer les composantes non-nulles dans le vecteur $spike_{final_i}^k(n)$;
- On conserve une composante nulle uniquement si elle est précédée et suivie d'une composante non-nulle (cas de certaines poly-pointes) ;
- On s'arrête dès que l'on rencontre une suite de 2 composantes nulles consécutives.

On obtient les vecteurs $spike_{final_i}^k(n)$ de forme très simple.

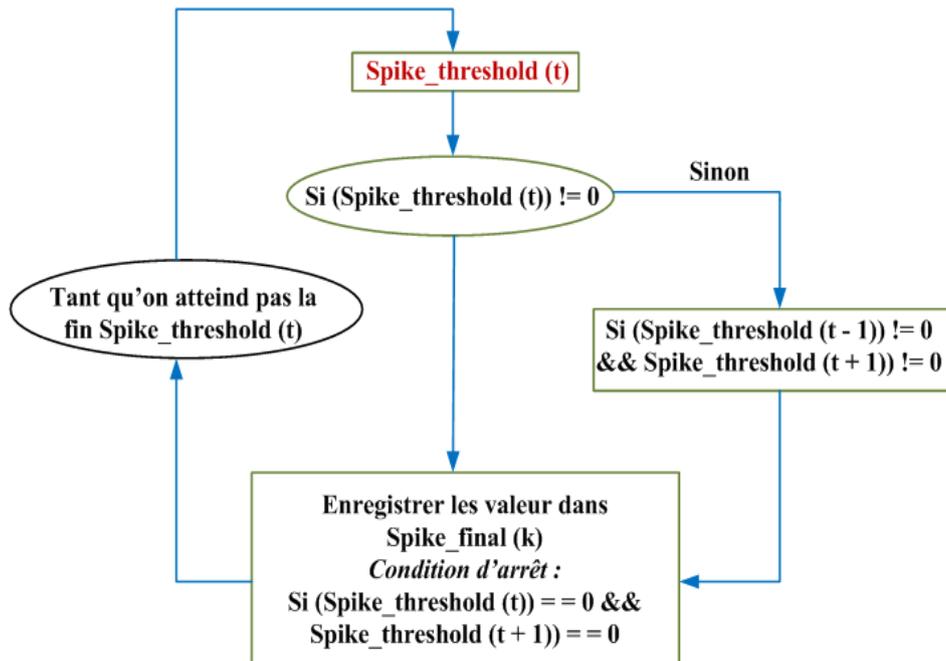


Figure 4-4 : Algorithme de détermination du vecteur final

4.4. Classification des EPICs

Après l'étape de la mise en forme des pointes, il devient plus aisé d'appliquer un algorithme de classification non supervisé.

4.4.1. Application des algorithmes de k-means

L'algorithme des k-means doit être exécuté plusieurs fois $N_{execution}$ avant de choisir la meilleure exécution. Nous résumons le fonctionnement d'une exécution étape par étape ci-après [108].

1. On choisit aléatoirement N_c (un pour chaque classe) éléments $x_i(n)$ parmi les N_k^{EPIC} . Ils joueront le rôle des centres de gravité (ou centroïdes) lors de la première itération.
2. On calcule toutes les distances éléments-centroïdes.
3. On assigne chaque élément $x_i(n)$ à la classe C_j du centroïde le plus proche de lui parmi les N_c .
4. On calcule le centre de gravité de chaque classe $G_j(n), j \in \{0, \dots, N_c - 1\}$: moyenne des éléments $x_i(n)$ appartenant à une classe C_j , et on remplace les anciens centroïdes par ces nouveaux centres de gravité. S'il n'y pas de mouvement par rapport à l'itération précédente (critère d'arrêt d'exécution des k-means), on arrête l'exécution.
5. On revient à l'étape 2.

La Figure 4-5 nous donne les différentes phases et boucles de l'algorithme des K-means.

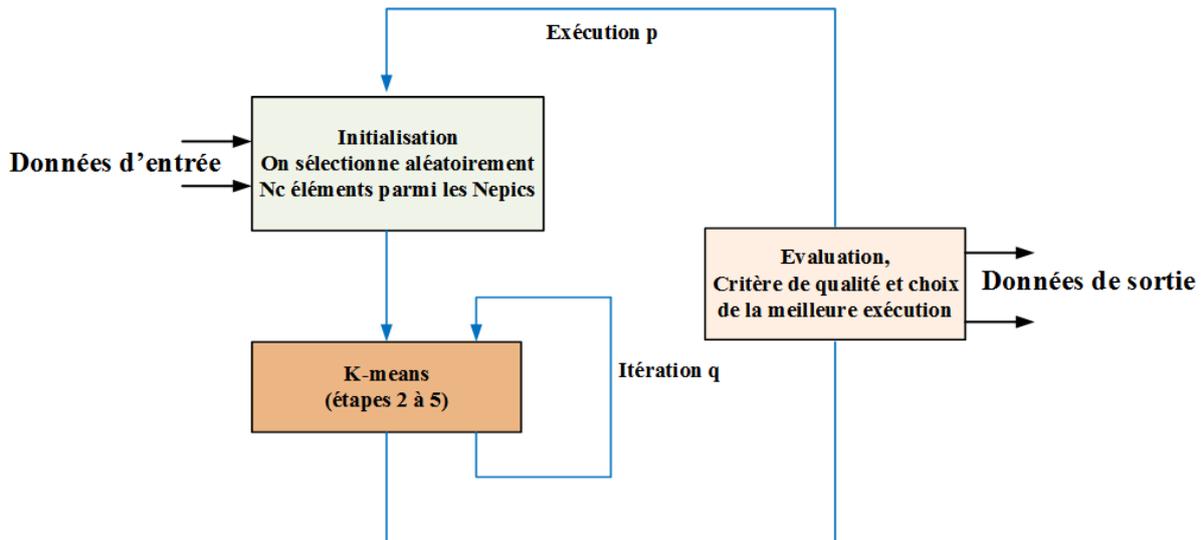


Figure 4-5 : Fonctionnement de l'algorithme k-means appliqué aux EPICs

4.4.1.1. Critère d'arrêt d'une exécution des k-means

On calcule, après chaque itération d'indice q d'une exécution p des k-means, l'erreur moyenne donnée par l'équation 4-8. En plus la variable q est utilisée pour faire les $N_{execution}$ de l'algorithme.

$$E_q^p = \sum_{j=0}^{N_c-1} \sum_{x(n) \in C_i} d(x(n), G_j^p(n)), q \in \{0, \dots, N_{execution} - 1\} \quad (4-8)$$

On décide qu'il n'y a plus de mouvement d'une itération à l'autre lorsque le critère d'arrêt est atteint (équation 4-9).

$$\left| \frac{E_q^p - E_{q-1}^p}{E_{q-1}^p} \right| < \varepsilon \quad (4-9)$$

Où ε est une constante réelle positive. Ce critère est atteint à l'itération $q = N_{iterations}^p$ ($N_{iterations}^p$ est l'indice de l'exécution p après stabilisation) $p \in \{0, \dots, N_{execution} - 1\}$. On choisit $\varepsilon = 10^{-5}$.

4.4.1.2. Critère de qualité d'une exécution des k-means et sortie du classificateur

Les résultats de la classification varient en fonction de l'initialisation plus ou moins bonne des centroïdes. C'est pourquoi nous choisissons de réaliser $N_{execution}$ exécutions de l'algorithme et de retenir celle qui donne les meilleurs résultats en se basant sur le critère de l'erreur moyenne intra-classes, c'est-à-dire la compacité moyenne de N_c nuages de points,

donnée par la quantité $E_{N_{iteration}}^p$. Il suffit de choisir l'exécution $p_{choisie}$ qui minimise cette quantité. On a donc :

$$p_{choisie} = \arg \min_{p \in \{0, \dots, N_{execution} - 1\}} \left\{ E_{N_{iteration}}^p \right\} \quad (4-10)$$

Par conséquent, on obtient en sortie du classificateur un vecteur $etiquette_spike_i^k$ dont chaque composante a une valeur entière comprise entre 0 et $N_c - 1$, désignant le numéro du type de $spike_i^k$ (n). Le gabarit de chaque type est donné par les centres de gravités de $final_i$ l'exécution choisie :

$$G_j^{p_{choisie}}(n), j \in \{0, \dots, N_c - 1\} \quad (4-11)$$

4.4.2. Application des algorithmes de k-médoïdes

Le processus d'exécution de l'algorithme des k-médoïdes est similaire à celui des k-means.

1. On choisit aléatoirement N_c (un pour chaque classe) objets x_i parmi les N_k^{EPIC} . Ils joueront le rôle des médoïdes ou de centres c_i lors de la première itération.
2. On considère chaque échange possible entre un centre c_i et un élément x_h (non-médoïde) pour chaque couple (c_i, x_h) .

Pour cela, on définit le coût de cet échange : $Cost(c_i, x_h)$. La contribution d'un élément x_j (non-médoïde et différent de x_h) à ce coût : $Cont(x_j, c_i, x_h)$.

On définit $Cont(x_j, c_i, x_h)$ de la manière suivante :

- a) Si x_j est plus loin de c_i et x_h que d'un autre centre.

$$Cont(x_j, c_i, x_h) = 0$$

- b) Si x_j est plus proche de c_i et x_h que d'un autre centre (alors $d(x_j, c_i) = D(x_j)$), où $D(x_j)$ est la distance entre l'élément x_j et son plus proche centre.

- Si x_j est plus proche de x_h que de son second plus proche centre.

$$Cont(x_j, c_i, x_h) = d(x_j, x_h) - d(x_j, c_i)$$

- Si x_j est plus loin de x_h que de son second plus proche centre.

$$Cont(x_j, c_i, x_h) = E(x_j) - D(x_j) \text{ où } E(x_j) \text{ est la distance entre l'élément } x_j \text{ et son second plus proche centre.}$$

- c) Si x_j est plus loin de c_i mais plus proche de x_h que d'un autre centre.

$$Cont(x_j, c_i, x_h) = d(x_j, x_h) - D(x_j)$$

On définit ensuite $Cost(c_i, x_h)$:

$$Cost(c_i, x_h) = \sum_{x_j \in spikes} Cont(x_j, c_i, x_h) \quad (4-12)$$

On remarque que la fonction $Cost(c_i, x_h)$ correspond à une somme de différence. Elle peut donc être nulle par moment.

L'algorithme se déroule ainsi :

3. Pour chaque couple (c_i, x_h) , on calcule $Cost(c_i, x_h)$.
4. On sélectionne le couple avec le coût minimum.
5. Si ce coût est négatif on procède à l'échange et on recommence à 3.
6. Sinon si ce coût est positif ou nulle, on arrête.

De ce fait, il existe plusieurs critères de qualité pour évaluer les méthodes de classification. La section suivante présente deux critères d'évaluation des méthodes de k-médoïdes [121].

4.4.2.1. Critère de qualité de la classification par la méthode SSE

Dans cette partie, nous nous intéressons à la méthode SSE (Sum Squared Error) essentiellement. Elle est définie par la somme des distances au carrée entre un centre et chacun des points de sa classe [121].

Nous avons :

- $X = [x_1, x_2, \dots, x_n]$ un ensemble de n EPICs.
- k le nombre de cluster.
- C est l'ensemble des k futurs centres $([c_1, c_2, \dots, c_k])$.

$$SSE(X) = \sum_{j=1}^k \sum_{i=1}^n \|x_i - c_j\|^2 \quad (4-13)$$

Ce critère donne des valeurs positives non nulle. Le meilleur clustering est obtenu par critère très faible.

4.4.2.2. Critère de qualité de la classification par la méthode de Sylvain Ferrandiz

Le critère de Sylvain Ferrandiz est donné par la relation suivante [121] :

$$c = \log(N) + \log\left(\binom{N+K-1}{K}\right) + \sum_{i=1}^K \log\left(\binom{N_i+J-1}{J-1}\right) + \sum_{i=1}^K \log\left(\frac{N_i!}{N_{i1}! \dots N_{ij}!}\right) \quad (4-14)$$

$$\text{Où } \binom{N+K-1}{K} = \frac{(N+K-1)!}{K!(N-1)!}$$

Pour ce critère, nous avons les paramètres suivant [122] :

- ✓ N est le nombre d'éléments de l'ensemble des EPICs.
- ✓ K est le nombre de clusters.

- ✓ J est le nombre de classes au sein de l'ensemble.
- ✓ N_i est le nombre d'éléments appartenant au cluster i.
- ✓ N_{ij} est le nombre d'éléments de classe j appartenant au cluster i.

On peut rencontrer un lors de l'implémentation de ce critère à cause l'expression suivante :

$$\binom{N+K-1}{K} = \frac{(N+K-1)!}{K! * (N-1)!} \quad (4-15)$$

Le calcul du factoriel d'un grand nombre peut prendre beaucoup de temps lors de l'exécution de l'algorithme.

Il y a un moyen de résoudre ce problème cherchant le logarithmique du factoriel :

$$\log n! = \sum_{l=1}^n \log l \quad (4-16)$$

Avec cette astuce, on obtient un algorithme très facile à implémenter :

$$\log \binom{N+K-1}{K} = \sum_{l=1}^{N+K-1} \log l - \sum_{l=1}^K \log l - \sum_{l=1}^{N-1} \log l \quad (4-17)$$

Ce critère donne aussi des valeurs positives non nulle. Le meilleur clustering est obtenu par critère très faible.

4.4.3. Le taux de bonne classification (accuracy) et Courbes ROC

Pour trouver le taux de bonne classification des données, on calcule le nombre d'éléments correctement classifié sur le nombre total d'éléments. On l'exprime généralement en pourcentage.

Ce critère peut donner des valeurs comprises entre 0 et 100. Si le critère vaut 100, cela signifie que tous les éléments ont été correctement classifiés.

Les courbes ROC (Receiver Operating Characteristics) ou COR (Caractéristiques Opérationnelles de Réception) sont utiles pour organiser les classificateurs et visualiser leur performance. Elles sont utilisées depuis longtemps dans la théorie de détection de signal pour représenter le compromis entre le taux de succès et le taux de fausses alarmes des classificateurs [123].

La performance du classificateur est déterminée par plusieurs paramètres. Etant donné un classificateur et un élément, il y a quatre résultats possibles. Si l'élément est positif et il est classifié comme positif, il est considéré comme « *Vrai Positif* » ; s'il est classifié comme négatif, considéré comme « *Faux Négatif* ». Si l'élément est négatif et il est classifié comme négatif, il est considéré comme « *Vrai Négatif* » ; s'il est classifié comme positif, considéré

comme « *Faux Positif* ». Pour faire la différence entre la classe actuelle et la classe prédite, nous utilisons les labels {*Y, N*} pour les prédictions de classe produites par un modèle.

En effet, la Figure 4-6 nous montre une matrice de confusion et des équations de plusieurs paramètres communs.

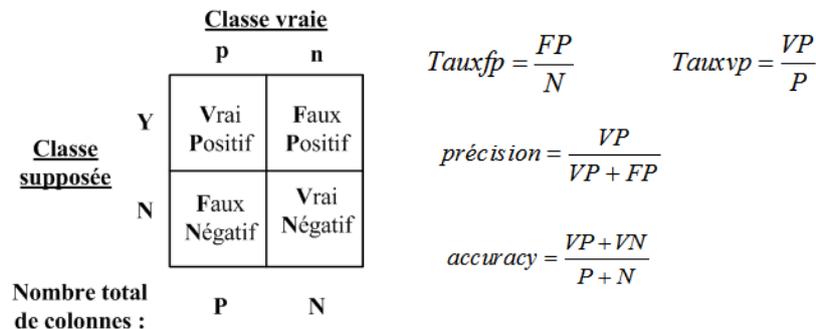


Figure 4-6 : Matrice de confusion et équations paramétriques

Les chiffres le long de la diagonale principale représentent les décisions correctement faites, et ceux de l'autre diagonale représentent les erreurs, la confusion entre les différentes classes.

Le taux de vrais positifs d'un classificateur est estimé par :

$$Taux_{vp} \approx \frac{\text{Les vrais correctement classés}}{\text{Nombre total de vrais}}$$

Le taux de faux positifs (communément appelé taux de fausse alarme) d'un classificateur est :

$$Taux_{fp} \approx \frac{\text{Les faux incorrectement classés}}{\text{Nombre total de faux}}$$

Il existe alors d'autres termes associés aux courbes ROC :

$$sensibilité = \frac{VP}{P}$$

$$sélectivité = \frac{VN}{FP + VN} = \frac{VN}{N} = 1 - Taux_{fp}$$

$$Valeur\ positive\ prédite = précision$$

Par ailleurs, les courbes ROC sont des graphes à deux dimensions, nous avons le taux de vrais positifs Tvp et le taux de faux positif Tfp respectivement sur l'axe des ordonnées et l'axe des abscisses. Un graphe ROC représente des compromis relatifs entre avantages (vrais positifs) et les coûts (faux positifs). La Figure 4-7 donne une représentation de quatre classificateurs dans l'espace ROC.

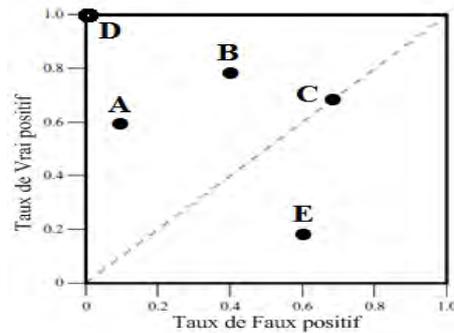


Figure 4-7 : Un graphique ROC de base montrant cinq classificateurs

Plusieurs points dans l'espace ROC sont à noter. Le point inférieur gauche (0,0) représente la stratégie de ne jamais émettre un classement positif ; un tel classificateur ne commet pas d'erreurs de faux positifs, mais gagne aussi aucun vrai positif. La stratégie inverse est l'utilisation inconditionnelle des classifications positives. Elle est représentée par le point supérieur droit (1,1). Alors que le point (0,1) représente une classification parfaite. Le classificateur **D** montre une performance parfaite.

Officieusement, un point dans l'espace ROC est meilleur qu'un autre ; s'il est au nord-ouest (taux de *VP* est plus élevé, le taux de *FP* est plus faible) du premier. Les classificateurs apparaissant sur le côté gauche d'un graphe ROC, près de l'axe des abscisses peuvent être considérés comme « conservateurs » : ils font des classifications positives seulement avec des preuves solides de sorte qu'ils font quelques erreurs sur le taux de faux positifs, mais ils ont le plus souvent un taux de vrais positifs faible. Les classificateurs sur le côté supérieur droit d'un graphe ROC peut être considéré comme « libérale » : ils font des classifications positives avec de faibles preuves afin qu'ils classent presque tous positifs correctement, mais ils ont souvent des taux élevés de faux positifs. Dans la Figure 4-7, **A** est plus conservateur que **B**. De nombreux domaines du monde réel sont dominés par un grand nombre de cas négatifs, donc la performance dans le côté extrême gauche du graphique ROC devient plus intéressant.

La ligne diagonale $y = x$ représente la stratégie de deviner au hasard une classe. Le classificateur **C** peut être dit en devinant la classe positive à 70% du temps. Le classificateur **E** effectue bien pire qu'aléatoire, et est en fait la négation de **B**. Un classificateur en dessous de la diagonale peut être dit avoir des informations utiles, mais il est dans l'application d'information incorrecte.

4.4.4. Détection de la présence d'une onde lente dans un EPIC

Bien que les pointes avec des ondes lentes se produisent fréquemment dans les signaux EEG épileptiques, elles ne sont pas utilisées dans la détection d'EPICs classique.

L'identification des pointes avec des ondes lentes permet au système d'avoir une meilleure capacité d'aider les neurologues cliniques dans les examens EEG de routine et le diagnostic d'épilepsie.

Dans cette partie, un modèle de détection d'ondes lente est adopté. Après la détection de partie pointue **P**, nous définissons quatre autres points de caractéristiques importantes du modèle. Le groupe de points **A**, **P** et **B** représente la portion de la partie pointue, alors que le groupe de points **B**, **Q** et **R** représente la portion de l'onde lente (Figure 4-8). Pour trouver les points **A** et **B**, on peut appliquer l'algorithme des triplets décrit dans la section 4.3.2.

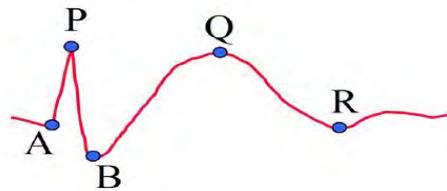


Figure 4-8 : Points caractéristiques du modèle de détection d'onde lente

Après traitement de la partie pointue, les points de référence pour la partie d'onde lente seront sélectionnés. Les deux autres points **Q** et **R** correspondent respectivement au maximum local et le point où une onde lente prend fin. En plus, le point **Q** est le point le plus élevé après le point **P** et le point **R** est le point le plus bas après le point **Q**.

Le principe de détection d'onde lente est représenté de manière explicite dans la Figure 4-9. On retient deux valeurs remarquables x_1 et x_2 parmi les trois points de l'onde lente. Le rapport de ces deux valeurs est grand s'il y a une onde lente qui suit la partie pointue, et il est au contraire plus petit s'il n'y a pas d'onde lente.

