



**IMPLANTATION SUR CIRCUIT FPGA D'UN SYSTÈME DE  
DÉTECTION AUTOMATIQUE DE CRISES D'ÉPILEPSIE  
PAR ANALYSE DE SIGNAUX EEG EN UTILISANT  
L'APPRENTISSAGE MACHINE**

MÉMOIRE PRÉSENTÉ

dans le cadre du programme de maîtrise en ingénierie  
en vue de l'obtention du grade de maître ès sciences appliquées (M.Sc.A.)

PAR

© WESTERN YVES ROODY JEAN

Février 2025



**Composition du jury :**

**Chan-Wang Park (Ph.D.), président du jury, Université du Québec à Rimouski**

**Mohammed Bahoura (Ph.D.), directeur de recherche, Université du Québec à Rimouski**

**Hassan Ezzaidi (Ph.D.), examinateur externe, Université du Québec à Chicoutimi**

Dépôt initial le 16 décembre 2024

Dépôt final le 11 février 2025



UNIVERSITÉ DU QUÉBEC À RIMOUSKI  
Service de la bibliothèque

Avertissement

La diffusion de ce mémoire ou de cette thèse se fait dans le respect des droits de son auteur, qui a signé le formulaire « *Autorisation de reproduire et de diffuser un rapport, un mémoire ou une thèse* ». En signant ce formulaire, l'auteur concède à l'Université du Québec à Rimouski une licence non exclusive d'utilisation et de publication de la totalité ou d'une partie importante de son travail de recherche pour des fins pédagogiques et non commerciales. Plus précisément, l'auteur autorise l'Université du Québec à Rimouski à reproduire, diffuser, prêter, distribuer ou vendre des copies de son travail de recherche à des fins non commerciales sur quelque support que ce soit, y compris Internet. Cette licence et cette autorisation n'entraînent pas une renonciation de la part de l'auteur à ses droits moraux ni à ses droits de propriété intellectuelle. Sauf entente contraire, l'auteur conserve la liberté de diffuser et de commercialiser ou non ce travail dont il possède un exemplaire.



À mon père

À ma mère

À mes sœurs

À ma femme

À mes filles

À mes amis



## REMERCIEMENTS

Mes premiers mots de remerciements sont dédiés à mon Père Céleste que je ne saurais tant remercier d'avoir fait abonder autant de grâce et d'affection envers moi, que je ne cesserai jamais de psalmodier pour la vie qu'IL m'a accordée en Jésus-Christ son bien-aimé fils qu'IL a donné à chacun qui reconnaît Jésus-Christ comme son Dieu, son Roi des rois et Seigneur des seigneurs ; et c'est ce que Jésus-Christ est pour moi. Alors, Merci Jésus pour tous les combats que tu as menés à ma place, d'avoir pris ma défense et me donner ta victoire depuis la genèse de ma vie jusqu'à la fin de mes jours. En toi, je me confierai éternellement, éternellement, Amen !

Par ailleurs, je tiens à exprimer ma gratitude envers mon directeur de recherche, Monsieur Mohammed Bahoura, professeur au Département de Mathématiques, d'Informatique et de Génie (DMIG) de l'Université du Québec à Rimouski (UQAR), qui, par son soutien constant et bienveillant, m'a permis de concrétiser avec grand succès ce travail de recherche.

Je tiens également à remercier les évaluateurs qui m'ont fait l'honneur d'examiner avec attention mon travail de recherche.

Je tiens à exprimer ma profonde gratitude envers mes parents, mes sœurs, mes amis qui ont cru en moi et m'ont soutenu tout au long de ce dur parcours universitaire.

Finalement, je remercie ma petite famille, ma chère et tendre épouse pour son amour constant, son dévouement envers moi et toute la famille, mes prunelles d'amour adorées Abir et Adaja, qui, de par leurs mots d'amour : « Papounet, je t'aime », leurs bisous, leurs caprices, leurs pleurs, etc. ont servi de catalyseur dans la réalisation de ce programme d'études.



## RÉSUMÉ

La crise épileptique est un dérèglement neuronal dangereux qui touche plus de cinquante millions de personnes dans le monde. En plus des conséquences néfastes sur la vie sociale de ses victimes, de nombreux chercheurs s'entendent sur le risque potentiel de mortalité prématurée que cause cette maladie. Au Canada, la diminution de l'épilepsie se faisait surtout remarquer par un diagnostic précoce et sa prise en charge qui ont favorisé le traitement approprié et le rétablissement du malade. Ce diagnostic était jadis réalisé par l'inspection visuelle d'un expert sur les signaux cérébraux du patient et s'avérait inefficace dans plusieurs situations, coûteux en temps et en ressources matérielles et humaines. Pour remédier aux problèmes de subjectivité de l'analyse du médecin traitant tout en lui fournissant une aide plus objective dans son diagnostic et en minimisant en même temps les coûts, des systèmes se basant sur l'intelligence artificielle sont proposés.

Ce projet consiste à réaliser un système de détection de crises épileptiques par analyse des signaux EEG pré-enregistrés dans les bases de données de CHB-MIT et de l'Université de Bonn afin de classer automatiquement un patient comme : soit malade (épileptique), soit sain (non-épileptique). Ce système opère en trois étapes principales : l'extraction des caractéristiques, la réduction de la dimensionnalité, et enfin la classification. Il sera implémenté à la fois en logiciel et en matériel.

Pour atteindre l'objectif visé, quarante-cinq systèmes, obtenus à partir des différentes combinaisons de trois techniques d'extraction des caractéristiques (la transformée en ondelette discrète et stationnaire (DWT et SWT) et le modèle d'estimation spectrale de Burg), trois techniques de réduction de dimensionnalité (l'analyse en composante principale (PCA), l'analyse en composante indépendante (ICA) et sans réduction de dimensionnalité (SRD)) et cinq techniques de classification (l'analyse discriminante linéaire (LDA), le k-plus proche voisin (KNN), la forêt aléatoire (RF), les machines à vecteurs de support (SVM) et le réseau de neurones (ANN)) ont été analysés. Un ensemble d'apprentissage formé de la meilleure combinaison de chacun des cinq classificateurs a été réalisé afin de détecter l'épilepsie par un vote de majorité dans le cas de l'implémentation logicielle. L'implantation matérielle quant à elle, teste l'efficacité des classificateurs SVM et ANN lorsqu'ils sont combinés avec la SWT comme méthode d'extraction des caractéristiques sur circuit FPGA, en utilisant l'outil de programmation de haut niveau Xilinx System Generator (XSG). Une phase de prétraitement a été réalisée tout au début sur les signaux EEG avant de les utiliser par les techniques susmentionnées.

Les meilleures combinaisons pour les cinq classificateurs du projet ont été surtout obtenues pour la base de données CHB-MIT avec une exactitude moyenne de 99.63% et pour

la base de données de l'Université de Bonn avec une exactitude moyenne de 96.55%. Quoique les cinq meilleures combinaisons des cinq classificateurs n'ont pas pu identifier et séparer à 100% tous les patients malades de ceux qui ne le sont pas, en revanche, le vote a prouvé son utilité dans la détection efficace et robuste de la crise épileptique, car l'exactitude mesurée dans la catégorisation des patients par le vote de majorité est de 100% pour la base de données CHB-MIT et de 99.79% pour la base de données de l'Université de Bonn.

L'implantation matérielle a donné elle aussi des résultats très satisfaisants pour les deux bases de données utilisées. En dépit des contraintes du système matériel, les machines à vecteurs de support (SVM) ont atteint une exactitude de 99% en logiciel et de 99% en matériel, tandis que le réseau de neurones (MLP) a atteint une exactitude de 99% en logiciel et de 99.5% en matériel pour la base de données CHB-MIT. Pour la base de données de l'Université de Bonn, les SVM ont donné une exactitude de 97.5% en logiciel et de 97.5% en matériel, et le réseau de neurones (MLP) a obtenu une exactitude de 99% en logiciel et de 98.5% en matériel. Ainsi, les performances des classificateurs SVM et MLP en matériel, mesurées sur les deux bases de données, sont proches de celles déterminées en logiciel, avec une erreur maximale de 0.5%. En somme, la performance moyenne des modèles SVM et ANN du système en matériel est d'environ 99.25% pour la base de données CHB-MIT et de 98% pour celle de l'Université de Bonn, comparée aux résultats obtenus en logiciel qui sont de 99% pour la base de données CHB-MIT et de 98.25% pour la base de données de l'Université de Bonn.

Mots clés : Crise épileptique, signaux EEG, extraction des caractéristiques, DWT, SWT, estimation spectrale, Réduction de dimensionnalité, PCA, ICA, ANN, SVM, k-NN, forêt aléatoire, LDA, FPGA.

## ABSTRACT

Epileptic seizures are a dangerous neuronal disorder affecting over fifty million people worldwide. In addition to the detrimental effects on the social lives of its victims, many researchers agree on the potential risk of premature mortality caused by this disease. In Canada, the reduction in the incidence of this disease was mainly due to early diagnosis and management, which led to appropriate treatment and recovery. In the past, this diagnosis was made by expert visual inspection of the patient's brain signals, and proved ineffective in many situations, costing time and material and human resources. To overcome the problems of subjectivity in the treating physician's analysis, while at the same time providing more objective help in diagnosis and minimizing costs, systems based on artificial intelligence are proposed.

This project involves the development of a system for detecting epileptic seizures by analyzing EEG signals pre-recorded in the databases of CHB-MIT and the University of Bonn, in order to automatically classify a patient as either sick (epileptic) or healthy (non-epileptic). The system operates in three main stages: feature extraction, dimensionality reduction and classification. It will be implemented in both software and hardware.

To achieve this objective, forty-five systems, obtained from different combinations of three feature extraction techniques (discrete and stationary wavelet transform (DWT and SWT) and Burg's spectral estimation model), three dimensionality reduction techniques (principal component analysis (PCA), independent component analysis (ICA) and without dimensionality reduction (SRD)) and five classification techniques (linear discriminant analysis (LDA), k-nearest neighbor (KNN), random forest (RF), support vector machines (SVM) and neural network (ANN)) were analyzed. A training set consisting of the best combination of each of the five classifiers was created to detect epilepsy by majority voting in the case of the software implementation. The hardware implementation tests the effectiveness of the SVM and ANN classifiers when combined with SWT as an FPGA-based feature extraction method, using the Xilinx System Generator (XSG) high-level programming tool. An initial pre-processing phase was carried out on the EEG signals before using them with the above-mentioned techniques.

The best combinations for the project's five classifiers were mainly obtained for the CHB-MIT database, with an average accuracy of 99.63%, and for the University of Bonn database, with an average accuracy of 96.55%. Although the best five combinations of the five classifiers were not able to identify and separate 100% of all ill patients from those who were not, voting proved its worth in the efficient and robust detection of epileptic seizures,

as the accuracy measured in patient categorization by majority voting was 100% for the CHB-MIT database and 99.79% for the University of Bonn database.

The hardware implementation also produced very satisfactory results for the two databases used. Despite the constraints of the hardware system, the support vector machines (SVM) achieved an accuracy of 99% in software and 99% in hardware, while the neural network (MLP) achieved an accuracy of 99% in software and 99.5% in hardware for the CHB-MIT database. For the University of Bonn database, SVM gave an accuracy of 97.5% in software and 97.5% in hardware, while the neural network (MLP) achieved an accuracy of 99% in software and 98.5% in hardware. Thus, the performance of the SVM and MLP classifiers in hardware, measured on both databases, is close to that determined in software, with a maximum error of 0.5%. In sum, the average performance of the system's SVM and ANN models in hardware is around 99.25% for the CHB-MIT database and 98% for the University of Bonn database, compared with the results obtained in software, which are 99% for the CHB-MIT database and 98.25% for the University of Bonn database.

*Keywords:* Epileptic seizure, EEG signals, feature extraction, DWT, SWT, spectral estimation, dimensionality reduction, PCA, ICA, ANN, SVM, k-NN, random forest, LDA, hardware implementation, FPGA, Xilinx System Generator.

## TABLE DES MATIÈRES

REMERCIEMENTS.....	ix
RÉSUMÉ.....	xi
ABSTRACT.....	xiii
TABLE DES MATIÈRES.....	xv
LISTE DES TABLEAUX.....	xix
LISTE DES FIGURES.....	xxi
LISTE DES ABRÉVIATIONS, DES SIGLES, DES ACRONYMES.....	xxv
INTRODUCTION GÉNÉRALE.....	1
CHAPITRE 1 LES CRISES ÉPILEPTIQUES ET LES SIGNAUX EEG.....	3
1.1 CONTEXTE.....	3
1.2 NOMENCLATURE DES CRISES ÉPILEPTIQUES.....	4
1.2.1 Manifestation des crises épileptiques.....	4
1.2.2 Les différents types de crises d'épilepsie.....	6
1.3 LES APPAREILS UTILISÉS DANS LE DIAGNOSTIC DES CRISES ÉPILEPTIQUES ET L'ACQUISITION DES SIGNAUX EEG.....	7
1.3.1 Rôle du scanner et de l'IRM dans la détection de la crise.....	7
1.3.2 Électroencéphalographie (EEG) et acquisitions des signaux cérébraux.....	8
1.3.3 Période critique et période sans crise.....	10
1.3.4 Bases de données EEG.....	13
1.4 PROBLÉMATIQUE DE RECHERCHE.....	17
1.5 OBJECTIFS VISÉS.....	18
1.6 HYPOTHÈSES.....	19
1.7 MÉTHODOLOGIE APPLIQUÉE.....	19

1.8	CONTRIBUTION .....	21
1.9	MATÉRIELS ET OUTILS UTILISÉS .....	21
<b>CHAPITRE 2 PRÉTRAITEMENT ET EXTRACTION DES CARACTÉRISTIQUES .....</b>		<b>23</b>
2.1	PRÉTRAITEMENT DES DEUX BASES DE DONNÉES DU PROJET .....	23
2.1.1	Filtration du signal.....	23
2.1.2	Normalisation ou Standardisation .....	24
2.1.3	Segmentation des données.....	25
2.2	MÉTHODES D'EXTRACTION DES CARACTÉRISTIQUES .....	25
2.2.1	Les méthodes d'analyse temps-fréquence.....	26
2.2.2	Modélisation paramétrique d'estimation spectrale du signal EEG .....	30
2.3	MÉTHODES DE RÉDUCTION DE LA DIMENSION DES CARACTÉRISTIQUES .....	34
2.3.1	L'analyse en composante principale (PCA).....	34
2.3.2	L'analyse en composante Indépendante (ICA) .....	36
2.4	APPROCHE PROPOSÉE.....	37
<b>CHAPITRE 3 ALGORITHMES D'APPRENTISSAGE MACHINE POUR LA CLASSIFICATION AUTOMATIQUE DES SIGNAUX EEG .....</b>		<b>41</b>
3.1	ANALYSE DISCRIMINANTE LINÉAIRE (LDA) .....	42
3.2	K PLUS PROCHES VOISINS (KNN) .....	43
3.3	FORÊT ALÉATOIRE (RANDOM FOREST).....	46
3.3.1	Étapes d'implémentation de la forêt aléatoire .....	46
3.4	MACHINES À VECTEURS DE SUPPORT (SVM) .....	49
3.4.1	SVM linéaire (LSVM).....	49
3.4.2	SVM non-linéaire (NLSVM) .....	51
3.5	RÉSEAU DE NEURONES ARTIFICIELS (ANN).....	53
3.5.1	Le Perceptron.....	53
3.5.2	Perceptron Multicouche (MLP).....	54
3.5.3	Apprentissage du réseau MLP.....	55
3.5.4	Fonction d'activation.....	55
3.6	MÉTRIQUES DE PERFORMANCE .....	58

3.6.1	Matrice de confusion .....	58
3.7	CLASSIFICATION PAR VOTE MAJORITAIRE .....	60
3.7.1	Vote de majorité simple (Hard voting).....	60
3.7.2	Vote de majorité pondérée (soft voting).....	61
3.8	SYSTÈME DE CLASSIFICATION PROPOSÉ POUR L'IMPLÉMENTATION LOGICIELLE .....	62
3.9	APPROCHE PROPOSÉE POUR LA CLASSIFICATION MATÉRIELLE .....	63
CHAPITRE 4 RÉSULTATS DE L'IMPLÉMENTATION LOGICIELLE .....		65
4.1	PRÉTRAITEMENT DES DEUX BASES DE DONNÉES DU PROJET .....	65
4.1.1	Prétraitement de la base de données CHB-MIT .....	65
4.1.2	Prétraitement de la base de données de l'Université de Bonn : Choix des classes.....	78
4.2	EXTRACTION DES CARACTÉRISTIQUES ET RÉDUCTION DE DIMENSIONNALITÉ .....	80
4.3	CLASSIFICATION DES SIGNAUX EEG : DÉTECTION DE LA CRISE.....	80
4.3.1	Validation croisée.....	81
4.3.2	Composition des différents modèles de classification.....	82
4.4	RÉSULTATS DES DIFFÉRENTES COMBINAISONS D'ALGORITHMES DE DÉTECTION DE CRISES D'ÉPILEPSIE.....	83
4.4.1	Classification à l'aide la base de données CHB-MIT .....	84
4.4.2	Classification à l'aide la base de données de l'Université de Bonn : AB vs E.....	85
4.4.3	Classification à l'aide la base de données de l'Université de Bonn : A vs E .....	86
4.4.4	Classification à l'aide la base de données de l'Université de Bonn : B vs E .....	87
4.5	ENSEMBLE D'APPRENTISSAGE.....	88
4.5.1	Résultats comparatifs du vote majoritaire pour l'ensemble des classificateurs LDA, KNN, RF, SVM et ANN .....	89
4.6	DISCUSSIONS DES DIFFÉRENTS RÉSULTATS OBTENUS .....	93

4.6.1 Comparaison de l'exactitude moyenne obtenue pour la classification en logiciel des classes A vs E, B vs E et AB vs E pour la base de données de l'Université de Bonn.....	93
4.6.2 Décision par vote à la majorité.....	94
<b>CHAPITRE 5 IMPLÉMENTATION MATÉRIELLE SUR CIRCUIT FPGA.....</b>	<b>95</b>
5.1 PLATEFORME DE DÉVELOPPEMENT DU SYSTÈME MATÉRIEL ET PUCE UTILISÉE.....	95
5.1.1 Xilinx System Generator (XSG).....	95
5.1.2 Circuit FPGA et carte de développement Nexys-4.....	96
5.2 IMPLÉMENTATION MATÉRIELLE D'UN DÉTECTEUR DE CRISES ÉPILEPTIQUES.....	97
5.2.1 L'acquisition du signal EEG par les blocs XSG.....	101
5.2.2 Transformée en ondelette stationnaire (SWT).....	102
5.2.3 La synchronisation des sous-bandes.....	104
5.2.4 Sélection de caractéristiques.....	105
5.2.5 Détection de la crise épileptique à l'aide du classificateur (SVM).....	108
5.2.6 Détection de la crise épileptique à l'aide du réseau de neurones.....	110
5.3 RÉSULTATS DE LA CLASSIFICATION DES SIGNAUX EEG OBTENUS AVEC L'IMPLÉMENTATION MATÉRIELLE.....	122
5.3.1 Limitations et restrictions dues à l'implémentation matérielle : Adaptation des paramètres des classificateurs pour une implémentation efficace sur FPGA.....	122
5.3.2 Méthodes utilisées pour évaluer les performances des implémentations matérielles des classificateurs SVM et ANN.....	123
5.3.3 Résultats de la classification du SVM et de MLP pour la base de données CHB-MIT (canal FP1-F3) : Comparaison des implémentations logicielle-matérielle.....	125
5.3.4 Résultats de la classification du SVM et de MLP pour la base de données de l'Université de Bonn : Comparaison des implémentations logicielle-matérielle.....	128
5.4 COSIMULATION (JTAG) ET RESSOURCES MATÉRIELLES UTILISÉES.....	131
5.5 DISCUSSIONS SUR LES DIFFÉRENTS RÉSULTATS DU CINQUIÈME CHAPITRE.....	133
5.5.1 Implémentation logicielle et matérielle.....	133
5.5.2 Ressources matérielles utilisées.....	134
<b>CONCLUSION GÉNÉRALE.....</b>	<b>137</b>
<b>RÉFÉRENCES BIBLIOGRAPHIQUES.....</b>	<b>139</b>

## LISTE DES TABLEAUX

Tableau 1.1 Bases de données EEG populaires utilisées dans la détection de la crise épileptique .....	13
Tableau 3.1 Représentation d'une matrice de confusion.....	59
Tableau 4.1 Meilleurs canaux de la base de données CHB-MIT prétraitée .....	72
Tableau 4.2 Segmentation des meilleurs canaux de la base de données CHB-MIT .....	73
Tableau 4.3 Regroupement des canaux du même indice.....	74
Tableau 4.4 Regroupement des caractéristiques SWT des quatre meilleurs canaux pour fusion.....	75
Tableau 4.5 Fusion (concaténation) des caractéristiques des meilleurs canaux .....	76
Tableau 4.6 Meilleurs canaux pour l'implémentation matérielle du projet.....	77
Tableau 4.7 Matrice de confusion des meilleures combinaisons trouvées avec la base de données CHB-MIT .....	84
Tableau 4.8 Matrice de confusion des meilleures combinaisons trouvées avec les classes AB et E de la base de données de l'Université de Bonn.....	85
Tableau 4.9 Matrice de confusion des meilleures combinaisons trouvées avec les classes A et E de la base de données de l'Université de Bonn.....	86
Tableau 4.10 Matrice de confusion des meilleures combinaisons trouvées avec les classes B et E de la base de l'Université de Bonn.....	87
Tableau 4.11 Matrice de confusion des prédictions de chacun des classificateurs pour le vote de majorité avec la base de données CHB-MIT .....	90
Tableau 4.12 Matrice de confusion du vote pour la base de données CHB-MIT.....	91
Tableau 4.13 Matrice de confusion des prédictions de chacun des classificateurs pour le vote de majorité avec la base de données de l'Université de Bonn .....	92

Tableau 4.14 Matrice de confusion du vote pour la base de l'Université de Bonn.....	93
Tableau 5.1 Description des composants de la carte Nexys-4.....	97
Tableau 5.2 Interprétation des résultats de SVM et de MLP.....	110
Tableau 5.3 Exemple de données d'apprentissage du prototype de MLP.....	113
Tableau 5.4 Matrices de confusion de SVM pour la classification logicielle avec la base de données CHB-MIT (canal P4-O2).....	125
Tableau 5.5 Matrice de confusion MLP pour la classification logicielle avec la base de données CHB-MIT (canal P4-O2).....	126
Tableau 5.6 Matrice de confusion SVM pour la classification matérielle avec la base de données CHB-MIT (canal P4-O2).....	127
Tableau 5.7 Matrice de confusion MLP pour la classification matérielle avec la base de données CHB-MIT (canal P4-O2).....	127
Tableau 5.8 Matrices de confusion de SVM pour la classification logicielle avec la base de données de l'Université de Bonn.....	128
Tableau 5.9 Matrices de confusion de MLP pour la classification logicielle avec la base de données de l'Université de Bonn.....	129
Tableau 5.10 Matrices de confusion de SVM pour la classification matérielle avec la base de données de l'Université de Bonn.....	130
Tableau 5.11 Matrices de confusion de MLP pour la classification matérielle avec la base de données de l'Université de Bonn.....	130
Tableau 5.12 Ressources matérielles consommées par l'architecture de détection proposée pour la puce Artix-7 XC7A100T de la Nexys-4.....	131

## LISTE DES FIGURES

Figure 1.1 Les principaux composants d'un neurone biologique.....	5
Figure 1.2 Patient sous crise d'épilepsie .....	6
Figure 1.3 Enregistrement de l'activité cérébrale à l'aide de l'électroencéphalographie (EEG) .....	9
Figure 1.4 Enregistrement de 10 s des signaux cérébraux d'un patient épileptique en temps normal .....	11
Figure 1.5 Enregistrement de 10 s des signaux cérébraux d'un patient épileptique en crise .....	12
Figure 1.6 Diagramme bloc décrivant les 45 systèmes évalués individuellement pour la détection de la crise épileptique .....	20
Figure 1.7 Diagramme bloc d'un ensemble d'apprentissage basé sur les 5 meilleurs classificateurs .....	20
Figure 2.1 Segmentation d'un signal EEG .....	25
Figure 2.2 Architecture générale de la décomposition en ondelettes discrète .....	27
Figure 2.3 Architecture générale de la décomposition en ondelettes stationnaire.....	28
Figure 2.4 Illustration du processus d'extraction des caractéristiques d'un signal EEG .....	38
Figure 2.5 Illustration du processus d'extraction des caractéristiques de 4 canaux.....	39
Figure 3.1 Illustration bidimensionnelle de la LDA .....	43
Figure 3.2 Classification à l'aide de KNN .....	44
Figure 3.3 Architecture générale de l'algorithme de Forêt aléatoire.....	48
Figure 3.4 Classification de données à l'aide de SVM linéaire.....	50
Figure 3.5 Présentation des points d'entraînements dans l'espace des échantillons d'origine et lorsqu'ils sont mappés dans une dimension supérieure .....	51
Figure 3.6 Réseau d'un seul neurone ou Perceptron .....	53
Figure 3.7 Architecture générale du Réseau de neurones artificiels.....	54