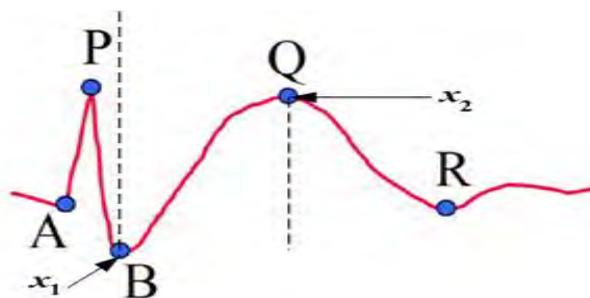


Figure 4-9 : Valeurs remarquables pour le calcul de ρ

Le rapport des deux valeurs remarquables est défini par [29] :

$$\rho = \left| \frac{x_2}{x_1} \right| \quad (4-18)$$

4.5. Les éléments caractérisant la sortie de la chaîne de traitement

Après la détection, l'extraction et la classification des EPICs, on a associé un vecteur caractéristique $\psi_{k,i}$ à chaque EPIC :

$$e_{k,i}(t) \rightarrow \psi_{k,i} = [\hat{t}_{k,i} \quad C_j \quad \hat{a}_{k,i}^{MAX} \quad \hat{\delta}t_{k,i}^{Pte} \quad C_{k,i}^{Onde}] \quad (4-19)$$

Avec $C_{k,i}^{Onde} = 1$ s'il en contient une partie « onde lente » et $C_{k,i}^{Onde} = 0$ sinon, où $i \in \{0, 1, \dots, N_k^{EPIC} - 1\}$ et $k \in \{0, 1, \dots, N_v - 1\}$.

Pour obtenir l'amplitude maximale $\hat{a}_{k,i}^{MAX}$ de la phase pointue, on utilise le vecteur contenant les instants d'occurrence de chaque pic de $spike^k(n)$. Il suffit d'accéder à $extrema_i$ l'instant d'occurrence correspondant au pic $n_{MAX} = \arg \max_n (n) \left\{ spike^k(n) \right\}_{extrema_i}$. On a alors $\hat{a}_{k,i}^{MAX} = instants_{extrema_i}^k(n_{MAX})$. Pour la durée de la phase pointue $\hat{\delta}t_{k,i}^{Pte}$: il suffit d'accéder à l'instant d'occurrence du premier et du dernier pic significatif de chaque $spike^k(n)$ et de $extrema_i$ faire la différence.

On pourra effectuer une analyse statistique sur chacune de ces caractéristiques ou étudier leurs dynamiques temporelles.

4.6. Conclusion

L'intégration de la morphologie dans l'analyse des EPICs peut apporter un complément significatif à l'analyse de la distribution spatio-temporelle habituellement utilisée. Pour mieux appréhender la forme des EPICs les outils de classification sont nécessaires. Ce chapitre a présenté quelques techniques de classification. Il a présenté les points forts et les points faibles de différentes catégories de méthodes. L'accent est particulièrement mis sur les méthodes de classification non supervisée. Les méthodes de k-means et celles des k-médoïdes ont été développées dans l'ordre chronologique. Avant l'application de ces méthodes, une extraction des EPICs et leur mise en forme sont nécessaires. Deux outils permettant l'analyse des performances de ces classificateurs ont été présentés à travers des taux de bonne classification et des courbes de ROC. La dernière section du chapitre aborde les ondes lentes qui peuvent accompagner plusieurs EPICs. Un modèle de détection de ces ondes lentes a été également proposé dans ce chapitre. Le cinquième et dernier chapitre applique la classification proposée dans ce chapitre ainsi que les différents outils présentés dans les autres chapitres dans une chaîne complète de traitement de signaux EEG enregistrés chez des patients souffrant d'une épilepsie.

Chapitre 5 : Evaluation et validation des résultats

5.1. Introduction

Ce dernier chapitre a pour objectif de mettre en application les méthodes de traitement des signaux EEG proposées dans les chapitres 2, 3 et 4. Les données utilisées ont été enregistrées chez différents patients souffrant d'une épilepsie partielle pharmaco-résistante [124]. Des données réelles et brutes sont utilisées pour la validation des méthodes de filtrage proposées dans le chapitre 2 et des méthodes de détection proposées dans le chapitre 3. Des gabarits (formes) d'EPICs sélectionnés et approuvés par le spécialiste sont utilisés pour la validation de l'identification de la morphologie des EPICs ainsi que leur classification. Ce chapitre est l'étape cruciale de la validation de notre chaîne de traitement des signaux EEG. D'abord une comparaison est effectuée entre les filtres SSA et de Kalman, pour en sélectionner le meilleur au niveau du prétraitement des signaux. Ensuite, nous avons associé chaque filtre avec les différents détecteurs proposés. Enfin, selon la sensibilité, la sélectivité et le temps d'exécution, un détecteur est aussi choisi. Par rapport à l'ordre des différents modules de la chaîne de traitement, la classification vient après l'extraction des différentes pointes détectées. Nous présentons dans cette partie les résultats de l'algorithme des k-means. Nous avons aussi associé la classification avec la représentation en composantes principales pour mieux analyser la performance de notre classificateur par rapport à la taille des données que nous manipulons. Par ailleurs, toutes les solutions proposées ont été implémentées sous l'environnement de Matlab installé sur un ordinateur DELL-PC INSPIRON 1440 Pentium (R) dual-core CPU T4400 @ 2.20 GHz 2.20 GHz et 3 Go RAM.

5.2. Filtrage des signaux EEG

Dans cette partie, nous présentons les résultats pratiques des filtres étudiés au chapitre 2. Pour ce faire, nous faisons varier le rapport signal sur bruit en utilisant le bruit blanc Gaussien additif (*AWGN : Add white Gaussian noise*). Afin de suivre cela, nous simulons l'effet du bruit amplificateur dans les signaux EEG. L'évaluation quantitative des performances des filtres se fait par le calcul du rapport signal sur bruit à la sortie des filtres, elle utilise la formule 5-1 [125].

$$RSB_{sortie}(dB) = \frac{\sum_i (x(i))^2}{\sum_i (x_d(i) - x(i))^2} \quad (dB) \quad (5-1)$$

Où x et x_d représentent respectivement le signal non bruité (original) et le signal débruité (la sortie de filtre).

Nous allons tracer la courbe du $RSB_{sortie}(dB)$ pour évaluer l'applicabilité des filtres étudiés face aux signaux EEG fortement bruités.

5.2.1. Filtres passe-bas et passe-haut

Cette partie présente l'application des filtres à réponse impulsionnelle infinie (RII) passe-bas et passe-haut. Les fréquences de coupure utilisées pour les filtres passe-bas et passe-haut sont respectivement 35 Hz et 5 Hz. Ces fréquences ont été choisies par rapport au contenu fréquentiel des rythmes dans l'EEG. La fonction modèle utilisée est celle de Chebyshev.

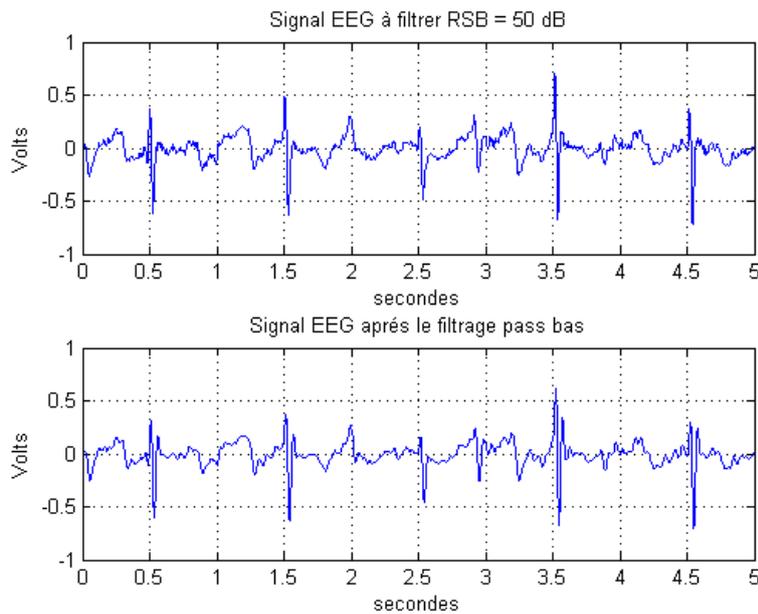


Figure 5-1 : Filtre passe-bas avec RSB = 50 dB

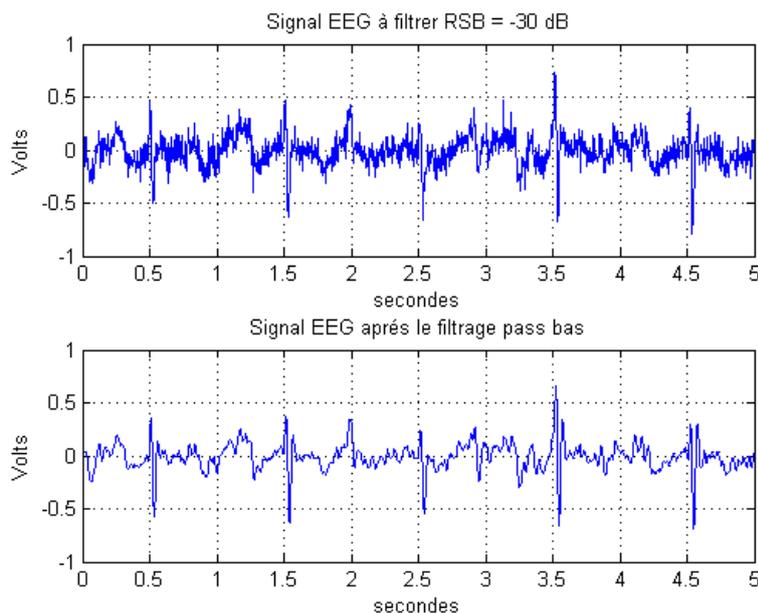


Figure 5-2 : Filtre passe-bas avec un RSB = - 30 dB

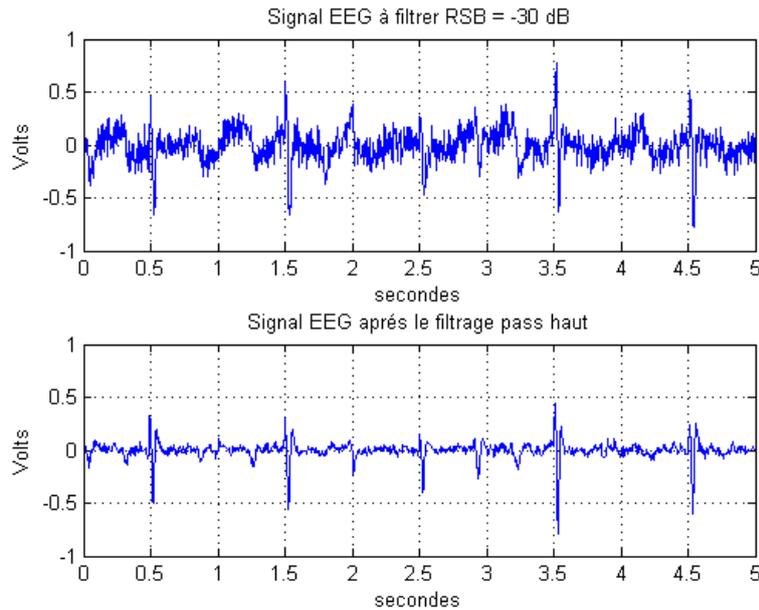


Figure 5-3 : Filtre passe-haut avec un RSB = - 30 dB

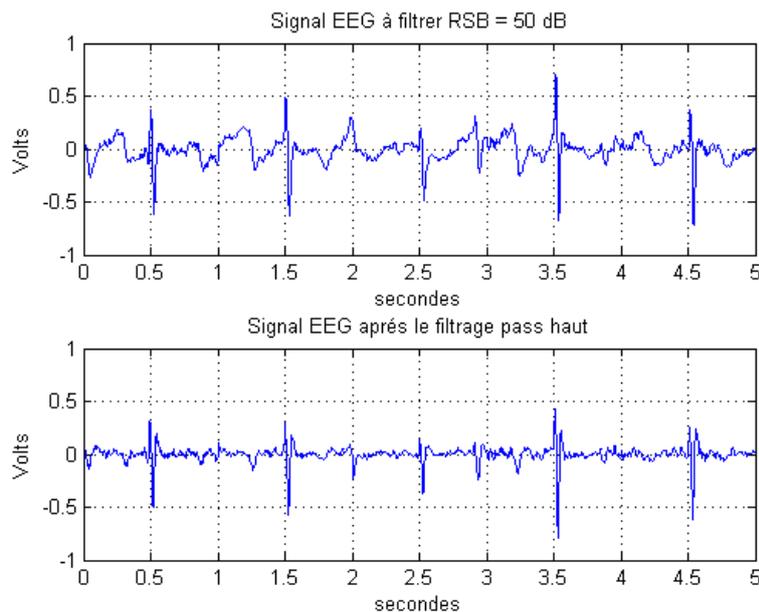


Figure 5-4 : Filtre passe-haut avec un RSB = 50 dB

Les figures 5-1 et 5-4 représentent respectivement les filtres passe-bas et passe-haut appliqués au signal EEG avec un RSB = 50 dB. Il n'y a pas assez de différence entre le signal d'entrée et le signal de sortie dans le cas du filtre passe-bas. Concernant le filtre passe-haut, on note l'élimination des ondes lentes et certaines formes d'ondes pointues. Pour les figures 5-2 et 5-3, nous avons utilisé un RSB = -30 dB. Cela montre que la puissance du bruit est supérieure à celle du signal EEG. Le signal de sortie avec le filtre passe-bas conserve plus la morphologie des EPICs que celui obtenu avec le filtre passe-haut. Pour ce dernier, on

remarque aussi l'atténuation de certaines parties du signal. En plus le signal de sortie n'est pas complètement débruité.

Nous évaluons les performances de ces filtres en se basant sur les courbes du RSB de sortie en fonction du RSB d'entrée (Figure 5-5 et Figure 5-6).

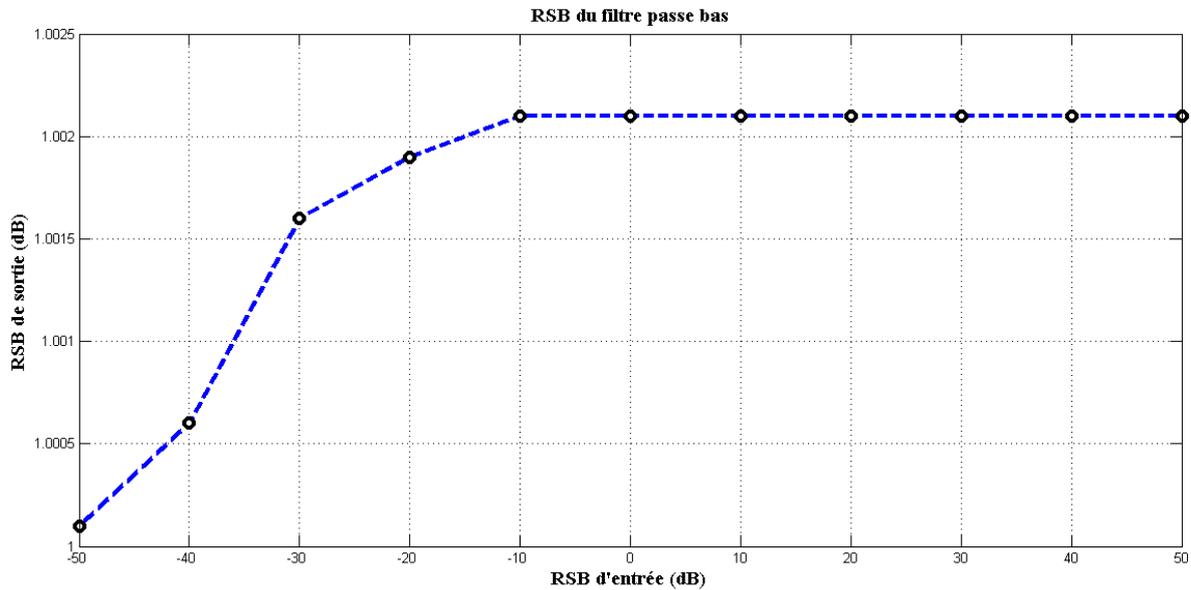


Figure 5-5 : Représentation RSB de sortie en fonction de RSB d'entrée du filtre passe bas

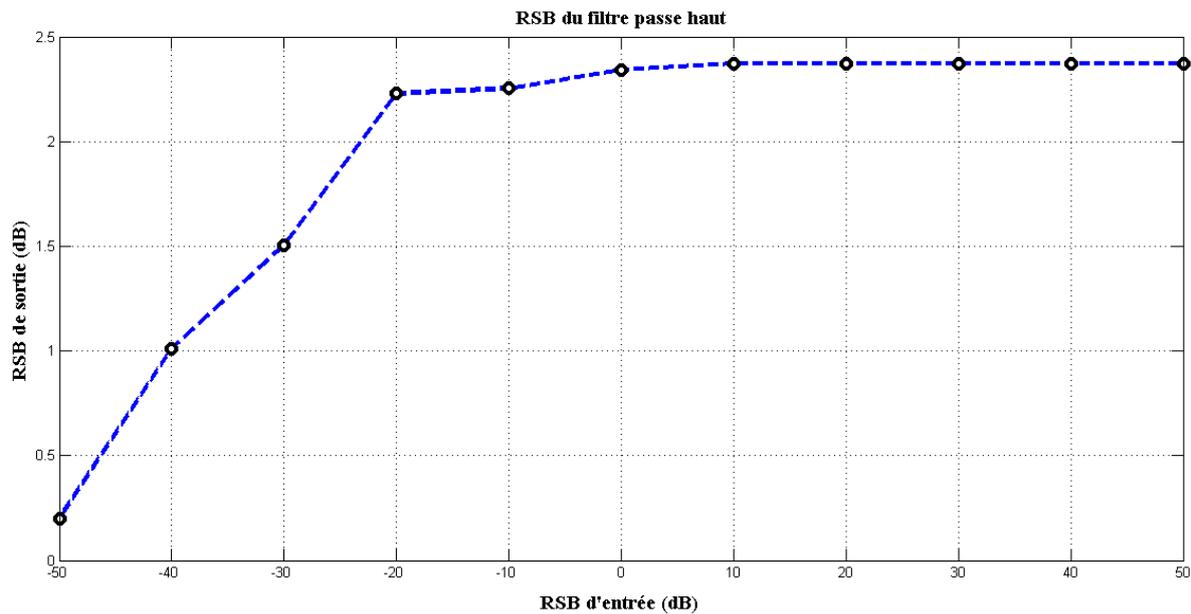


Figure 5-6 : Représentation RSB de sortie en fonction de RSB d'entrée du filtre passe haut

La Figure 5-5 montre que le filtre passe-bas est instable pour des RSB < -10 dB. Les valeurs du RSB de sortie sont constantes pour des RSB ≥ -10 dB. Comme l'ont montré les figures ci-dessus (Figure 5-1 et Figure 5-2), le filtre passe-bas permet d'éliminer les bruits tout en conservant la morphologie des EPICs.

Dans le cas du filtre passe-haut, la courbe du RSB de sortie montre une instabilité du système pour des valeurs négatives du RSB d'entrée. Cela montre que ce filtre est inefficace face aux signaux EEG fortement bruités.

Par conséquent, nous avons proposé dans cette thèse d'utiliser des filtres dynamique (SSA et Kalman) qui pourraient conserver les EPICs dans le cas des signaux très bruités. Pour évaluer la qualité, et l'applicabilité de ces filtres, nous avons aussi tracé le RSB de sortie en fonction du RSB d'entrée (Figure 5-9 et Figure 5-14).

5.2.2. Filtre SSA

Le filtre SSA, comme beaucoup de filtres, a un rôle important en traitement des signaux non stationnaires (signaux EEG). Il y a plusieurs paramètres à ajuster en utilisant un grand nombre d'essais. Le procédé de filtrage d'un signal particulier est sensible à la sélection de ces paramètres. Lorsque l (longueur de la fenêtre) et I (composant de regroupement pour la reconstruction de la série) sont choisis trop grands, certaines informations importantes du signal d'origine sont éliminées par ce filtre. Pour l et I trop petits, ce filtre ne peut pas atténuer suffisamment les bruits destructeurs. Alors, nous devrions essayer de faire un compromis entre ces deux limites. Le nombre de valeurs propres sélectionnées dépend de la complexité du composant souhaité. Le couple que nous avons utilisé pour la simulation de ce filtre est : $l = 20$ et $I = 2$.

Dans cette partie, nous faisons varier aussi le RSB à l'entrée du filtre. Ceci nous permettra de tracer la courbe du RSB de sortie en fonction de celui d'entrée (Figure 5-9).