Figure 3.8 Fonction sigmoïde .....	56
Figure 3.9 Fonction tangente hyperbolique .....	56
Figure 3.10 Fonction ReLU .....	57
Figure 3.11 Schématique de la fonction d'activation Softmax pour la classification multi-classe de ANN .....	58
Figure 3.12 Schématique du vote hard et soft pour la classification des méthodes d'ensemble .....	62
Figure 3.13 Diagramme bloc décrivant les 45 systèmes évalués individuellement pour la détection de la crise épileptique .....	63
Figure 3.14 Diagramme bloc d'un ensemble d'apprentissage basé sur les 5 meilleurs classificateurs .....	63
Figure 3.15 Architecture générale proposée pour la détection de la crise épileptique par matériel à l'aide des classificateurs SVM et ANN .....	64
Figure 4.1 Traitement réalisé pour former deux classes de données (épileptiques et non épileptiques) .....	67
Figure 4.2 Segmentation de la base de données CHB-MIT prétraitée .....	70
Figure 4.3 Schéma illustrant la validation croisée k-Fold avec k=5 .....	82
Figure 4.4 Diagramme bloc décrivant les 45 systèmes évalués individuellement pour la détection de la crise épileptique .....	83
Figure 4.5 Vote de majorité appliqué sur les cinq classificateurs du projet .....	88
Figure 4.6 Vote de majorité appliqué sur la base de données CHB-MIT .....	90
Figure 4.7 Vote de majorité appliqué sur la base de données de l'Université de Bonn .....	91
Figure 5.1 Architecture de la carte Nexys-4 .....	96
Figure 5.2 Diagramme d'implémentation matérielle des modèles de classification de la crise d'épilepsie .....	98
Figure 5.3 Implémentation matérielle de deux systèmes de détection de la crise d'épilepsie réalisée avec des blocs XSG .....	100
Figure 5.4 Fenêtres de configuration du bloc « System Generator » .....	102

Figure 5.5 Architecture de la transformée en ondelette stationnaire (SWT) réalisée avec des blocs XSG.....	102
Figure 5.6 Architecture du filtre passe-haut .....	103
Figure 5.7 Architecture du filtre passe-bas .....	104
Figure 5.8 Synchronisation des sorties des filtres de la SWT .....	105
Figure 5.9 Architecture du bloc calculant la variance des sous-bandes du signal EEG .....	106
Figure 5.10 Implémentation du classificateur SVM à l'aide des blocs XSG .....	109
Figure 5.11 Boîte à outils du Neural Network Start (nnstart).....	111
Figure 5.12 Prototype du réseau de neurones créé à l'aide de la boîte à outils « nnstart ...	111
Figure 5.13 a) Intérieur du bloc : Pattern Recognition Neural Network, b) Intérieur du bloc : Process Input 1 .....	112
Figure 5.14 Intérieur du bloc « mapminmax » ou bloc de normalisation.....	112
Figure 5.15 Intérieur du bloc de Normalisation du « mapminmax » de XSG.....	114
Figure 5.16 Bloc complet de « mapminmax » ou de Normalisation réalisé avec XSG .....	115
Figure 5.17 a) Couche cachée du prototype, b) Somme pondérée des neurones cachés....	115
Figure 5.18 Fonction d'activation tangente hyperbolique du prototype .....	116
Figure 5.19 Somme pondérée du neurone cachée réalisée sur XSG .....	116
Figure 5.20 Fonction d'activation tangente hyperbolique réalisée sur XSG.....	117
Figure 5.21 a) Couche de sortie du prototype, b) Neurones de sortie du prototype .....	117
Figure 5.22 Implémentation d'un neurone de sortie avec les blocs XSG.....	118
Figure 5.23 Fonction d'activation softmax du prototype .....	118
Figure 5.24 Implémentation de la fonction softmax avec les blocs XSG.....	119
Figure 5.25 Architecture matérielle finale du réseau de neurones MLP .....	121
Figure 5.26 Architecture de base du détecteur et Cosimulation matériel (JTAG) .....	132



## LISTE DES ABRÉVIATIONS, DES SIGLES, DES ACRONYMES

ANN	<i>Artificial Neural Network</i> Réseau de neurones artificiels
AR	<i>Autoregressive model</i> Modèle autorégressif
ARMA	<i>Autoregressive-Moving-Average</i> Moyenne mobile Autoregressive
AUC	<i>Area Under the Curve</i> Aire sous la courbe
BSS	<i>Blind Source Separation</i> Séparation aveugle de sources
CHB-MIT	<i>Children's Hospital Boston - Massachusetts Institute of Technology</i> Hôpital pour enfants de Boston – Institut Technologique de Massachusetts
DTCWT	<i>Dual-Tree Complex Wavelet Transforms</i> Transformée en ondelettes complexe à double arbre
DWT	<i>Discrete Wavelet Transforms</i> Transformations en ondelettes discrètes
EEG	<i>Electroencephalography</i> Électro-encephalographie
EWT	<i>Empirical Wavelet Transform</i> Transformée en ondelettes empirique
EMD	<i>Empirical Mode Decomposition</i> Décomposition en mode empirique
EEMD	<i>Ensemble Empirical Mode Decomposition</i> Décomposition en mode empirique d'ensemble

CEEMD	<i>Complete Ensemble Empirical Mode Decomposition</i> Décomposition en mode empirique d'ensemble complète
FFT	<i>Fast Fourier Transform</i> Transformée de Fourier rapide
FIR	<i>Finite impulse response (filter)</i> Filtre à réponse impulsionnelle finie
FPGA	<i>Field-programmable gate array</i> Réseau de portes logiques programmables
HOS	<i>Higher Order Statistics</i> Statistiques d'ordre supérieur
ICA	<i>Independent Component Analysis</i> Analyse en composantes indépendantes
ICM	Institut du Cerveau et de la Moelle épinière
iEEG	<i>Intracranial Electroencephalography</i> Électro-encéphalographie invasive
IIR	<i>Infinite impulse response (filter)</i> Filtre à réponse impulsionnelle infinie
IRM	<i>Magnetic Resonance Imaging</i> Imagerie par Résonance Magnétique
JTAG	<i>Joint Test Action Group</i> Groupe d'action de test commun
KNN	<i>K-Nearest Neighbors</i> K-plus proches voisins
LDA	<i>Liner Discriminant Analysis</i> Analyse discriminante linéaire
LSVM	<i>Linear Support Vector Machine</i> Machine à vecteurs de support linéaire

MA	<i>Moving Average</i> Moyenne mobile
ML	<i>Machine Learning</i> Apprentissage machine ou automatique
MLP	<i>Multilayer Perceptron</i> Perceptron multicouche
MSPCA	<i>Multiscale principal component analysis</i> Analyse en composantes principales multi-échelle
NLSVM	<i>Non-Linear Support Vector Machine</i> SVM non-linéaire
PCA	<i>Principal Component Analysis</i> Analyse en composantes principales
PSD	<i>Power Spectral Density</i> Densité spectrale de puissance
RF	<i>Random Forest</i> Forêt aléatoire
ROC	<i>Receiver Operating Characteristic</i> Caractéristique de fonctionnement du récepteur
SCSMC	Système Canadien de Surveillance des Maladies Chroniques
sEEG	<i>Scalp Electroencephalography</i> EEG du cuir chevelu
SNR	<i>Signal to Noise Ratio</i> Rapport signal sur bruit
SRD	<i>Without dimension reduction</i> Sans Réduction de Dimension
STD	<i>Standard Deviation</i> Écart-type
STFT	<i>Short-Time Fourier Transform</i> Transformée de Fourier à court terme

SVD	<i>Singular Value Decomposition</i> Décomposition en valeurs singulières
SVM	<i>Support Vector Machine</i> Machine à vecteurs de support
SWT	<i>(Nondecimated) Stationary Wavelet Transforms</i> Transformations en ondelettes stationnaires (non décimées)
TF	<i>Times-Frequency (methods)</i> (Méthodes) de temps-fréquence
TFD	<i>Discrete Fourier transform</i> Transformée de Fourier discrète
WPD	<i>Wavelet packet decomposition</i> Décomposition en paquets d'ondelettes
XSG	<i>Xilinx System Generator</i> Système générateur de Xilinx

## INTRODUCTION GÉNÉRALE

Depuis plusieurs décennies, 1 à 2 % de la population mondiale fait face à une maladie non contagieuse, mais dangereuse connue sous le nom de crises d'épilepsie (Acharya et al., 2015). Cette maladie, potentiellement mortelle, est associée à un risque de mortalité prématuré ; et a déjà fait 177 décès parmi un groupe de 564 patients épileptiques observés pendant près de 15 ans (Gaitatzis et al., 2004). Selon l'agence de la santé publique du Canada (ASPC), près de 1 canadien sur 100 était atteint d'épilepsie pour l'année fiscale (2021-2022) ; et en l'espace de dix ans, cette maladie a augmenté de 2% en moyenne à tous les ans (ASPC, 2024). Face à cette augmentation continue de nouveaux cas, le Canada comme tant d'autres pays du monde doit déployer davantage d'efforts pour faire face à cette maladie neurologique qui met tant en danger la vie de ses victimes. En effet, l'épilepsie expose les individus à des risques graves, tels que des accidents mortels lors de crises, notamment la noyade, les chutes ou d'autres incidents liés à la perte de conscience et aux convulsions (INSERM, 2018) ou à cause de l'affaiblissement de l'espérance de vie du malade (Gaitatzis et al., 2004; Neligan et al., 2011; Trinkka et al., 2023).

Autrefois, la détection de la crise épileptique était rendue possible grâce à l'évaluation manuelle ou visuelle des signaux biomédicaux du patient faite par un spécialiste dans le domaine, un neurophysiologiste (Hassan et al., 2016; Siuly et al., 2016). Cette évaluation subjective des signaux biomédicaux par des médecins experts peut aboutir à un diagnostic peu fiable ou inefficace (Sörnmo & Laguna, 2005), et était très coûteuse en temps et en ressources humaines (Siuly et al., 2016). De nos jours, en se basant sur de nombreuses techniques du traitement du signal développées récemment, surtout grâce aux avancées de l'intelligence artificielle (IA), plusieurs approches ont été proposées pour la détection objective des crises épileptiques, à l'aide de l'analyse des signaux électroencéphalogrammes (EEG) (Hassan et al., 2016).

Comme réponse à la crise épileptique et à ses effets secondaires et pour apporter une aide appréciable aux médecins experts dans l'analyse et le diagnostic des signaux biomédicaux, le présent projet de recherche a été initié afin de réaliser un système robuste de détection automatique des crises d'épilepsie.

Ce travail de recherche consiste à réaliser, à l'aide de l'apprentissage automatique, ou apprentissage machine, un système de classification des crises épileptiques, basé exclusivement sur l'analyse des signaux EEG. Le premier chapitre introduit la notion des crises épileptiques, les appareils utilisés dans le diagnostic des crises épileptiques et dans l'acquisition de ses signaux EEG, suivi de la problématique de recherche, les objectifs, les hypothèses ainsi que la méthodologie utilisée. Le deuxième chapitre présente les méthodes d'extractions de caractéristiques et de réduction de dimension. Le troisième chapitre aborde les différents algorithmes de classifications les plus utilisés ; et les quatrième et cinquième chapitres sont dédiés à la présentation des résultats obtenus, d'abord par les détecteurs les plus performants au quatrième chapitre, et ensuite, par l'implantation matérielle au cinquième et dernier chapitre. Pour conclure ce rapport, une conclusion générale avec des pistes d'optimisation pour le système développé est présentée.

# **CHAPITRE 1**

## **LES CRISES ÉPILEPTIQUES ET LES SIGNAUX EEG**

Ce chapitre décrit d'abord les crises épileptiques, comment elles se manifestent, les appareils utilisés dans l'acquisition des signaux cérébraux ; ensuite, la problématique de la détection de l'épilepsie, les objectifs du projet, ainsi que les hypothèses sur lesquelles se base la méthodologie appliquée. Ce travail de recherche met également en lumière l'emploi de certains outils de traitement du signal dans l'interprétation des signaux cérébraux pour diagnostiquer la crise épileptique.

### **1.1 CONTEXTE**

L'épilepsie est un trouble neurologique chronique manifesté par des convulsions qui affecte depuis plusieurs milliers d'années beaucoup de gens dans le monde. Du grec : « epilêpsia » qui signifie une attaque subite, un arrêt soudain, cette maladie remonte au temps de l'Égypte antique avant même le premier traité sur l'épilepsie attribué à Hippocrate et était pendant longtemps considérée comme une maladie démoniaque. Très tard, vers la fin du 18<sup>ème</sup> siècle, cette maladie est appréhendée de manière plus objective grâce aux avancées technologiques dans le domaine médical. C'est en effet, la découverte de Hans Berger qui marquera le plus la compréhension et l'interprétation de cette maladie grâce à l'utilisation de l'Électroencéphalographie (EEG) dans l'acquisition de l'activité électrique du cerveau qui permet de détecter toutes sortes d'anomalies du cerveau en utilisant les outils de l'intelligence artificielle. Depuis, médecins et scientifiques se lancent le défi de comprendre et de combattre cette maladie par tous les moyens que ce soit par pharmacologie ou neurochirurgie, ou l'utilisation des outils statistiques et mathématiques (Issaka, 2017).

## **1.2 NOMENCLATURE DES CRISES ÉPILEPTIQUES**

L'épilepsie est une maladie neurodégénérative courante qui touche des millions de gens dans le monde et qui augmente considérablement chez les personnes âgées (Acharya et al., 2015). Elle est caractérisée par des crises soudaines, des comportements anormaux et inappropriés périodiques et un état de conscience altéré (Ghazali et al., 2022). Selon les situations, les symptômes neuropsychiatriques des patients peuvent être diagnostiqués comme avant la crise (précritique), après la crise (postcritique), indépendamment de l'apparition de la crise (inter critique) ou comme expression de la crise (critique) (Mula & Monaco, 2011).

### **1.2.1 Manifestation des crises épileptiques**

Pour comprendre comment une crise se produit, il faut remonter au fonctionnement du cerveau. En effet, toutes les actions, mouvements et autres, que produit le corps sont déclenchées à partir des activités de certaines cellules du cerveau connues sous le nom de neurones (Olokodana et al., 2020). Dans la suite, est mis en exergue le fonctionnement de la cellule neuronale et les événements liés au déclenchement de la crise.

#### **1.2.1.1 Les neurones et leur fonctionnement**

Les neurones sont en fait des cellules spécialisées du système nerveux qui reçoivent, traitent et transmettent des signaux électrochimiques à travers le corps. Comme le montre la figure 1.1 ci-après, ils sont principalement composés d'un corps cellulaire (ou soma) contenant le noyau et le cytoplasme, des dendrites et d'axone. Les dendrites sont des prolongements du corps cellulaire qui reçoivent les signaux provenant des autres neurones. L'axone est un prolongement unique du corps cellulaire qui envoie les signaux vers d'autres neurones ou vers d'autres cellules grâce à ses terminaisons nerveuses ou axonales appelées synapses. Les synapses, quant à eux, contiennent deux sortes de substance ou molécule chimique utilisées comme code de communication pour transférer des messages (sous forme d'influx chimique) entre neurones du nom de neurotransmetteurs qui peuvent être inhibiteurs

ou excitateurs. Les neurotransmetteurs peuvent être considérés comme un système d'aiguillage du cerveau qui activent ou désactivent un neurone, dépendamment du type (excitateur ou inhibiteur) et de la quantité de neurotransmetteurs présente à l'entrée de ce neurone-là (dans les dendrites). Car, un neurone peut être relié à un autre par un ou plusieurs interrupteurs synaptiques. La somme des entrées excitées peut pousser le neurone suivant à s'activer pour émettre lui aussi un signal électrique si celle-ci dépasse un certain seuil (Medani, 2016; Zippo, 2014). La figure 1.1 présente les principaux composants d'un neurone biologique.

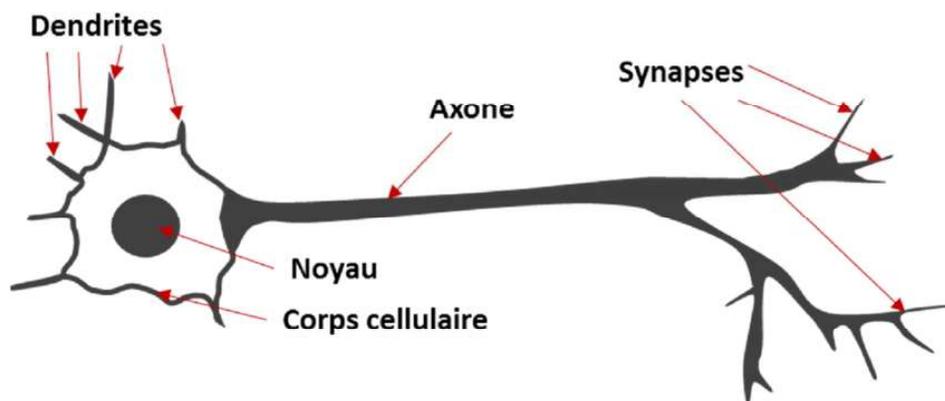


Figure 1.1 Les principaux composants d'un neurone biologique (Reche, 2019)

#### 1.2.1.2 Dérèglement neuronal, production d'une première crise

Les neurones ont la capacité de transmettre des influx nerveux, c'est-à-dire des impulsions électriques. Ces impulsions électriques peuvent venir de différentes régions du cerveau pour activer ou désactiver des parties du corps selon le besoin du présent moment. Par exemple, lorsque nous voulons marcher, manger ou danser, des signaux électriques partent du cortex moteur de notre cerveau pour envoyer les commandes aux muscles concernés. De même, le cortex visuel dans le lobe occipital gère le traitement des informations visuelles, tandis que le cortex auditif dans le lobe temporal traite les sons. Le fonctionnement normal de l'ensemble du système nerveux est réalisé lorsque les impulsions électriques sont envoyées au reste du corps de manière synchronisée et préméditée.

Cependant, lorsqu'un groupe de neurones envoient des signaux électriques de manière incontrôlée et inattendue dans le corps, cela produit un choc électrique dans le cerveau menant à une sorte de court-circuit; et lorsque ce phénomène est répétitif, il s'agit d'une crise épileptique. Ce phénomène conduit souvent à des convulsions et une perte de connaissance et de contrôle (Olokodana et al., 2020). La figure 1.2 montre un patient dans un état de crises d'épilepsie.



Figure 1.2 Patient sous crise d'épilepsie (Olokodana et al., 2020)

### 1.2.2 Les différents types de crises d'épilepsie

Dépendamment d'où elles sont localisées dans le cerveau, des symptômes physiques et du taux d'apparition, les crises peuvent être classées en (ICM, 2022; Rahman et al., 2021) :

- Focales, si elles sont limitées à un hémisphère;
- Généralisées, si elles commencent à divers endroits et s'engagent rapidement;
- À début inconnu, dans ce cas, non localisées.

Elles peuvent aussi être :

- Idiopathiques, si elles sont d'origine génétique (Aghakhani et al., 2004; ICM, 2022; Loiseau et al., 1991);

- Symptomatiques, si elles résultent d'une lésion ou d'une inflammation cérébrale (ICM, 2022; Loiseau et al., 1991).

### **1.3 LES APPAREILS UTILISÉS DANS LE DIAGNOSTIC DES CRISES ÉPILEPTIQUES ET L'ACQUISITION DES SIGNAUX EEG**

Actuellement, il existe un nombre limité d'appareils utilisés pour analyser les signaux cérébraux des patients épileptiques. Parmi les trois appareils les plus couramment employés, on retrouve le scanner (le rayon X), l'imagerie par résonance magnétique (IRM) et surtout le plus performant, l'électroencéphalographie (EEG). Les deux premiers appareils, le scanner et l'IRM, sont particulièrement utilisés pour déceler et identifier les causes et les types de crises d'épilepsie, mais surtout la gravité de la crise. Quant au troisième, l'EEG, il est particulièrement utile pour étudier l'évolution des crises et, dans certains cas, pour prédire leur apparition.

#### **1.3.1 Rôle du scanner et de l'IRM dans la détection de la crise**

Généralement le scanner et surtout l'IRM sont utilisés après une première crise pour aider le neurologue à effectuer un diagnostic différentiel de la crise. Ils sont le plus souvent utilisés en complément dans la recherche approfondie de l'origine de la maladie (Assia et al., 2017; Hodel, 2022).

##### **1.3.1.1 L'imagerie par résonance magnétique (IRM)**

L'imagerie par résonance magnétique (IRM) contribue au diagnostic positif de la crise épileptique en cas de mise en évidence d'une lésion possiblement épileptogène. Elle aide à écarter la cause de l'épilepsie en la différenciant d'autres troubles cérébraux tels que : l'ischémie cérébrale et la migraine, et permet d'identifier si la crise est liée ou non à une lésion cérébrale focale (Hodel, 2022).

### 1.3.1.2 Le scanner

D'un autre côté, deux types de scanner peuvent être utilisés dans le diagnostic différentiel de la crise : l'angioscanner, utilisé pour révéler la sténose ou l'occlusion artérielle qui est responsable de l'ischémie cérébrale ; et le scanner de perfusion, utilisé pour vérifier s'il y a une diminution systématisée du débit sanguin dans les vaisseaux des cortex (en cas de crise épileptique aiguë, le scanner de perfusion montrera une augmentation non systématisée du débit sanguin). En essence, la vérification avec le scanner est basée sur des indicateurs, des effets secondaires, généralement liés à la crise épileptique (Hodel, 2022).

### 1.3.2 Électroencéphalographie (EEG) et acquisitions des signaux cérébraux

Du terme allemand « elektrenkephalogramm » (Siuly et al., 2016), l'électroencéphalogramme (EEG) est un examen qui permet de mesurer les potentiels reflétant l'activité électrique du cerveau humain. Étant le seul outil connu facilitant l'acquisition des données, il permet l'étude des fonctions cérébrales et le diagnostic des maladies neurologiques (telles que l'épilepsie, les tumeurs cérébrales, les traumatismes crâniens, les troubles du sommeil, la démence et le contrôle de la profondeur de l'anesthésie pendant une intervention chirurgicale), il est largement utilisé par les médecins et les scientifiques. Il a été introduit pour la première fois en 1929 par un neuropsychiatre du nom de Hans Berger (Medani, 2016; Siuly et al., 2016). Ce premier test a été réalisé à l'aide de deux électrodes placées sur la tête d'un être humain pour acquérir un courant à faible intensité au moyen d'un galvanomètre (Subasi, 2019). Selon Berger, l'état fonctionnel du cerveau, comme le sommeil, l'anesthésie et l'épilepsie aurait un impact significatif sur les courants cérébraux. Cette idée révolutionnaire contribue à la naissance d'une nouvelle branche de la science médicale du nom de neurophysiologie (Siuly et al., 2016). Aujourd'hui, les équipements d'acquisition des signaux EEG cliniques sont munis de plusieurs électrodes, positionnées sur le cuir chevelu selon les normes internationales 10 - 20, et sont utilisés pour soutenir les processus décisionnels des médecins en matière de surveillance de l'activité électrique cérébrale de routine (Subasi, 2019).

Plusieurs chercheurs renforcent leurs études de l'épilepsie en analysant parallèlement ou en combinant l'imagerie par résonance magnétique (IRM) à l'électroencéphalographie (EEG) (Van de Velden et al., 2023). Toutefois, puisque la crise épileptique est caractérisée par des anomalies sous forme de pointes d'ondes (ou pics) présentes dans certaines régions du cerveau, causées par des décharges épileptiformes (Adeli et al., 2007; Bronzino & Peterson, 2014; Sörnmo & Laguna, 2005; Subasi, 2007a; Subasi & Gursoy, 2010), l'électroencéphalogramme (EEG) sera l'instrument incontournable utilisé dans la détection de la crise d'épilepsie, car ce dernier permet d'obtenir les tracés de l'activité électrique du cerveau et ainsi détecter toutes décharges épileptiformes produites lors de la crise épileptique (Medani, 2016; Pittau et al., 2014). De plus, puisque les signaux EEG peuvent d'être stockés en grande quantité dans des bases de données pour être analysés et traités ultérieurement, ces derniers révèlent être la source d'informations la plus pertinente pour l'analyse de l'état et de l'activité du cerveau (Subasi, 2019). La figure 1.3 illustre le processus d'enregistrement actuel de l'activité cérébrale à l'aide de l'électroencéphalographie (EEG).

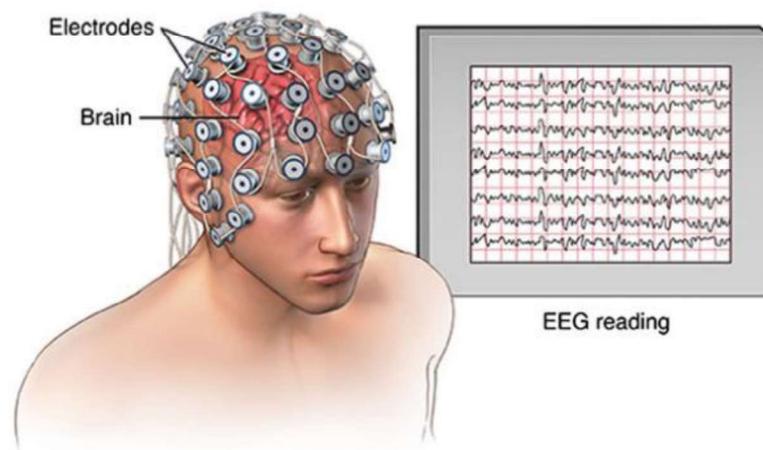


Figure 1.3 Enregistrement de l'activité cérébrale à l'aide de l'électroencéphalographie (EEG) (Siuly et al., 2016)

Pour extraire les données cérébrales à l'aide de l'électroencéphalographie (EEG), deux sortes de techniques sont couramment utilisées : EEG non invasif ou scalp EEG, et EEG invasif ou iEEG. L'utilisation des différentes techniques, qui sont détaillées un peu plus bas, dépend de la situation actuelle du patient.

### 1.3.2.1 EEG non invasif

Le EEG scalp est la méthode la plus basique pour extraire des mesures de potentiels du cerveau. Cela consiste à placer des électrodes non invasives sur le cuir chevelu d'un patient afin de capter ses activités cérébrales. Il est généralement utilisé après une première crise, en cas de suivi pour des crises bénignes, ou en laboratoire sur des patients sains (Cattan, 2019; Rahman et al., 2021; Subramaniyam, 2021).

### 1.3.2.2 EEG invasif

L'électroencéphalographie invasive (iEEG) est réalisée le plus souvent dans le cadre du traitement chirurgical de l'épilepsie, en cas de lésion ou de tumeur cérébrale. Cependant, pour certains patients présentant une épilepsie du lobe extra-temporal ou une épilepsie du lobe temporal non lésionnel, l'enregistrement de routine (non invasif) de l'EEG du cuir chevelu n'est pas suffisant (Shah & Mittal, 2014). Chez ces patients-là, il est nécessaire que l'enregistrement EEG soit fait à proximité du foyer de la crise, ce qui est réalisé en plaçant des électrodes intracrâniennes invasives dans la substance du cerveau.

## 1.3.3 Période critique et période sans crise

Un patient épileptique ne présente pas toujours de signes et/ou de symptômes lors de la crise. Ces événements peuvent se produire plusieurs fois par jour, ou se limiter à une seule fois dans toute la vie de l'individu. Peu importe le type d'encéphalographie utilisé pour détecter la crise en tenant compte des conditions courantes d'utilisation de l'une ou l'autre méthode mentionnée plus haut, le résultat a tendance à converger vers le même point : une structure dans laquelle s'ajoutent plusieurs composantes fréquentielles pour des périodes critiques ou de convulsions, une structure plus régulière sans composantes fréquentielles additionnelles pour des périodes sans convulsions (Shoeb & Guttag, 2010). La figure 1.4 suivante présente les signaux cérébraux d'un patient pour des périodes sans convulsions (état normal), et la figure 1.5 pour les périodes critiques (Goldberger et al., 2000).

Patient : CHB01\_02, c'est à dire : deuxième heure d'enregistrement du patient CHB01.  
 Nombre de crises : 0, Durée d'enregistrement : 1h de temps, Période d'enregistrement : 12 :42 :57 à  
 13 :42 :57, Durée d'enregistrement capturée : 10 secondes, Période d'enregistrement capturée : 13 :10 :27 à

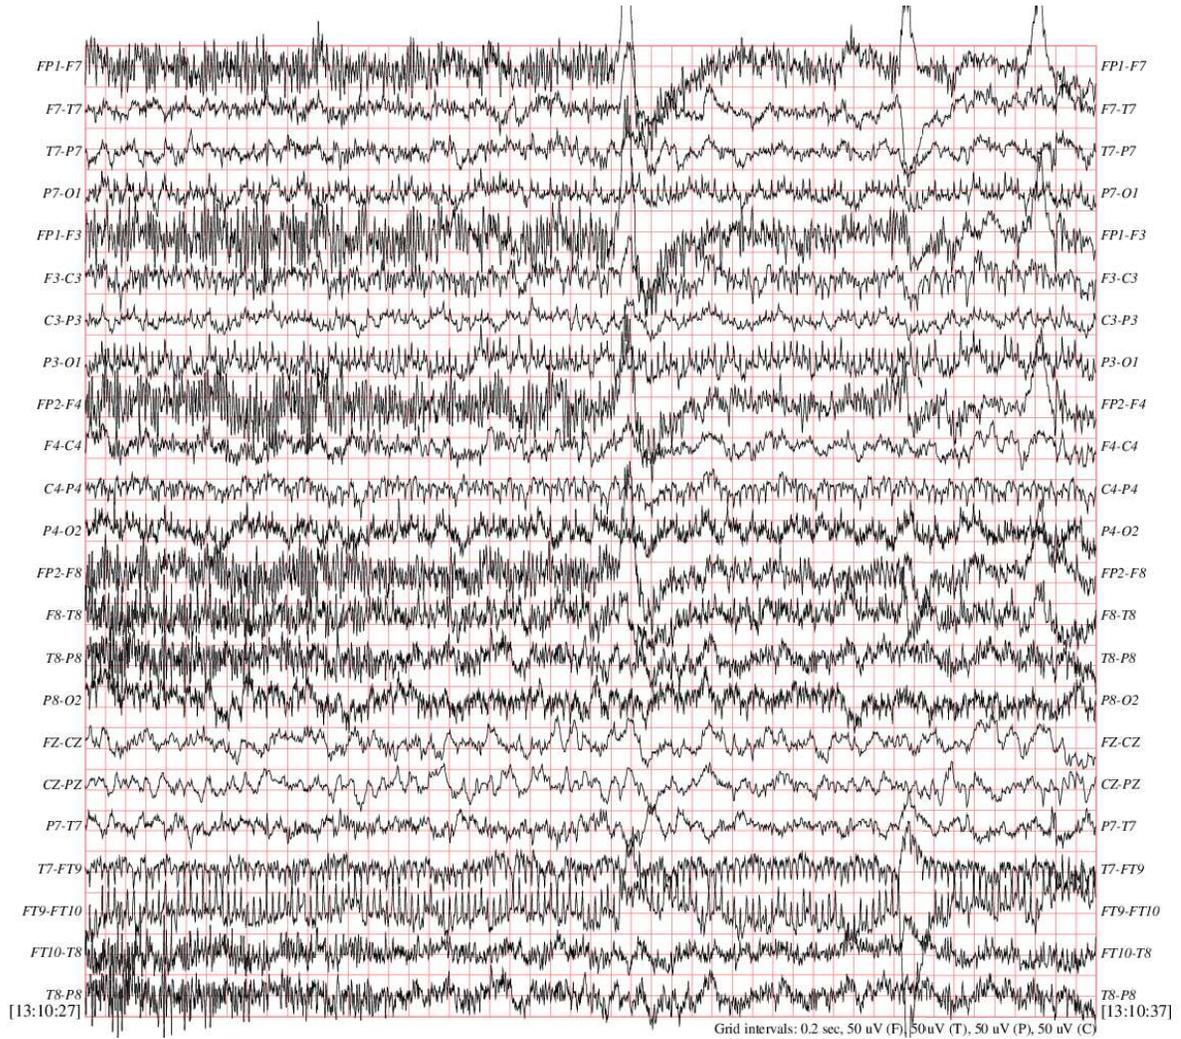


Figure 1.4 Enregistrement de 10 s des signaux cérébraux d'un patient épileptique en temps normal, capturé à l'aide des outils disponibles sur la plateforme de PhysioBank ATM (Goldberger et al., 2000)

Patient : CHB01\_04, c'est à dire : quatrième heure d'enregistrement du patient CHB01.  
Nombre de crises : 1, Début de crise : 15 : 07 :39 (1467 secondes) fin de crise 15 :08 :06 (1494 secondes),  
Durée d'enregistrement : 1h de temps, Période d'enregistrement : 14 :43 :12 à 15 :43 :12,  
Durée d'enregistrement capturée : 10 secondes, Période d'enregistrement capturée : 15 :07 :52 à 15 :08 :02

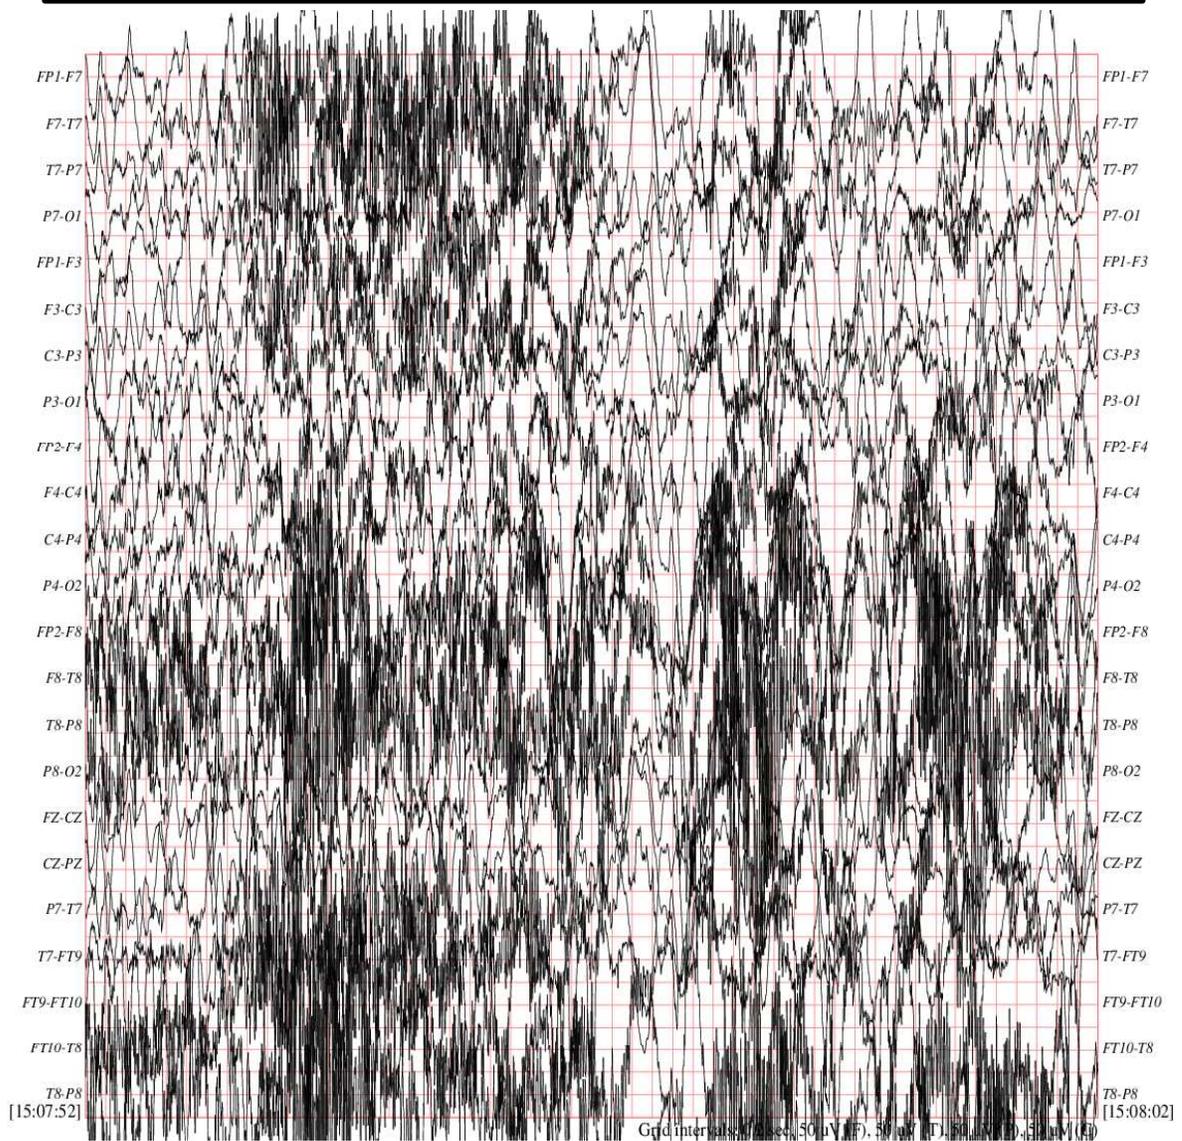


Figure 1.5 Enregistrement de 10 s des signaux cérébraux d'un patient épileptique en crise, capturé à l'aide des outils disponibles sur la plateforme de PhysioBank ATM (Goldberger et al., 2000)

Comme on peut le voir, les pointes d’ondes de l’activité électrique du cerveau du patient CHB01 sont nettement différentes dans les figures 1.4 et 1.5 précédentes. En effet, l’activité cérébrale critique se manifeste par des décharges épileptiformes caractérisées par des pointes d’onde ou pics. Ces pics peuvent être expliqués par plusieurs composantes fréquentielles qui s’ajoutent lors des périodes critiques ou des convulsions, ce qui n’est pas le cas en temps normal. Plus ces décharges sont abondantes, plus des composantes fréquentielles s’ajoutent aux précédents signaux, cela explique les tâches en noir foncé de la figure 1.5; représentant la variation fréquentielle au niveau des canaux les plus proches de la zone épileptogène, due à la présence des convulsions.

### 1.3.4 Bases de données EEG

#### 1.3.4.1 Bases de données EEG les plus populaires

De nos jours, plusieurs bases de données sont utilisées pour étudier les crises épileptiques à partir des signaux cérébraux enregistrés grâce à l’utilisation de l’encéphalographie EEG. Le tableau 1.1 présente les bases les plus citées dans la littérature (Gutttag, 2010; Ihle et al., 2012; Rahman et al., 2021; Shoeibi et al., 2022; Wong et al., 2023).

Tableau 1.1 Bases de données EEG populaires utilisées dans la détection de la crise épileptique

Base de données	Type	Nombre de sujets	Nombre de canaux	Fréquence d’échantillonnage (en Hz)	Durée (en heure)	Nombre de crises dans la base de données
CHB-MIT	Scalp EEG	23	23-26	256	959	198
University Of Bonn	Scalp EEG + iEEG	5	1	173,61	3,3	NA
Melbourne	iEEG	3	16	400	1155	1139
American Epilepsy Society	iEEG	7	15-24	400-5000	1333,7	NA
European Epilepsy Dataset	iEEG	30	31-125	256-2500	6488	590
Epilepsia (Freiburg)	iEEG	21	NA	256	708	87
Flint Hills Scientific	iEEG	10	48-64	249	1419	59

### 1.3.4.2 Bases de données utilisées dans le développement de ce projet

Pour entraîner et tester les différents modèles d'apprentissage automatique de ce projet, les bases de données de l'hôpital pour enfants de Boston (CHB-MIT) et de l'Université de Bonn ont été utilisées, car elles sont largement reconnues et fréquemment employées par de nombreux chercheurs, tels que (Acharya et al., 2015; Anuragi et al., 2022; Elhosary et al., 2021; Shoeb & Guttag, 2010; Slimen et al., 2020; Subasi, 2007a), pour ne citer que ceux-là. Le choix de la base de données CHB-MIT s'explique par le fait qu'elle est complète, ouverte au public et facile à utiliser, tandis que le choix de la base de données de l'Université de Bonn repose sur le fait qu'elle ne dispose que d'un seul canal pour l'analyse de l'activité cérébrale, ce qui est particulièrement très avantageux pour une implémentation matérielle. De plus, la performance de la classification est excellente avec l'utilisation de ce seul canal.

#### a) *BASE DE DONNÉES CHB-MIT*

La base de données CHB-MIT a été collectée par un groupe de chercheurs de l'Hôpital pour enfants de Boston (CHB) et de l'Institut Technologique de Massachussetts (MIT). Elle se compose d'enregistrements EEG de sujets pédiatriques souffrant de crises épileptiques insurmontables et en attente d'une intervention chirurgicale. Les enregistrements, regroupés en 23 cas, ont été collectés auprès de 22 sujets, dont 5 garçons, âgés de 3 à 22 ans, et 17 filles âgées de 1,5 à 19 ans. Un des 23 cas (le chb21) a été obtenu après 1.5 ans auprès du même sujet féminin (le cas chb01). Dans cette base de données, les dates d'origine sont remplacées par des dates de substitution afin de protéger la vie privée de ces sujets. Les enregistrements, découpés en tronçon d'une heure de temps, contiennent des signaux échantillonnés à 256 Hz avec une résolution de 16 bits. La plupart de ces enregistrements contiennent 23 canaux EEG (quelques cas contiennent 24 ou 26) et ont été recueillis selon le standard international 10-20 en matière de positionnement et nomenclature des électrodes EEG. Les autres informations relatives à cette base se trouvent sur la page web de PhysioNet (Guttag, 2010).

Les données EEG de la base CHB-MIT utilisées dans ce projet ne proviennent pas directement de PhysioNet (Goldberger et al., 2000), mais de la version prétraitée par (Deepa & Ramesh, 2022). En effet, les données EEG brutes de la base CHB-MIT, disponibles sur le site PhysioNet, sont réparties entre plusieurs patients. Pour former une base représentative à partir de ces données, il faut repérer et extraire toutes les périodes de crise pour chaque patient, puis les regrouper ensemble afin de former une classe épileptique pour la base de données CHB-MIT. Simultanément, il faut aussi sélectionner une portion de données inter-critiques pour chaque patient, équivalente à la portion critique, afin de créer une classe non-épileptique pour cette base. C'est ce travail de prétraitement qu'ont effectué (Deepa & Ramesh, 2022) à partir de la base de données originale, ce qui explique pourquoi leurs données sont utilisées à la place des données EEG brutes de CHB-MIT.

Les données prétraitées utilisées incluent les enregistrements représentatifs des 23 patients épileptiques de la base de données originale disponible sur le site PhysioNet. Ces données sont organisées en deux fichiers distincts : l'un contient les périodes de crise (périodes critiques), et l'autre regroupe les périodes sans crises (périodes inter-critiques). Chacun de ces fichiers est organisé en 23 canaux, car les canaux supplémentaires des patients en ayant plus ont été éliminés lors de la création de cette version de la base de données. Les détails sur l'utilisation de ces données sont décrits dans le quatrième chapitre de ce mémoire et les autres informations relatives à cette base de données de EEG scalp de la base de données CHB-MIT prétraitée sont présentées dans l'étude de (Deepa & Ramesh, 2022).

#### **b) BASE DE DONNÉES DE L'UNIVERSITÉ DE BONN**

Contrairement à la base de données CHB-MIT qui est constituée de données EEG captées sur le cuir chevelu et organisées en canaux, la base de données de l'Université de Bonn est formée de données EEG invasives et non invasives, possède un seul canal et est organisée en cinq (5) classes de cent (100) segments chacune. Les classes sont notées de A à E et ont été recueillies auprès de dix (10) sujets dont cinq (5) d'entre eux sont en bonne santé et forment les classes A et B, et les cinq (5) autres sujets sont épileptiques et forment les

classes C, D et E. Le sexe de ces sujets n'a pas été révélé. Contrairement aux classes A et B qui ont été recueillies auprès des personnes qui n'ont jamais contracté la maladie, les données des classes C et D ont été collectées auprès des patients épileptiques pendant des périodes où ces derniers n'étaient pas en crise. Cela dit, les classes C et D ne contiennent aucune donnée critique, mais uniquement des données reflétant l'activité électrique des zones les plus touchées par la crise pendant les périodes inter-critiques (i.e. les périodes sans rapport avec la crise). Les données de la classe A, quant à elles, ont été collectées pendant que les patients sains étaient éveillés (yeux ouverts), tandis que celles de la classe B ont été recueillies lorsque ces patients sains étaient vraisemblablement endormis (yeux fermés). Les données de la classe C sont obtenues à partir des électrodes placées directement dans l'hippocampe du cerveau des patients épileptiques et celles de la classe D, dans la zone épileptogène du cerveau des patients épileptiques. Enfin, c'est uniquement la classe E qui est formée de segments critiques capturés lors des différentes périodes de crise des patients épileptiques testés. La longueur de chacun des segments est de 4097 échantillons. Ces enregistrements, découpés en segments, contiennent des signaux échantillonnés à 173.61 Hz acquis à partir d'un système d'amplification de 128 canaux avec une résolution de 12 bits. Les autres informations relatives à cette base sont présentées dans (Andrzejak et al., 2001).

Pour beaucoup de chercheurs tels que (Guo et al., 2009; Li et al., 2017; Zairi et al., 2022) et tant d'autres encore utilisant la base de données de l'Université de Bonn, les classes d'intérêt pour catégoriser l'épilepsie sont les classes A et E ; pour (Ghosh-Dastidar et al., 2007) ce sont les classes A, D et E ; tandis que (Faticah et al., 2014; Wijayanto et al., 2020) utilisent toutes les cinq classes de cette base de données dans leur classification d'épilepsie. Le plus souvent, le choix de ces classes est réalisé en fonction de l'objectif fixé par les chercheurs. Par exemple, la classification à l'aide des classes A et E ou B et E permet de distinguer les personnes saines des personnes malades tandis que la classification à l'aide des classes C et E ou D et E permet de différencier les patients en état de crise à ceux ne présentant aucun signe ou symptôme de crise. Donc, les deux premières et la dernière classes (A, B et E) sont utilisées pour prédire si un patient est épileptique ou non (prédiction de la maladie de

l'épilepsie), tandis que les trois dernières (C, D et E) sont utilisées pour prédire si le patient épileptique est en crise ou pas (prédiction des convulsions chez les patients épileptiques).

Les classes C et D peuvent aussi être utilisées pour créer d'autres étiquettes de sortie comme une étiquette inter-critique, puisque C et D sont les classes inter-critiques respectivement des zones hippocampique et épileptogène. D est par contre la classe inter-critique généralement la plus utilisée puisqu'elle regorge d'informations de l'endroit où débute la crise. Étant donné que ce projet se limite à une classification binaire (malade ou en bonne santé / en état de crise ou non), l'ajout d'une troisième étiquette n'est pas prévu. De plus, comme la base de données CHB-MIT n'est constituée que de données des patients qui souffrent de l'épilepsie, elle est utilisée à la place des classes C et D afin de prédire les convulsions chez les patients épileptiques puisqu'elle est aussi formée de deux types de données épileptiques : données inter-critiques et données critiques.

La classe B de la base de données de l'Université de Bonn permet de réaliser un tout autre test extrêmement important pour la classification de l'épilepsie à partir de signaux EEG. En effet, un phénomène particulier se produit lorsqu'un patient en bonne santé dort : ses signaux cérébraux se manifestent presque de la même façon que les signaux cérébraux d'un patient épileptique et, quelquefois, sont très mal interprétés par les algorithmes de classification. Ce phénomène, appelé « fuseau de sommeil », ou « sommeil lent », ou « spindle » en anglais (Shoeb & Guttag, 2010), sera également pris en compte dans ce projet.

#### **1.4 PROBLÉMATIQUE DE RECHERCHE**

L'inspection visuelle des signaux EEG est une technique qui permet aux neurophysiologistes de diagnostiquer des patients ayant divers troubles et problèmes neurologiques, comme l'épilepsie. En dépit de ses avantages dans le diagnostic différentiel de ces maladies neurologiques, cette méthode subjective nécessitait un temps d'analyse extrêmement long et l'avis de plusieurs experts avant d'arriver à une décision définitive. De plus, l'interprétation des tracés des signaux cérébraux ne conduit pas toujours à un résultat précis puisque celle-ci est basée sur la comparaison successive du tracé cérébral actuel avec

des cas antérieurs, qui, parfois, n'avaient aucun lien avec le cas actuel. En ce sens, construire un système d'analyse automatique de la crise épileptique devient très crucial. Ce dernier pourra détecter et différencier, avec précision, et dans un délai considérablement court, les périodes de crise de celles sans crise, et cela de manière objective. Ce qui pourrait faciliter la prise de décision du médecin dans son diagnostic différentiel précis de la crise épileptique.

Plusieurs études se concentrent sur la réalisation d'un tel système basé sur les outils de l'apprentissage machine en utilisant la base de données CHB-MIT (Elhosary et al., 2021; Shoeb & Guttag, 2010; Slimen et al., 2020) et d'autres celle de l'Université de Bonn (Acharya et al., 2015; Anuragi et al., 2022; Subasi, 2007a). D'autres systèmes se basent sur l'apprentissage profond comme ceux de (Gao et al., 2020; Sahani, 2021; Xiong et al., 2021) en utilisant la base de données CHB-MIT et ceux de (Akut, 2019; Sahani, 2021; Zeng et al., 2021) en utilisant la base de données de l'Université de Bonn.

Les systèmes d'acquisition des signaux EEG peuvent comporter de un à plusieurs dizaines de canaux, placés à différents endroits du cerveau. Plus le nombre de canaux est élevé, plus le système d'analyse et d'aide au diagnostic devient complexe et exigeant en ressources matérielles et en temps de calcul. La précision de la classification peut être alors grandement influencée par la gestion de tous ces canaux.

## **1.5 OBJECTIFS VISÉS**

L'objectif principal de ce travail de recherche est la réalisation d'un système efficace, robuste et fiable de détection automatique des crises d'épilepsie, basé sur l'analyse des signaux EEG, ainsi que son implémentation matérielle pour un traitement en temps réel.

Ce système devra être capable de détecter avec précision les crises d'épilepsie, même en présence de bruit ou de variabilité importante dans les signaux EEG, et ce, indépendamment des différences inter-patients.

Il devra utiliser un nombre minimal de canaux tout en maintenant une précision de détection élevée. Cela permettra non seulement de réduire les coûts matériels et la

complexité, mais aussi d'optimiser les temps de calcul et l'utilisation des ressources matérielles, conditions essentielles pour un traitement en temps réel fiable et efficace.

## **1.6 HYPOTHÈSES**

Les algorithmes d'apprentissage machine ont été appliqués avec succès aux tâches de classification et de régression dans divers domaines d'application. Les solutions proposées dans la littérature vont d'un simple système d'apprentissage à un ensemble d'apprentissage, dont l'agrégation finale est obtenue par vote pour la classification ou par moyenne pour la régression. Des modèles d'apprentissage machine simples, mais efficaces, peuvent être développés pour permettre une détection précise et en temps réel.