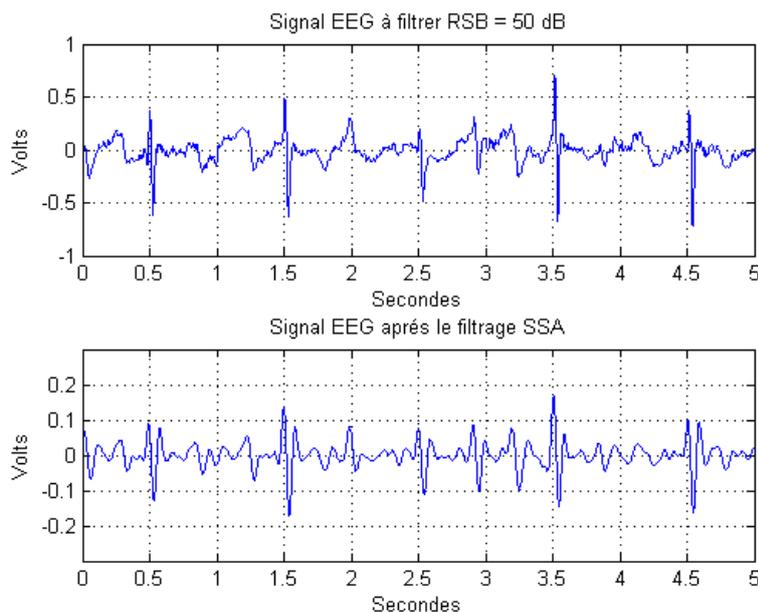


Figure 5-7 : Filtre SSA avec un RSB = 50 dB

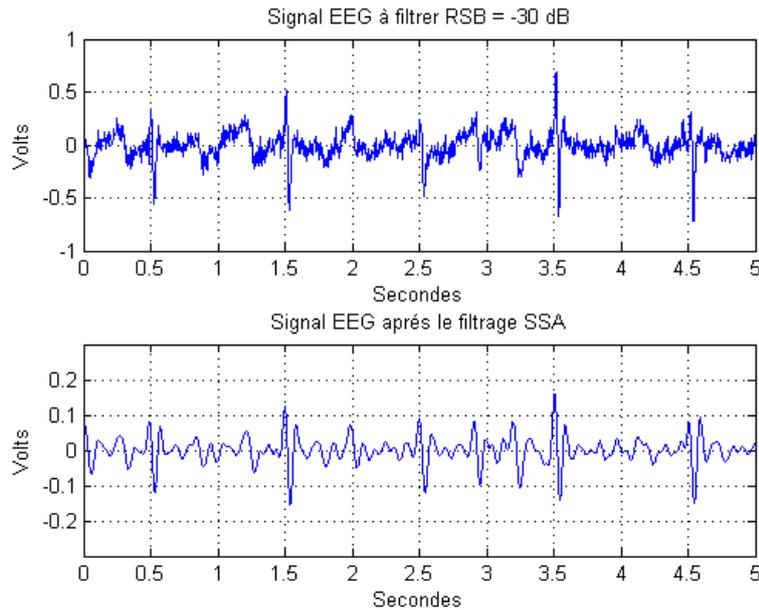


Figure 5-8 : Filtre SSA avec un RSB = - 30 dB

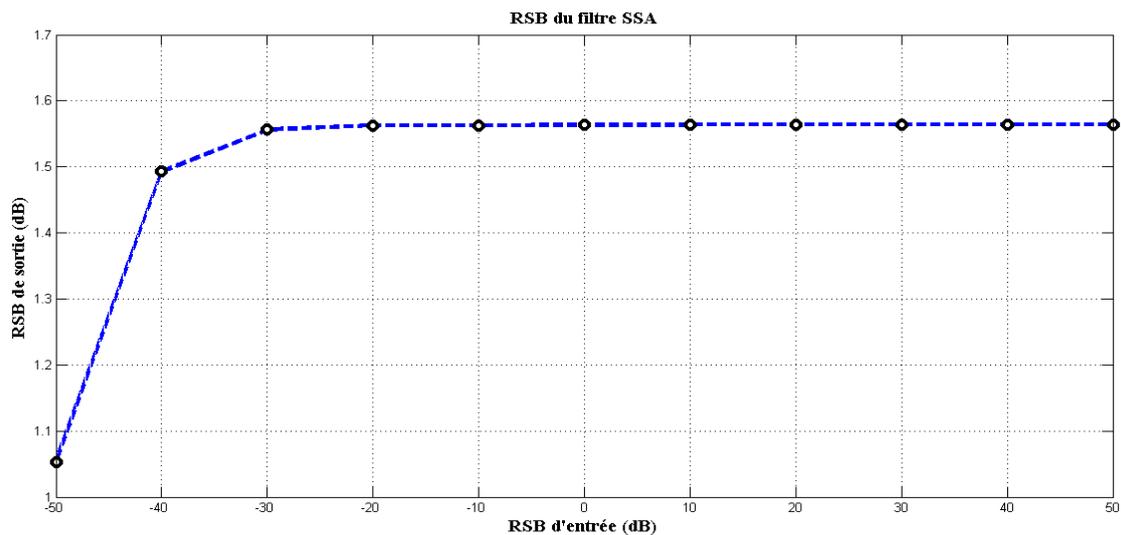


Figure 5-9 : Représentation RSB de sortie en fonction de RSB d'entrée du filtre SSA

Les signaux obtenus à la sortie du filtre SSA des figures 5-7 et 5-8 sont presque identiques alors que les RSB sont différents. Cela montre que les événements (EPICs) à détecter sont conservés après filtrage. Donc, le filtre a le pouvoir d'éliminer les bruits sans altérer les informations utiles (EPICs).

La Figure 5-9 représente la variation du RSB de sortie en fonction de celui d'entrée. Pour la plage [-50 dB, -30 dB], les valeurs du RSB de sortie augmentent de manière progressive. Ce filtre présente une variation pour cette plage. En effet, il apporte des modifications sur des EPICs du signal EEG. A partir de la valeur -30 dB, la courbe montre que le RSB de sortie

devient une constante (Figure 5-7 et Figure 5-8). En plus, SSA est une méthode dépendante des données et flexible qui peut être adaptée aux données. Cela montre la robustesse de ce filtre devant un signal bruité. Par conséquent, le filtre sera appliqué avant d'utiliser les méthodes de détection proposées.

5.2.3. Filtrage par ondelette

Nous avons appliqué le filtrage par ondelette sur le même signal EEG. Le niveau de détail ou d'approximation 2 est présenté dans cette partie pour tous les cas du RSB.

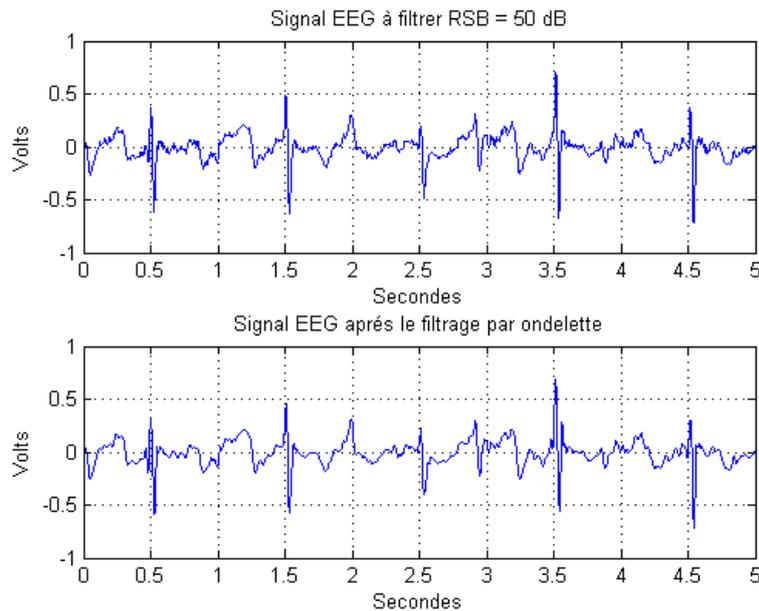


Figure 5-10 : Filtrage par ondelette avec un RSB = 50 dB

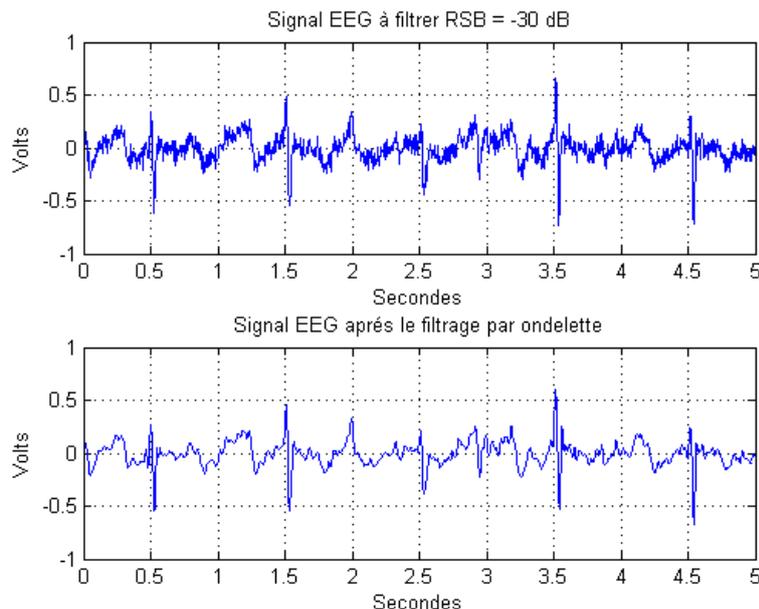


Figure 5-11 : Filtrage par ondelette avec un RSB = - 30 dB

Les ondelettes (*DWT : Discret Wavelet Transform*) ont aussi la possibilité de supprimer les bruits destructeurs. Par rapport aux différents niveaux de détails, la forme des EPICs peut être modifiée en atténuant certaines amplitudes du signal EEG. Comme les EPICs présentent plusieurs morphologies différentes, nous avons choisi dans cette thèse d'utiliser la DWT avec l'ondelette mère de Daubechies d'ordre 6 sur les différents événements du signal EEG. L'ondelette nous permettra de faire la différence en la partie pointue de l'EPIC et l'onde lente.

5.2.4. Filtre de Kalman

Dans cette partie, nous appliquons aussi le filtre de Kalman avec le même signal.

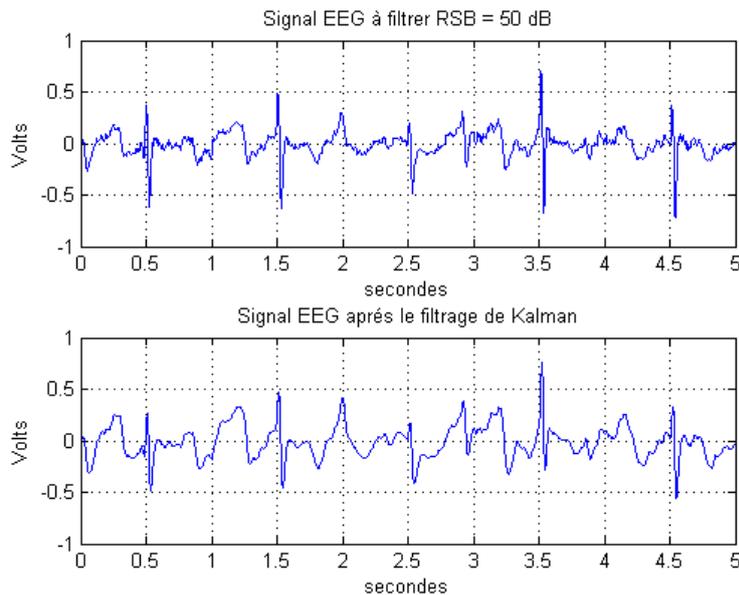


Figure 5-12 : Filtre de Kalman avec un RSB = 50 dB

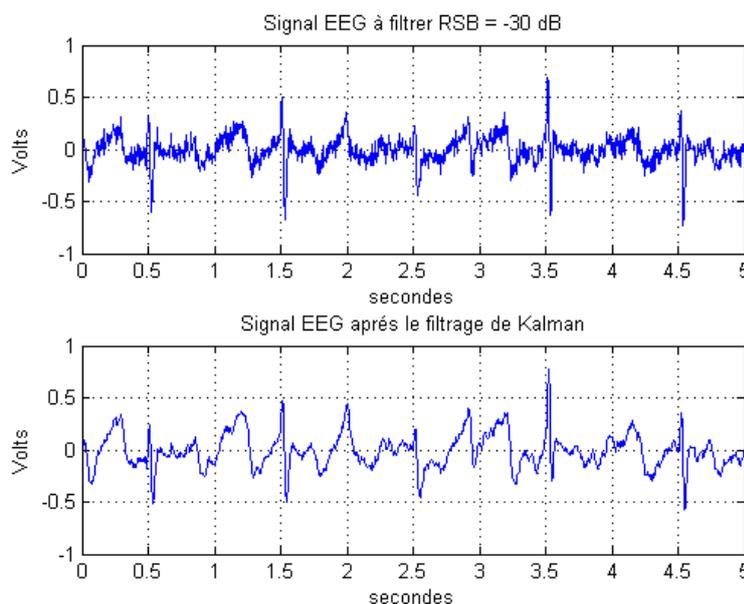


Figure 5-13 : Filtre de Kalman avec un RSB = -30 dB

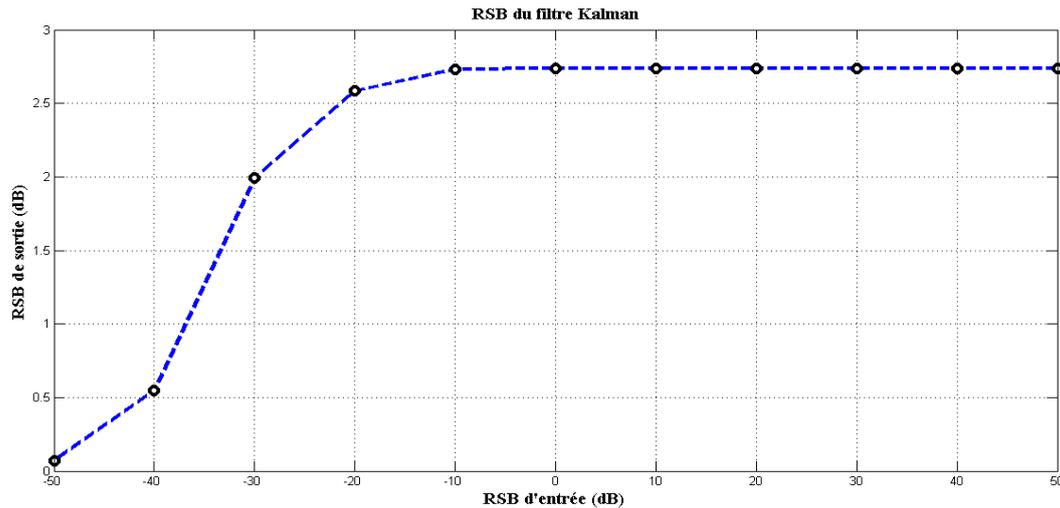


Figure 5-14 : Représentation RSB de sortie en fonction de RSB d'entrée du filtre de Kalman

Le filtre de Kalman est le deuxième filtre qu'on va utiliser dans la partie prétraitement de notre chaîne de traitement. Il est aussi une méthode dépendante des données et flexible qui peut être adaptée aux données. On observe aussi dans les figures 5.10 et 5.11 que les signaux obtenus à la sortie de Kalman sont plus lisses que le signal d'entrée. La Figure 5-13 montre une atténuation de certaines parties du signal et une amplification d'autres pour un RSB = -30 dB mais les événements contenus dans le signal sont conservés.

La Figure 5-14 détermine le RSB de sortie en fonction du RSB d'entrée. Elle montre que les valeurs du RSB de sortie augmentent progressivement et considérablement en fonction des valeurs du RSB d'entrée dans la plage [-50 dB, -10 dB]. A partir de -10 dB, les valeurs du RSB de sortie sont constantes. Le filtre de Kalman conserve la morphologie des EPICs pour des $RSB \geq -10$ dB.

5.3. La détection des EPICs

Dans cette partie, nous présentons les résultats de test des détecteurs proposés. Les tests s'effectuent sur plusieurs signaux de morphologies différentes. *Ces signaux sont extraits de l'enregistrement des signaux EEG de deux patients (P1 et P2) souffrant d'une épilepsie pharmaco-résistante du lobe temporal.* Pour évaluer la performance de ces détecteurs, nous utilisons plusieurs indices. Par définition, les fausses alarmes (FA) nous donnent les parties détectées alors qu'elles ne sont pas des EPICs. Quant aux bonnes détections (BD), elles nous renseignent sur les EPICs qui ont été bien détectées. Enfin, les non détections (ND) représentent les EPICs non trouvés par le détecteur.

- Le taux de fausses (FA) alarmes se calcule comme suit : $T_{FA} = \frac{FA}{BD+FA}$

- La sensibilité (ou taux de bonnes détections) est une mesure de la capacité du détecteur à détecter les EPICs : $sensibilité = T_{BD} = \frac{DB}{BD+ND}$
- La sélectivité est une mesure de la capacité du détecteur à rejeter les fausses alarmes $sélectivité = \frac{BD}{BD+FA} = 1 - T_{FA}$

Les méthodes de détection sont souvent basées sur le principe du seuillage décidant de la détection des événements si une mesure quelconque dépasse un seuil prédéterminé. Plus ce seuil est élevé, moins l'algorithme est permissif et si les fausses alarmes diminuent, la sensibilité peut quant à elle chuter.

De même, un algorithme de détection nécessite une troisième mesure, il s'agit du délai de détection (DD), c'est-à-dire l'écart temporel entre le début réel de la pointe au point de vue électrique (à l'EEG, pas au niveau clinique donc) et le moment auquel elle est détectée.

$$DD = |t_{pointe} - t_{algo}| \quad (5.2)$$

Avec t_{pointe} le moment réel du début de la pointe et t_{algo} celui donné par l'algorithme de détection. Ce dernier indicateur de performance est calculé pour chaque EPIC et évalue la capacité de l'algorithme à détecter rapidement un EPIC.

Finalement, en tenant compte de ces indicateurs de performance, nous tracerons les courbes ROC (Receiver Operating Characteristics) ou COR (Caractéristiques Opérationnelles de Réception) pour chaque détecteur.

La Figure 5-15 représente les blocs de simulation de la détection des EPICs contenus dans un signal EEG. Nous appliquons un filtre (SSA ou Kalman) avant d'utiliser le détecteur concerné.

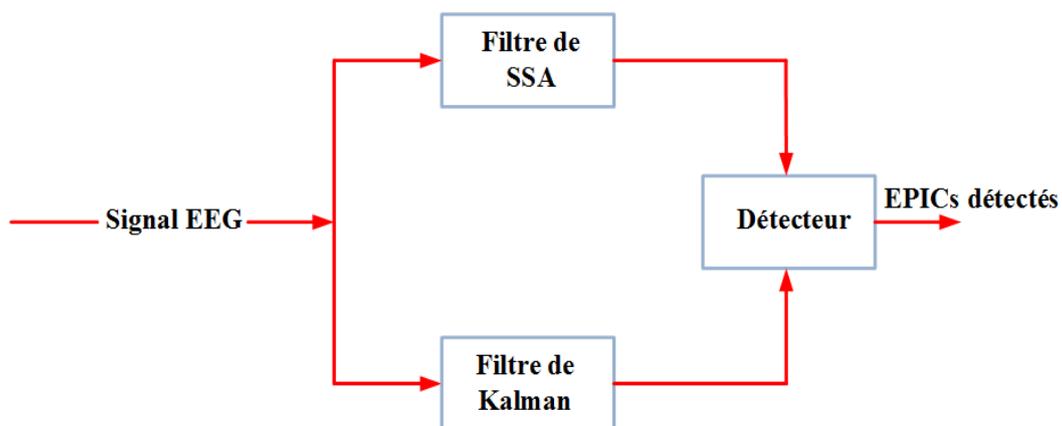


Figure 5-15 : Schéma de simulation de la détection des EPICs

5.3.1. Résultats de la détection avec l’algorithme de Page Hinkley

L’algorithme de Page Hinkley a plusieurs paramètres d’entrée. Le paramètre qui a plus d’influence sur la détection est $\nu = \text{médiane}(\text{signal}(t)).(RSB - 1)$. Ce dernier dépend de la valeur médiane estimée sur le signal entier, il est impossible de bien choisir le paramètre RSB pour détecter toutes les pointes (de petite et grande amplitude) sans engendrer de nombreuses fausses alarmes.

On utilise le terme RSB pour désigner le paramètre de l’algorithme de Page-Hinkley que l’on fixe avant le lancement de la détection, et non pas le rapport signal/bruit classique (que l’on ne maîtrise pas dans notre cas, puisqu’il s’agit de signaux réels) [5].

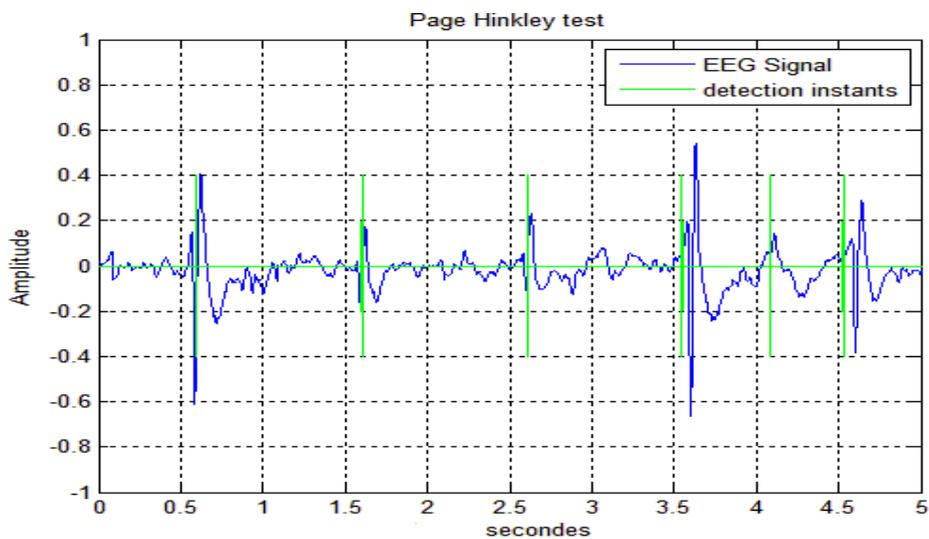


Figure 5-16 : Détection des EPICs NP avec Page Hinkley

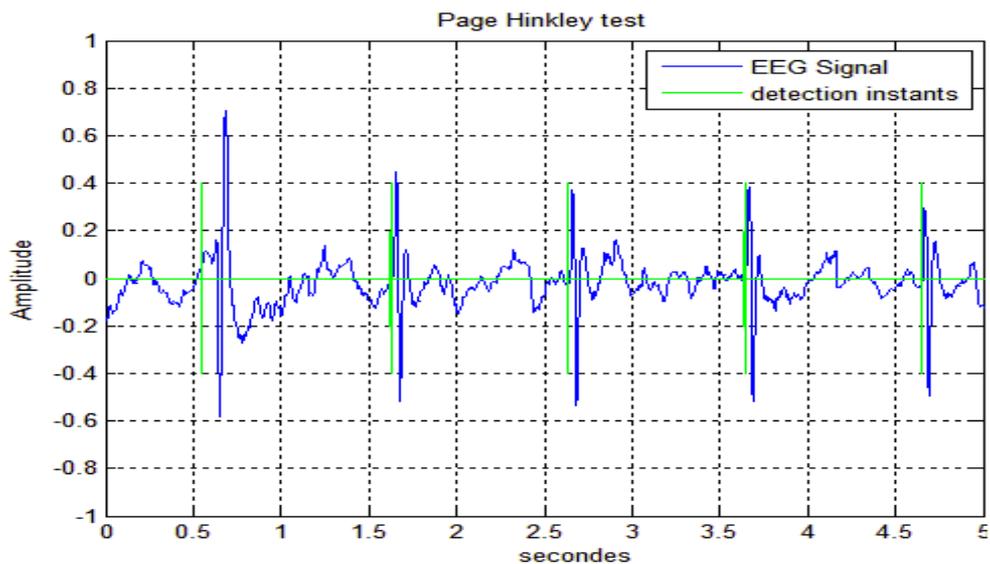


Figure 5-17 : Détection des EPICs PN avec Page Hinkley

On observe aux figures 5-16 et 5-17 (Figure 5-16 et Figure 5-17) des EPICS (bleu) avec leurs instants de détection (vers). Les tableaux 5-1 et 5-2 nous donnent les différentes valeurs moyennes des indicateurs de performance. Nous utilisons dans ces tableaux les données des patients (P1 et P2) avec des RSB différents. En plus nous testons l'algorithme avec plusieurs valeurs du RSB. Dans le Tableau 5-1, on remarque que l'algorithme de Page Hinkley avec le filtre SSA a un taux de fausses alarmes important pour les RSB < 0. Mais la sensibilité a atteint son maximum. Quand les RSB > 0, les résultats sont très satisfaisants. Par conséquent, pour les données de P1, le couple Page Hinkley et SSA présente les meilleurs résultats de la détection des EPICs.