## **1.7 MÉTHODOLOGIE APPLIQUÉE**

Pour atteindre les objectifs visés dans ce projet de recherche, tout en tenant compte des contraintes liées à l'accessibilité des données, nous avons adopté la démarche suivante :

1. Réalisation d'une recherche bibliographique pour bien comprendre l'état de l'art relatif à cette problématique ;
2. Analyse des bases de données existantes afin de sélectionner les plus représentatives ;
3. Recherche de modèles d'apprentissage machine efficaces, mais dont la complexité reste compatible avec une implémentation matérielle ;
4. Sélection des techniques composant un système d'apprentissage type, incluant le prétraitement des données, l'extraction des caractéristiques, la réduction de dimensionnalité et la classification ;
5. Comparaison des performances des systèmes de détection d'épilepsie sélectionnés ;
6. Implémentation matérielle de certains systèmes de détection sur un circuit FPGA à l'aide d'outils de prototypage rapide.

La figure 1.6 présente le diagramme en blocs permettant d'évaluer les 45 modèles présélectionnés, obtenus par les différentes combinaisons de 3 méthodes d'extraction des caractéristiques, 3 méthodes de réduction de dimension et 5 méthodes de classification. Ces 45 combinaisons ont été implémentées et évaluées par logiciel afin d'identifier la meilleure combinaison pour chacun des 5 classificateurs (LDA, KNN, RF, SVM et ANN). Par la suite, un ensemble d'apprentissage, formé des 5 systèmes correspondant aux meilleures combinaisons décrites précédemment, a été proposé pour améliorer leur performance globale (voir figure 1.7). L'agrégation globale pour ce type de système repose sur un vote à la majorité. Cet ensemble d'apprentissage a également été implémenté par logiciel.

Pour l'implémentation matérielle, le choix s'est porté sur les circuits FPGA, qui allient puissance de calcul et flexibilité de programmation. L'outil de programmation haut-niveau *AMD/Xilinx System Generator* a été utilisé pour le prototypage rapide des systèmes de détection sélectionnés pour l'implémentation matérielle. Il permet de profiter de l'environnement convivial de Simulink pour concevoir, implémenter et tester les modèles avant de les cosimuler sur la puce FPGA, à partir de ce même environnement.

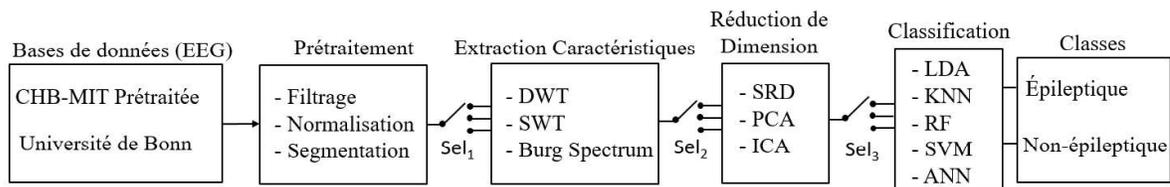


Figure 1.6 Diagramme bloc décrivant les 45 systèmes évalués individuellement pour la détection de la crise épileptique

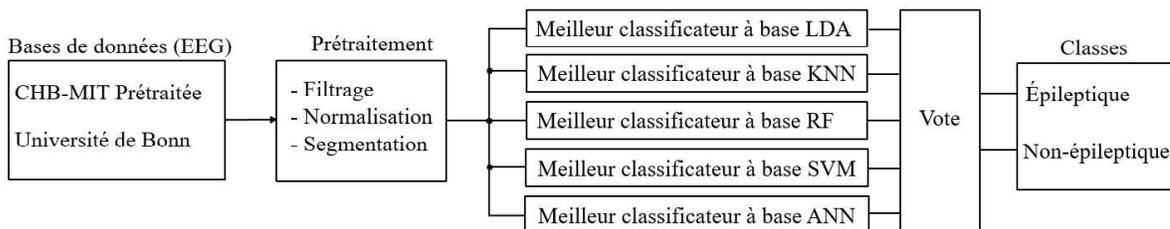


Figure 1.7 Diagramme bloc d'un ensemble d'apprentissage basé sur les 5 meilleurs classificateurs

## 1.8 CONTRIBUTION

Dans ce travail, quarante-cinq (45) modèles de classification des crises d'épilepsie ont été étudiés et comparés en logiciel afin d'établir un ensemble d'apprentissage, constitué du meilleur modèle de chacun des 5 classificateurs. Cet ensemble tire avantage des points forts de chaque modèle afin d'améliorer les performances globales.

Parmi les 45 modèles, deux (2) ont été implémentés en matériel sur puce FPGA. Des architectures matérielles optimisées ont été proposées pour l'implémentation des techniques d'extraction des caractéristiques basées sur la transformée en ondelettes et de classification utilisant les réseaux de neurones (MLP) et les machines à vecteurs de support (SVM).

## 1.9 MATÉRIELS ET OUTILS UTILISÉS

Dans ce travail de recherche, l'environnement Matlab/Simulink a été utilisé au début pour entraîner et tester différents algorithmes d'apprentissage automatique. Ensuite, l'outil *AMD/Xilinx System Generator* est utilisé pour créer l'architecture ou le design de la classification matérielle et pour générer le bloc de la cosimulation pour la puce FPGA.

Un ordinateur muni d'un processeur Intel Core i7-2600, une horloge de 3.4 GHz, une mémoire vive de 6 Go, et Windows 10 de 64 bits comme système d'exploitation a été utilisé pour développer et tester le système de détection automatique de la crise d'épilepsie ; la carte de développement Nexys-4 basée sur la puce FPGA Xilinx Artix-7, plus précisément XC7A100T-CSG324, a été utilisée pour implémenter matériellement le système.

Toutes les opérations menant à la détection de la crise épileptique ont été développées sur le logiciel Matlab-R2021a incluant les boîtes à outils de l'apprentissage automatique et profond.

Une boîte à outils open source, du nom de fastICA de (Hurri et al., 1997), a été utilisée à l'étape de réduction de dimension lors du développement de ce travail afin de comparer

l'exactitude des classificateurs pour différentes combinaisons de méthodes de réduction de dimension versus méthodes d'extraction des caractéristiques.

## **CHAPITRE 2**

### **PRÉTRAITEMENT ET EXTRACTION DES CARACTÉRISTIQUES**

Comme mentionné dans le chapitre précédent, la détection de la crise épileptique se fait à travers un ensemble d'étapes, connues sous les noms de : prétraitement, extraction des caractéristiques, réduction de dimension et enfin classification (Geethu & Santhoshkumar, 2020; Jose et al., 2020; Meddah et al., 2020; Rahman et al., 2021; Saidi et al., 2018). Dans la suite, seront présentés le prétraitement, l'extraction des caractéristiques et la réduction de dimensionnalité utilisées pour capturer les informations pertinentes du signal EEG. La classification fera l'objet du troisième chapitre.

#### **2.1 PRÉTRAITEMENT DES DEUX BASES DE DONNÉES DU PROJET**

Le prétraitement des données est une étape cruciale en apprentissage automatique qui permet de les préparer au modèle de classification afin d'éviter plus tard des problèmes de sous ou de sur-apprentissage. Il consiste en une série de traitements appliqués aux données originales, afin d'améliorer leur qualité pour une utilisation ultérieure. Cette étape comprend le filtrage du bruit, la normalisation et la segmentation.

##### **2.1.1 Filtration du signal**

L'objectif de la filtration du signal est d'éliminer les informations inutiles dans le signal EEG, afin de garantir que le reste du système traite uniquement les véritables signaux cérébraux, et non les bruits induits dans ces derniers ou les deux en même temps. Deux sources majeures d'artéfacts peuvent contaminer les signaux EEG : les artéfacts d'origine interne comme clignements des yeux, activités musculaires, mouvements oculaires et ceux d'origine externe comme le bruit des électrodes, les interférences des fils électriques, etc.

Plusieurs techniques sont proposées dans la littérature pour nettoyer les données EEG de leurs bruits. Parmi celles-ci, il y a l'analyse en composantes indépendantes (ICA) qui analyse chaque entrée indépendamment des autres en se basant sur la variance la plus élevée des signaux. Elle est capable de supprimer les artéfacts puisque leur variance est supérieure à celle du vrai signal EEG (Kappel et al., 2017). Une autre approche est l'analyse en composantes principales multi-échelle MSPCA, qui combine les avantages du PCA et des ondelettes pour débruiter le signal (Alickovic et al., 2018). Par ailleurs, des filtres à réponse impulsionnelle finie (FIR) ont également été utilisés pour le traitement du bruit (Geethu & Santhoshkumar, 2020; Jose et al., 2020; Saidi et al., 2018; Wickramasuriya et al., 2015), tout comme les filtres à réponse impulsionnelle infinie (IIR) de Butterworth qui offrent un meilleur rapport signal sur bruit (SNR) lorsqu'ils sont appliqués à la prédiction des crises à partir de signaux EEG (Patnaik & Manyam, 2008; Usman et al., 2019). Dans ce projet, le choix s'est porté sur le filtre IIR de Butterworth de type passe-bande, car sa fonction de lissage est excellente. Les fréquences de coupures ainsi que les ordres des filtres utilisés sont présentés au quatrième chapitre de ce document.

### 2.1.2 Normalisation ou Standardisation

Une fois les signaux EEG filtrés, la deuxième étape du prétraitement consiste à appliquer la normalisation, qui permet de standardiser les données. La technique de normalisation appliquée est celle du z-score. Cette technique permet de transformer les signaux EEG de manière à ce qu'ils aient une moyenne de 0 et un écart-type de 1, aidant ainsi à uniformiser l'échelle des données, les rendant comparables entre eux, en neutralisant les effets des différences de moyenne et de dispersion initiales. Elle est effectuée sur tous les signaux EEG et peut être calculée à l'aide de la formule suivante (Meddah et al., 2020) :

$$z = \frac{s - \mu}{\sigma} \quad (2.1)$$

où  $z$  représente le signal EEG normalisé.  $s$  est le signal EEG original composé d'échantillons de moyenne  $\mu$  et d'écart-type  $\sigma$ .

### 2.1.3 Segmentation des données

La segmentation est une étape cruciale du prétraitement qui consiste à découper dans le temps les signaux EEG, afin de les analyser sur une courte durée tout en réduisant leurs effets de bord. Elle est réalisée en multipliant les signaux EEG par une fenêtre glissante d'observation ou de pondération, telle qu'une fenêtre de Hanning, de Hamming, de Blackman, etc. (Lyons, 2011). Ces segments sont réalisés sans chevauchement, dans le cas de ce projet, comme le montre la figure 2.1 suivante et seront ensuite utilisés dans le processus d'extraction des caractéristiques.

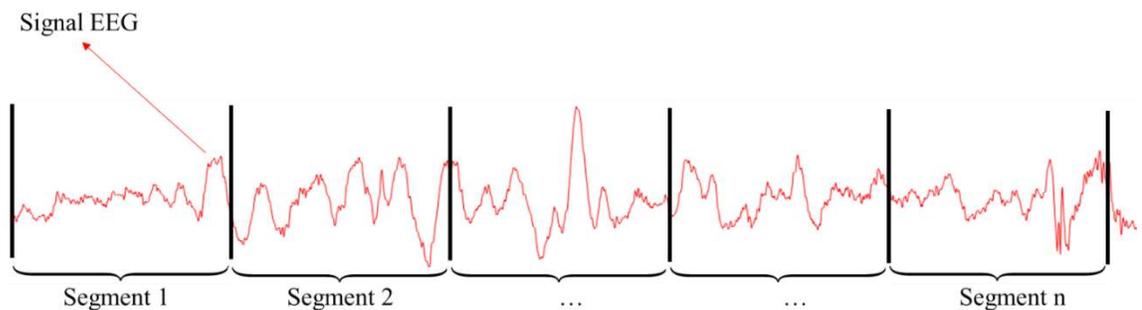


Figure 2.1 Segmentation d'un signal EEG

Ainsi, une fois que tous les signaux EEG sont filtrés, normalisés et segmentés, le processus de classification se poursuit avec la deuxième étape : l'extraction des caractéristiques.

## 2.2 MÉTHODES D'EXTRACTION DES CARACTÉRISTIQUES

L'extraction des caractéristiques est une étape cruciale en traitement du signal biomédical, car elle permet de représenter et coder le signal par un vecteur d'attributs caractéristiques distinctif, informatif et réduit, pour améliorer l'efficacité du stockage et du traitement de données (Siuly et al., 2016; Subasi, 2019). Cette technique permet, à l'aide des outils de traitement avancé du signal, d'extraire un petit ensemble de paramètres (informations) à partir d'un grand ensemble d'échantillons ou données brutes.

Parmi les diverses méthodes proposées dans la littérature, les modèles paramétriques d'estimation spectrale et l'analyse temps-fréquence sont les plus populaires et sont étudiés dans ce présent projet de recherche.

### **2.2.1 Les méthodes d'analyse temps-fréquence**

Les méthodes de caractérisation temps-fréquence (TF) sont largement utilisées dans le traitement et l'analyse des signaux biomédicaux (Siuly et al., 2016). Parmi ces méthodes se retrouvent la transformée de Fourier à court-terme (STFT), la distribution de Wigner-Ville, la transformée en ondelettes (WT), la transformée en ondelettes discrète (DWT), la décomposition en paquets d'ondelettes (WPD), la transformée en ondelettes stationnaire (SWT), la transformée en ondelettes complexe à double arbre (DTCWT), la transformée en ondelettes empirique (EWT), la décomposition en mode empirique (EMD), l'EMD d'ensemble (EEMD) et l'EEMD complète (CEEMD) (Subasi, 2019).

Ces méthodes d'extraction des caractéristiques sont les plus populaires pour la classification de l'épilepsie à partir d'un signal EEG et sont des techniques qui permettent d'extraire les informations simultanément du domaine temporel et du domaine fréquentiel (Subasi, 2019).

#### **2.2.1.1 Transformée en ondelettes discrète (DWT)**

La transformée en ondelettes discrète (DWT) est un outil puissant du traitement du signal qui opère sur des échantillons d'un signal discret et offre une analyse temps-fréquence capable de décomposer le signal en utilisant un ensemble de fonctions d'ondelettes obtenues à partir d'une fonction mère par des opérations de décalage et de dilatation/compression (Bahoura et al., 2022).

L'algorithme de la transformée en ondelettes discrète utilisée dans ce projet est basé sur l'algorithme dyadique de Mallat (Mallat, 1989) utilisant une paire de filtres miroirs en quadrature.

La figure 2.2 présente l'architecture générale de la décomposition en ondelettes discrète (DWT), appelée encore décomposition multi-résolution, d'un signal quelconque  $s(n)$  passant à la fois par un filtre numérique passe-bas  $H$  et un filtre numérique passe-haut  $G$ . Chaque niveau de décomposition est constitué de ces deux filtres suivis de deux sous-échantillonneurs par 2 (Geethu & Santhoshkumar, 2020; Meddah et al., 2020; Saidi et al., 2018; Subasi, 2007a; Subasi & Gursoy, 2010).

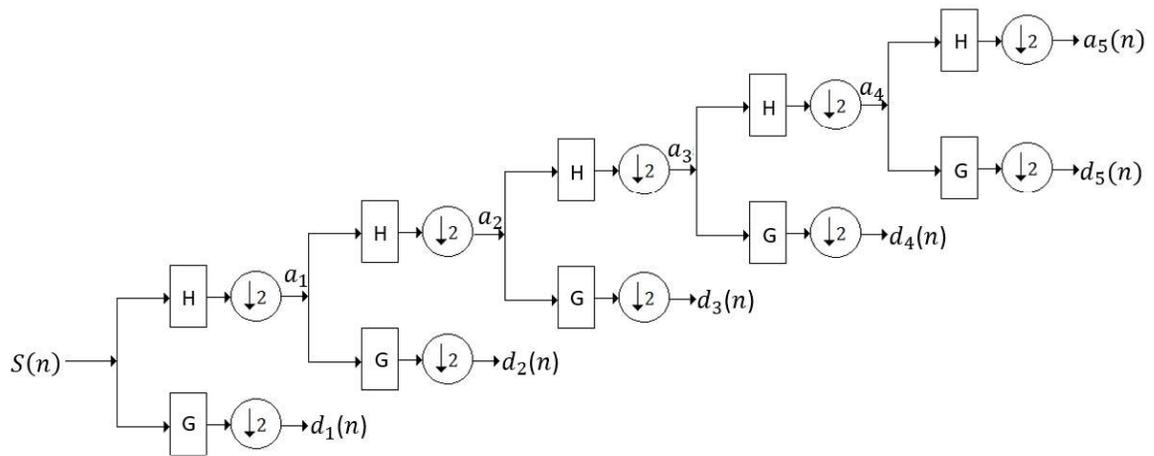


Figure 2.2 Architecture générale de la décomposition en ondelettes discrète (DWT)

En ce sens, les vecteurs des caractéristiques qui serviront de variables d'entrées pour un classificateur quelconque seront composés à partir des détails ( $d_1, d_2, d_3, d_4, d_5$ ) et la dernière approximation, dans ce cas  $a_5$ .

### 2.2.1.2 Transformée en ondelette stationnaire (SWT)

Si après chaque étape de décomposition par transformée en ondelettes, les sorties ne sont pas décimées (sous-échantillonnées), le processus s'appellerait transformée en ondelettes stationnaire (SWT). Cependant, les filtres sont itérativement suréchantillonnés. Les filtres  $H_{i+1}$  et  $G_{i+1}$  sont obtenus par suréchantillonnage respectif de  $H_i$  et  $G_i$  par insertion de zéro,  $H_0 = H$  et  $G_0 = G$ . Ainsi, toutes les sorties, à savoir les détails comme les approximations du signal, conservent le même nombre d'échantillons que le signal de départ

(Grace et al., 2016; Subasi, 2019). La figure 2.3 montre l'architecture générale de la décomposition en ondelettes stationnaire.

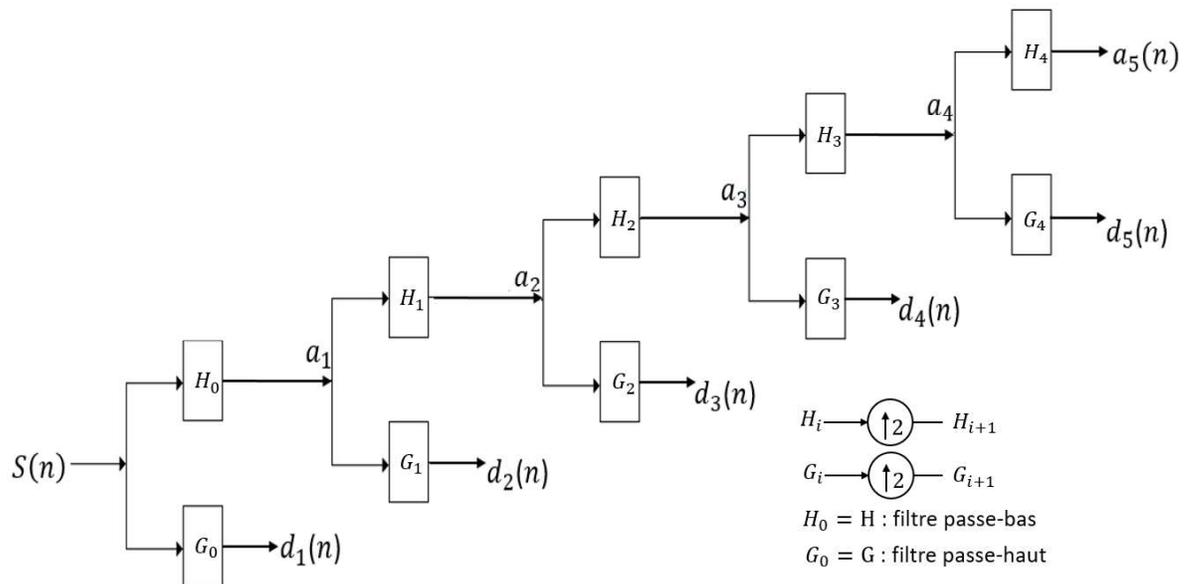


Figure 2.3 Architecture générale de la décomposition en ondelettes stationnaire (SWT)

La transformée SWT est utilisée pour remédier à la limitation du décalage temporel à des puissances de 2 (Subasi, 2019) afin de minimiser les bruits contenus dans le signal (Grace et al., 2016; Subasi, 2019), ce qui n'est pas possible de faire avec la transformée DWT. Elle est donc capable d'améliorer les performances de la transformation en ondelettes discrètes et ainsi renforcer la prédiction et la classification des signaux EEG (Grace et al., 2016).

La sélection de l'ondelette mère appropriée et du nombre de niveaux de décomposition est très importante lors de l'application de la transformée en ondelettes (DWT ou SWT). Le nombre de niveaux de décomposition doit être choisi en fonction des composantes fréquentielles dominantes du signal, de sorte que les parties du signal qui correspondent aux fréquences requises pour la classification du signal soient retenues dans les coefficients des ondelettes (Subasi, 2007a).

Dans la littérature, les auteurs utilisent généralement cinq niveaux de décomposition pour les transformées en ondelettes. Parmi les différents types d'ondelettes, la Daubechies 4

(db4) est la plus couramment choisie en raison de ses propriétés de lissage, qui la rendent particulièrement adaptée à la détection des changements dans les signaux EEG. Cependant, l'ondelette Daubechies 2 (db2) est aussi bien très utilisée, mais elle est légèrement moins performante que l'ondelette db4 (Subasi, 2007a).

### 2.2.1.3 Extraction des caractéristiques

Les données (approximation et détails) obtenues à l'aide de la transformée en ondelettes (DWT et SWT) sont trop volumineuses pour être utilisées comme entrées d'un quelconque classificateur. Par conséquent, sélectionner les caractéristiques pertinentes parmi les données des différentes sous-bandes de la décomposition par ondelettes pour l'entraînement des modèles devient plus qu'évident. En effet, pour exploiter les données des différentes sous-bandes de la décomposition par ondelettes et extraire les informations pertinentes des signaux EEG, on utilise les caractéristiques statistiques qui permettent d'avoir un petit ensemble de paramètres à partir de chaque sous-bande de décomposition. Les caractéristiques statistiques le plus souvent utilisées sont: la moyenne, l'écart-type, la variance, l'asymétrie, l'aplatissement, etc. où l'ensemble réduit de caractéristiques est calculé à partir des sous-bandes de la décomposition (Subasi, 2019).

Afin de simplifier la complexité du système de détection et de réduire son temps de calcul que ce soit pour l'implémentation logicielle ou matérielle, seule la variance est utilisée comme caractéristique pertinente des signaux EEG étudiés.

La variance du signal de détail  $d_i$  est définie par :

$$\sigma_{d_i}^2 = \frac{1}{N_i} \sum_{n=1}^{N_i} (d_i(n) - \mu_{d_i}), \quad 1 \leq i \leq 5 \quad (2.2)$$

où  $N_i$  est le nombre d'échantillons du signal de détail  $d_i$  et  $\mu_{d_i}$  est sa moyenne définie par :

$$\mu_{d_i} = \frac{1}{N_i} \sum_{n=1}^{N_i} d_i(n) \quad (2.3)$$

Ainsi, le vecteur des caractéristiques obtenu à partir de la transformée en ondelettes discrète (DWT) sera :

$$X = [Var_{d_1} Var_{d_2} Var_{d_3} Var_{d_4} Var_{d_5} Var_{d_6}] \quad (2.4)$$

où la variance  $Var_{d_6}$  correspond à la variance de l'approximation  $a_5$ . De même, le vecteur de caractéristiques pour la transformée en ondelettes stationnaire (SWT) sera :

$$X = [Var_{s_1} Var_{s_2} Var_{s_3} Var_{s_4} Var_{s_5} Var_{s_6}] \quad (2.5)$$

où la variance  $Var_{s_6}$  correspond à la variance de l'approximation  $a_5$ .

Dans ces expressions, chaque élément représente la variance des coefficients d'ondelettes à différents niveaux de décomposition.

### 2.2.2 Modélisation paramétrique d'estimation spectrale du signal EEG

Les méthodes paramétriques d'estimation spectrale, dites méthodes modernes d'analyse spectrale, sont très efficaces pour l'analyse des signaux transitoires tels que le signal EEG (Marple & Carey, 1989). Elles constituent une alternative proposée pour surmonter les lacunes et distorsions produites par les estimateurs spectraux classiques basés sur le calcul des spectres de puissance à l'aide de la transformée de Fourier (TF) dans l'analyse fréquentielle de l'activité électrique du cerveau (Bigan, 1998). Les méthodes paramétriques les plus populaires sont : le modèle autorégressif (AR), le modèle de moyenne mobile (MA), le modèle de moyenne mobile autorégressive (ARMA) et les exposants de Lyapunov (Kay, 1993; Kay & Marple, 1981; Proakis & Manolakis, 2007; Stoica & Moses, 1997).

Parmi tous les modèles paramétriques, le modèle autorégressif AR est le plus utilisé, car l'évaluation de ses paramètres consiste uniquement à résoudre une équation matricielle linéaire simple, ce qui n'est pas le cas avec les autres modèles (Sörnmo & Laguna, 2005). D'autre part, le modèle AR convient principalement à l'évaluation de spectres présentant des

pics nets, ce qui est très recherché pour l'estimation spectrale de puissance des signaux biomédicaux (Semmlow, 2004).

### 2.2.2.1 Les Modèles autorégressifs

Les méthodes paramétriques sont employées pour modéliser les données d'une série temporelle  $s(n)$  comme la sortie d'un système linéaire, dont le processus d'estimation du spectre se compose de deux étapes. Dans la première étape, les paramètres basés sur le modèle sont estimés à partir d'une séquence de données  $s(n)$ ,  $0 \leq n \leq N - 1$ . L'estimation de la densité spectrale de puissance (DSP) est ensuite calculée à partir de l'estimation de ces paramètres. Dans le modèle autorégressif (AR), les données peuvent être modélisées comme une sortie d'un filtre discret causal tous pôles, dont l'entrée est un bruit blanc (Subasi, 2019) :

$$s(n) = - \sum_{k=1}^p a(k)s(n-k) + w(n) \quad (2.6)$$

où  $a(k)$  sont les coefficients du modèle autorégressif (AR) et  $w(n)$  est un bruit blanc de variance égale à  $\sigma^2$ . Un modèle AR d'ordre  $p$  peut être caractérisé par les paramètres  $\{a(1), a(2), \dots, a(p), \sigma^2\}$ . La densité spectrale de puissance (DSP) est donnée alors par (Subasi, 2019):

$$P_{AR}(f) = \frac{\sigma^2}{|A(f)|^2} \quad (2.7)$$

où

$$A(f) = 1 + a_1 e^{-j2\pi f} + \dots + a_p e^{-j2\pi f p} \quad (2.8)$$

Pour trouver un modèle AR approprié et stable, différents facteurs doivent être pris en considération, tels que la sélection de l'ordre du modèle, la longueur du signal et le niveau de stationnarité du signal (Kay, 1993; Subasi, 2019).

Les techniques les plus utilisées pour évaluer les paramètres du modèle AR et le spectre de puissance associé directement à partir de la forme d'onde sont les suivantes : les méthodes de Yule-Walker, de Burg, de covariance et de covariance modifiée. Ces quatre méthodes d'estimation spectrale sont implémentées dans la boîte à outils de traitement du signal (*Signal Processing Toolbox*) de l'environnement MATLAB, et elles produisent toutes des spectres similaires (Semmlow, 2004).

Étant donné que toutes ces méthodes d'estimation spectrale autorégressive AR produisent des spectres quasiment similaires, le choix est fait pour n'utiliser qu'une seule, à savoir le spectre de Burg, dont l'approche aboutit à un modèle autorégressif AR stable selon (Sörnmo & Laguna, 2005).

Le modèle AR de Burg utilise la minimisation des erreurs de prédiction avant ( $\hat{e}_{f,p}(n)$ ) et arrière ( $\hat{e}_{b,p}(n)$ ), ainsi que l'estimation du coefficient de réflexion ( $\hat{K}_p$ ), pour produire un algorithme récursif permettant d'estimer les coefficients AR. Les erreurs de prédiction avant et arrière pour un modèle d'ordre  $p$  sont définies comme :

$$\hat{e}_{f,p}(n) = s(n) + \sum_{i=1}^p \hat{a}_{p,i} s(n-i) \quad n = p+1, \dots, N \quad (2.9)$$

$$\hat{e}_{b,p}(n) = s(n-p) + \sum_{i=1}^p \hat{a}_{p,i}^* s(n-p+i) \quad n = p+1, \dots, N \quad (2.10)$$

Les paramètres AR liés au coefficient de réflexion  $\hat{K}_p$  peuvent être notés :

$$\hat{a}_{p,i} = \begin{cases} \hat{a}_{p-1,i} + \hat{K}_p \hat{a}_{p-1,p-i}^* & i = 1, \dots, p-1 \\ \hat{K}_p & i = p \end{cases} \quad (2.11)$$

La méthode de Burg reflète l'estimation récursive dans l'ordre de  $\hat{K}_p$ , étant donné que les coefficients AR pour l'ordre  $p-1$  ont été calculés. L'estimation du coefficient de réflexion est donnée par :

$$\widehat{K}_p = \frac{-2 \sum_{n=p+1}^N \hat{e}_{f,p-1}(n) \hat{e}_{b,p-1}^*(n-1)}{\sum_{n=p+1}^N [|\hat{e}_{f,p-1}(n)|^2 + |\hat{e}_{b,p-1}(n-1)|^2]} \quad (2.12)$$

Les erreurs de prédiction satisferont à l'expression réursive dans l'ordre suivant :

$$\hat{e}_{f,p}(n) = \hat{e}_{f,p-1}(n) + \widehat{K}_p \hat{e}_{b,p-1}(n-1) \quad (2.13)$$

$$\hat{e}_{b,p}(n) = \hat{e}_{b,p-1}(n-1) + \widehat{K}_p \hat{e}_{f,p-1}(n) \quad (2.14)$$

Ces expressions sont utilisées pour produire un algorithme réursive d'ordre  $p$ , afin d'estimer les coefficients AR. À partir de ces estimations des paramètres AR, l'estimation PSD est ensuite déterminée comme suit (Kay & Marple, 1981; Proakis & Manolakis, 2007; Stoica & Moses, 1997) :

$$\widehat{P}_{BURG}(f) = \frac{\hat{e}_p}{\left| 1 + \sum_{k=1}^p \hat{a}(k) e^{-j2\pi f k} \right|^2} \quad (2.15)$$

où  $\hat{e}_p = \hat{e}_{f,p} + \hat{e}_{b,p}$  est l'erreur totale des moindres carrés et  $\hat{a}(k)$  représente les paramètres liés au coefficient de réflexion  $\widehat{K}_p$  (Subasi, 2007b).

Dans le cadre de ce projet, l'extraction des caractéristiques à l'aide de la méthode de Burg se concentre sur l'estimation des coefficients AR, plutôt que sur l'estimation de la densité spectrale. L'estimation des coefficients AR prendra à la fin la forme de l'équation 2.8, sauf que ses paramètres sont déterminés à partir des coefficients de réflexion  $\widehat{K}_p$  de l'algorithme de Burg.

Pour capturer toutes les dynamiques du signal, l'ordre  $p$  du modèle autorégressif a été fixé à 6, afin de sélectionner les 6 premiers coefficients du polynôme comme les caractéristiques pertinentes du signal EEG et de produire en même temps des caractéristiques de taille comparable à celles des autres méthodes évoquées précédemment.

Ainsi, le vecteur des caractéristiques AR d'un signal  $s(n)$  est défini par :

$$X = [a_1 \ a_2 \ a_3 \ a_4 \ a_5 \ a_6] \quad (2.16)$$

### 2.3 MÉTHODES DE RÉDUCTION DE LA DIMENSION DES CARACTÉRISTIQUES

Lorsque la taille du vecteur des caractéristiques est très grande, la réduction de dimension devient une étape essentielle, tant pour simplifier la complexité du système de détection que pour améliorer ses performances. Cette étape est cruciale car elle permet d'éliminer les caractéristiques non significatives ou redondantes, surtout lorsqu'on utilise les ondelettes pour l'extraction des caractéristiques (Wołczowski & Zdunek, 2017). Elle favorise ainsi une meilleure capacité de généralisation et permet d'obtenir une classification plus rapide, par rapport à l'utilisation de l'ensemble complet des caractéristiques (Abe, 2010).

Parmi les méthodes populaires de réduction de dimension, on trouve l'analyse en composantes principales (PCA), l'analyse en composantes indépendantes (ICA) et l'analyse discriminante linéaire (LDA). Les deux premières seront présentées dans la suite.

#### 2.3.1 L'analyse en composante principale (PCA)

L'analyse en composantes principales (PCA) est une méthode statistique qui permet de traiter des données multivariées dans un espace de  $M$  dimensions, où chaque dimension représente une variable. Se basant sur la maximisation de la variance des données projetées ou la minimisation de l'erreur de reconstruction (Du et al., 2006), l'analyse en composante principale cherche à produire des résultats dans lesquels la relation entre différentes variables, ainsi qu'au sein des variables elles-mêmes, est prise en compte. C'est le principe de la

corrélation. L'objectif est de transformer ces données multivariées en un ensemble réduit de données non corrélées.

Pour trouver une représentation réduite de l'ensemble de données d'origine, l'analyse PCA commence par créer un modèle linéaire passant par l'origine d'un plan cartésien formé à partir du point central des données caractéristiques originales, puis projette les données caractéristiques dessus. Ensuite, en faisant tourner à chaque fois le modèle et en projetant dessus les caractéristiques, l'analyse PCA cherche la première composante qui est la ligne maximisant la variance de la première dimension.

La deuxième composante principale ainsi que toutes les autres seront calculées de la même façon que la première, sauf que celles-ci ne doivent pas être corrélées à la première composante principale, ni à aucune d'entre elles. Autrement dit, toutes les autres composantes doivent être orthogonales entre elles, y compris avec la première, et doivent exprimer la variance la plus élevée suivante. Ce processus continue jusqu'à ce que toutes les composantes principales soient calculées et égales au nombre initial de variables. Puis, les composantes principales avec les variances les plus élevées sont choisies et le reste, éliminé.

Si l'ensemble d'apprentissage contient  $M$  exemples d'apprentissage, avec l'espace de caractéristiques de dimension  $X = \{x_1, x_2, \dots, x_D\}$ , alors l'algorithme crée des composants principaux ou vecteurs propres de même dimension,  $P_k$ , qui sont des combinaisons linéaires des caractéristiques originales  $X$  (Begg et al., 2007). Cela se traduit par :

$$P_k = a_{k1}x_1 + a_{k2}x_2 + \dots + a_{kD}x_D, \quad k = 1, 2, \dots, D \quad (2.17)$$

où les coefficients sont obtenus par cette analyse,  $\sum_i a_{ki}^2 = 1$ , avec  $i = 1, 2, \dots, D$ .

Les vecteurs de composantes principales sont définis de manière à avoir la variance la plus élevée (composantes principales), c'est pour cela qu'ils sont orthogonaux les uns avec les autres. Généralement, avant d'utiliser l'algorithme PCA, les données d'entraînement sont d'abord normalisées à une moyenne nulle et à une variance unitaire (Begg et al., 2007). La réduction de dimension à l'aide de PCA peut être réalisée au moyen de l'algorithme de

décomposition en valeurs singulières (SVD) qui fait partie de la boîte à outil de l'environnement MATLAB (Blinowska & Żygierewicz, 2021). Dans ce mémoire, le vecteur de caractéristiques est réduit de 6 composantes à 4 composantes principales :

$$X_r = [P_1 P_2 P_3 P_4] \quad (2.18)$$

### 2.3.2 L'analyse en composante Indépendante (ICA)

L'analyse en composantes indépendantes (ICA) est un modèle statistique récemment développé en tant qu'une alternative à l'analyse PCA. Initialement présenté pour la séparation aveugle de sources (BSS), elle a ensuite été adaptée pour l'extraction des caractéristiques et la réduction de dimension. Contrairement à l'analyse en composantes principales (PCA), qui se concentre sur la maximisation de la variance des données, la méthode ICA vise à identifier des composantes indépendantes sous-jacentes dans les données, ce qui est crucial pour des applications biomédicales. En exploitant des ensembles de base multi-échelles et redondants, la méthode ICA permet de décomposer des signaux complexes en sources distinctes, facilitant ainsi l'extraction des caractéristiques pertinentes et la réduction de dimensionnalité (Du et al., 2006).

L'objectif de l'analyse ICA est d'estimer les composantes indépendantes  $Y$  en appliquant une combinaison linéaire des données d'origine, exprimée par :

$$Y = WX \quad (2.19)$$

où  $W$  est la matrice de séparation,  $X$  est un ensemble de données avec  $N$  observations et  $p$  variables (Du & Swamy, 2006). Le vecteur des caractéristiques réduit  $X_r$  est obtenu des 4 premières composantes de  $Y$ :

$$X_r = [y_1 y_2 y_3 y_4] \quad (2.20)$$

Il existe plusieurs outils pour calculer les composantes ICA dans l'environnement MATLAB. Pour utiliser l'algorithme fastICA, il faut d'abord installer la boîte à outils (Jarmo Hurri et al., 2013).

La méthode ICA est très utilisée dans les applications biomédicales. Elle est surtout utilisée dans la réduction des artefacts des signaux d'électroencéphalogrammes (EEG) et d'électromyogramme (MEG), dans l'extraction des caractéristiques et dans la réduction de dimensionnalité dans les études de classification des signaux EEG. Elle est également employée dans l'analyse des signaux cardiaques et musculaires (Blinowska & Żygierewicz, 2021).

## 2.4 APPROCHE PROPOSÉE

Le processus d'extraction des caractéristiques du  $i^{\text{ème}}$  segment d'un signal EEG d'un seul canal est détaillé à la figure 2.4 suivante et celui des 4 canaux est illustré à la figure 2.5. Dans ces architectures, trois techniques d'extraction des caractéristiques avec trois techniques de réduction de dimensionnalité sont combinées ensemble afin de capturer les caractéristiques pertinentes du signal EEG pour l'entraînement et le test des algorithmes de classification du projet. La SRD (sans réduction de dimension) est considérée comme étant une troisième technique de réduction de dimensionnalité dans ce projet, mais en vrai, il s'agit de laisser passer les caractéristiques sans appliquer de méthodes de réduction de dimensionnalité dessus. Les caractéristiques obtenues à l'aide de la technique SRD (sans réduction de dimensionnalité) sont utilisées afin d'évaluer l'importance réelle de l'étape de réduction de dimension dans l'amélioration des performances des modèles de classification.

Aussi, dans la première architecture, le signal EEG filtré et normalisé  $s(n)$  est découpé par une fenêtre glissante  $w_i$ , pour fournir les segments  $s_i(n)$ . Une fois que les caractéristiques du signal  $s_i(n)$  sont extraites, des méthodes de réduction de dimension sont appliquées dessus afin d'obtenir des caractéristiques réduites et pertinentes pour entraîner les classificateurs. Puis, parmi les neuf ensembles de caractéristiques générés, celui qui permet

à un classificateur de donner la meilleure performance est sélectionné et sauvegardé pour la prédiction finale par vote de majorité. Cette règle s'applique à tous les segments de la base.

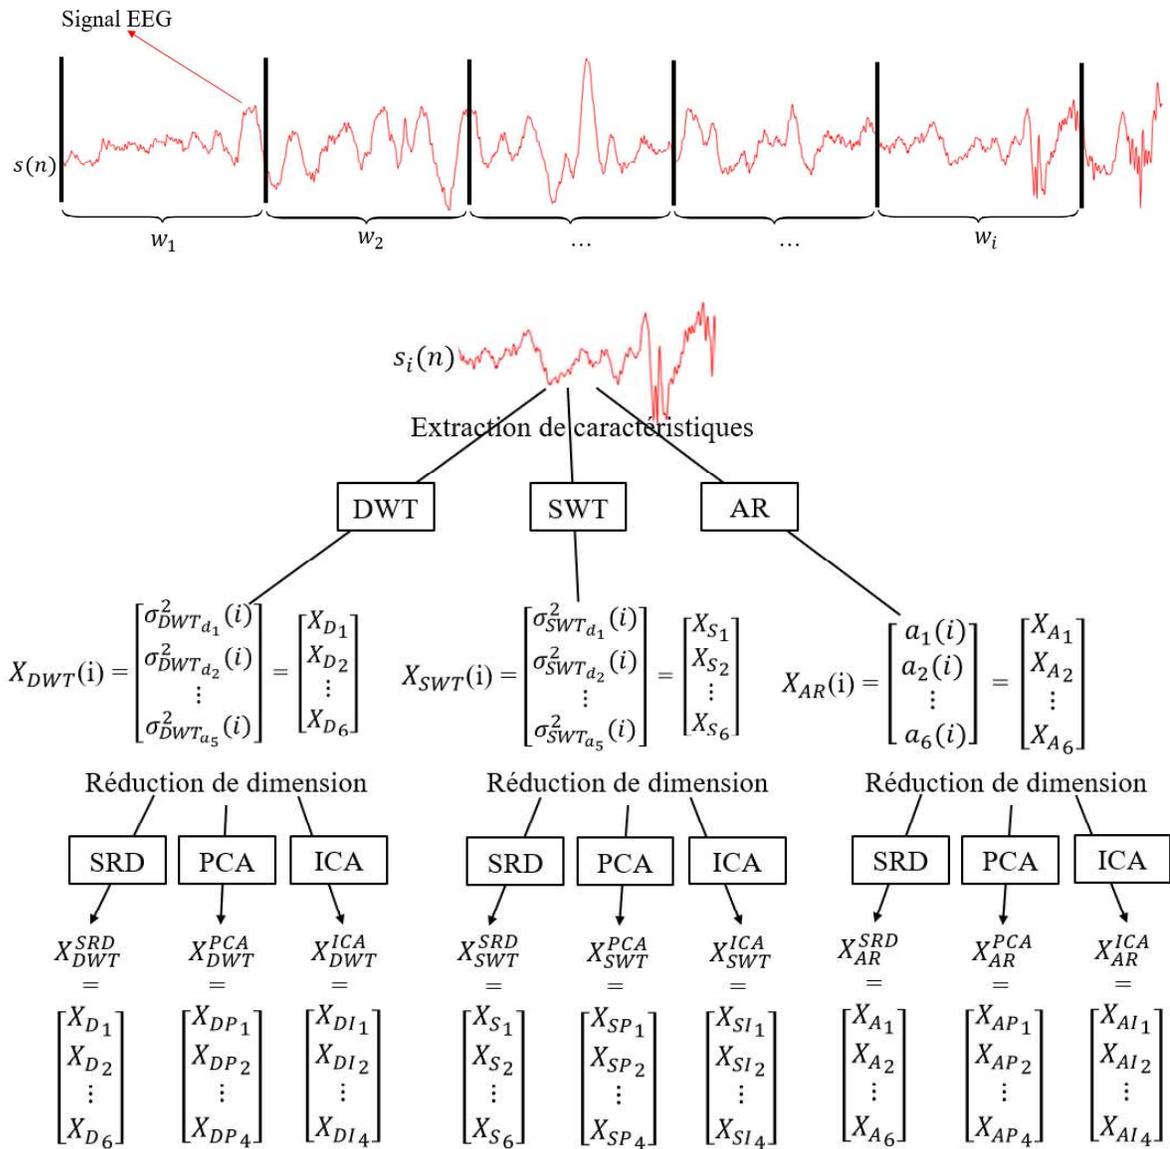


Figure 2.4 Illustration du processus d'extraction des caractéristiques d'un signal EEG

Le processus d'extraction des caractéristiques dans la deuxième architecture est le même que dans la première, mais il est appliqué séparément sur chaque canal. Ensuite, les caractéristiques des différents canaux d'une même méthode sont combinées ensemble avant de passer par les différentes méthodes de réduction de dimensionnalité et de produire les neuf

ensembles de vecteurs de caractéristiques nécessaires pour évaluer les classificateurs comme dans la première architecture. Ce processus est illustré dans la figure 2.5 ci-dessous.

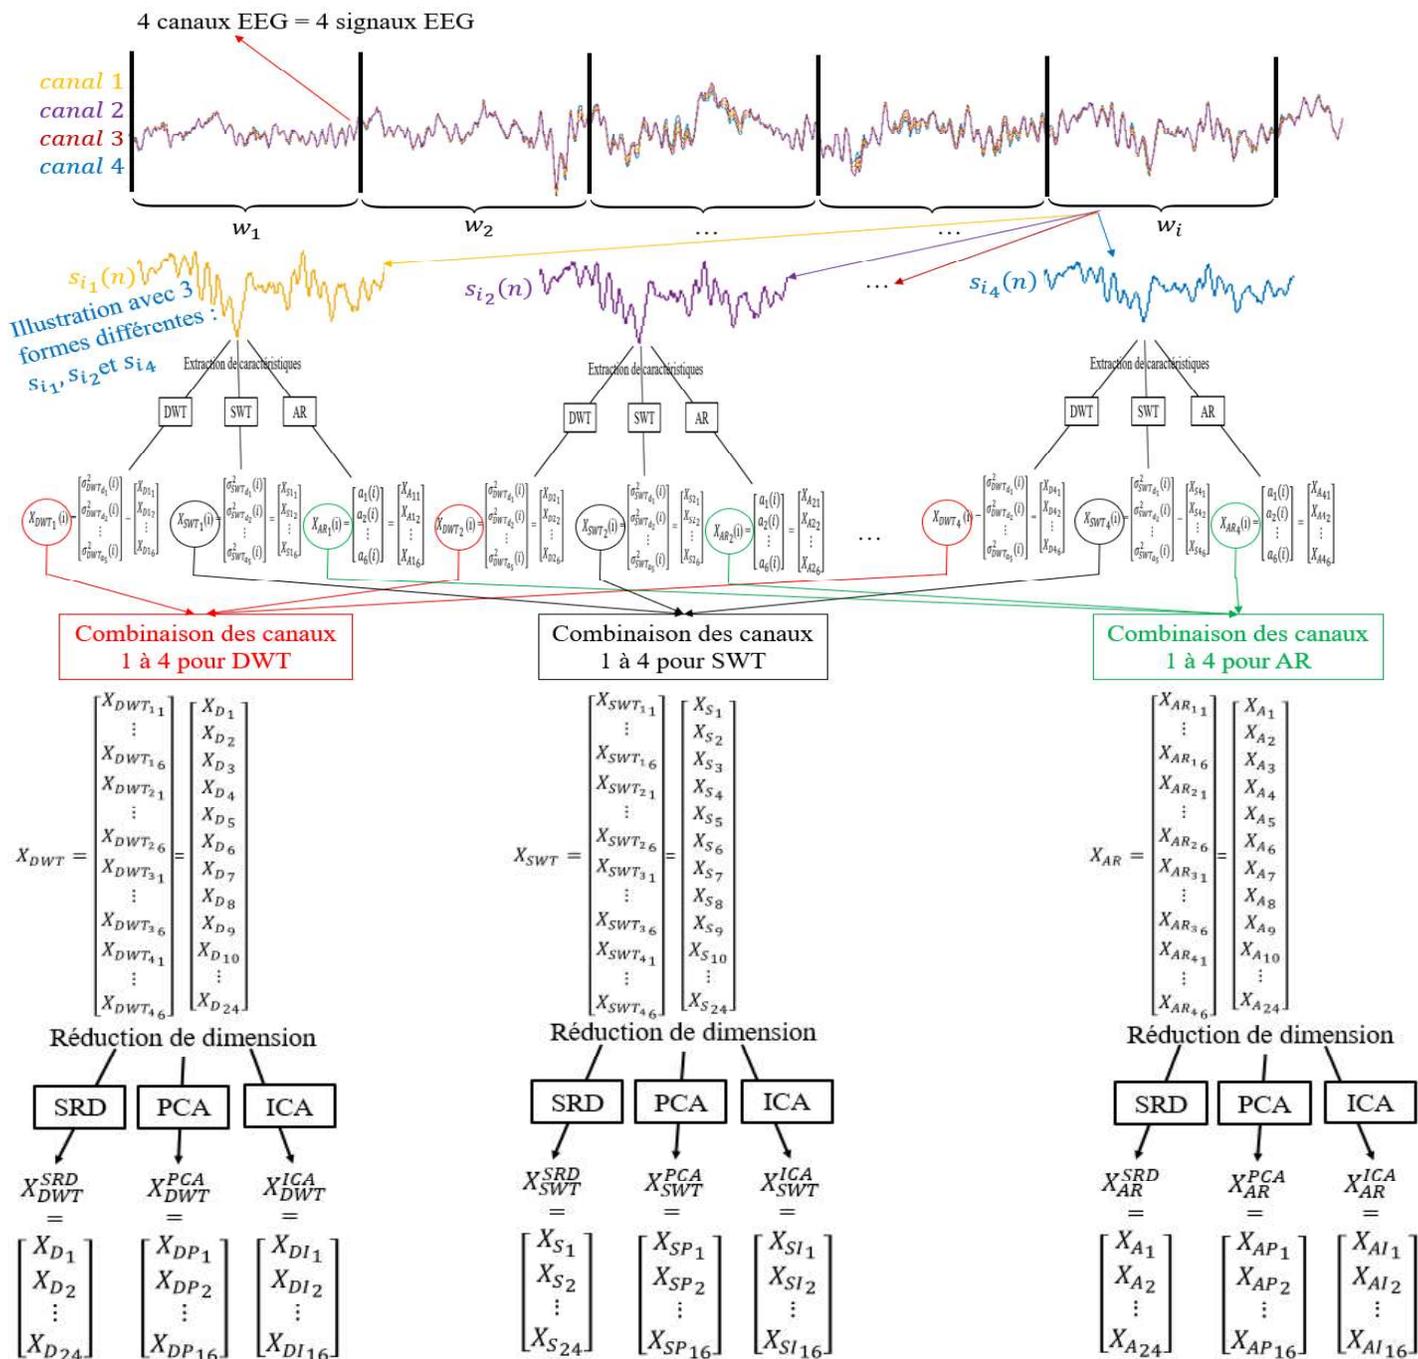


Figure 2.5 Illustration du processus d'extraction des caractéristiques de 4 canaux EEG



### **CHAPITRE 3**

## **ALGORITHMES D'APPRENTISSAGE MACHINE POUR LA CLASSIFICATION AUTOMATIQUE DES SIGNAUX EEG**

La classification automatique des signaux EEG constitue l'essence même de ce projet de recherche. L'approche adoptée parmi les différentes techniques d'apprentissage automatique est l'apprentissage supervisé, qui vise à utiliser un ensemble de données préalablement étiquetées, réparti en données d'apprentissage et données de test. Le sous-ensemble des données d'apprentissage est utilisé pour l'entraînement du modèle afin qu'il puisse regrouper les données en deux ou plusieurs classes. En pratique, il s'agit de trouver une frontière entre deux ou plusieurs classes et les étiqueter en fonction de leurs caractéristiques mesurées. Le sous-ensemble des données de test est utilisé pour évaluer les performances des classificateurs (Sanei, 2013).