Nous retrouvons presque les mêmes performances sur le Tableau 5-2 (données de P2).

Par conséquent, les valeurs de ces tableaux sont utilisées pour tracer les courbes ROC (Figure 5-18 et Figure 5-19).

Tableau 5-1 : Performances moyennes de la détection avec Page Hinkley (données de P1)

Méthodes	Paramètres	-30 dB	-10 dB	0 dB	20 dB	40 dB	60 dB
Page Hinkley et SSA	<i>Sensibilité (%)</i>	91	98	100	100	100	100
	<i>T_{ND} (%)</i>	9	2	0	0	0	0
	<i>T_{FA} (%)</i>	3	5	22	14	11	8
	<i>Sélectivité (%)</i>	97	95	78	86	89	92
Page Hinkley et Kalman	<i>Sensibilité (%)</i>	87	93	98	100	100	100
	<i>T_{ND} (%)</i>	13	10	7	0	0	0
	<i>T_{FA} (%)</i>	6	15	17	20	22	26
	<i>Sélectivité (%)</i>	94	85	83	83	78	74

Tableau 5-2 : Performances moyennes de la détection avec Page Hinkley (données de P2)

Méthodes	Paramètres	-30 dB	-10 dB	0 dB	20 dB	40 dB	60 dB
Page Hinkley et SSA	<i>Sensibilité (%)</i>	89	98	99	100	100	100
	<i>T_{ND} (%)</i>	11	2	1	0	0	0
	<i>T_{FA} (%)</i>	1	5	12	22	17	13
	<i>Sélectivité (%)</i>	99	95	88	78	83	87
Page Hinkley et Kalman	<i>Sensibilité (%)</i>	75	92	97	99	100	100
	<i>T_{ND} (%)</i>	25	8	3	1	0	0
	<i>T_{FA} (%)</i>	3	7	11	16	23	17
	<i>Sélectivité (%)</i>	97	93	89	84	77	83

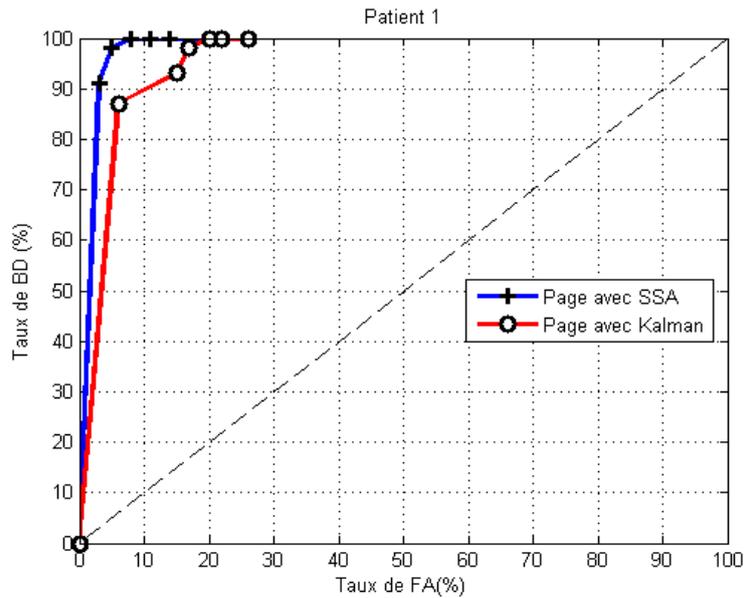


Figure 5-18 : Courbes de performances de Page Hinkley avec des données de P1

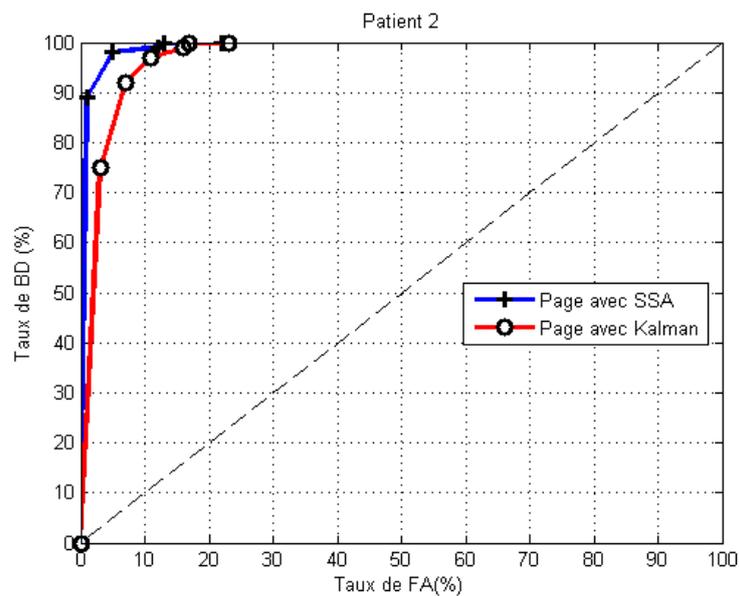


Figure 5-19 : Courbes de performances de Page Hinkley avec des données de P2

Les figures 5-18 et 5-19 (Figure 5-18 et Figure 5-19) représentent les courbes ROC du détecteur de Page Hinkley avec les filtres SSA et Kalman. On constate que les deux courbes ont des points qui sont proches du point de fonctionnement idéal pour un détecteur (point de coordonnées $(0\%, 100\%)$). En comparant les deux couples, le Page Hinkley avec SSA donne les meilleurs points de la représentation de l'espace ROC.

5.3.2. Résultats de la détection avec le SNEO

Contrairement à la méthode de Page Hinkley, le SNEO ne demande pas beaucoup de paramètres à l'entrée. Il suffit de donner la largeur de la fenêtre de lissage et du paramètre

d'estimation du seuil adaptatif. Sur les figures 5-20 et 5-21 (Figure 5-20 et Figure 5-21), nous avons le signal EEG (bleu) avec les instants de détection des EPICs (vert) [108].

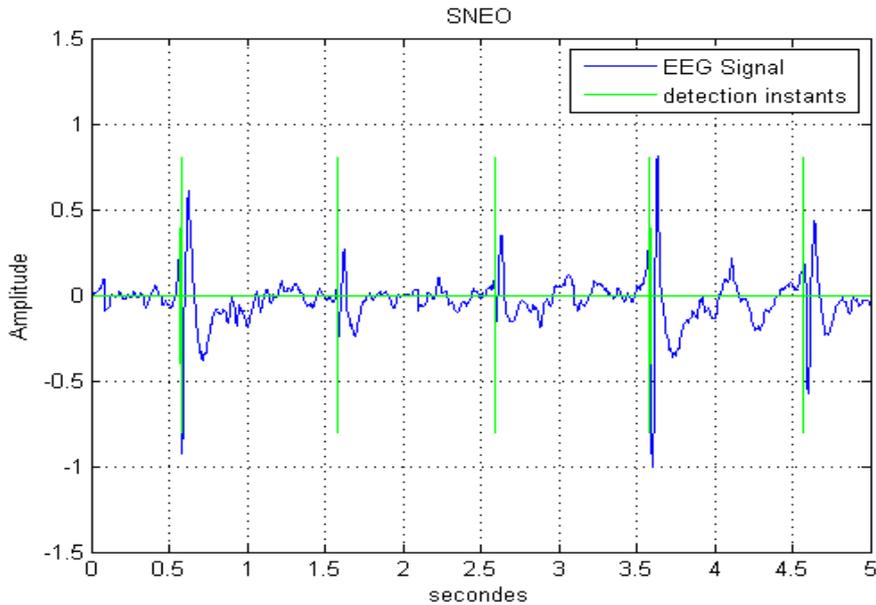


Figure 5-20 : Détection des EPICs NP avec SNEO

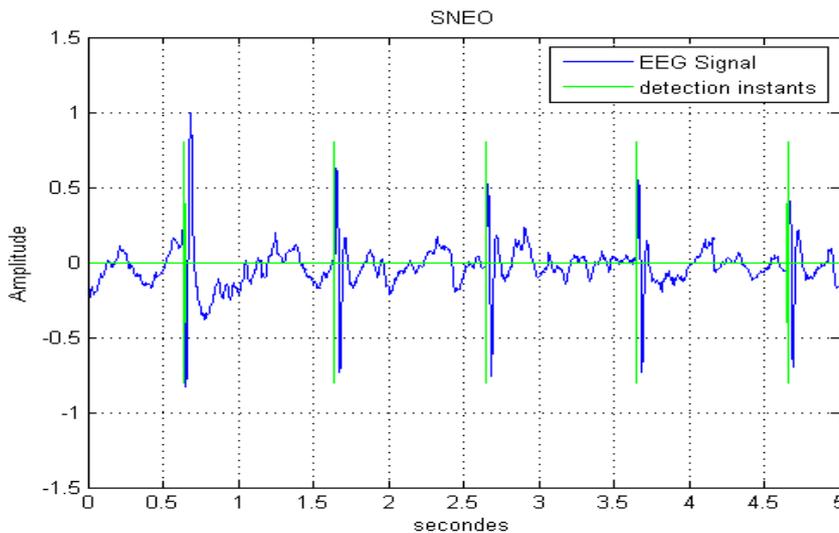


Figure 5-21 : Détection des EPICs PN avec SNEO

Les tableaux 5-3 et 5-4 représentent les moyennes des indicateurs de performance de la méthode SNEO avec les filtres de SSA et de Kalman. Pour différentes valeurs du RSB, les indicateurs sont calculés. Pour un RSB élevé, SNEO est une très bonne méthode pour détecter les EPICs, mais si le bruit augmente, la performance de cette méthode sera réduite de manière significative car il amplifie en même temps le signal utile et le bruit. Dans l'ordre de résoudre ces problèmes, nous utilisons les filtres de SSA et de Kalman. En plus, quand les $RSB > 0$, SNEO avec le filtre SSA donne les meilleurs résultats concernant la sensibilité et la sélectivité (voir tableaux 5-3 et 5-4).

Tableau 5-3 : Performances moyennes de la détection avec SNEO (données de P1)

Méthodes	Paramètres	-30 dB	-10 dB	0 dB	20 dB	40 dB	60 dB
SNEO et SSA	<i>Sensibilité (%)</i>	96	100	100	100	100	100
	<i>T_{ND} (%)</i>	4	0	0	0	0	0
	<i>T_{FA} (%)</i>	3	20	12	9	6	4
	<i>Sélectivité (%)</i>	97	80	88	92	96	99
SNEO et Kalman	<i>Sensibilité (%)</i>	95	99	100	100	100	100
	<i>T_{ND} (%)</i>	5	1	0	0	0	0
	<i>T_{FA} (%)</i>	6	9	26	19	13	11
	<i>Sélectivité (%)</i>	94	85	74	81	87	93

Tableau 5-4 : Performances moyennes de la détection avec SNEO (données de P2)

Méthodes	Paramètres	-30 dB	-10 dB	0 dB	20 dB	40 dB	60 dB
SNEO et SSA	<i>Sensibilité (%)</i>	100	100	100	100	100	100
	<i>T_{ND} (%)</i>	0	0	0	0	0	0
	<i>T_{FA} (%)</i>	35	23	16	13	6	2
	<i>Sélectivité (%)</i>	65	77	84	87	94	97
SNEO et Kalman	<i>Sensibilité (%)</i>	98	100	100	100	100	100
	<i>T_{ND} (%)</i>	3	0	0	0	0	0
	<i>T_{FA} (%)</i>	4	27	20	11	8	6
	<i>Sélectivité (%)</i>	96	73	80	89	92	94

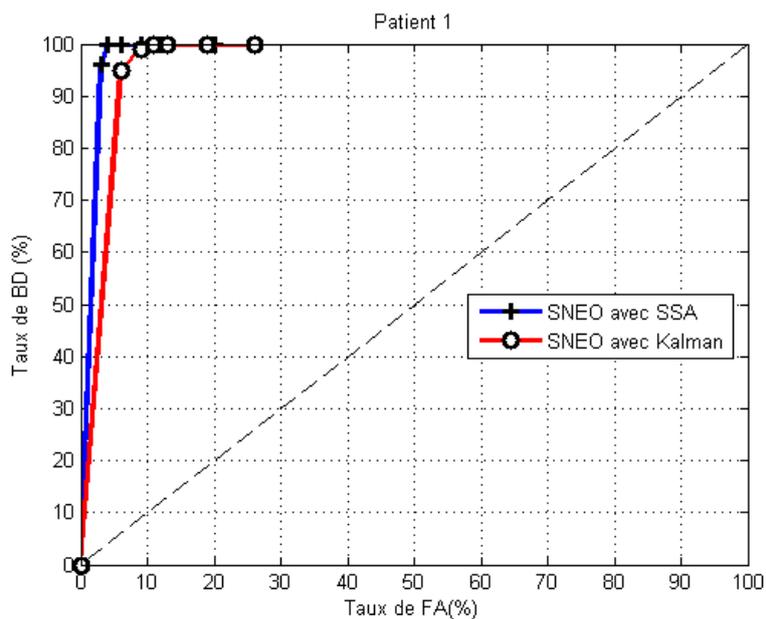


Figure 5-22 : Courbes de performances de SNEO avec des données de P1

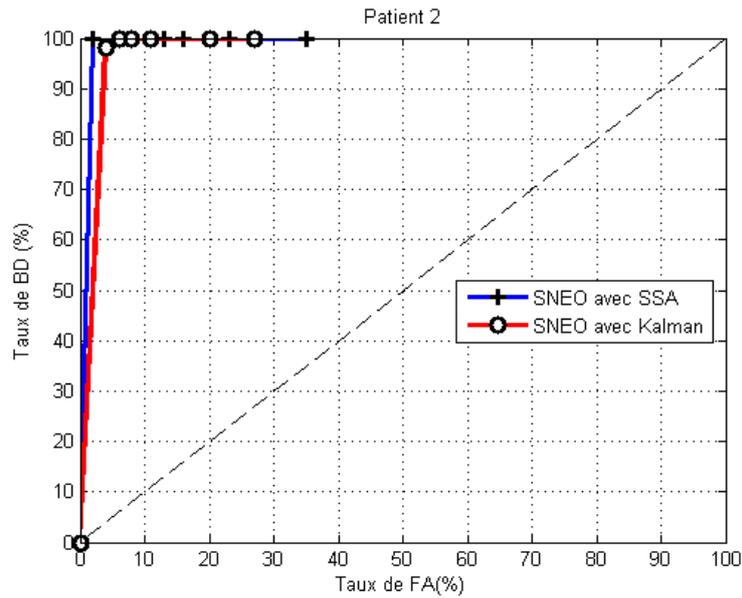


Figure 5-23 : Courbes de performances de SNEO avec des données de P2

Pour confirmer cela, nous avons tracé dans l'espace ROC (Figure 5-22 et Figure 5-23) les points représentant les indicateurs de performance du détecteur. Les courbes ROC représentent les performances de SNEO avec les filtres SSA et de Kalman. On constate l'existence de points qui sont proches du point idéal (0 %, 100 %) pour les deux courbes. En effet, SNEO et SSA a le meilleur point surtout pour les données de P2 (2 %, 100 %).

5.3.3. Résultats de la détection avec la dimension fractale

Dans cette partie, nous présentons les résultats de la détection d'EPICs obtenus avec la méthode FD.

Les figures 5-24 et 5-25 (Figure 5-24 et Figure 5-25) illustrent quelques EPICs détectées (nous avons en bleu et en vert, respectivement le signal EEG et les instants de détection des EPICs) par la méthode FD. On remarque aussi comme les méthodes précédentes, La FD donne des résultats satisfaisants avec un seuil adaptatif. En plus, le paramétrage de la méthode FD est plus simple que les deux autres méthodes précédemment utilisées. Donc l'utilisateur n'aura pas besoin d'ajuster certains paramètres pour avoir une bonne détection [29].

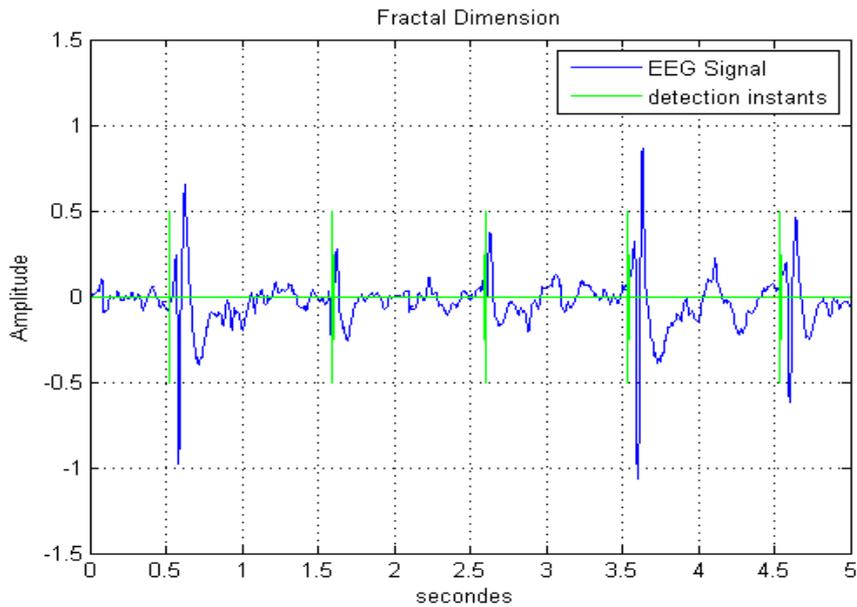


Figure 5-24 : Détection des EPICs NP avec Dimension Fractale

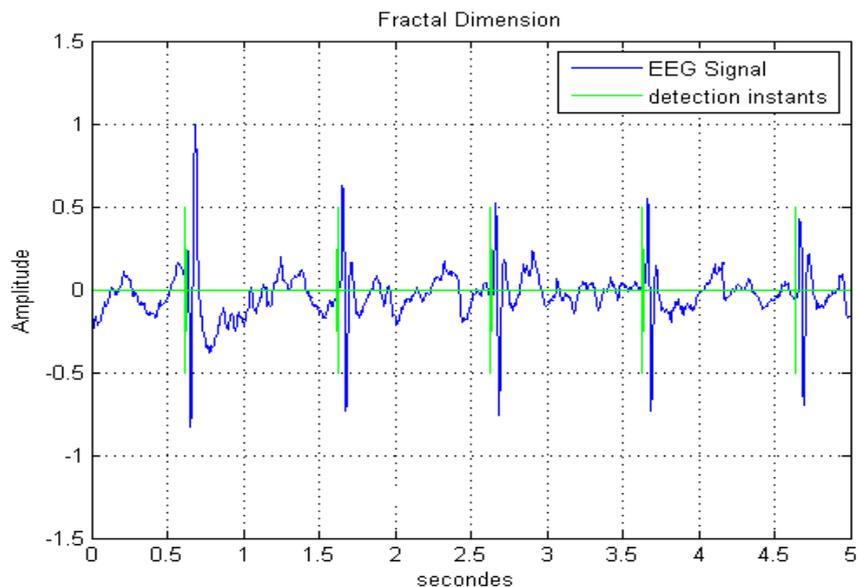


Figure 5-25 : Détection des EPICs PN avec Dimension Fractale

Sur les tableaux 5-5 et 5-6, nous représentons les moyennes des indicateurs de performance de la méthode FD avec les filtres de SSA et de Kalman. Pour différentes valeurs du RSB, les indicateurs sont calculés.

La méthode FD avec le filtre de Kalman présente une bonne sensibilité ; mais la détection est accompagnée d'un taux de fausses alarmes important. Cependant, La FD avec SSA nous donne les mêmes sensibilités mais le taux de fausses alarmes est moins important. Les deux couples donnent des résultats satisfaisants par rapport à la sensibilité et à la sélectivité pour des RSB positifs.