En effet, la communauté scientifique s'intéresse beaucoup aux techniques d'apprentissage automatique pour la reconnaissance, la classification et le diagnostic des maladies, notamment les maladies cardiaques et les troubles cérébraux ou musculaires, qui conduisent généralement à des circonstances mettant la vie des patients en danger. Des diagnostics précoces et précis sont primordiaux avant d'appliquer des mesures préventives ou un traitement. La surveillance des anomalies du corps humain peut être prise en charge par l'analyse des signaux biomédicaux. Grâce aux méthodes d'apprentissage automatique, qui permettent de créer des plateformes de décision en classifiant ces signaux en normaux et pathologiques, cet outil est devenu un aspect essentiel de la surveillance clinique (Begg et al., 2007).

Dans ce chapitre, sont présentés quelques-uns des principaux algorithmes utilisés par la communauté scientifique pour créer des plateformes de décision dans la catégorisation des signaux biomédicaux en normaux et pathologiques. Autrement dit, il s'agit de quelques algorithmes populaires de classification utilisés en apprentissage automatique.

### 3.1 ANALYSE DISCRIMINANTE LINÉAIRE (LDA)

L'analyse discriminante linéaire LDA (*Linear Discriminant Analysis*) est une technique d'apprentissage supervisé qui vise à trouver, dans l'espace des caractéristiques, une combinaison linéaire qui maximise la dispersion entre différentes classes en minimisant simultanément la variance intra-classe. Ce qui a pour effet de distancier les échantillons des différentes classes tout en rapprochant ceux d'une même classe (Zhu et al., 2022). Pour classer un nouvel échantillon à une classe particulière dans l'espace des caractéristiques, la technique LDA le projette sur la droite et la position occupée par cet échantillon dans l'espace de projection détermine sa classe d'appartenance.

Soit un ensemble de données  $D = \{(x_i, y_i)\}$ ,  $i = 1, \dots, N$  dans l'espace des caractéristiques, avec  $y_i \in \{0,1\}$ . Soient  $\mu_j$  et  $\Sigma_j$  désignant respectivement le vecteur moyen et la matrice de covariance de l'ensemble des échantillons  $X_j$  de la  $j^{\text{ème}}$  classe ( $j \in \{0,1\}$ ). La projection des données sur la droite  $\omega$  crée de nouveaux échantillons, dont les centres peuvent être représentés respectivement par  $\omega^T \mu_0$  et  $\omega^T \mu_1$ , de même que les covariances associées à ces deux classes représentées par  $\omega^T \Sigma_0 \omega$  et  $\omega^T \Sigma_1 \omega$  (Zhou, 2021).

Ainsi, pour regrouper les points de projection des échantillons d'une même classe, la technique LDA minimise la covariance de ces points, c'est-à-dire minimiser  $\omega^T \Sigma_0 \omega + \omega^T \Sigma_1 \omega$ , tout en augmentant la distance entre les classes afin de les éloigner l'une de l'autre, c'est-à-dire en maximisant  $\|\omega^T \mu_0 - \omega^T \mu_1\|$ . Cela revient à maximiser le critère suivant (Zhou, 2021) :

$$J = \frac{\|\omega^T \mu_0 - \omega^T \mu_1\|_2^2}{\omega^T \Sigma_0 \omega + \omega^T \Sigma_1 \omega} = \frac{\omega^T (\mu_0 - \mu_1)(\mu_0 - \mu_1)^T \omega}{\omega^T (\Sigma_0 + \Sigma_1) \omega} \quad (3.1)$$

La figure 3.1 ci-après illustre les tâches réalisées par la technique LDA pour séparer deux classes : minimiser la variance au sein de chaque classe et maximiser la distance entre les moyennes des classes.

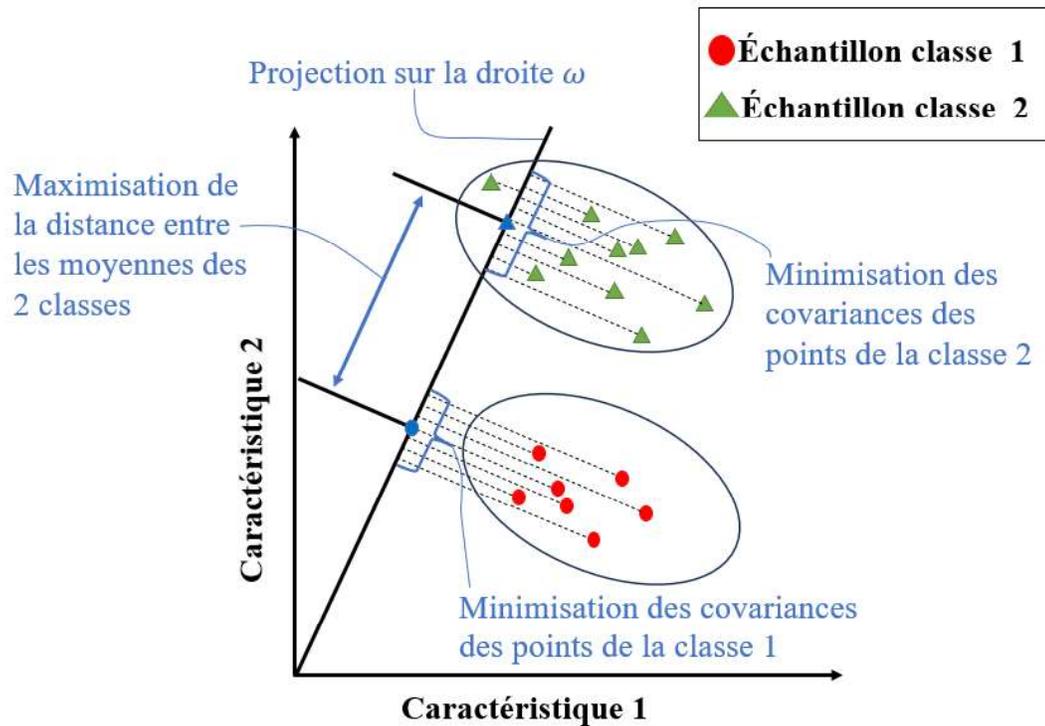


Figure 3.1 Illustration bidimensionnelle de la LDA. Les ellipses sont les limites des groupes; les lignes en pointillé représentent les projections; le point bleu et le triangle bleu sont les centres des projections (Zhou, 2021)

### 3.2 K PLUS PROCHES VOISINS (KNN)

La méthode des  $k$  plus proches voisins KNN (*K-Nearest Neighbor*) est une méthode d'apprentissage supervisé non-paramétrique utilisée dans l'estimation statistique et la reconnaissance de modèles. Pour analyser un échantillon  $x$ , la méthode KNN suppose que les échantillons les plus proches de cet échantillon cible, dans l'espace des caractéristiques, fournissent des informations utiles pour déterminer son étiquette de classe (Kramer, 2013).

Une fois que les plus proches voisins du nouvel échantillon sont sélectionnés, l'algorithme KNN fait le comptage des points de chaque catégorie puis attribue le nouvel échantillon à la catégorie la plus présente d'entre les voisins, c'est-à-dire à la classe ayant le plus grand nombre de voisins proches (Ali, 2017). La figure 3.2 ci-après illustre la classification à l'aide de la méthode KNN.

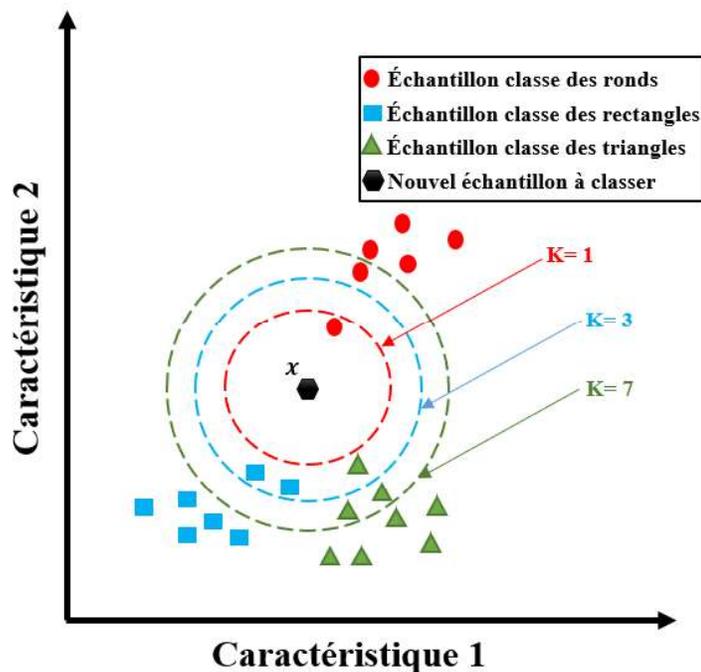


Figure 3.2 Classification à l'aide de KNN

Comme le montre la figure 3.2 précédente, le seul paramètre capable d'influencer le choix de la classe cible idéale est  $k$  (le nombre de voisins considérés). Ainsi, si la forme en noir est un nouvel échantillon à classer, alors, pour  $k=1$ , la classe prédite sera la classe des ronds en rouge, puisque le seul voisin plus proche de la forme en noir est un rond. Pour  $k=3$ , c'est la classe des rectangles en bleu qui sera prédite, parce qu'elle a plus d'entités que les autres classes voisines. Enfin, pour  $k=7$ , la classe des triangles en vert sera prédite, pour la même raison que précédemment (Kramer, 2013).

La méthode KNN peut être utilisée tant pour la classification que pour la régression. Pour les problèmes de classification, KNN utilise le vote ou comptage des plus proches voisins pour prédire un échantillon de test comme associé à l'étiquette de classe la plus présente des voisins. Pour les problèmes de régression, c'est la moyenne des voisins proches qui est déterminée pour prédire la réponse à un échantillon de test, en attribuant à chacun des voisins un poids en fonction de sa distance par rapport à l'échantillon de test. Plus un voisin est proche, plus son poids est important (Kramer, 2013).

Soit un ensemble étiqueté de  $N$  observations  $\{(x_1, \omega_1), (x_2, \omega_2), \dots, (x_N, \omega_N)\}$  où  $x_i$  et  $\omega_i$  sont respectivement les vecteurs de caractéristiques et leurs identifiants de classes correspondants. Pour classer une nouvelle observation  $x$  de classe inconnue, une cellule est placée autour de  $x$  pour capturer  $k$  prototypes voisins. Soit  $k_j$  le nombre d'échantillons, identifiés  $\omega_j$ , capturés par la cellule (de sorte que  $\sum_{j=1}^K k_j = k$ ). La nouvelle observation  $x$  est prédite dans la classe  $w$  par vote majoritaire (Bahoura & Simard, 2012):

$$\omega = \arg \max_{1 \leq j \leq k} \{k_j\} \quad (3.2)$$

où  $K$  est le nombre de classe et  $k$  est le nombre de voisins.

Pour mesurer la distance entre l'échantillon inconnu et chacun de ses voisins, les métriques suivantes sont utilisées (Ali, 2017) :

- La distance Euclidienne :

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (3.3)$$

- La distance de Manhattan :

$$d(x, y) = \sum_{i=1}^n |x_i - y_i| \quad (3.4)$$

- La distance de Minkowsky :

$$d(x, y) = \left( \sum_{i=1}^n |x_i - y_i|^p \right)^{1/p} \quad (3.5)$$

où  $x, y$  sont deux vecteurs correspondants à deux points de l'espace des caractéristiques et  $p$  est le paramètre de contrôle de la métrique (Labiad Ali, 2017). Si  $p$  est choisi égal à 1, la métrique utilisée sera celle de Manhattan, et si  $p$  est égal à 2, ce sera la métrique Euclidienne.

En ce sens, la distance de Minkowsky peut être utilisée comme métrique fondamentale, puisqu'elle permet de retrouver à la fois la distance de Manhattan et la distance Euclidienne, ou leurs caractéristiques (Kramer, 2013).

### **3.3 FORÊT ALÉATOIRE (RANDOM FOREST)**

La forêt aléatoire RF (*Random Forest*) est un algorithme d'apprentissage supervisé qui combine deux grandes techniques de classification en un seul pour faire des prédictions : les arbres de décisions et la technique d'ensemble d'apprentissage. Comme avec la technique KNN, elle peut faire des classifications en se basant sur un vote à la majorité ou la régression en calculant la moyenne de toutes les sorties (Kibria & Matin, 2022).

L'importance d'utiliser la forêt aléatoire est due au fait que les arbres de décision souffrent de problème de sur-apprentissage (*overfitting*) puisqu'ils sont performants sur le jeu d'entraînement, mais pas assez flexible pour donner de bonnes performances avec les données de test. Or, le but d'un algorithme de l'apprentissage machine est de pouvoir faire des prédictions sur des données inconnues, donc des données autres que celles d'entraînement. Il s'agit d'utiliser plusieurs arbres de décisions pour créer une forêt et la théorie d'ensemble d'apprentissage pour faire fonctionner ces arbres ensemble afin d'améliorer la généralisation de l'ensemble du modèle (Fu & Qi, 2022).

#### **3.3.1 Étapes d'implémentation de la forêt aléatoire**

La première étape de l'implémentation de la forêt aléatoire consiste à créer un ensemble de données d'entraînement ou « trainset » pour chaque arbre de décision à partir du « trainset » original où une portion de données est sélectionnée aléatoirement par un échantillonnage avec remise (exemples : trainset du premier arbre, 4 observations : échantillons 1, 5, 7 et 9 ; trainset du second arbre, 4 observations : échantillons 2, 4, 9 et 12 ; tous issus d'un seul trainset original de 20 échantillons). Avec le Bagging, une même observation peut être sélectionnée plusieurs fois pour créer le trainset d'un arbre de décision. Comme les données utilisées pour créer l'arbre de décision sont extraites du trainset original de manière aléatoire

avec remise, cela a pour effet de maximiser la variété des arbres de la forêt. Le fait d'avoir un ensemble d'arbres très variés a pour effet de rendre performant le modèle, car les arbres qui sont forts dans une situation pourront compenser la faiblesse des autres arbres dans d'autres situations (Fu & Qi, 2022).

Ainsi, lors de la phase d'entraînement, une partie des données et des caractéristiques sont sélectionnées au hasard du trainset de chaque arbre récemment créé afin d'entraîner et de créer un arbre de décision (i.e. de créer la racine, les branches, les nœuds de décision ainsi que les nœuds de feuilles de l'arbre). Par exemple, pour reconnaître l'espèce d'une fleur de la base d'Iris de Fisher, les deux premières variables du trainset peuvent être utilisées pour entraîner le premier arbre : longueur de pétales et longueur de sépales d'une fleur, deux autres variables du trainset pour entraîner le second arbre : largeur de pétales et largeur de sépales d'une fleur. Le processus est répété plusieurs fois en fonction du nombre de composants de vecteurs de caractéristiques souhaité par arbre de décision (exemples : 2, 5, 7, ou 10 composants par arbre) et du nombre d'arbres de décision de la forêt (exemples : une forêt de 5, 15, 50 ou 100 arbres) (Fu & Qi, 2022).

Pour un échantillon de test à traiter, ses caractéristiques sont données à tous les arbres de la forêt qui, à leur tour, font une prédiction pour cet échantillon en question. Puis, un vote est réalisé pour l'ensemble des arbres de la forêt afin de déterminer la classe dominante pour la forêt et attribuer l'échantillon de test à cette classe. Dans le cas d'une régression, la moyenne de la sortie de tous les arbres de la forêt sera calculée pour pouvoir enfin prédire la valeur de ce nouvel échantillon (Kibria & Matin, 2022). Le classificateur utilise l'indice de Gini pour la sélection d'attributs qui évalue l'impureté d'un attribut par rapport aux classes. L'impureté mesure la qualité d'un nœud de décision dans l'arbre ou branche ; plus un nœud est pur, c'est-à-dire plus il contient des exemples appartenant à une classe, plus il est efficace pour la classification.

La figure 3.3 suivante montre un classificateur de forêt aléatoire avec  $n$  arbres provenant de différents jeux de données d'entraînement. Chaque arbre produit un résultat

unique et le résultat final est obtenu à partir d'un vote majoritaire sur les  $n$  résultats des arbres, ce qui représente la classe prédite par l'algorithme.

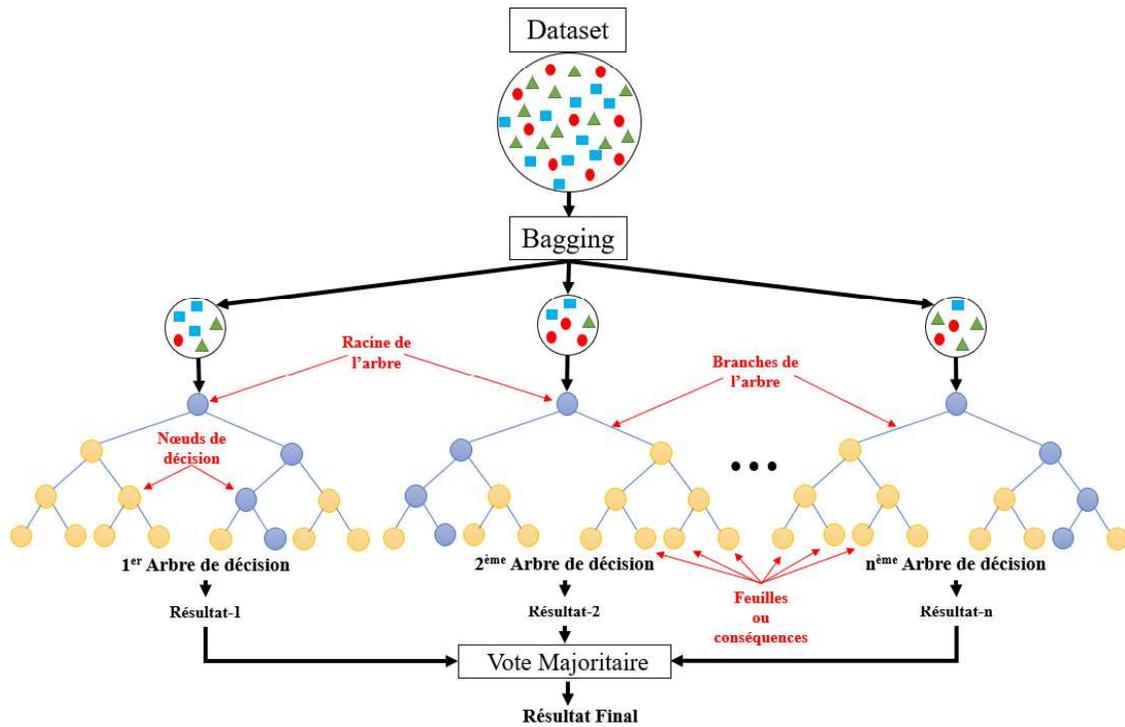


Figure 3.3 Architecture générale de l'algorithme de Forêt aléatoire

De manière générale, un arbre de décision est formé d'un ensemble de conditions et de conséquences. Les feuilles sont les conséquences des décisions, donc les réponses liées aux questions des nœuds de décision. Pour mesurer l'impureté d'un nœud de décision, on utilise l'entropie, le gain d'information et l'indice de Gini. L'impureté mesure la qualité d'un nœud de décision dans l'arbre. Donc, pour évaluer la qualité de sa décision, l'algorithme de l'arbre de décision utilise une mesure d'impureté, le plus souvent l'indice de Gini. En règle générale, l'algorithme sélectionne la variable (le nœud de décision) qui donne la plus grande réduction d'impureté pour chaque nœud de décision. Ensuite, l'ensemble des meilleurs arbres de décision (les arbres les plus purs) sont utilisés pour former les arbres de la forêt, et le vote majoritaire des arbres de la forêt permet de prédire les classes.

### 3.4 MACHINES À VECTEURS DE SUPPORT (SVM)

La technique des machines à vecteurs de support SVM (*Support Vector Machine*) a été proposée par Vapnik comme méthode d'apprentissage supervisé pour la classification binaire des données. Cet algorithme, qui permet de faire des prédictions sur des variables qualitatives (classification) ou quantitatives (régression), utilise le mappage non linéaire pour transformer les données d'entraînement de l'espace des caractéristiques originales non-linéairement séparables vers un espace de dimension supérieure afin de les rendre linéairement séparables et de les séparer. Cette opération porte le nom d'astuce du noyau (kernel trick). L'algorithme SVM est un classificateur linéaire qui cherche à déterminer l'hyperplan qui maximise la marge existante entre deux classes à partir des points de données les plus proches de chaque classe (vecteurs de support). Il produit ainsi une frontière de décision, représentée par une droite passant parallèlement par le milieu de l'hyperplan, pour séparer les classes de façon efficace et optimale (Han et al., 2012).

#### 3.4.1 SVM linéaire (LSVM)

La technique SVM est avant tout un classificateur binaire capable de séparer deux classes, qui sont linéairement séparables, dans l'espace des caractéristiques. Pour faire une classification binaire de deux classes, qui sont linéairement séparables, il cherche à créer une frontière de décision entre les deux classes en développant un hyperplan de séparation généralement représenté par un vecteur poids  $w$  et un vecteur biais  $b$ . Pour  $m$  observations de l'ensemble de données d'apprentissage (training set), les couples  $(x_i, y_i)$ , avec  $i=1, 2, \dots, m$  où  $x_i^T = (x_{i1}, \dots, x_{id}) \in \mathbb{R}^d$  est un vecteur de caractéristiques et  $y_i \in \{-1, +1\}$  représente son étiquette de classe codée. En ce sens, si l'échantillon  $x_i$  est affecté à la classe positive, alors  $y_i$  prend l'étiquette +1, et si  $x_i$  est affecté à la classe négative, alors  $y_i$  prend l'étiquette -1. Cela permet de séparer les données d'entraînement par l'équation de l'hyperplan (García-Gonzalo et al., 2016; Han et al., 2012):

$$w^T x_i + b = 0 \tag{3.6}$$

La figure 3.4 présente le principe de séparation de deux classes par un hyperplan. Les équations des hyperplans marginaux,  $H_1$  et  $H_2$  sont données par :

$$H_1: (w^T x_i + b = 1) \quad (3.7)$$

$$H_2: (w^T x_i + b = -1) \quad (3.8)$$

où  $T$  désigne la transposition du vecteur poids  $w$ . Ainsi, les points correctement classés satisferont à l'équation d'inégalité suivante :

$$y_i(w^T x_i + b) \geq 1 \quad (3.9)$$

La marge qui représente la distance entre les hyperplans marginaux  $H_1$  et  $H_2$  est égale à  $\frac{2}{\|w\|}$ . Les échantillons d'entraînement qui se trouvent directement sur les hyperplans  $H_1$  ou  $H_2$ , sont appelés vecteurs de support, comme indiqué dans la figure 3.4.

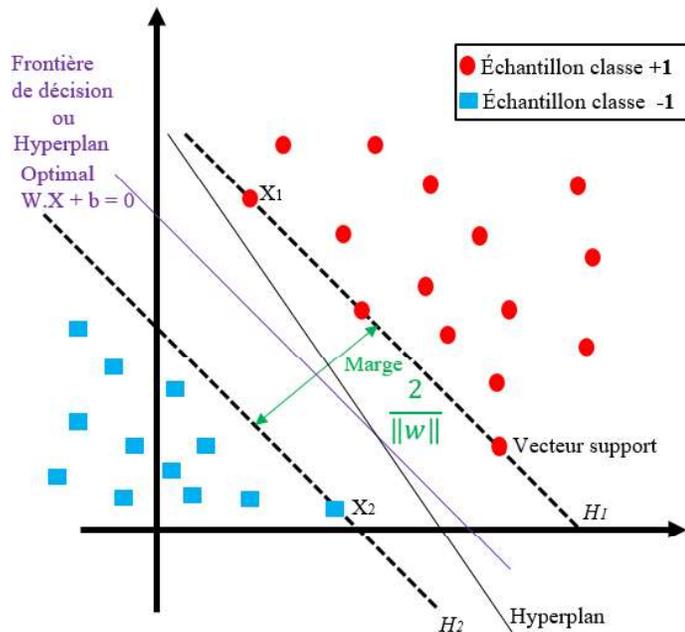


Figure 3.4 Classification de données à l'aide de SVM linéaire

La fonction de décision du SVM linéaire (LSVM) est donnée par (Boujelben & Bahoura, 2018) :

$$d(x) = \text{sign} \left[ \sum_{i=1}^S \alpha_i y_i x^T x + b \right] \quad (3.10)$$

où  $\alpha_i$  sont les coefficients associés aux vecteurs de support,  $y_i$  sont les étiquettes des classes associées aux points  $x_i$ ,  $b$  est le biais du classificateur et  $S$  est le nombre des vecteurs de support.

### 3.4.2 SVM non-linéaire (NLSVM)

Si les échantillons d'entraînement  $x_i$  ne sont pas linéairement séparables dans l'espace des caractéristiques, la technique SVM va mapper ces points, à l'aide d'une fonction  $\phi$ , dans un espace de caractéristiques de plus grande dimension où une séparation linéaire devient possible, de sorte que  $\phi(x_i)$  soit l'image des points d'entraînements d'origine dans ce nouvel espace. La figure 3.5 suivante montre une classification à deux classes où les données de l'espace d'origine sont mappées dans une dimension supérieure en passant par un noyau, et où les classes bleu et rouge sont linéairement séparées par l'hyperplan.