Tableau 5-5 : Performances moyennes de la détection avec FD (données de P1)

Méthodes	Paramètres	-30 dB	-10 dB	0 dB	20 dB	40 dB	60 dB
FD et SSA	<i>Sensibilité (%)</i>	90	97	99	100	100	100
	T_{ND} (%)	10	3	0	0	0	0
	T_{FA} (%)	2	5	7	23	11	8
	<i>Sélectivité (%)</i>	98	95	93	77	89	92
FD et Kalman	<i>Sensibilité (%)</i>	85	92	96	100	100	100
	T_{ND} (%)	15	8	4	0	0	0
	T_{FA} (%)	7	11	17	43	28	23
	<i>Sélectivité (%)</i>	93	89	83	57	72	77

Tableau 5-6 : Performances moyennes de la détection avec FD (données de P2)

Méthodes	Paramètres	-30 dB	-10 dB	0 dB	20 dB	40 dB	60 dB
FD et SSA	<i>Sensibilité (%)</i>	94	99	100	100	100	100
	T_{ND} (%)	6	1	0	0	0	0
	T_{FA} (%)	1	4	22	15	11	6
	<i>Sélectivité (%)</i>	99	96	78	85	89	94
FD et Kalman	<i>Sensibilité (%)</i>	89	97	100	100	100	100
	T_{ND} (%)	11	3	0	0	0	0
	T_{FA} (%)	4	11	56	37	21	17
	<i>Sélectivité (%)</i>	96	89	44	63	79	83

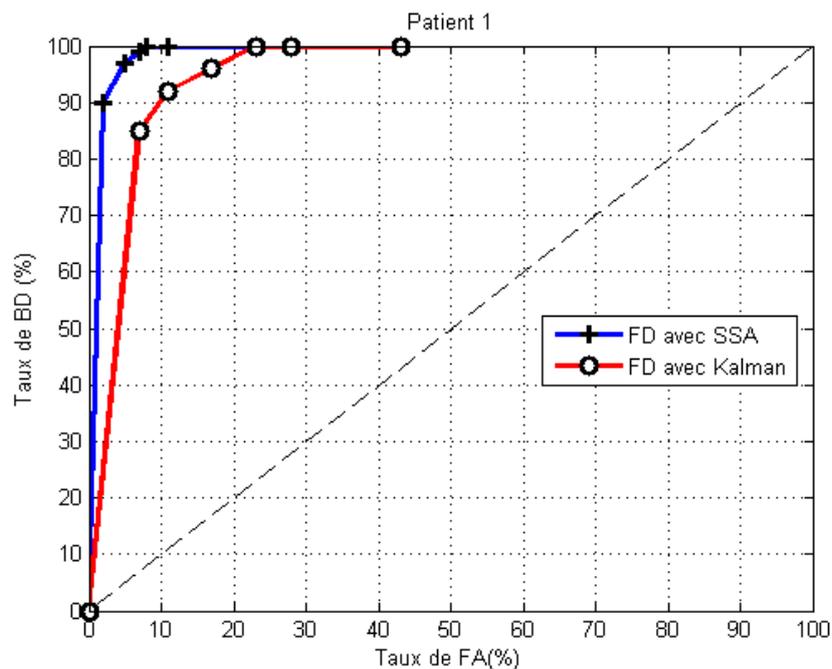


Figure 5-26 : Courbes de performances de FD avec des données de P1

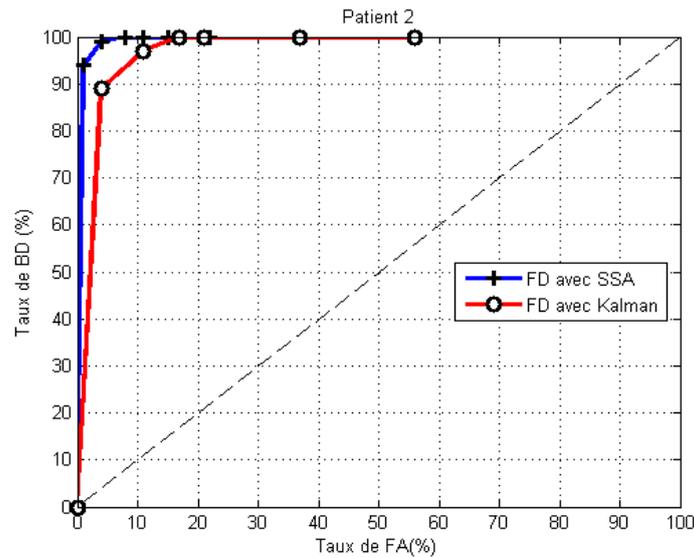


Figure 5-27 : Courbes de performances de FD avec des données de P2

Nous avons utilisé les résultats de ces tableaux pour tracer dans l'espace ROC (Figure 5-26 et Figure 5-27) les points représentant les indicateurs de performance du détecteur. On constate qu'il y a aussi des points qui sont proches du point idéal. On remarque aussi que la FD avec SSA donne de bons résultats pour la sensibilité et la sélectivité.

Par conséquent, les courbes de performances nous montrent que quel que soit le niveau de bruit dans le signal, les détecteurs proposés nous donnent des résultats satisfaisants en termes de sensibilité et de sélectivité. Par ailleurs, nous allons comparer les trois méthodes proposées utilisant le filtre SSA. Ce dernier a montré sa robustesse face aux signaux bruités. Nous présentons alors les performances des détecteurs pour les données des deux patients étudiés (P1 et P2). Les figures 5-28 et 5-30 (Figure 5-28 et Figure 5-30) nous donnent la représentation des trois détecteurs dans l'espace ROC.

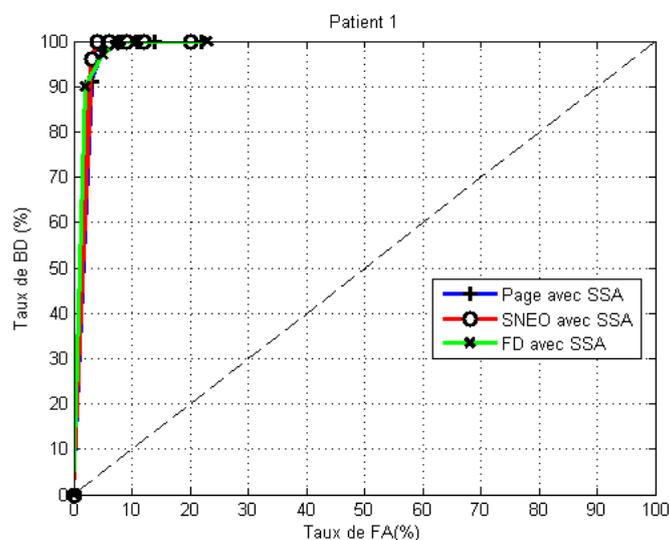


Figure 5-28 : Performances des trois détecteurs avec des données de P1

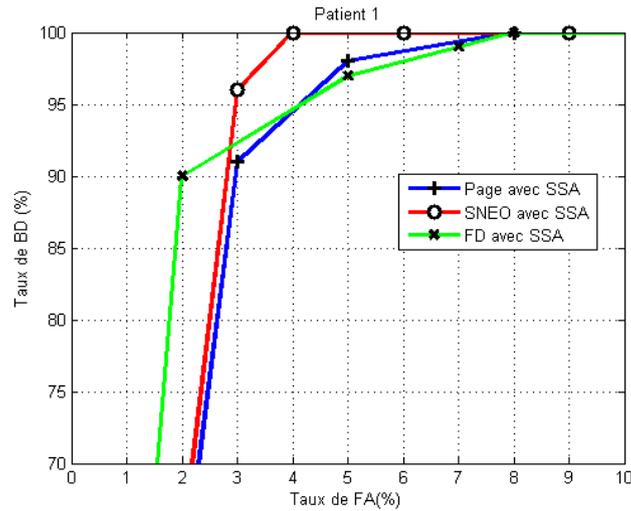


Figure 5-29 : Zoom des performances de trois détecteurs avec les données de P1

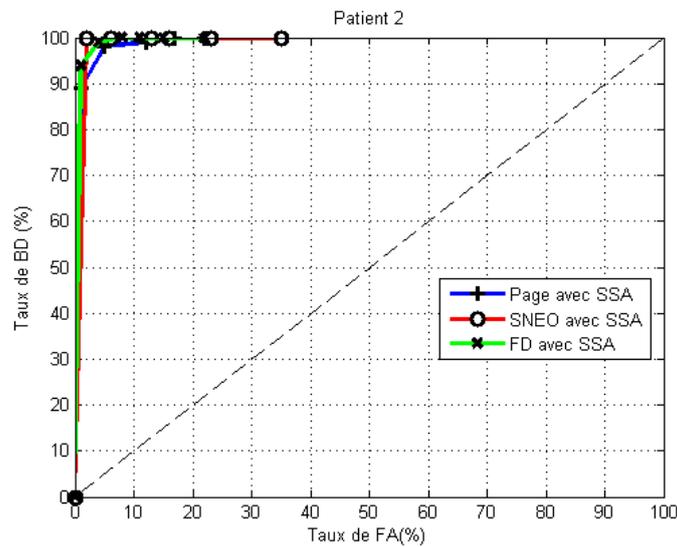


Figure 5-30 : Performances des trois détecteurs avec des données de P2

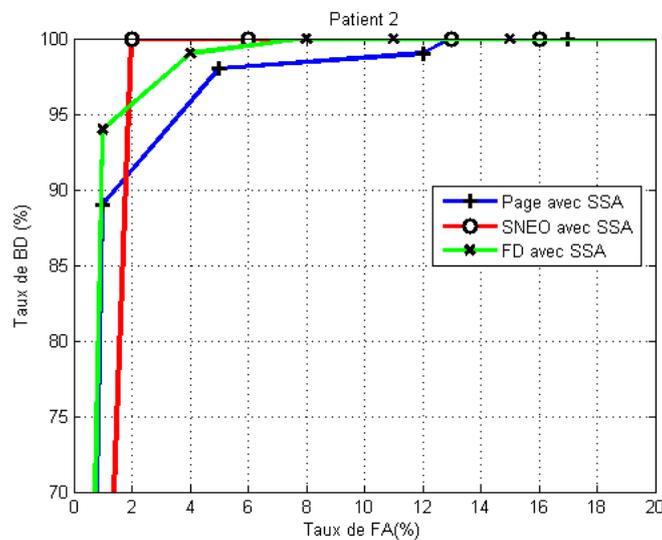


Figure 5-31 : Zoom des performances des trois détecteurs avec les données de P2

Tableau 5-7 : Temps moyen d'exécution des trois détecteurs sur des signaux d'une heure

<i>Méthodes</i>	<i>Temps (secondes)</i>
Page Hinkley	4.5
SNEO	5.9
FD	180

Pour mieux voir la différence de représentation des trois détecteurs, nous avons fait un zoom sur la partie idéale d'un bon détecteur (Figure 5-29 et Figure 5-31). On voit sur les figures que la courbe de la méthode SNEO est au-dessus des autres et présente les meilleurs points dans l'espace ROC.

Nous avons aussi estimé le temps d'exécution de chacune des trois méthodes sur des données EEG d'une heure (Tableau 5-7).

La différence majeure entre le Page Hinkley et les autres se trouve sur le nombre de paramètres à l'entrée de l'algorithme. En plus l'utilisateur doit avoir des connaissances de base sur les signaux EEG pour pouvoir bien ajuster les paramètres. Cependant, la méthode FD prend trop de temps quand la durée du signal augmente (Tableau 5-7). Cela peut s'expliquer du fait que l'on calcule toujours les dimensions fractales des deux fenêtres glissantes avant de faire leur différence. Cette différence est comparée au seuil adaptatif pour déterminer la présence ou pas d'un EPIC. Ce qui diminue les performances de la méthode FD en termes de temps d'exécution.

En conclusion, la méthode SNEO répond mieux aux critères de sélection d'un bon détecteur en termes de sensibilité, de sélectivité et de temps d'exécution.

Après l'étape de la détection, les sections 5.4 et 5.5 déterminent l'identification et la classification des EPICs extraits. La Figure 5-32 illustre les étapes de la simulation des EPICs extraits, triés et classifiés.

5.4. La classification des EPICs

La classification représente la dernière étape de notre chaîne de traitement des signaux EEG. Avant de classer les EPICs, nous les extrayons en utilisant une fenêtre de largeur 0.5 seconde. Les EPICs extraits sont stockés dans un fichier texte pour faciliter leur rechargement sous Matlab.

Les données des patients P1 et P2 utilisées dans cette partie contiennent des centaines d'EPICs de type P, PP, N, NN, NP, PN, PO, PPO, NO, NNO, NPO et PNO.

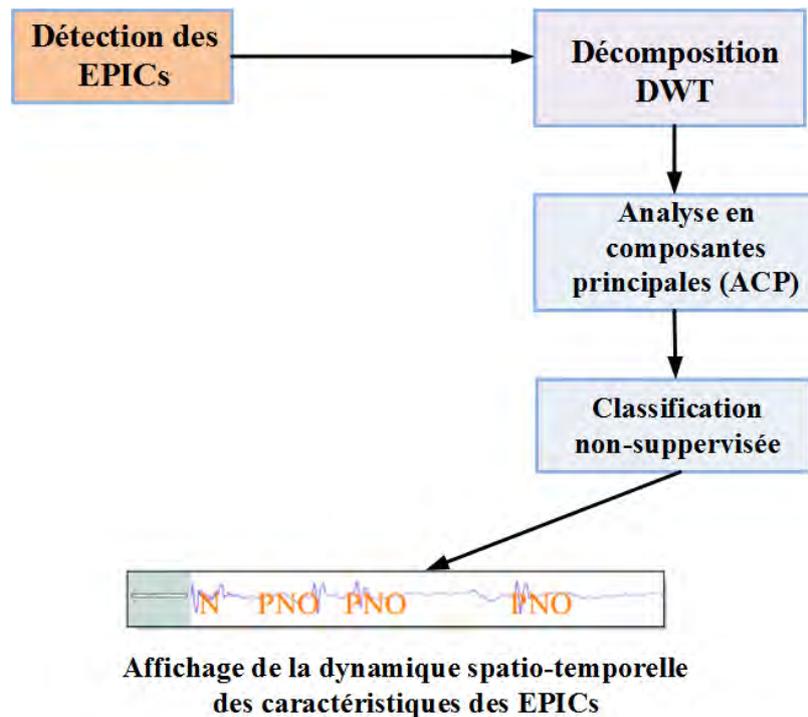


Figure 5-32 : Schéma de simulation pour l'identification et la classification des EPICs

Par ailleurs, d'après les experts, on rencontre en pratique rarement plus de 3 morphologies d'EPICs très différentes sur une heure d'enregistrement. On évaluera notre classificateur sur des mélanges de 3 types d'EPICs au maximum.

Comme l'explique très bien [126], « l'évaluation de la pertinence des groupes formés en classification non supervisée reste un problème ouvert. La difficulté vient principalement du fait que l'évaluation des résultats d'algorithmes de clustering est subjective par nature car il existe souvent différents regroupements pertinents possibles pour un même jeu de données ». Les résultats de la classification dépendent des décisions de l'expert. Cela signifie que les EPICs que nous utilisons ont été étiquetés par l'expert. Par conséquent, nous utilisons les indices de la matrice de confusion définie à la section 4.4.3 du document. Donc, on définit deux paramètres importants :

- T_{BC} : taux de bonne classification sur des EPICs.
- T_{EC} : taux d'erreurs (taux de fausse alarme) de classification sur des EPICs.

Nous appliquons d'abord l'algorithme de k-means sur des données générées de manière aléatoire. La Figure 5-33 montre un jeu de données regroupé et classifié au tour du centroïde.

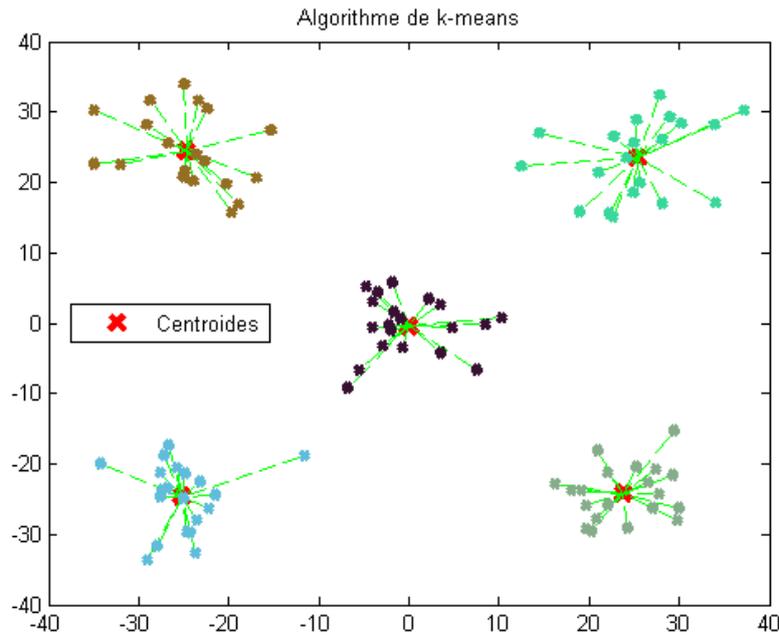


Figure 5-33 : Exemple de clustering des données aléatoires

Sur la Figure 5-33, nous remarquons que tous les points qui ont les mêmes caractéristiques sont représentés au tour de leur centroïde (même classe) respectif (5 au total).

Comme un EPIC est représenté par un vecteur, leur classification ne semble pas facile puisque dans un mélange, il peut y avoir des confusions sur des nombres à traiter. Face à cela, nous avons intégré dans notre chaîne la représentation en composantes principales. Cette méthode nous permettra d'identifier les différents EPICs appartenant à une même classe. Pour mieux illustrer cela, nous avons implémenté un algorithme qui permettra de tracer sur la même fenêtre les classes et les clusters en 2D sur le plan principal de la technique d'analyse en composantes principales (ACP). C'est une méthode fondamentale en statistique descriptive multidimensionnelle.

Cette technique est basée sur la réduction des attributs. Elle calcule dans un premier temps la matrice de corrélation R (ou matrice des variances-covariances) des N_a attributs. Dans un second temps, elle recherche les valeurs propres λ_i et les vecteurs propres v_i de R . Pour finir, elle sélectionne parmi les N attributs les N_{ACP} qui ont la plus grande valeur propre [127]. Il s'agit donc d'obtenir le résumé le plus pertinent des données initiales.

La représentation en 2 dimensions est faite grâce aux 2 premières grandes valeurs propres. Ces dernières déterminent les facteurs (composantes principales) qui restituent à eux seuls la quasi-totalité de la dispersion du nuage de points. En plus, les axes passant par l'origine 0 sont engendrés par les vecteurs propres associés aux valeurs propres choisies. Ces axes doivent passer le mieux possible au milieu des nuages. Ils ne sont pas en corrélation.

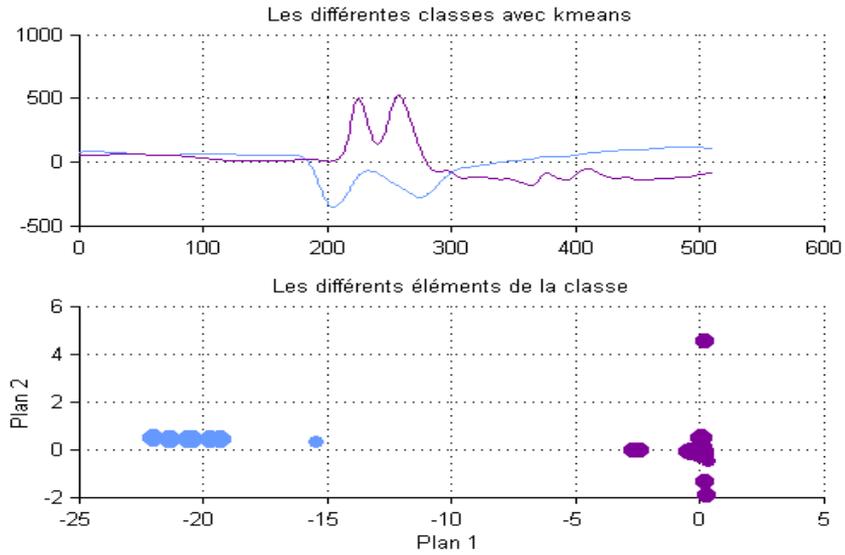


Figure 5-34 : Clustering d'un mélange de 2 EPICs (NN et PP)

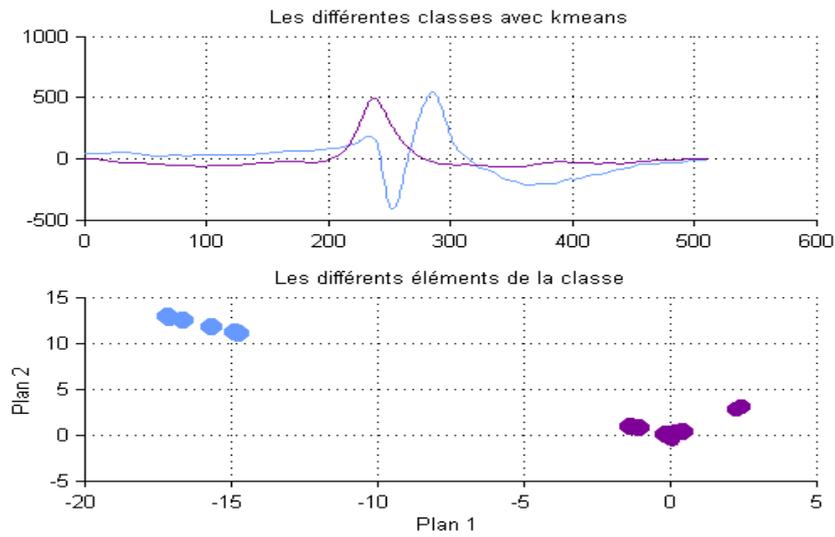


Figure 5-35 : Clustering d'un mélange de 2 EPICs (P et NPO)

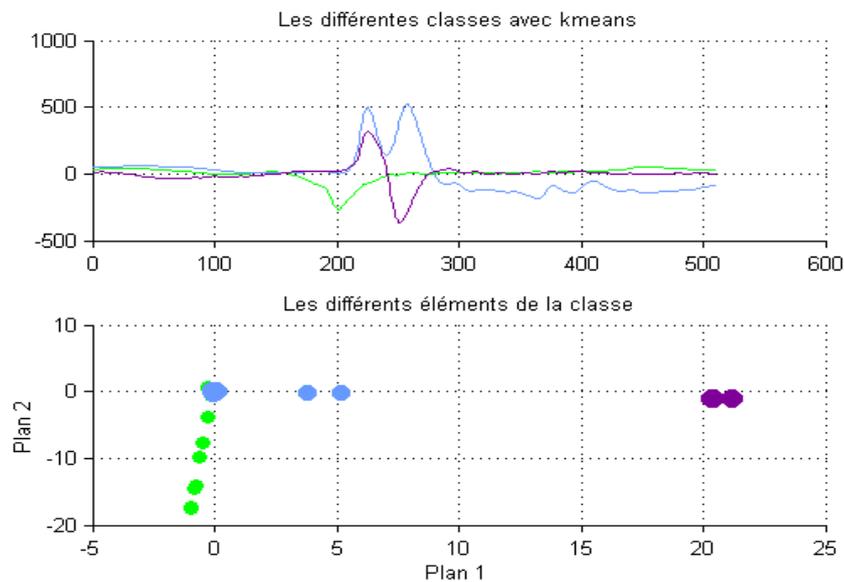


Figure 5-36 : Clustering d'un mélange de 3 EPICs (N, PN et PP)

Les figures 5-34, 5-35 et 5-36 (Figure 5-34, Figure 5-35 et Figure 5-36) nous montrent la classification des différents EPICs dans un mélange donné. Dans chaque figure, nous pouvons bien identifier les clusters correspondant à chaque EPIC [108]. Ces clusters nous donnent la représentation en composantes principales des différents EPICs. Nous remarquons que la position des clusters correspond exactement à la morphologie des EPICs classifiés. La bonne répartition des clusters dépend de la performance de l'algorithme de k-means. Comme nous l'avons mentionné plus haut, les meilleures exécutions ont été choisies. Ces figures nous montrent que les EPICs mélangés ont été bien classifiés.