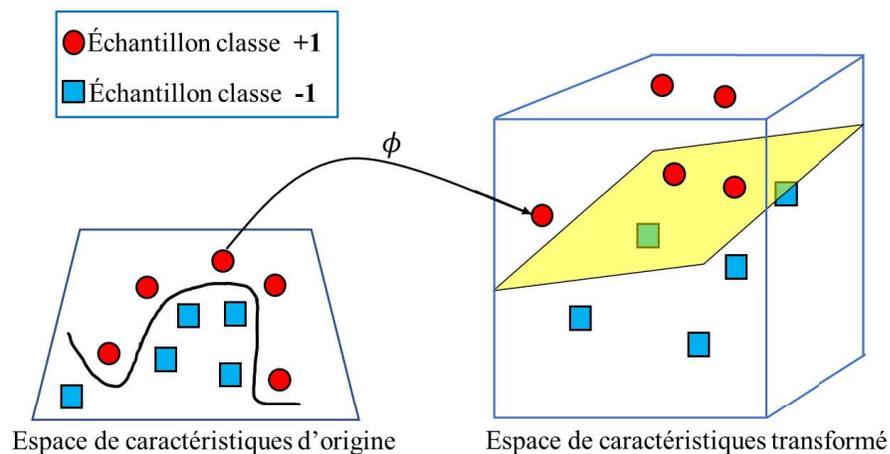


Figure 3.5 Présentation des points d'entraînements dans l'espace des échantillons d'origine et lorsqu'ils sont mappés dans une dimension supérieure

Ainsi, grâce à  $\phi(x_1)_1, \phi(x_2)_2, \dots, \phi(x_m)_m$ , le nouvel ensemble de caractéristiques d'entrées, qui sont les nouveaux points d'entraînement du système dans un nouvel espace de dimension supérieure (Han et al., 2012), l'algorithme SVM sera capable de séparer linéairement les classes de données transformées à l'aide de la fonction linéaire  $f(\phi(x)) = w^T \phi(x) + b$  (Boujelben & Bahoura, 2018; García-Gonzalo et al., 2016). Cependant, il est difficile de calculer directement  $\phi(x)$  et de trouver  $w$  dans cet espace transformé. Pour éviter cela, on utilise l'astuce du noyau.

Le noyau  $K(x_i, x_j) = \phi^T(x_i) \cdot \phi(x_j)$  remplace tout simplement le produit scalaire  $w^T \phi(x)$  dans l'espace transformé par un produit scalaire dans l'espace d'origine, ce qui permet de travailler dans l'espace d'origine sans connaître explicitement la transformation  $\phi$ . La fonction de décision dans le cas de NLSVM est donnée par (Boujelben & Bahoura, 2018) :

$$d(x) = \text{sign} \left[ \sum_{i=1}^s \alpha_i y_i K(x_i, x) + b \right] \quad (3.11)$$

Quatre fonctions de noyau sont couramment utilisées dans la littérature pour classification à l'aide de SVM. Il s'agit de la fonction linéaire, la fonction de base polynomiale, la fonction sigmoïde et la fonction de base radiale (RBF) ou gaussienne (Boujelben & Bahoura, 2018; Sanei, 2013). La fonction RBF est la fonction du noyau la plus utilisée pour les classes non linéairement séparables, parce qu'elle permet de séparer pratiquement n'importe quel ensemble de données en projetant les données d'origine dans un espace de dimension infinie tout en créant une frontière autour de chaque point de données (Sanei, 2013). Les équations de toutes ces fonctions du noyau sont données ci-après (Boujelben & Bahoura, 2018; Sanei, 2013) :

- La fonction linéaire :  $K(x_i, x_j) = x_i^T x_j$
- La fonction polynomiale :  $K(x_i, x_j) = (x_i^T x_j + 1)^d$ , où  $d$  est le degré du polynôme.

- La fonction sigmoïde :  $K(x_i, x_j) = \tanh(\alpha x_i^T x_j + \beta)$
- La fonction de base radiale RBF :  $K(x_i, x_j) = \exp\left(-\frac{1}{\sigma} \|x_i - x_j\|^2\right)$ ,  $\sigma > 0$

### 3.5 RÉSEAU DE NEURONES ARTIFICIELS (ANN)

Avant de définir un réseau de neurones artificiels (ANN), il est important de saisir et comprendre ce que c'est un neurone artificiel. En effet, un neurone artificiel est avant tout une modélisation formelle du neurone biologique et qui a une structure fonctionnelle semblable à celui-ci. Étant donc une expression mathématique dont la valeur dépend des coefficients (ou poids,  $w$ ) et d'un biais ( $b$ ), un neurone artificiel reçoit une ou des entrées, fait un traitement qui consiste à effectuer la somme pondérée de ses entrées à laquelle on additionne le biais, i.e.,  $\sum_i w_i x_i + b$ . Cette somme est ensuite transformée par une fonction de transfert ou d'activation  $\varphi$  qui produit la sortie finale  $y$  du neurone (Djeriri, 2017).

$$y = \varphi\left(\sum_i w_i x_i + b\right) \quad (3.12)$$

#### 3.5.1 Le Perceptron

Le perceptron est le plus simple des réseaux de neurones qui se compose d'une seule couche. La figure 3.6 suivante montre un neurone (un perceptron).

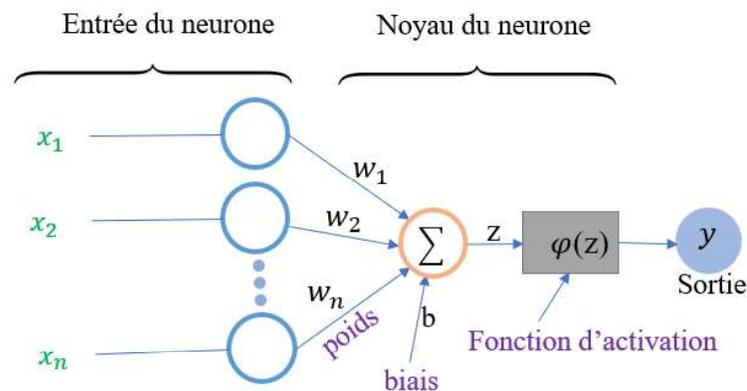


Figure 3.6 Réseau d'un seul neurone ou Perceptron

### 3.5.2 Perceptron Multicouche (MLP)

Plusieurs perceptrons peuvent être combinés entre eux pour créer un vaste réseau de perceptrons multicouches ou MLP (Multi-Layer Perceptrons) pouvant contenir une ou plusieurs couches cachées (Djeriri, 2017).

Le perceptron multicouche est un réseau constitué de neurones interconnectés et organisés en couches. Dans ce type de réseau, les connexions vont uniquement de la couche d'entrée vers la couche de sortie. La figure 3.7 ci-dessous présente un réseau MLP formé d'une couche d'entrée, d'une couche cachée et d'une couche de sortie.

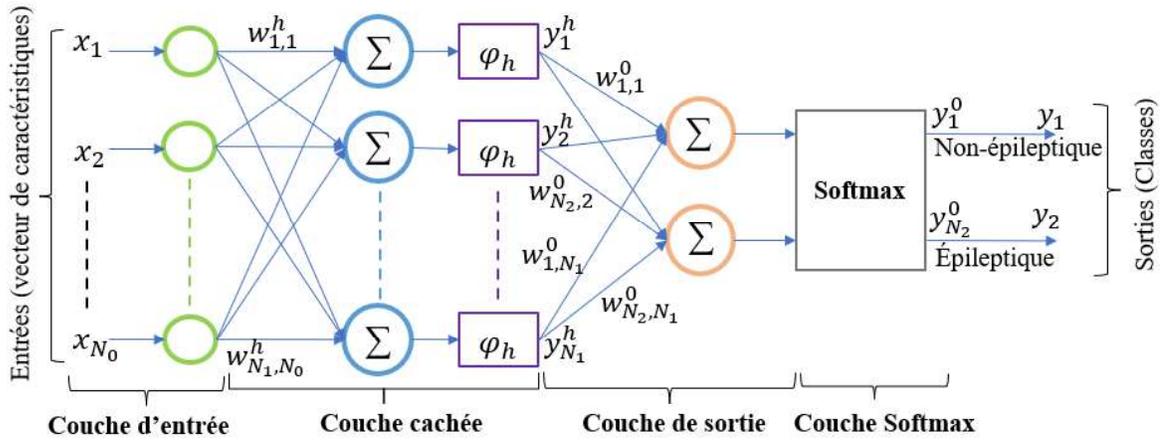


Figure 3.7 Architecture générale du Réseau de neurones artificiels

Pour un réseau neuronal MLP standard ayant  $N_0$  entrées, une seule couche cachée contenant  $N_1$  neurones et une couche de sortie de  $N_2$  neurones, les équations suivantes illustrent le calcul de la sortie pour un neurone situé dans la couche cachée du MLP :

$$y_j^h = \varphi_h \left( \sum_{i=1}^{N_0} w_{j,i}^h x_i + b_j^h \right) \quad j = 1, \dots, N_1 \quad (3.13)$$

où  $w_{j,i}^h$  est le poids synaptique reliant la  $i^{\text{ème}}$  entrée au  $j^{\text{ème}}$  neurone caché,  $x_i$  représente les entrées du réseau de neurone, et  $w_{j,0}^h$  représente le biais du  $j^{\text{ème}}$  neurone caché et  $\varphi_h$  désigne la fonction d'activation des neurones cachés.

Pour les sorties des neurones appartenant à la couche de sortie,

$$y_k^0 = \varphi_0 \left( \sum_{j=1}^{N_1} w_{k,j}^0 y_j^h + b_k^0 \right) \quad k = 1, \dots, N_2 \quad (3.14)$$

où  $w_{k,j}^0$  est le poids synaptique reliant le  $j^{\text{ème}}$  neurone caché au  $k^{\text{ème}}$  neurone de sortie,  $w_{k,0}^0$  représente le biais du  $k^{\text{ème}}$  neurone de sortie et  $\varphi_0$  désigne la fonction d'activation des neurones de sortie. Dans ce cas, les neurones cachés utilisent l'activation par tangente hyperbolique  $\varphi_h$ , tandis que les neurones de sortie utilisent la fonction linéaire. Cependant, les  $N_2$  neurones de sortie passe à travers la fonction d'activation softmax.

### 3.5.3 Apprentissage du réseau MLP

Les réseaux MLP sont capables d'apprendre et ajuster les paramètres du modèle en cherchant à minimiser une fonction de coût par des algorithmes d'optimisation tel que la méthode du gradient.

### 3.5.4 Fonction d'activation

Plusieurs fonctions d'activations sont utilisées dans la littérature. Parmi les plus citées, on trouve la fonction Logistique (ou Sigmoidé), la fonction Tangente Hyperbolique (Tanh) et encore la fonction Rectified Linear Unit (ReLU) (Djeriri, 2017).

La fonction sigmoïde. C'est la plus populaire dans la littérature. Elle est définie par l'équation 3.15 et illustrée à la figure 3.8.

$$\varphi(x) = \text{sig}(x) = \frac{1}{1 + e^{(-x)}} \quad (3.15)$$

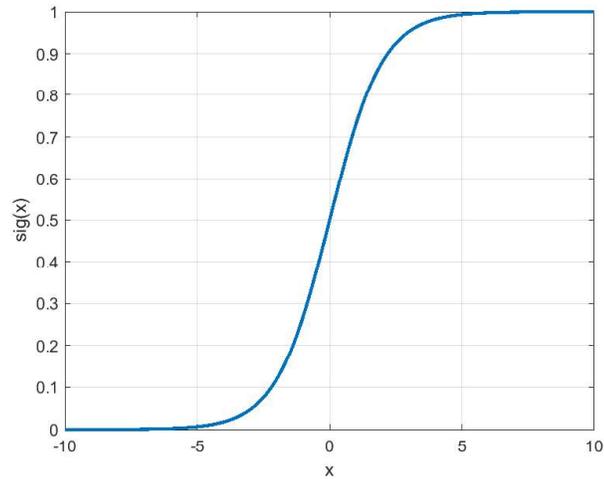


Figure 3.8 Fonction sigmoïde

- La fonction tangente hyperbolique. Elle est définie par l'équation 3.16 et illustrée à la figure 3.9.

$$\varphi(x) = \text{tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.16)$$

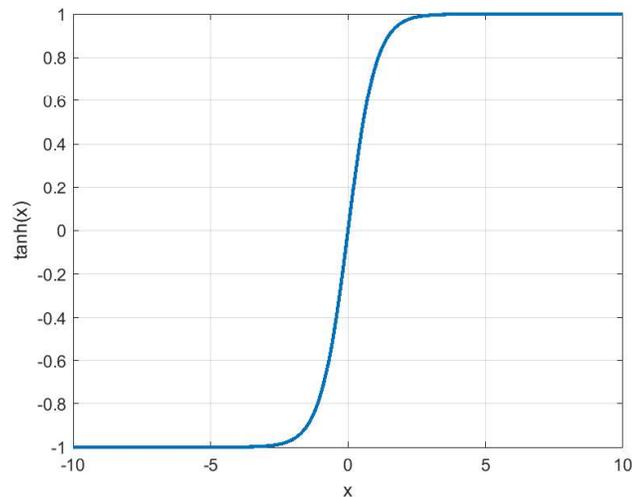


Figure 3.9 Fonction tangente hyperbolique

- La fonction Rectified Linear Unit (ReLU). Elle est définie par l'équation 3.17 et illustrée à la figure 3.10.

$$\varphi(x) = \text{ReLU}(x) = \max(0, x) \quad (3.17)$$

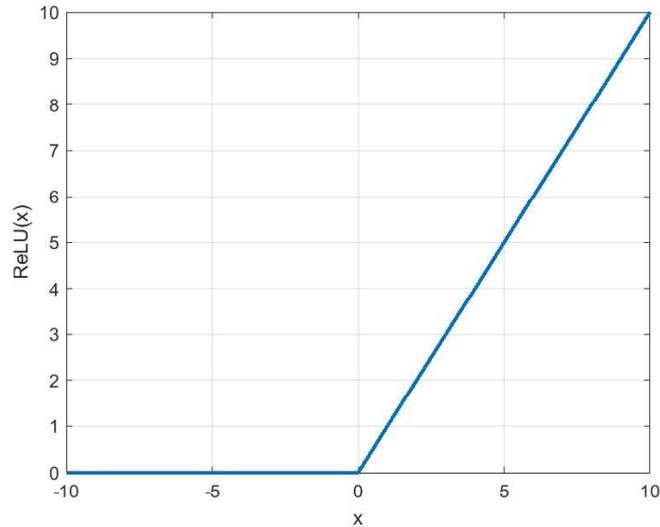


Figure 3.10 Fonction ReLU

- La fonction Softmax. C'est une version améliorée du sigmoïde. Cette fonction est surtout utilisée pour la classification neuronale multi-classe, afin de normaliser les sorties de manière à ce que leur somme soit égale à 1, permettant ainsi de les interpréter comme des probabilités. Pour chaque entrée, elle produit la probabilité de chaque classe à laquelle elle appartient.

$$\varphi(x_i) = \text{softmax}(x_i) = \frac{e^{x_i}}{\sum_{j=1}^{N_s} e^{x_j}}, \quad (i = 1, 2, \dots, N_s) \quad (3.18)$$

où  $x_i$  est la valeur d'entrée de la couche softmax et  $\varphi(x_i)$  est la valeur de sortie qui indique la probabilité que l'échantillon appartienne à la  $i^{\text{ème}}$  catégorie (Aggarwal, 2018).  $N_s$  est le nombre de classes qui correspond au nombre de neurones dans la couche de sortie. La figure 3.11 suivante donne un aperçu du fonctionnement de cette fonction d'activation.

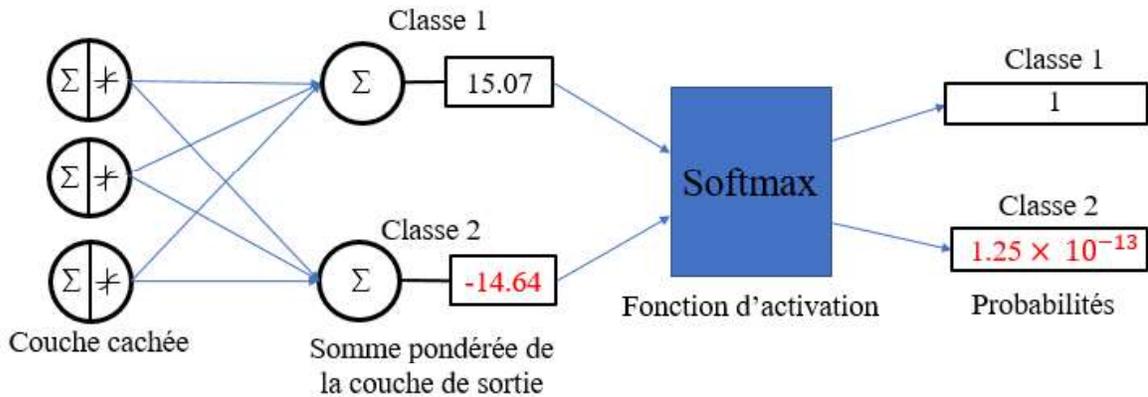


Figure 3.11 Schématique de la fonction d'activation Softmax pour la classification multi-classe de ANN

Selon la figure 3.11, la classe détectée par la fonction d'activation softmax pour les données présentes à l'entrée est la première classe, puisque sa probabilité de prédiction est supérieure aux autres classes, soit 1.

$$\text{Softmax}(x_1) = \frac{e^{15.07}}{e^{15.07} + e^{-14.64}} \approx 1 \quad (3.19)$$

### 3.6 MÉTRIQUES DE PERFORMANCE

Les métriques de performances sont des outils utilisés en apprentissage supervisé pour évaluer la capacité prédictive d'un modèle. Plusieurs métriques sont utilisées à cette fin, les plus populaires sont la matrice de confusion, les caractéristiques du fonctionnement de récepteur (ROC), aire sous la courbe (AUC), la statistique Kappa (k), etc. Cependant, parmi toutes ces métriques, la matrice de confusion demeure la plus populaire.

#### 3.6.1 Matrice de confusion

La matrice de confusion est utilisée pour évaluer les performances d'un modèle et fournir un aperçu utile de sa capacité à prédire ces classes particulières, ainsi que de ses propriétés de généralisation (Cichosz, 2015).

Différentes mesures de performance dérivées de la matrice de confusion s'appliquent uniquement aux modèles à deux classes. La convention utilisée dans une matrice de confusion est que « positif » ou « négatif » fait référence aux étiquettes de classe prédites par le modèle, et « vrai » et « faux » fait référence à l'exactitude de la prédiction. Les mesures de performance les plus populaires calculées pour une matrice de confusion 2 x 2 sont illustrées dans le tableau 3.1 (Cichosz, 2015), où TN désigne « vrai négatif », TP désigne « vrai positif », FP désigne « Faux positif » et FN, « faux négatif ».

Tableau 3.1 Représentation d'une matrice de confusion

		Classe Prédite	
		Non-Épileptique=No	Épileptique=Yes
Classe réelle	Non-Épileptique =No	(TN)	(FP)
	Épileptique = Yes	(FN)	(TP)

où l'erreur de classification est représentée par le rapport entre les instances mal classées et toutes les instances :

$$\text{Erreur de classification} = \frac{FP+FN}{TP+TN+FP+FN} \quad (3.20)$$

Le taux de réussite ou exactitude de classification est donné comme le rapport entre les instances correctement classées et toutes les instances :

$$\text{Exactitude de classification} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.21)$$

La sensibilité ou rappel (recall) ou TPR (taux des vrais positifs) est le rapport entre les instances correctement classées comme positives et toutes les instances positives :

$$\text{Rappel} = \text{Sensibilité} = \text{TPR} = \frac{TP}{TP+FN} \quad (3.22)$$

Le taux de faux positifs (spécificité) est représenté par le rapport entre les instances incorrectement classées comme positives et toutes les instances négatives :

$$\text{Spécificité} = 1 - \text{FPR} = \frac{TN}{FP+TN} \quad (3.23)$$

La précision est le rapport entre les instances correctement classées comme positives et toutes les instances classées comme positives :

$$\text{Précision} = \frac{TP}{FP+TP} \quad (3.24)$$

### 3.7 CLASSIFICATION PAR VOTE MAJORITAIRE

Le classificateur de vote est une méthode d'ensemble d'apprentissage qui combine les prédictions de plusieurs algorithmes de classification pour produire la prédiction optimale finale. Le classificateur de vote devient un modèle unique qui s'entraîne à partir de ces algorithmes et prédit les résultats en fonction de leur majorité combinée des votes pour chaque classe de résultats. La performance du modèle de vote majoritaire ne peut pas être dégradée par l'erreur d'un seul modèle puisque le vote repose sur les performances de nombreux modèles. En d'autres termes, les mauvaises performances d'un modèle peuvent être compensées par les bonnes performances des autres modèles. Deux types de vote, basés sur la méthode d'ensemble, sont utilisés dans la classification : le vote majoritaire simple (hard voting) et le vote majoritaire pondéré (soft voting) (Manconi et al., 2022).

#### 3.7.1 Vote de majorité simple (Hard voting)

Dans le vote hard (également appelé vote majoritaire simple), les modèles prédisent la classe de sortie indépendamment les uns des autres, et la classe qui obtient la plus grande majorité de voix est la classe prédite (Manconi et al., 2022). Si, par exemple, trois classificateurs distincts prédisent successivement la classe de sortie (A, A et B), comme la majorité prédit A comme sortie, A sera donc la prédiction finale.

Soit  $m_i$  le  $i^{\text{ème}}$  modèle d'un ensemble composé de  $N$  classificateurs individuels visant à prédire l'étiquette de classe d'une entrée  $x$ , à partir d'un ensemble de  $k$  étiquettes possibles  $\{c_1, c_2, \dots, c_k\}$ . Pour une entrée  $x$  donnée, le classificateur  $m_i$  générera un vecteur à  $k$  dimensions  $[m_i^1(x), m_i^2(x), \dots, m_i^k(x)]$ , où  $m_i^j(x)$  est la sortie du  $i^{\text{ème}}$  modèle pour la  $j^{\text{ème}}$  étiquette de catégorie. Ainsi, la formule du vote de majorité est donnée par (Manconi et al., 2022) :

$$y^* = \arg \max_j \frac{1}{N} \sum_{i=1}^N m_i^j(x) = \arg \max_j \sum_{i=1}^N m_i^j(x) \quad j = 1, 2, \dots, k \quad (3. 25)$$

### 3.7.2 Vote de majorité pondérée (soft voting)

En plus du vote majoritaire simple (vote hard) décrit précédemment, un vote majoritaire pondéré (ou vote soft) peut être déterminé en associant un poids  $w_i$  au  $i^{\text{ème}}$  classificateur. Dans le vote soft, la classe de sortie est la prédiction basée sur la moyenne des probabilités données à cette classe. Il consiste à combiner les probabilités de prédiction de chaque modèle et à choisir la classe avec la probabilité de prédiction totale la plus élevée (Manconi et al., 2022). Si, par exemple, trois modèles distincts prédisent deux classes A et B avec des probabilités différentes pour chaque classe comme classe A = (0.85 ; 0.36; 0.53) et classe B = (0.15 ; 0.64 ; 0.47). Ainsi, la moyenne pour la classe A est (0.85 + 0.36 + 0.53) / 3 qui est égale à 0.58 et la classe B est de 0.42 ; donc la classe élue est clairement la classe A, car elle a sa probabilité moyenne qui est plus élevée que celle de la classe B.

Le vote pondéré est une généralisation des cas précédents, car ici les modèles de base sont combinés en fonction d'un poids qui reflète leur importance. Sous les mêmes hypothèses faites ci-dessus, et en supposant que  $w_i$  est le poids attribué au  $i^{\text{ème}}$  modèle  $m_i$ , la politique de vote pondéré peut être résumée comme suit (Manconi et al., 2022):

$$y^* = \arg \max_j \sum_{i=1}^N w_i m_i^j(x) \quad j = 1, 2, \dots, k \quad (3. 26)$$

La figure 3.12 ci-dessous montre les deux politiques de vote utilisées dans la classification à l'aide des méthodes d'ensemble.

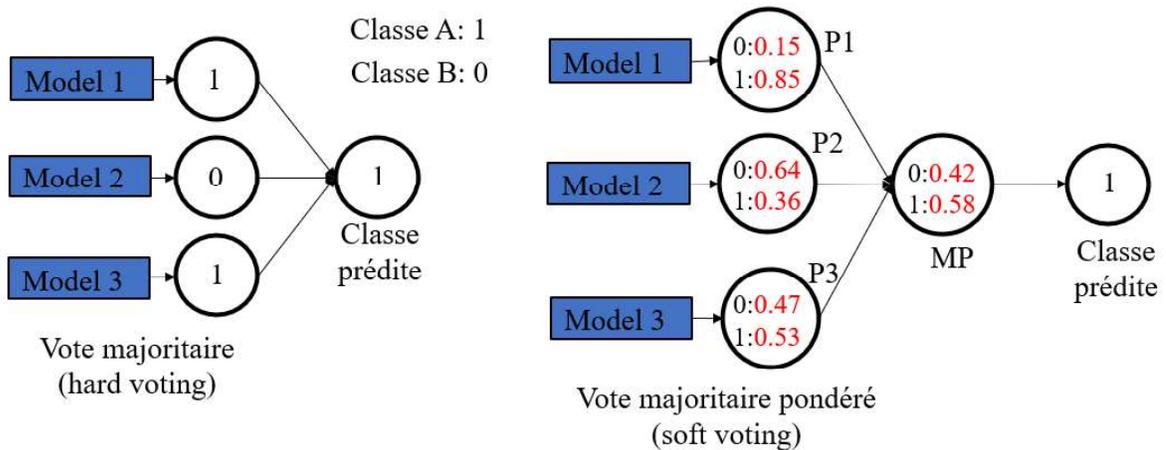


Figure 3.12 Schématisation du vote hard et soft pour la classification des méthodes d'ensemble, avec P1, P2 et P3 la probabilité de prédiction respective des modèles 1, 2 et 3 ; et MP est la moyenne des probabilités des classes A et B (Manconi et al., 2022)

### 3.8 SYSTÈME DE CLASSIFICATION PROPOSÉ POUR L'IMPLEMENTATION LOGICIELLE

Pour l'étape de classification des signaux EEG, cinq techniques de classification sont combinées avec les caractéristiques extraites à l'étape de sélection de caractéristiques. L'objectif de cette deuxième combinaison est d'entraîner et tester toutes les paires de sélection de caractéristiques formées (à savoir extraction et réduction de dimension) avec tous les cinq classificateurs du projet (à savoir : LDA, KNN, RF, SVM et ANN) afin de sélectionner les meilleures paires de sélection de caractéristiques correspondant le mieux à chaque classificateur pour la prédiction par vote de majorité ou des futures applications, comme l'implémentation matérielle du système de détection de la crise. En ce sens, l'implémentation logicielle se fait en deux étapes :

1. Évaluation des 3 x 3 x 5 combinaisons afin de choisir la meilleure pour chaque classificateur du projet.