En plus nous avons appliqué notre algorithme sur plusieurs mélanges à 2 et 3 EPICs. Par rapport aux meilleures exécutions, nous obtenons les résultats dans les tableaux 5-8, 5-9 et 5-10 (Tableau 5-8, Tableau 5-9 et Tableau 5-10). Nous ne présentons que les valeurs moyennes des taux de bonne détection et de fausses alarmes pour chaque EPIC donné.

Tableau 5-8 : Performance de classification des mélanges de 2 EPICs (données de P1 et de P2)

Taux (%)	P1 (NN et PP)		P1 (P et NPO)		P2 (N et PN)		P2 (PO et NO)	
	NN	PP	P	NPO	N	PN	PO	NO
T _{BC}	93	97	100	98	87	80	98	95
T _{FA}	6	12	22	12	6	2	18	12
T _{BC} moy	95		99		83.5		97	
T _{FA} moy	9		17		4		15	
<i>Sélectivité</i>	91		83		83		85	

Tableau 5-9 : Performance de classification des mélanges de 3 EPICs (données de P1)

Taux (%)	PN, N et PP			P, NO et NPO			PN, P et NNO		
	PN	N	PP	P	NO	NPO	PN	P	NNO
T _{BC}	96	99	98	75	67	86	89	92	81
T _{FA}	11	22	16	6	4	10	9	13	7
T _{BC} moy	97.66			76			87.33		
T _{FA} moy	16.33			6.66			9.66		
<i>Sélectivité</i>	83.67			93.34			90.34		

Tableau 5-10 : Performance de classification des mélanges de 3 EPICs (données de P2)

	N, NN et PPO			PO, PPO et NNO			N, PNO et P		
Taux (%)	N	NN	PPO	PO	PPO	NNO	N	PNO	P
T _{BC}	90	87	96	98	99	97	78	80	83
T _{FA}	15	9	17	17	26	13	4	6	12
T _{BC} moy	91			98			80.33		
T _{FA} moy	13.66			18.66			7.33		
<i>Sélectivité</i>	86.34			81.34			92.67		

Les tableaux ci-dessus nous donnent les performances de notre algorithme de k-means selon le type de mélange. Pour les mélanges à 2 EPICs, nous avons de bonnes combinaisons entre la sensibilité et la sélectivité ((93% et 94%) pour l'identification et la classification de la morphologie NN du mélange PP et NN des données de P1). Nous nous remarquons que pour les mélanges à 3 EPICs, nous retrouvons de bonnes combinaisons mais pour certains mélanges, la performance de l'algorithme a un peu baissé. Par exemple pour le mélange P, NO et NPO, le couple (76% 93.34%) donne la performance moyenne de la classification des différentes morphologies. Cela est dû à une confusion entre les EPICs c'est-à-dire ceux qui ont des parties morphologiques identiques.

Nous utilisons les valeurs moyennes des différents indicateurs de performances afin de les représenter dans l'espace ROC (Figure 5-37).

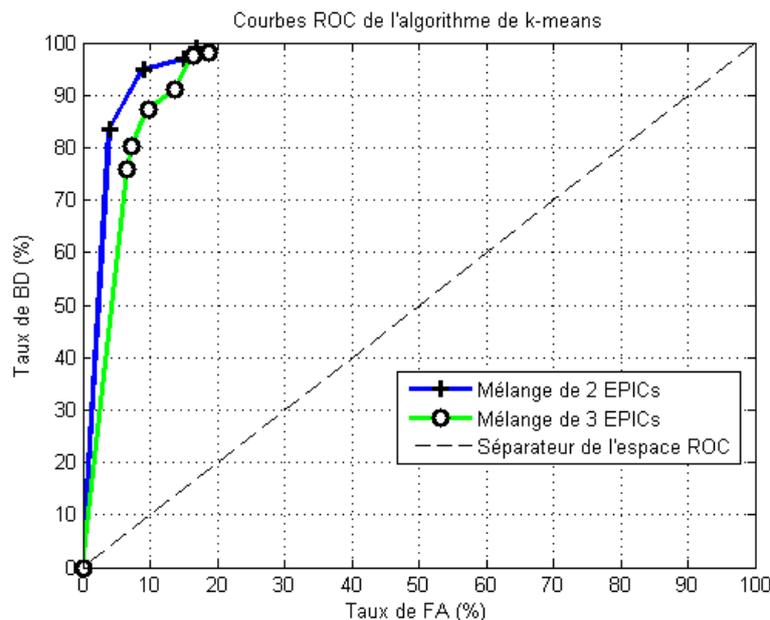


Figure 5-37 : Performances de la classification avec l'algorithme des k-means

Dans la Figure 5-37 la ligne séparatrice (séparateur de l'espace ROC) est la frontière des zones de bonnes classifications (au-dessus) et de mauvaises classifications (au-dessous). Nous voyons que les courbes se trouvent dans la bonne zone de l'espace ROC. La courbe des mélanges à 2 EPICs est au-dessus de celle des mélanges à 3 EPICs. En plus, les points de la courbe à 2 EPICs se trouvent plus au Nord-Ouest (tendant vers le point idéal d'un classificateur) dans l'espace de ROC que ceux des 3 EPICs. Par conséquent, les résultats dans le cas des mélanges à 2 EPICs sont meilleurs que ceux de 3 EPICs. Mais les résultats des mélanges à 3 EPICs sont aussi très satisfaisants. Et notre module de traitement s'applique sur des signaux de durée inférieure ou égale à une heure. On trouve des centaines d'EPICs dans ces signaux qui pourront être classifiés correctement selon leur morphologie. En plus, le temps moyen d'exécution de la classification des différents mélanges de 1032 EPICs est estimé à 48 secondes.

5.5. Détection des ondes lentes

Après la classification des EPICs, nous pouvons déterminer si la pointe est accompagnée d'une onde lente grâce à notre modèle. On obtient ainsi pour différentes valeurs du seuil, les performances présentées dans la Figure 5-38.

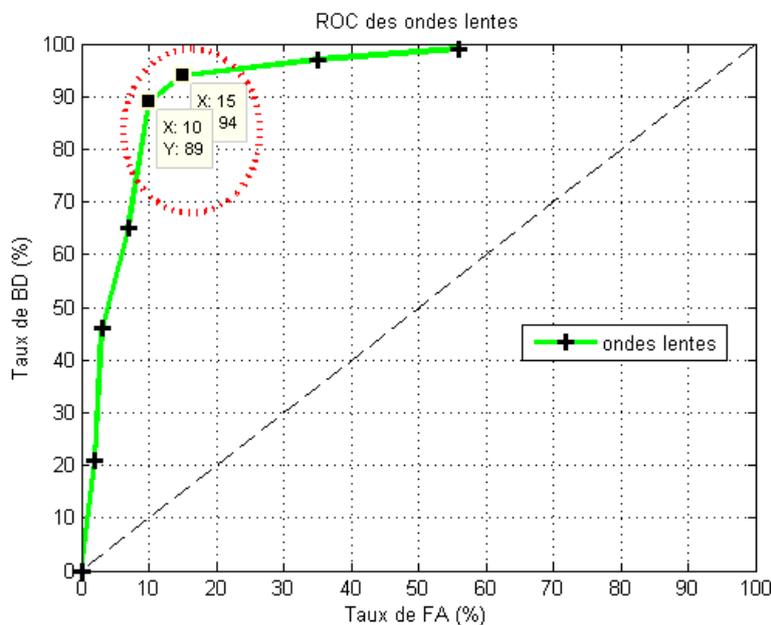


Figure 5-38 : Performances de la détection d'ondes lentes

Nous avons deux valeurs remarquables sur la Figure 5-38 ; elles représentent les meilleurs résultats en termes de sensibilité et de sélectivité ((89 % et 90 %), (94 % et 85 %)). Les seuils correspondant se trouvent dans l'intervalle [2.5, 4].

5.6. Validation de la classification des EPICs sur des données réelles et brutes

L'objectif de cette partie est d'appliquer notre méthode de classification sur des EPICs extraits des signaux EEG réels de durée inférieure ou égale à 1 heure. La classification concerne uniquement des EPICs contenus dans un même signal EEG. D'abord, nous utilisons le filtre SSA pour éliminer les artéfacts du signal. Ensuite nous appliquons la méthode SNEO pour détecter les EPICs présents dans le signal EEG. En plus la densité des EPICs est donnée par le nombre de détection. Tous les instants de détection sont enregistrés dans un fichier texte lors de l'exécution du détecteur. Ces instants d'occurrence sont utilisés pour extraire les EPICs détectés avec une fenêtre de longueur 0.5 seconde. Enfin, l'ensemble des EPICs extraits contenus dans un fichier texte est soumis aux différents blocs de l'identification et la classification de la morphologie des EPICs.

Tous les signaux que nous utilisons présentent au plus deux morphologies différentes après leur identification et classification. Par rapport à la densité des EPICs, nous pouvons faire des estimations statistiques sur la sortie du classificateur pour déterminer les taux de bonnes classifications et de fausses alarmes des différentes morphologies contenues dans un même signal EEG.

La Figure 5-39 donne l'histogramme de la classification de la morphologie des EPICs détectés dans des portions de signaux de durées différentes. Nous avons considéré les EPICs dont la fréquence d'apparition dans les signaux est très élevée (P, NP, PN, N et PNO). Les valeurs inscrites sur l'histogramme représentent les moyennes des taux (en %) de bonne classification et de fausses alarmes [29].

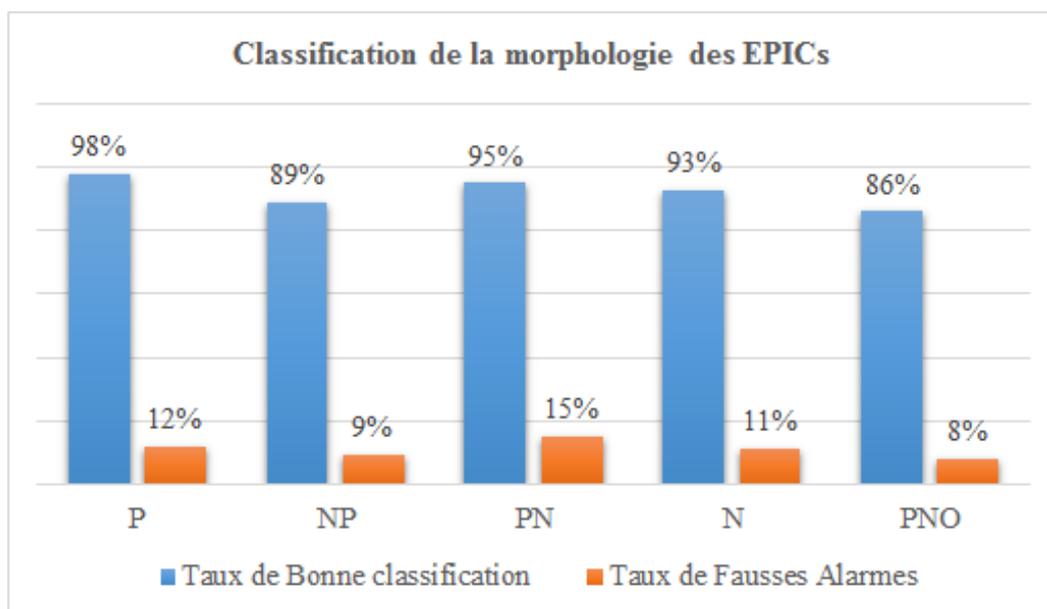


Figure 5-39 : Classification moyenne des EPICs validés

Dans la Figure 5-39, le plus faible taux de bonne classification est 86 % qui est acceptable pour ce type de classification. Les taux de fausses alarmes sont aussi satisfaisants en termes d'erreurs de classification sur des EPICs détectés.

Par conséquent, nous pouvons avoir la distribution spatio-temporelle des EPICs dans un signal EEG grâce aux différentes méthodes testées et validées sur des données réelles. Comme la densité des EPICs peut varier chez un patient ou chez des patients différents, nous pouvons identifier la morphologie des EPICs rencontrés lorsque les crises arrivent. Si les méthodes de traitement sont appliquées sur des données plus importantes avec des patients différents, le lien entre les étapes critiques et intercritiques pourrait être trouvé par rapport à la morphologie des EPICs détectés.

5.7. Conclusion

Ce chapitre présente une application des différentes étapes de la chaîne de traitement sur des données enregistrées chez des patients souffrant d'une épilepsie partielle pharmaco-résistante. Il présente les résultats des différentes simulations effectuées sous Matlab. Les tests sur les filtres par rapport au RSB ont montré que le filtre SSA modifie moins les informations utiles dans les signaux EEG. Les filtres passe-haut et passe-bas présentent des faiblesses pour les signaux très bruités. En effet, ils sont incapables de séparer le bruit et l'évènement (EPIC) sans altérer le signal. Ces filtres modifient la morphologie des EPIC en enlevant les artefacts pour les signaux très bruités. Les filtres de Kalman et SSA ont été choisis pour les combiner avec les différents détecteurs proposés. Les résultats ont montré que le détecteur SNEO avec le filtre SSA nous donne les meilleures performances en termes de sensibilité, de sélectivité et du temps d'exécution. Après la détection et l'extraction des EPICs (filtrage par ondelettes), l'algorithme de k-means associé à l'analyse en composantes principales nous donne des clusters qui représentent exactement la morphologie des pointes concernées. En plus, la représentation dans l'espace ROC nous donne des points proches du point idéal d'un bon classificateur. Grâce à cet indicateur de performance, nous avons pu atteindre en valeurs moyennes 94 % pour le mélange à 2 EPICs contre 88 % dans le cas des mélanges à 3 EPICs. Certains EPICs sont accompagnés d'ondes lentes. Enfin, nous avons pris des portions de signaux de durée inférieure ou égale à 1 heure pour valider le schéma de la classification. L'objectif est de détecter tous les EPICs d'un même signal afin de les identifier et classer pour déterminer les morphologies présentes.

Conclusion générale

Les signaux biomédicaux sont complexes et par conséquent difficiles à analyser. Les outils de traitement du signal développés constituent un complément significatif pour aider les médecins à mieux appréhender les informations contenues dans les données enregistrées chez des patients épileptiques. C'est dans ce contexte que s'inscrit notre travail de thèse qui vise à développer des outils d'aide à la décision (filtrage, détection et identification de la morphologie des EPICs et classification).

Nous avons présenté dans ce document la physiologie du cerveau pour mieux comprendre la génération des activités paroxystiques intercritiques et critiques.

Le cadre général et le contexte de la prise en charge de l'épilepsie ont été présentés ainsi que ses différentes causes et ses différents traitements.

Les méthodes d'investigation et d'exploration de l'épilepsie sont également présentées. Après avoir fait une présentation des événements paroxystiques critiques et intercritiques, nous avons mis en exergue les relations entre ces deux périodes qui constituent une question récurrente et essentielle en épilepsie. Une meilleure réponse à cette question pourrait se baser sur une analyse de la distribution spatio-temporelle des EPICs tout en tenant compte de leur morphologie.

Pour éviter des erreurs d'interprétation des EPICs, il est nécessaire d'appliquer des méthodes de filtrage pour diminuer voire éliminer tous les artefacts contenus dans les signaux EEG lors de leurs acquisitions. Plusieurs filtres ont été proposés. Le filtre SSA est basé sur la décomposition en valeurs singulières de la série chronologique des données. Il a deux étapes principales. La première est l'étape de la décomposition en valeurs singulières des éléments du signal EEG. Les résultats nous permettent de construire la matrice de trajectoire dit matrice de Hankel. Après la décomposition, vient la reconstruction de la série chronologique. Cette partie contient deux étapes, le regroupement et la diagonalisation. Il n'y a pas de standard pour le regroupement, il dépend de l'application et la contribution du bruit. La diagonalisation est la dernière étape de l'analyse de la série chronologique. Le deuxième filtre proposé est celui de Kalman qui est un filtre récursif. Il est beaucoup utilisé dans les systèmes dynamiques. Ce filtre utilise des modèles mathématiques dits stochastiques pour prédire et corriger les informations. La force de ces deux filtres est l'adaptation aux données d'entrées. Enfin, l'application de la décomposition en ondelettes des signaux est présentée. Ces ondelettes sont appliquées aux EPICs détectés et extraits afin de faciliter leur classification. Nous nous sommes intéressés aux ondelettes mères de Daubechies.

Les tests expérimentaux effectués nous montrent la robustesse de ces filtres. Selon le signal d'entrée, nous avons fait varier le RSB de -30 dB à 60 dB. Les résultats nous montrent que le filtre SSA est meilleur que les autres pour la conservation des informations utiles dans les signaux EEG. En plus, pour le filtre SSA, le RSB de sortie varie légèrement en fonction du RSB d'entrée.

Après l'étape de prétraitement, une revue globale des méthodes de détection d'EPICs a été effectuée. Les détecteurs sont classifiés en cinq catégories. En tenant compte de l'existant, nous avons choisi trois méthodes de détection. Le filtre SSA associé à ces détecteurs nous donne les meilleurs résultats en termes de sensibilité et de sélectivité. La première méthode de détection est l'algorithme de Page Hinkley. Elle offre des performances satisfaisantes. En ajustant correctement les paramètres d'entrée, nous avons obtenu une sensibilité moyenne de 98 % et une sélectivité moyenne de 90 %. La méthode SNEO est la deuxième proposition qui donne des performances remarquables. La sensibilité et la sélectivité moyenne sont respectivement égales à l'ordre de 99 % et 92 % sur les tests effectués. La dernière méthode est celle de la dimension fractale qui présente aussi des résultats satisfaisants avec une sensibilité moyenne de 99 % contre 90 % de sélectivité.

Le choix d'un bon détecteur dépend non seulement des indicateurs de performances mais aussi de son temps d'exécution. Bien vrai que ces méthodes nous donnent des résultats très satisfaisants, mais pour le Page Hinkley et la FD, nous rencontrons quelques difficultés lors de leur exécution. La méthode Page Hinkley a un nombre de paramètres important à l'entrée qu'il faudra ajuster pour avoir de bons résultats, ce qui nécessite certaines connaissances sur les signaux EEG. Quant à la méthode FD, son seul problème se trouve sur le temps d'exécution. Dans les mêmes conditions d'exécution (durée du signal, machine) que les deux autres méthodes, la durée d'exécution de la méthode FD est 36 fois plus longue que celles des deux autres. Enfin, notre choix porte sur le SNEO puisqu'il répond à tous les critères d'un bon détecteur.

Hormis le choix du détecteur, nous remarquons sur nos résultats expérimentaux que les performances d'un détecteur peuvent varier d'un patient à l'autre et même sur différents signaux EEG d'un même patient. Néanmoins nos détecteurs se sont révélés robustes aux variabilités morphologiques qui peuvent exister entre les EPICs de différents patients.

La classification est en parfaite relation avec la détection. Une fois que l'EPIC est détecté, nous avons lancé une fenêtre pour l'extraire dans le but de le préparer à la classification. Après l'extraction, nous appliquons le filtrage par ondelettes en prenant les premiers niveaux de résolutions pour les parties pointues et les tous derniers niveaux pour les ondes lentes. Des

algorithmes ont été développés pour l'identification de la forme des EPICs suivant différents gabarits. Ils ont permis de réduire le temps d'exécution de nos algorithmes de classification. Nous avons adapté deux algorithmes de la classification non supervisée aux EPICs. Le premier s'est basé sur les k-means et le deuxième sur les k-médoïdes.

Au niveau de la partie pratique, nous avons présenté les résultats de l'algorithme des k-means. Pour une meilleure représentation des clusters en deux dimensions, nous avons intégré l'analyse en composantes principales dans la chaîne de classification des EPICs. Elle nous a permis de bien analyser et d'interpréter les résultats de la classification. Tous les EPICs utilisés pour la classification ont été étiquetés par un expert.

De ce fait, notre algorithme s'est montré capable de distinguer les différents EPICs extraits selon leur morphologie. Pour les différents mélanges, nous avons obtenu de bons taux de classification. Nous avons pu atteindre en valeurs moyennes 94 % pour le mélange à 2 EPICs contre 88 % dans le cas des mélanges à 3 EPICs. Certains EPICs sont accompagnés d'ondes lentes. Notre modèle de détection d'ondes lentes donne aussi des résultats satisfaisants selon la sensibilité et la sélectivité. Enfin une validation de la chaîne de la classification est faite sur des données réelles de durée inférieure ou égale à 1 heure.

Par ailleurs, ces travaux constituent un point de départ à toute une série de travaux possibles. Plusieurs perspectives sont envisageables :

L'expérimentation de la classification non supervisée basée sur les k-médoïdes. En plus, nous allons orienter vers une approche supervisée avec différentes méthodes comme les réseaux de neurones, le machine vecteurs support etc. Nous allons faire une comparaison des différents algorithmes de classification supervisée et non supervisée.

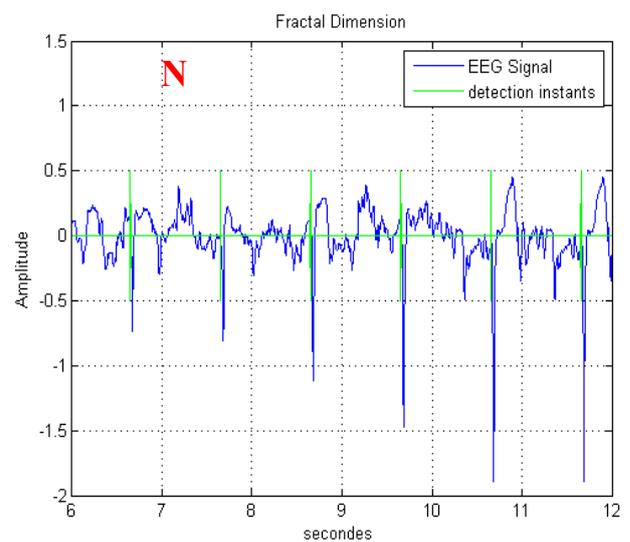
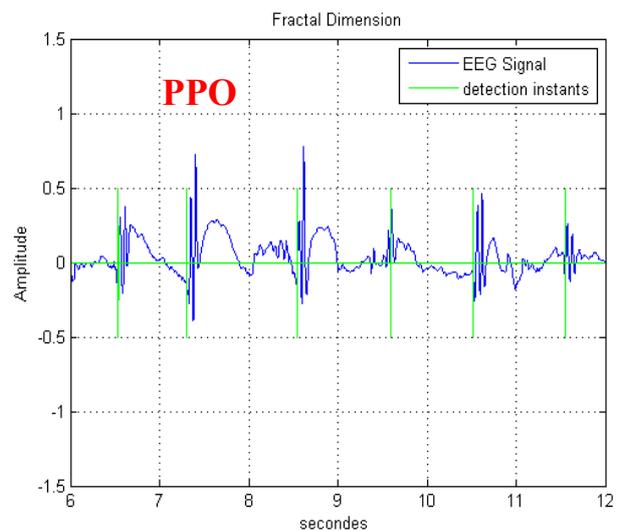
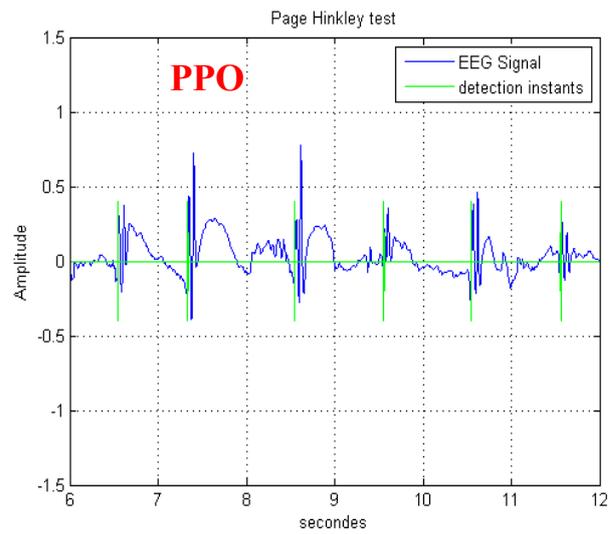
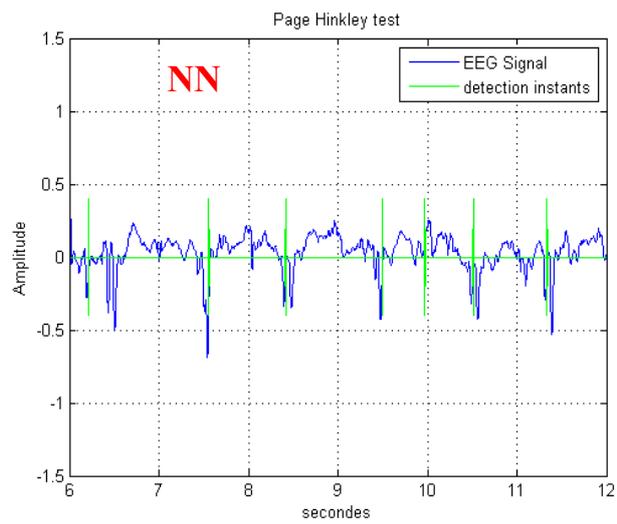
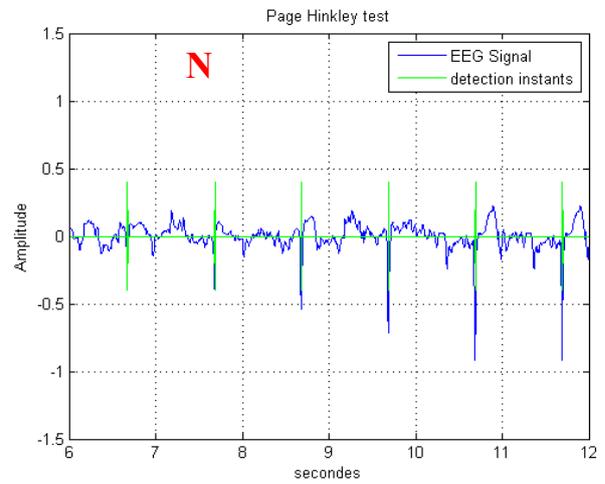
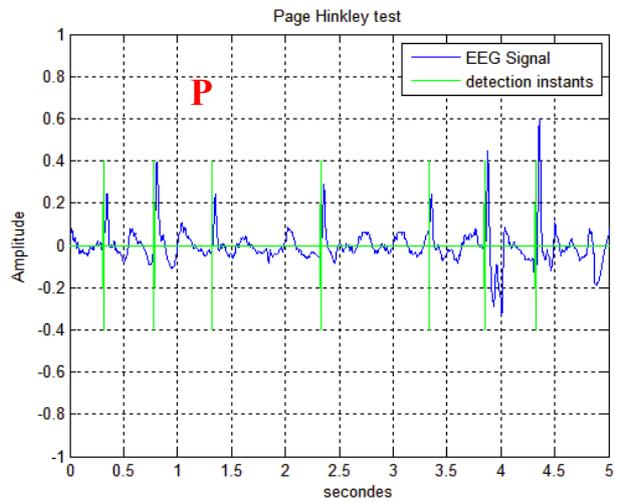
Notre chaîne traitement pourra être transformée en une plateforme logicielle d'aide à la décision pour être utilisée par des équipes médicales des hôpitaux de la place.

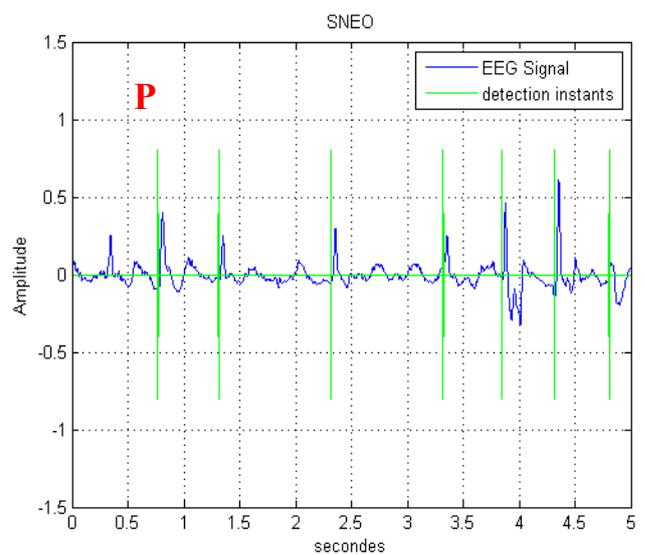
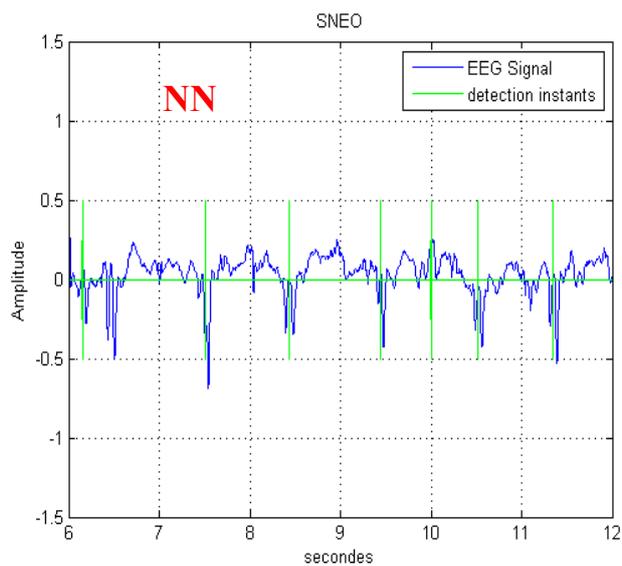
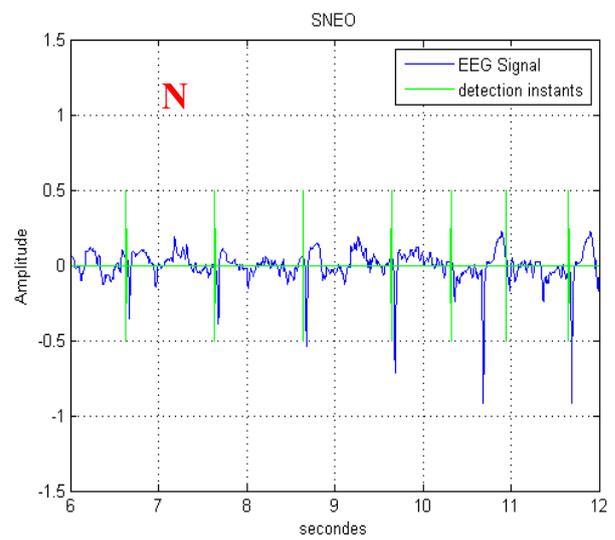
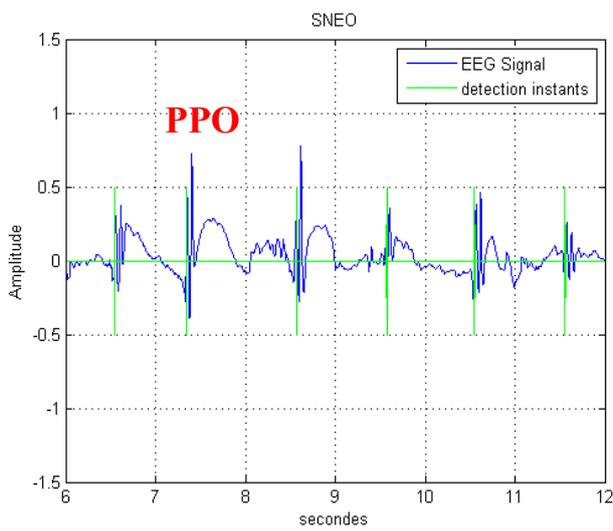
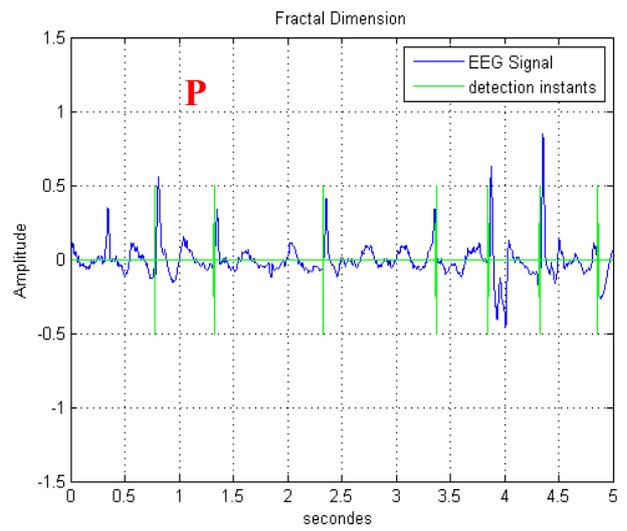
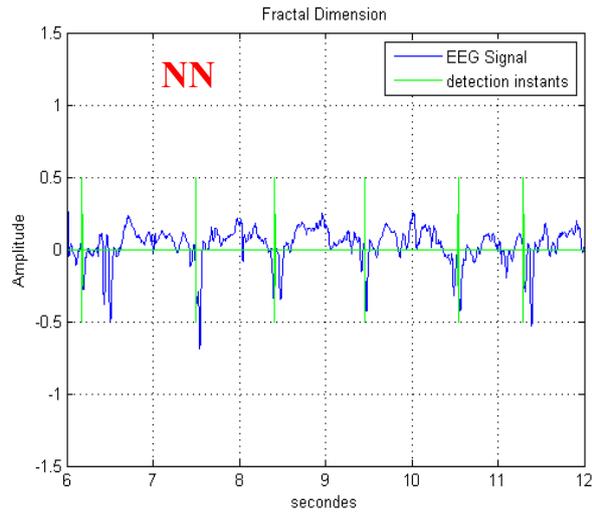
Les résultats de ce projet pourront s'appliquer au diagnostic de patients souffrant d'épilepsies partielles ou généralisées dans le cadre d'une collaboration avec le Centre Hospitalier Universitaire de FANN à Dakar. En plus, une ouverture sur le plan africain est envisageable.

Nous pouvons aussi envisager une extension de l'application de nos travaux à la problématique cardiaque qui constitue aujourd'hui l'une des causes les plus récurrentes des morts subites. En effet, notre méthode de détection de la morphologie des EPICs pourra être appliquée aussi au traitement des signaux électrocardiogrammes (ECG) pour la prévention.

Annexe

Détection de quelques morphologies d'EPICs :





Références

- [1] Löscher W, Schmidt D, « *Modern antiepileptic drug development has failed to deliver: ways out of the current dilemma* » *Epilepsia*, 52(4), pp. 657–78, 2011.
- [2] Sagher O, « *Editorial: Epilepsy surgery* », *J Neurosurg*, 2012.
- [3] Schaul N, « *The fundamental neural mechanisms of electroencephalography* », *Electroencephalogram Clinic neurophysiology*, Vol.106 pp.101-107, 1998.
- [4] Binnie C. D, Stefan H, « *Modern electroencephalography: its role in epilepsy management* », *Clinic Neurophysiology*, Vol. 110: pp.1671-1697, 1999.
- [5] Khouma O, Ndiaye M. L, Farssi S. M, Montois J. J, Diop I, Diouf B, « *Comparative Methods of Spike Detection in Epilepsy* », *IEEE, Scopus, SAI*, July 28-30, London, UK, 2015.
- [6] Rebeca R. V, « *Contribution à la détection et à l'analyse des signaux EEG épileptiques : débruitage et séparation de sources* ». PhD, Institut national polytechnique de Lorraine, Université de Nancy, France, 2010.
- [7] Velez Perez H. A, « *Localisation et caractérisation du déroulement de la crise d'épilepsie temporale* ». PhD, Institut national polytechnique de Lorraine, Université de Nancy, France, 2010.
- [8] Williams R. W, Herrup K, « *The control of neuron number. Annual Review of Neuroscience* », pp. 423–453, 1988.
- [9] Adam C, « *Epilepsies, de la clinique aux examens complémentaires : les méthodes (Tome 1)* », Expressions santé éditions, 2000.
- [10] Nunez P, Srinivasan R, « *Electric fields of the brain: the neurophysics of EEG* », Oxford University Press, USA, 2006.
- [11] OMS (2017). « [Http://www.who.int/mediacentre/factsheets/fs999/fr/](http://www.who.int/mediacentre/factsheets/fs999/fr/) ».
- [12] Ndiaye M. L, « *Analyse vectorielle des signaux épileptiques intracérébraux pour la compréhension des mécanismes d'initiation et de propagation des crises. Approche comportementale par système multi-agent* », PhD, Université de Renne 1, France, 2007.
- [13] Eich C, « *Epilepsy and state specific memory* », *Acta Neurol Scand Suppl*; Vol.109: pp.15-21, 1986.
- [14] Reynolds E. H, « *The influence of antiepileptic drugs on the natural history of epilepsy* », *Epilepsy Res Suppl*, Vol.3: pp.15-20, 1991.
- [15] Person C, « *Quantification des anomalies neurologiques métaboliques et imagerie de sources électriques* ». PhD, Université de Lorraine, France, 2012.
- [16] Talairach J, Bancaud J, « *L'exploration chirurgicale stéréotaxique du lobe temporal dans l'épilepsie temporale* ». Masson et Cie, 1958.

- [17] Bancaud J, « *Techniques et méthodes de l'exploration fonctionnelle stéréotaxique des structures encéphaliques chez l'homme (cortex, sous-cortex, noyaux gris centraux)* ». *Rev. Neurol.*, 101 :220-227, 1959.
- [18] Bourien J, « *Analyse de distributions spatio-temporelles de transitoires dans des signaux vectoriels. Application à la détection-classification d'activités paroxystiques intercritiques dans des observations EEG* ». PhD, Université Rennes 1, France, 2003
- [19] Wendling F, « *Mise en correspondance d'observations EEG de profondeur pour la reconnaissance des signatures spatio-temporelles dans les crises d'épilepsie* », PhD, Université de Rennes1, 1996.
- [20] Merlet I, « *Analyse dipolaire des paroxysmes intercritiques et critiques en EEG et HEG* ». *Epilept Disord; Vol.3 (Special Issue 1)* : pp. 11- 35, 2001.
- [21] Barth D. S, Sutherling W, Engle J, Beatty J, « *Neuromatic evidence ofspatially distributed sources underlying epileptiform spikes in the human brain* », *Science*, Vol. 223, n° 4633, pp. 293-296, 1984.
- [22] Kinié A, « *Détection de réalisation de causalité et estimation de temps de retard en épilepsie* ». Thèse de Doctorat, Université de Rennes1, France, avril 1996.
- [23] Adams R. D, Victor M, Ropper A. H, « *Epilepsy and other seizure disorders* ». In Wonsiewicz MJ, Navrozov M, Eds. *Principles of neurology*. New York: McGraw-Hill, pp. 313-43, 1997.
- [24] Woods J. P, Siccardi S. C, Crandall P. H, Walter D. O, Leake B, « *Quantitative analysis of depth spiking in relation to seizure foci in patients with temporal lobe epilepsy* » *Electroencephalogram Clinic Neurophysiology*, Vol.44: pp.641-643, 1978.
- [25] Gotman J, « *Relationships between interictal spiking and seizures: human and experimental evidence* », *Can J Neuro Science* Vol.18: pp.573-6, 1985.
- [26] Dadah S. M. L et al, « *épilepsie de l'enfant et de l'adolescent au Sénégal* », *African Journal of Neurological Sciences*, Vol. 34, No 1, 2015.
- [27] www.globalcampaignagainstepilepsy.org/files/Protocole%20Senegal.doc consulté 30/10/2016.
- [28] Ndiaye M. et al, « *Épilepsie dans le contexte neuropédiatrique sénégalais* », *Revue neurologique*, Science Direct pp. 162-168, 2008.
- [29] Khouma O, Ndiaye M. L, Diop I, Diaw S, Diop A. K, Farssi S. M, Diouf B, TALL K, Montois J. J, « *A New approach to detection and classification epileptic spikes in EEG* », *IEEE EMBS, Conference On Neural Engineering*, May 25-28, Shanghai, China, 2017.
- [30] Hwei P. Hsu, « *Communications analogiques et numériques* », McGraw-Hill, Inc., Paris, ISBN 2-7042- 1283-X, 1994.
- [31] Cottet F, « *Traitement des signaux et Acquisition de données* », Cours et exercices corrigés, DUNOD, 1997.
- [32] De Coulon F, « *Théorie et traitement des signaux* », traité d'électricité volume VI, PPUR, 1998.

- [33] Herut R, Rakotomamonjy A, « *Introduction aux signaux aléatoires* », INSA, Rouen, France, 20012.
- [34] Belmahdi F, « *Application du filtre de Kalman pour débruitage des signaux* », Magister, Université Mouloud Mammeri, Tizi Ouzou, Algérie, 2015.
- [35] Ruch J. J, « *Statistique : estimation* », préparation à l'agrégation Bordeaux 1, France 2012-2013.
- [36] Schwartz D, « *Méthodes statistiques à l'usage des médecins et des biologistes* », 4ème Edition, Médecine-Sciences Flammarion, 1993.
- [37] Van Den Enden A.W.M, Verhoeckx N.A.M, « *Traitement numérique du signal une introduction* », ed., Dunod, Paris, 2003.
- [38] Vautard R, Ghil M, « *Singular spectrum analysis in nonlinear dynamics, with applications to paleoclimatic time series* », Physica D 35, 395–424 1989.
- [39] Castagnoli G.C, Taricco C, Alessio S, « *Isotopic record in a marine shallow-water core: imprint of solar centennial cycles in the past 2 millennia* », Adv. Space Res. 35, 504–508, 2005.
- [40] Vautard R, Yiou P, Ghil M, « *Singular-spectrum analysis: a toolkit for short, noisy chaotic signals* », Physica D 58, 95–126, 1992.
- [41] Jemwa G.T, Aldrich C, « *Classification of process dynamics with Monte Carlo singular spectrum analysis* », Comput. Chem. Eng. 30, 816–831, 2006.
- [42] Tzagkarakis G, Papadopouli M, Panagiotis T, « *Singular spectrum analysis of traffic workload in a large-scale wireless lan* », Proceedings of the 10th ACM Symposium, pp. 99–108, 2007.
- [43] M. Papadopouli, G. Tzagkarakis, T. Panagiotis, « *Trend forecasting based on singular spectrum analysis of traffic workload in a large-scale wireless lan* », Perform. Eval. 66, 173–190, 2009.
- [44] Jean Fresnel, « *Algèbre des matrices* », Hermann, 2013.
- [45] Lloyd Trefethen and David Bau, « *Numerical linear algebra* », volume 50. Siam, 1997.
- [46] Pellete J, « *Résolution de systèmes non réguliers par une méthode de décomposition en valeurs singulières* », Sous licence GNU FDL (<http://www.gnu.org/copyleft/fdl.html>), 2013.
- [47] Phillipe B, Saad Y, « *Calcul des valeurs propres* », INRIA Rennes-Bretagne Atlantique, France et Department of computer science and engineering, university of Minnesota, edition TI.
- [48] Hamed A, Saeid S, « *Spike detection approaches for noisy neuronal data: Assessment and comparison* » ScienceDirect, Neurocomputing 133, pp. 491–506, 2014.
- [49] Ghaderi F, Mohseni H, Sanei S, « *Localizing heart sounds in respiratory signals using singular spectrum analysis* », IEEE Trans. Biomed. Eng. 59(12) 3360–3367, 2011.
- [50] Hassani H, « *Singular spectrum analysis: methodology and comparison* », J. Data Sci. 5(2) 239–257, 2007.
- [51] Rioul O, Vetterli M, « *Wavelets and signal processing* », IEEE Magazine, october 1991
- [52] Morizet N, « *Initiation aux ondelette (Une approche pédagogique des ondelettes, de leurs origines aux applications actuelles dans les domaines du traitement du signal et de l'image.)* », REE, Institut Supérieur d'Électronique de Paris (ISEP), France, 2006.

- [53] Truchetet F, « *Ondelette pour le signal numérique* », Editions Hermes, Paris, France 1998.
- [54] Damerval C, « *Ondelettes pour la détection de caractéristiques en traitement d'images. Application à la détection de région d'intérêt* ». PhD, UNIVERSITE JOSEPH FOURIER de Grenoble I, France, 2008.
- [55] Meyer Y, « *Ondelettes et opérateurs I : ondelettes* ». Paris, Hermann, 1990.
- [56] Morizet N, « *Reconnaissance Biométrique par Fusion Multimodale du Visage et de l'Iris* », Ph. D, ENST, Télécoms Paris, France, 2009.
- [57] Kalman R. E, « *A new Approach to linear Filtering and Prediction Problems* » Transaction of the ASME-Journal of Basic Engineering, 82 (series D): 35-45, 1960.
- [58] Beyou S, « *Estimation de la vitesse des courants marins à partir de séquences d'images satellitaires* », Ph. D, Université de Rennes 1, France, 2013.
- [59] Blum J, Hoteit I, Pham D. T « *A simplified reduced order Kalman filtering and application to altimetric data assimilation in the Tropical Pacific* », Journal of Marine Systems 36,1, p 101-127, 2002.
- [60] Hilairat M, « *Application des outils du traitement du signal à la commande des machines tournantes* », Thèse de Doctorat, Université de Nantes, France, 2001.
- [61] Welch G, Bishop G, « *An Introduction to the Kalman Filter* », Department of the Computer Science, University of North Carolina at Chapel Hill, USA, 2006.
- [62] Ndjeng A, « *Localisation robuste multi-capteurs et multi-modèles* », Thèse de doctorat, université D'Evry Val d'Essonne, France, 2009.
- [63] Sameni R, Shamsollahi M. B, Jutten C, « *Filtering Electrocardiogram signals using the extended Kalman Filter* », IEEE, 2005.
- [64] Grewal M. S, Andrews A. P, « *Kalman Filtering: Theory and Practice Using Matlab* » Edi, John Wily, Sons, Inc, 2008.
- [65] Norgaad M, « *State estimation for Nonlinear systems* », Technical Report IMM-REP, Technical University of Denmark, 2002.
- [66] Caparos M, « *Analyse automatique des crises d'épilepsie du lobe temporal à partir des EEG de surface* », Thèse de doctorat, Institut National Polytechnique de Lorraine – INPL, France, 2006.
- [67] Hamadene W, « *Systèmes chaotiques et méthode des récurrences : application à la détection précoce des crises d'épilepsie* », Thèse de doctorat, Lille 1, France, 2005.
- [68] Hocepied G, « *Détection précoce de crises d'épilepsie à l'aide d'une modélisation du comportement oscillatoire neuronal* », Thèse de doctorat, Ecole Polytechnique de Bruxelles, Belgique, 2012.
- [69] Gotman J, Gloor P, « *Automatic recognition and quantification of interictal epileptic activity in the human scalp EEG* », Electroencephalogram Clinic Neurophysiology, 41(5), 513-529, 1976.
- [70] Guedes O, « *Spike detection based on a pattern recognition approach using a microcomputer* », Electroencephalograph Clinical Neurophysiology, 56, 97-103, 1983.

- [71] Ktonas, « *Automated analysis of abnormal electroencephalograms* », Crit Rev Biomed Eng, 9(1), 39-97, 1983.
- [72] Diambra L, Malta, C. P, « *Nonlinear models for detecting epileptic spikes* », Phys. Lett. A, 241, 61-66, 1999.
- [73] Tzallas A. T, Karvelis P. S, Katsis, C. D., Fotiadis, D. I., Giannopoulos, S., & Konitsiotis, S, « *A method for classification of transient events in EEG recordings: application to epilepsy diagnosis* », Methods Inf Med, 45(6), 610-621, 2006.
- [74] Tzallas A. T, Markos G. Tsipouras, « *Automated Epileptic Seizure Detection Methods: A Review Study* », Epilepsy - Histological, Electroencephalographic and Psychological Aspects, ISBN: 978-953-51-0082-9, InTech, 2012.
- [75] Gotman J, « *Automatic seizure detection: improvements and evaluation* » Electroencephalogram Clinic Neurophysiology, 76(4), 317-324, 1990.
- [76] Huneau C, « *Détection et modélisation biomathématique d'événements transitoires dans les signaux EEG intracérébraux : application au suivi de l'épileptogénèse dans un modèle murin* », thèse de doctorat, université de Rennes 1, France, 2013.
- [77] Hesse C. W, James, C. J, « *Tracking and detection of epileptiform activity in multichannel ictal EEG using signal subspace correlation of seizure source scalp topographies* ». Med Biol Eng Comput, 45(10), 909-916, 2007.
- [78] Ossadtchi A, Baillet S, Mosher J. C, Thyerlei D, Sutherling W, Leahy, R. M, « *Automated interictal spike detection and source localization in magnetoencephalography using independent components analysis and spatiotemporal clustering* », Clin Neurophysiol, 115(3), 508-522, 2004.
- [79] Kobayashi K, James C. J, Nakahori T, Akiyama T, Gotman, J, « *Isolation of epileptiform discharges from an averaged EEG by independent component analysis* », Clinic Neurophysiology, 110(10), 1755-1763, 1999.
- [80] Sommer D, Golz M, « *Clustering EEG-segments using hierarchical agglomerative methods and self-organizing maps* », Paper presented at the Annual conference of the European Neural Network Society, 2001.
- [81] Shen T. W, Kuo X., Hsin Y. L, « *Ant K-Means Clustering Method on Epileptic Spike Detection* », Paper presented at the Fifth International Conference on Natural Computation, 2009.
- [82] Inan Z. H., Kuntalp M, « *A study on fuzzy C-means clustering-based systems in automatic spike detection* », Computer Biology Med, 37(8), 1160-1166, 2007.
- [83] Exarchos T. P, Tzallas A. T, Fotiadis, D. I, Konitsiotis, S Giannopoulos, S, « *EEG transient event detection and classification using association rules* », IEEE Trans Inf Technol Biomed, 10(3), 451-457, 2006.

- [84] Castellaro C, Favaro G, Castellaro, A, Casagrande A, Castellaro, S, Puthenparampil, D. V, « *An artificial intelligence approach to classify and analyse EEG traces* », *Neurophysiol Clin*, 32(3), 193-214, 2002.
- [85] Gabor A. J, Seyal M, « *Automated interictal EEG spike detection using artificial neural networks* », *Electroencephalograph Clin Neurophysiology*, 83(5), 271-280, 1992.
- [86] Webber W. R., Litt B, Wilson K, Lesser R. P, « *Practical detection of epileptiform discharges (EDs) in the EEG using an artificial neural network: a comparison of raw and parameterized EEG data* », *Electroencephalogram Clinic Neurophysiology*, 91(3), 194-204, 1994.
- [87] Ozdamar O, Yaylali I, Jayakar P, Lopez, C, « *Multilevel neural network system for EEG spike detection* », Paper presented at the Conf Proc 4th IEEE symp IEEE Computer society press Washington, 1991.
- [88] Acir N, Oztura I, Kuntalp M, Baklan B, Guzelis C, « *Automatic detection of epileptiform events in EEG by a three-stage procedure based on artificial neural networks* », *IEEE Trans Biomed Eng*, 52(1), 30-40, 2005.
- [89] Glover, J. R. Jr, Raghavan N, Ktonas P. Y, Frost J. D Jr, « *Context-based automated detection of epileptogenic sharp transients in the EEG: elimination of, false positives* », *IEEE Trans Biomed Eng*, 36(5), 519-527, 1989.
- [90] James C. J, « *Detection of epileptiform activity in the electroencephalogram using the electroencephalogram using artificial neural networks* », University of Canterbury, Christchurch, 1997.
- [91] Oikonomou V, Tzallas A. T, Fotiadis D. I, « *A Kalman filter based methodology for EEG spike enhancement* », *Comput Methods Programs Biomed*, 85(2), 101-108, 2007.
- [92] Hamed A, Saeid S, « *Spike detection approaches for noisy neuronal data: Assessment and comparison* », *ScienceDirect, Neurocomputing* 133, pp. 491–506, 2014.
- [93] Vaibha S, Manish R, « *Spike detection in biomedical signal like EEG and ECG using TEO* », *IJARCCCE*, vol. 2, issue 12, 2013.
- [94] Page E.S., « *Continuous inspection schemes* », *Biometrika*, 41(1-2), pp.100–115.
- [95] Hinkley D. V, « *Inference about the change-point from cumulative sum tests* ». *Biometrika*, 58(3), pp.509–523, 1971.
- [96] Boashash B, « *Time-Frequency Signal Analysis and Processing: A Comprehensive Reference* », Elsevier Ltd., Oxford, UK, 2003.
- [97] Cexus J. C, « *Analyse des signaux non-stationnaires par transformation de Huang, Opérateur de Teager-Kaiser, et Transformation de Huang-Teager (THT)* », thèse de doctorat, université de Renne 1, France, 2005.
- [98] Hamila R, Cheikh F. A, Vesma J, Astola J, Gabbouj M, « *Relationship between the Wigner-distribution and the Teager energy* », In *Proceedings of EUSIPCO 98*, volume 3, pages 1857–1860, Island of Rhodes, Greece, September 1998.

- [99] Cohen L, « *Time-Frequency Analysis* », Englewood Cliffs, NJ, Prentice-Hall, 1995.
- [100] Teager H. M, Teager S. M, « *A phenomenological model for vowel production in the vocal tract* », In CA, College-Hill, pages 73–109, San Diego, 1983.
- [101] Teager H. M, Teager S. M, « *Evidence for nonlinear sound production mechanisms in the vocal tract* », In NATO ASI on Speech Production and Speech Modeling, volume 55(D), pages 241–261, 1990.
- [102] Kaiser J. F, « *on simple algorithm to calculate the energy of signal* », In Proceedings of IEEE ICASSP 90, pages 381–384, Albuquerque, New Mexico, April 1990.
- [103] Maragos P, Quatieri T. F, Kaiser J. F, « *Speech nonlinearities, modulations, and energy operators* », In Proceedings of IEEE ICASSP, p.421–424, Canada, may 1991.
- [104] Kaiser J. F, « *Some useful properties of teager's energy operators* », In Proceedings of IEEE ICASSP 93, volume 3, pages 149–152, Minneapolis, NN, April 1993.
- [105] Cottet F, « *Traitement des signaux et acquisition de données* », cours et exercices corrigés, 3^{ème} édition, collection DUNOD, Paris, 2009.
- [106] Hassanpour H, Boashash B, « *A time-frequency approach for EEG spike detection* », Iran, J. Energy Environ. 2(4) 390–395, 2011.
- [107] Mukhopadhyay. S, Ray G. C, « *A new interpretation of nonlinear energy operator and its efficiency in spike detection* », IEEE Trans. Biomed. Eng. 49(12) 1526–1533, 2002.
- [108] Khouma O, Ndiaye M. L, Diop I, Diaw S, Diop A. K, Farssi S. M, Diouf B, TALL K, Montois J.J, « *Classification model of spikes morphology using principal components analysis in drug-resistant epilepsy* », Springer, INTERSOL, CNRIA, April 11-12, Dakar, Senegal, 2017.
- [109] Mandelbrot B. B, « *Les objets fractals, forme, hasard et dimension* », pp.190, Edition Flammarion, Paris, 1975.
- [110] Bouzboudja A, « *L'influence de la dimension fraction en 3D sur les caractéristiques mécaniques des matériaux granuleux* », thèse doctorat, Algérie, 2016.
- [111] Acharya U. R, Faust O, Kannathal N, Chua T, Laxminarayan S, « *Non-linear analysis of EEG signals at various sleep stages* », Computer. Methods, Programs Biomed, 2005.
- [112] Higuchi T, « *Approach to an irregular time series on the basis of the fractal theory* », Physical D, vol. 31, pp. 277–283, 1988.
- [113] Esteller R, Vachtsevanos G, Echauz J, Litt B, « *A Comparison of Waveform Fractal Dimension Algorithms* », IEEE transactions on circuits and systems, fundamental theory and applications, vol. 48, no. 2, February 2001.
- [114] Katz M, « *Fractals and the analysis of waveforms* », Computer. Biol. Med., vol. 18, no. 3, pp. 145–156, 1988.
- [115] MacQueen J. B, « *Some methods for classification and analysis of multivariate observations* », In Proceedings of Fifth Berkeley Symposium, vol 2, pp. 281-297, 1967.

- [116] Forgy E. W, « *Cluster analysis of multivariate data: efficiency versus interpretability of classifications* », *Biometrics*, 21: 768- 769, 1996.
- [117] Diday E, Govaert G, Lechevallier Y, Sidi J, « *Clustering in pattern recognition* », In NATO advanced study Institute on Digital Image Processing and Analysis, Bonas, 1980
- [118] Boubou M, « *Contribution aux méthodes de classification non supervisée via des approches prétopologique et d'agrégation d'opinion* », thèse de doctorat, université Claude Bernard, Lyon I, France, 2007.
- [119] Khouma O, Ndiaye M. L, Diop I, Farsi S. M, Diop A. K, Diouf B, Montois J. J, « *New Clustering of the Spikes Morphology Based on Dynamic Cloud in Partial Epilepsy* », IEEE, Scopus, Computing Conference, July 13-15, London, UK, 2016.
- [120] Kaufman L, Rousseeuw P. J, « *Finding Group in Data* », John Wiley & Sons, Inc 1990
- [121] Creff N, « *Clustering à l'aide d'une représentation supervisée* », Master thesis, Ecole d'ingénieur en informatique, France, 2011.
- [122] Ferrandiz S, « *Bayesian instance selection for the nearest neighbor rule* », 2010
- [123] Fawcett T, « *An introduction to ROC analysis* », *Pattern Recognition Letters* 27, Science direct, 2006.
- [124] <http://www.ltsi.univ-rennes1.fr/>
- [125] Ouali M. A, Khaeirddine C, Mouna G, Lorente L. M, Rojas D. B, « *ECG denoising using Extended Kalman Filter* », IEEE, 2013.
- [126] Candillier L, Tellier I, Torre F, Bousquet O, « *Évaluation en cascade d'algorithmes de clustering* », CAP Lille, 2006.
- [127] Voisine N, « *Approche adaptative de coopération hiérarchique de méthodes de segmentation, application aux images multi composantes* » Phd thesis, Université de Rennes 1, France, 2002.

Publications

- [1] **Khouma O, Ndiaye M. L, Diop I, Diaw S, Diop A. K, Farssi S. M, Diouf B, TALL K, Montois J. J**, « *A New approach to detection and classification epileptic spikes in EEG* », IEEE EMBS, Conference On Neural Engineering, May 25-28, Shanghai, China, 2017.
- [2] **Khouma O, Ndiaye M. L, Diop I, Diaw S, Diop A. K, Farssi S. M, Diouf B, TALL K, Montois J.J**, « *Classification model of spikes morphology using principal components analysis in drug-resistant epilepsy* », Springer, INTERSOL, CNRIA, April 11-12, Dakar, Senegal, 2017.
- [3] **Khouma O, Ndiaye M. L, Diop I, Farsi S. M, Diop A. K, Diouf B, Montois J. J**, « *New Clustering of the Spikes Morphology Based on Dynamic Cloud in Partial Epilepsy* », IEEE, Scopus, Computing Conference, July 13-15, London, UK, 2016.
- [4] **Khouma O, Ndiaye M. L, Farssi S. M, Montois J. J, Diop I, Diouf B**, « *Comparative Methods of Spike Detection in Epilepsy* », IEEE, Scopus, SAI, July 28-30, London, UK, 2015.
- [5] **Diop I, Farssi S. M, Khouma O, Diouf H. B, Tall K**, « *USING OF LDPC CODES IN STEGANOGRAPHY* », Journal of Theoretical and Applied Information Technology, 15th April 2012, vol.38 no.1.
- [6] **Diop I, Farssi S. M, Khouma O, Diouf H. B, Tall K, Sylla K**, « *New Steganographic scheme based of Reed-Solomon codes* » International Journal of Distributed and Parallel systems (IJDPSS), March 2012, Volume 3.
- [7] **Diop I, Farssi S. M, Chaumont M, Khouma O, Diouf H. B**, « *Utilisation des codes LDPC en stéganographie* » CORESA 2012, Compression et Représentation des Signaux Audiovisuels, Lille France, 24-25 mai, 7 pages.
- [8] **Diouf B, Diop I, Farssi S. M, Khouma O**, « *Adaptive Linear Programming of Polar Codes to Minimize Additive Distortion in Steganography* », IEEE, Computing Conference, July 13-15, London, UK, 2016.
- [9] **Diouf B, Diop I, Farssi S. M, Khouma O**, « *Practical Polar Coding Method to Minimize the Embedding Impact in Steganography* », IEEE, SAI, July 28-30, London, UK, 2015.

Nom et prénoms : KHOUMA Ousmane

Titre de la thèse : Analyse distribuée de la morphologie des événements paroxystiques intercritiques (EPICs) dans l'épilepsie pharmaco-résistante.

Résumé : L'épilepsie est l'une des maladies qui font plus l'objet de consultation dans les cliniques neurologiques. Pour aider les neurologues à bien diagnostiquer cette maladie, plusieurs outils technologiques ont été développés. L'électroencéphalographie (EEG) de surface ou de profondeur est un outil d'acquisition de signaux provenant des décharges électriques des zones cérébrales. Ces signaux sont souvent accompagnés des événements transitoires communément appelés événements paroxystiques intercritiques (EPICs) de courtes durées. L'analyse de ces EPICs pourrait avoir un apport substantiel sur le diagnostic et le traitement de l'épilepsie.

Dans cette thèse, nous proposons des outils de filtrage pour mettre en évidence les EPICs afin de faciliter leur détection. De ce fait, trois méthodes de détection ont été proposées. La première est basée sur l'algorithme de Page Hinkley. Les autres utilisent des modèles dynamiques basés sur un seuil adaptatif. Elles reposent respectivement sur l'utilisation de l'opérateur d'énergie non linéaire et de la dimension fractale.

Une nouvelle méthode de classification non supervisée de la morphologie des EPICs détectés est proposée. Elle est associée à l'analyse en composantes principales.

L'application de ces outils de traitement du signal pourrait apporter des éléments de réponse sur la relation (qui fait encore l'objet de beaucoup de travaux de recherche) entre la distribution spatio-temporelle des EPICs et l'arrivée des crises.

Mots clés : épilepsie, électroencéphalographie, filtrage, détection d'EPICs, analyse en composantes principales, classification non supervisée.

Name and first name: KHOUMA Ousmane

Thesis title: Distributed analysis of the morphology of interictal paroxystic events (IPE) in drug-resistant epilepsies.

Summary: Epilepsy is one of the diseases that are more subject to consultation in neurological clinics. To help neurologists to accurately diagnose this disease, several technological tools have been developed. Electroencephalography (EEG) of scalp or deep is a signal acquisition tool from electrical discharges of the brain areas. These signals are often accompanied by transient events commonly called interictal paroxystic events (IPE) of short durations. IPE Analysis could have a substantial impact on the diagnosis and the treatment of epilepsy.

In this thesis, we provide filtering tools to highlight the IPE for facilitate their detection. Therefore, three methods of detection have been proposed. The first is based on the Page Hinkley algorithm. Others use dynamic models based on an adaptive threshold. They are based respectively on the use of non-linear energy operator and fractal dimension.

A new clustering method of the spike morphology is proposed. It is associated with the principal component analysis. The latter makes us the interpretation of the distribution of IPE. The application of these signal processing tools could provide answers on the not yet found relationship between the spatial and temporal distribution of IPE and the arrival of crises.

Keywords: epilepsy, electroencephalography, filtering, spikes detection, principal components analysis, unsupervised classification.