2. Formation d'un ensemble d'apprentissage basé sur les 5 meilleurs systèmes de classification individuels.

La figure 3.13 ci-dessous illustre les traitements réalisés dans la première étape et la figure 3.14, ceux réalisés dans la deuxième étape de l'implémentation logicielle du projet.

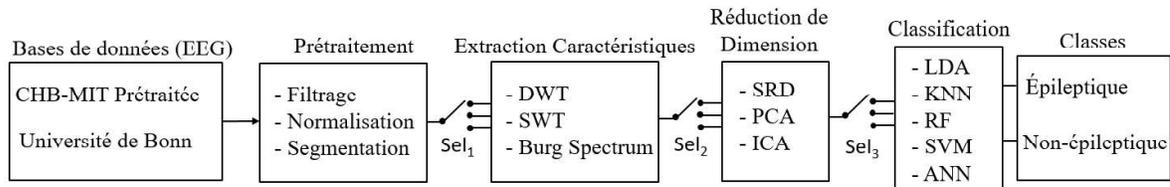


Figure 3.13 Diagramme bloc décrivant les 45 systèmes évalués individuellement pour la détection de la crise épileptique

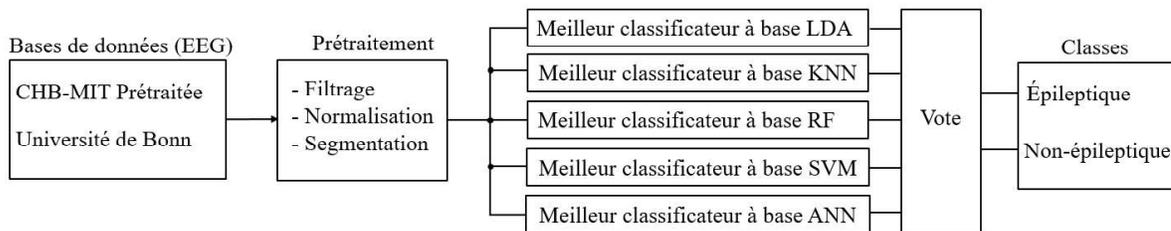


Figure 3.14 Diagramme bloc d'un ensemble d'apprentissage basé sur les 5 meilleurs classificateurs

### 3.9 APPROCHE PROPOSÉE POUR LA CLASSIFICATION MATÉRIELLE

Pour l'étape de classification des signaux EEG par matériel, sont proposés une machine à vecteurs de supports (SVM) et un perceptron multicouche (MLP). Ces deux modèles prédisent séparément l'état du patient en utilisant la transformée en ondelettes stationnaire (SWT) et la variance pour l'étape de sélection de caractéristiques. L'architecture matérielle suit la même logique que l'architecture logicielle en utilisant uniquement moins d'outils que cette dernière. L'architecture de ce système est présentée à la figure 3.15 suivante.

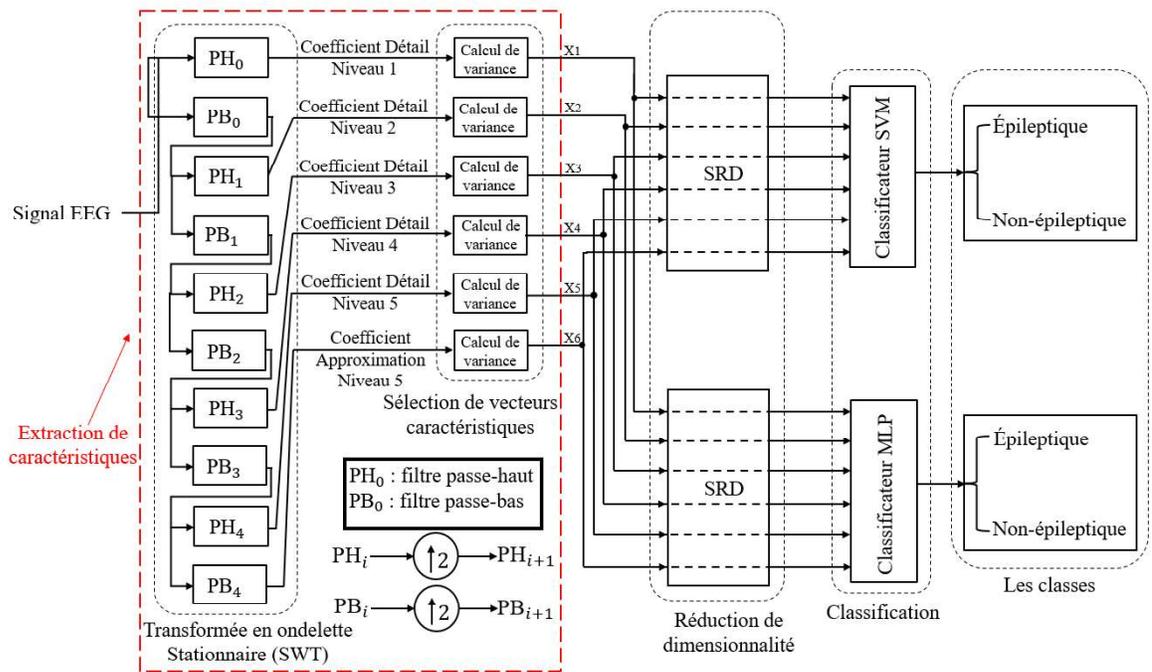


Figure 3.15 Architecture générale proposée pour la détection de la crise épileptique par matériel à l'aide des classificateurs SVM et ANN

## **CHAPITRE 4**

### **RÉSULTATS DE L'IMPLÉMENTATION LOGICIELLE**

Ce chapitre met en exergue l'évaluation des performances de classification obtenues avec les différents outils d'apprentissage automatique présentés dans les deuxième et troisième chapitres. L'expérimentation de ces outils commence avec le prétraitement pour bien préparer les données. Elle se poursuit avec l'application des différents algorithmes de détection d'épilepsie en les combinant ensemble à la recherche de la meilleure combinaison pour chacun des cinq classificateurs utilisés dans ce projet. Enfin, la détection de l'épilepsie est réalisée par un vote de majorité des meilleurs détecteurs trouvés. Le résultat des meilleures combinaisons ainsi que les performances du vote de majorité avec les meilleurs détecteurs pour les deux bases de données utilisées sont aussi présentés et commentés.

#### **4.1 PRÉTRAITEMENT DES DEUX BASES DE DONNÉES DU PROJET**

Le prétraitement des données, déjà présenté dans le deuxième chapitre de ce présent document, consiste en une série de traitements appliqués aux données originales afin d'améliorer leur qualité pour une utilisation ultérieure. Elle comprend le filtrage du bruit, la normalisation et la segmentation. Étant donné que ce projet utilise deux bases de données différentes construites dans des conditions différentes, le prétraitement sera effectué en fonction des nécessités de chacune d'elles.

##### **4.1.1 Prétraitement de la base de données CHB-MIT**

Avant d'expliquer comment les étapes de prétraitement ont été réalisées dans le cadre de ce projet pour la base de données CHB-MIT, il est impératif d'expliquer comment la base de données CHB-MIT utilisée est organisée. Dans la suite est présenté le traitement réalisé par (Deepa & Ramesh, 2022) pour transformer la base de données CHB-MIT originale en uniquement deux enregistrements représentant les deux classes de données. Plus tard, ce sont ces deux enregistrements de données qui seront utilisés dans les implémentations logicielle et matérielle de ce projet.

#### 4.1.1.1 Organisation de la base de données utilisée

La base de données CHB-MIT utilisée dans ce projet provient indirectement de l'étude de (Goldberger et al., 2000), car elle a été prétraitée et réorganisée par (Deepa & Ramesh, 2022) pour avoir une seule séquence de données pour chacune des deux classes. Dans la base de données originale, les données critiques sont réparties entre 23 patients, et la durée totale des enregistrements est de 958 heures, dont seulement environ 1 heure 8 minutes et 16 secondes contiennent des périodes critiques. Cela correspond à 1048576 échantillons critiques, calculés à partir de la fréquence d'échantillonnage de 256 Hz (soit  $(3600 + 8 * 60 + 16) * 256$ ). Le travail colossal réalisé par (Deepa & Ramesh, 2022) est surtout la création d'une base de données comportant une seule séquence de données par classe (étiquette), chacune formée de 23 canaux, quoique le nombre de canaux n'est pas identique pour tous les patients de la base originale. Ce processus a impliqué l'extraction et le regroupement (concaténation), par canal, de toutes les périodes de crise contenues dans les enregistrements des 23 patients de la base originale. De plus, une portion de données inter-critiques équivalente à celle des données critiques a été sélectionnée afin de former une classe non-épileptique pour la base de données CHB-MIT. Ce travail vient faciliter la tâche aux chercheurs qui souhaiteront utiliser la base de données CHB-MIT dans leurs travaux de recherche. La figure 4.1 suivante illustre le processus de création de la base de données CHB-MIT prétraitée (Deepa & Ramesh, 2022). Elle représente notre interprétation du travail colossal qui avait été réalisé, afin d'expliquer et de rendre compréhensible le regroupement des périodes critiques en un seul enregistrement et l'équivalent pour les périodes inter-critiques.

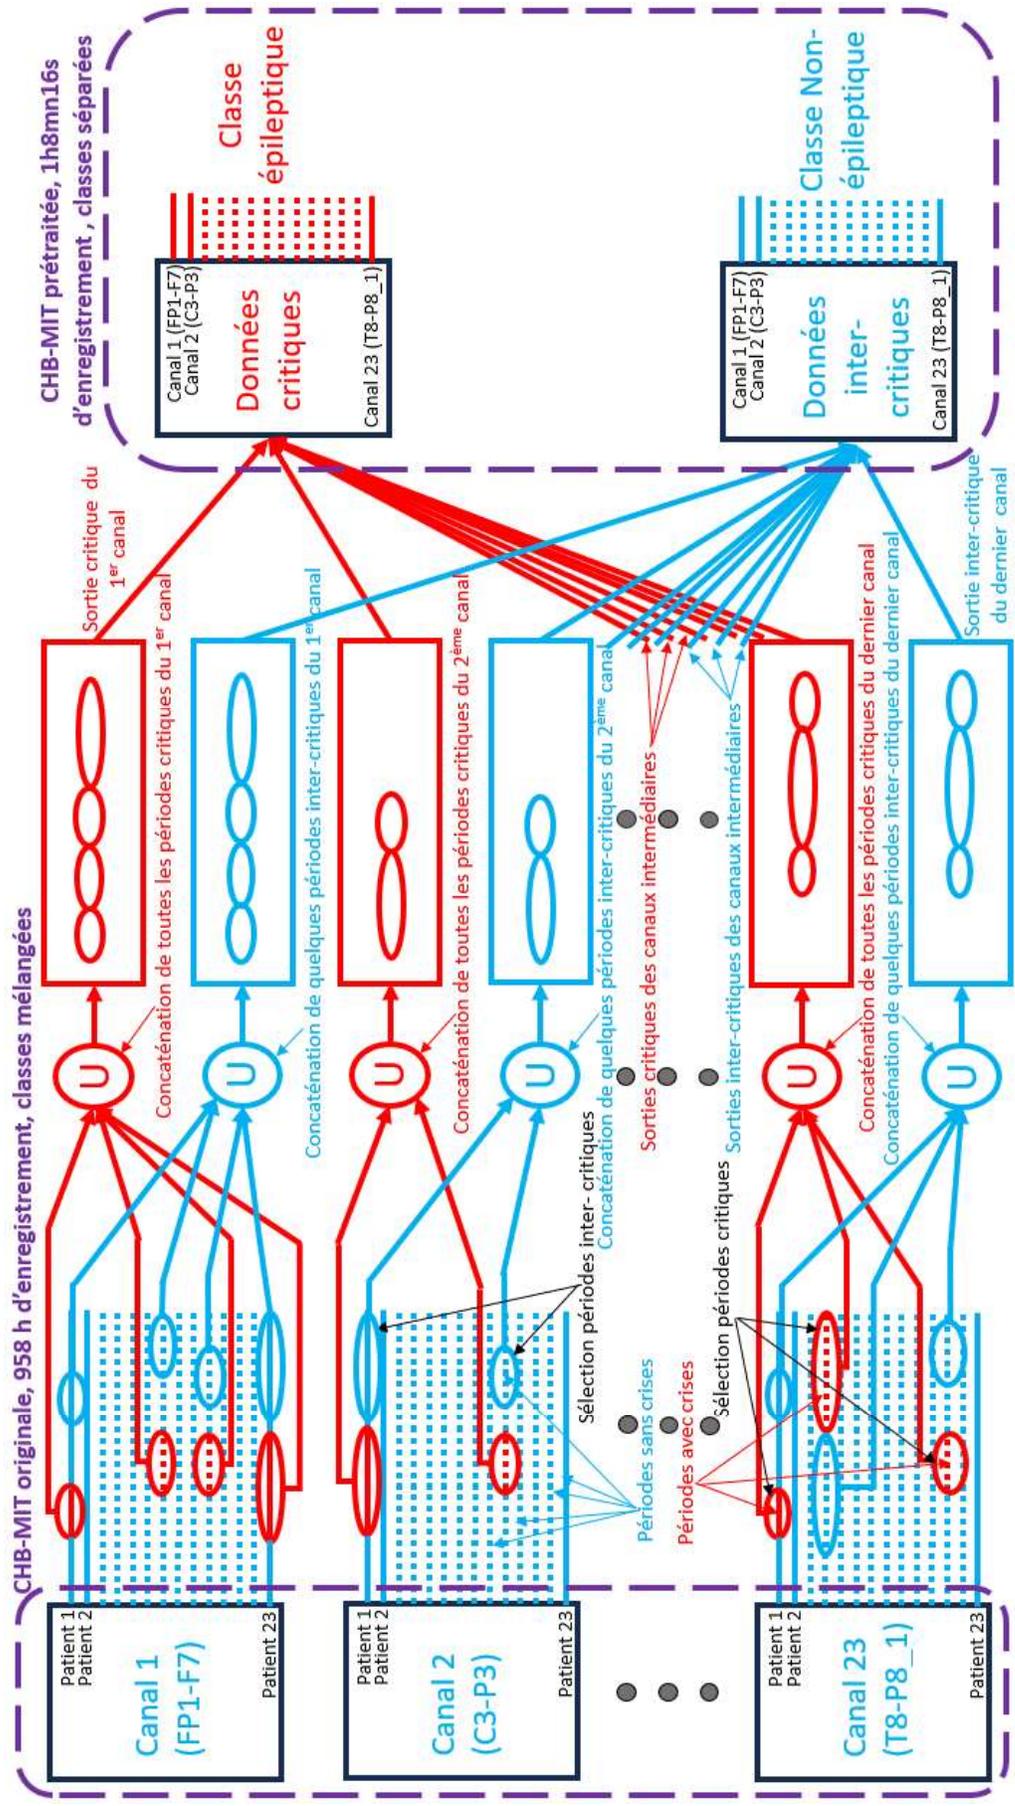


Figure 4.1 Traitement réalisé par (Deepa & Ramesh, 2022) pour former deux classes de données (épileptiques et non épileptiques) à partir de la base de données CHB-MIT originale

#### 4.1.1.2 Filtrage et normalisation des signaux EEG de la base de données CHB-MIT

Comme mentionné précédemment, les données EEG doivent être prétraitées avant d'être utilisées. Ainsi, avant de débiter les autres traitements liés à la détection de l'épilepsie, les signaux EEG de la base de données CHB-MIT ont d'abord été soumis aux deux premières étapes du prétraitement, à savoir le filtrage et la normalisation.

Dans un premier temps, un filtre passe-bande de Butterworth de type IIR, d'ordre 10, avec des fréquences de coupure fixées à 0.5 Hz et 25 Hz, a été appliqué pour supprimer les artéfacts présents dans les signaux EEG. Ensuite, les signaux EEG filtrés ont été normalisés à l'aide de la méthode de normalisation z-score. Le filtre de Butterworth a été conçu à l'aide de l'outil filterDesigner de l'environnement Matlab/Simulink.

#### 4.1.1.3 Segmentation de la base

Le premier grand défi dans la segmentation des données est la longueur du segment nécessaire pour extraire les informations suffisantes et pertinentes des signaux EEG afin de détecter efficacement l'épilepsie. Cette longueur de segment est très cruciale, car des segments de petite taille peuvent ne pas contenir suffisamment d'informations pertinentes que l'algorithme d'extraction des caractéristiques peut capturer tout comme des segments trop longs peuvent noyer les caractéristiques réelles des données (Ali et al., 2024).

La longueur de la fenêtre d'un signal EEG provenant de la base de données CHB-MIT peut être choisie égale à 10 secondes. En effet, selon (Shoeb et al., 2004; Shoeb & Guttag, 2010), une activité peut être qualifiée comme critique si ça dure au moins entre 6 à 10 secondes. Avec une fréquence de 256 Hz comme fréquence d'échantillonnage pour la base de données CHB-MIT, cela revient à dire que la longueur de la fenêtre peut être de 2560 observations (soit  $256 \text{ Hz} \times 10 \text{ s} = 2560$  échantillons). Cette taille de fenêtre est aussi confirmée par (Issaka, 2017) qui affirme que la longueur de la fenêtre à choisir pour capturer les périodes de convulsions doit être supérieure à 2560 échantillons. D'un autre côté, les auteurs (Abdelhameed & Bayoumi, 2021; Wei et al., 2019; Wu et al., 2019),

traitant ce même sujet avec la base données CHB-MIT, utilisent des fenêtres de 2 ou 5 secondes pour détecter les crises. La technique de détection utilisée par ces auteurs est la détection par évènements et non par segments. La détection par évènements consiste à capturer des périodes spécifiques d'intérêt uniquement lorsqu'elles se produisent, indépendamment de la longueur du signal EEG. Sa durée dans le temps peut varier (plus courte ou plus longue) par rapport à un segment arbitraire. Comparativement, la détection par segments consiste à diviser le signal EEG en des segments de temps fixes, et chaque segment est traité comme une unité indépendante pour la classification.

Dans le cadre de la classification par évènements, pour prendre une décision concernant un patient, les auteurs récupèrent et analysent entre trois et cinq évènements de 2 secondes (entre  $3 \times 2s = 6s$  et  $5 \times 2s = 10s$ ) ou deux évènements de 5 secondes ( $2 \times 5s = 10s$ ) du signal EEG. Ce qui revient à utiliser quand bien même une taille de fenêtre entre 6 et 10 secondes pour la prédiction de l'épilepsie. Cependant, quoiqu'une fenêtre de taille de 6 secondes ou 3 évènements de 2s ( $3 \times 2s = 6s$ ) pourrait suffire pour refléter la présence de l'épilepsie avec la base de données CHB-MIT, (Ali et al., 2024) affirment que la détection de crise est bien meilleure lorsque la taille de la fenêtre de détection est de 10 secondes.

Ainsi, la segmentation de la base de données CHB-MIT prétraitée à l'aide d'une fenêtre de 10 s a fourni 818 segments, sans chevauchement, chacun comportant 23 canaux de 2560 échantillons. La base de données qui servira à entraîner et tester les différents algorithmes de détection de l'épilepsie est composée de 409 segments épileptiques et 409 segments non-épileptiques.

Lors de ce traitement, chaque canal est interprété comme étant un signal EEG à part entière et est découpé en segment. Cela dit, la base de données a permis de créer  $23 \times 818$  segments qui ne se chevauchent pas, soit 18814 segments en total. Tous ces segments ne sont pas utilisés pour l'entraînement des modèles et la prédiction par vote majoritaire de l'épilepsie ; certains ont été délaissés à l'étape de sélection des meilleurs canaux en raison du faible taux d'exactitude qu'ils donnent. Seulement quatre canaux ont finalement été

sélectionnés pour l'entraînement et la prédiction de l'épilepsie pour la partie logicielle et un seul canal, le meilleur canal pour les classificateurs SVM et ANN (offrant les meilleures performances), est utilisé pour implémenter matériellement le détecteur de l'épilepsie. La figure suivante montre comment sont obtenus les segments à partir de la base de données prétraitée de (Deepa & Ramesh, 2022).

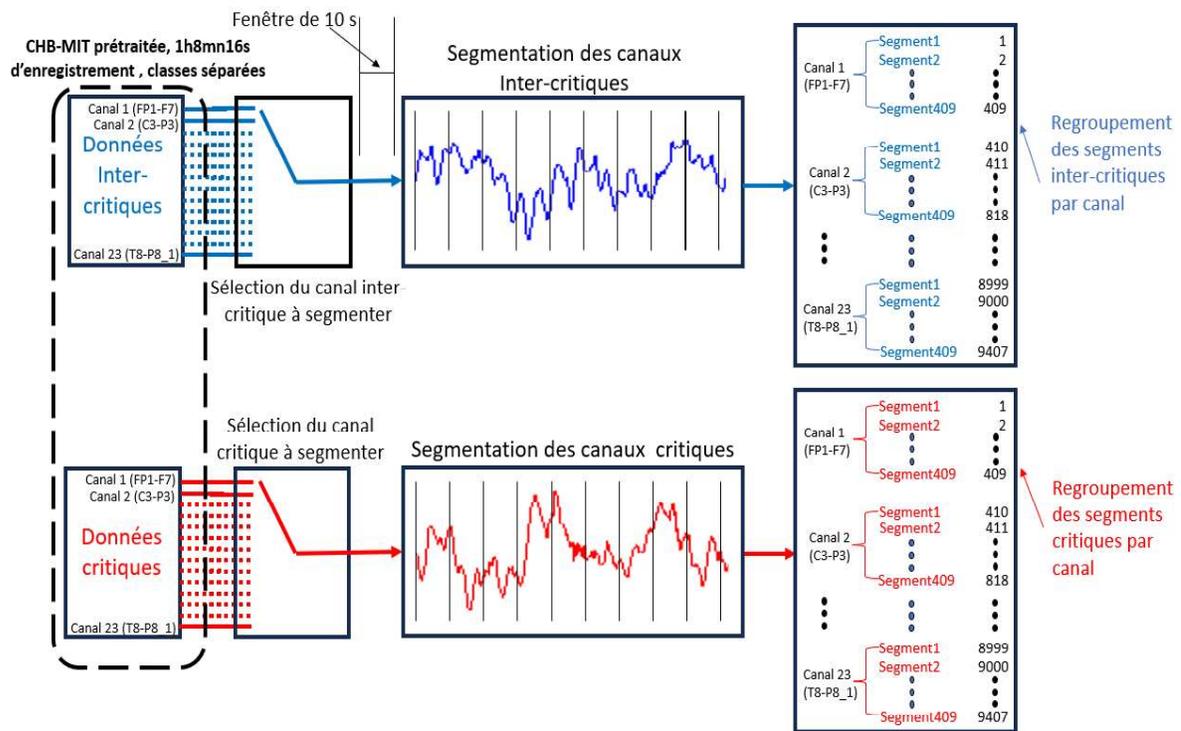


Figure 4.2 Segmentation de la base de données CHB-MIT prétraitée

#### 4.1.1.4 Choix des meilleurs canaux EEG pour décrire toute la base dans le cas de l'implémentation logicielle

Comme mentionné dans le premier chapitre de ce document, le choix des canaux à utiliser pour représenter toute la base de données CHB-MIT est crucial pour la détection de l'épilepsie tant par logiciel que par matériel, car il permet de réduire le temps de traitement et la complexité des implémentations. Ce projet ne prétend pas à être le premier se proposant de sélectionner une quantité réduite de canaux EEG de la base CHB-MIT pour détecter l'épilepsie puisqu'en effet, le choix des canaux de ce projet s'est inspiré de

(Humairani et al., 2021) qui ont mené une étude sur le sujet pour identifier les canaux les plus représentatifs énergétiquement pour la base CHB-MIT. Les résultats proposés par cet article se limitaient aux huit premiers patients de la base de données CHB-MIT originale, ce qui paraît clairement non représentatifs si c'est la base de données CHB-MIT prétraitée de (Deepa & Ramesh, 2022) qui est utilisée puisque les données EEG de tous les 23 patients de cette base sont désormais mélangées.

Face à cette situation, nous avons mené nos propres tests de sélection de canaux. Ces tests sont basés sur l'analyse de chaque canal afin de déterminer celui qui offre la meilleure exactitude moyenne pour les cinq classificateurs du projet. Cette approche permet d'identifier les canaux les plus pertinents pour capturer les caractéristiques spécifiques des signaux, en particulier ceux associés aux événements critiques. Ainsi, les quatre meilleurs canaux (ceux avec les exactitudes moyennes les plus élevées) sont conservés pour l'entraînement et le test des différents modèles de classification. Cela dit, pour l'implémentation logicielle, seulement  $4 \times 409$  segments = 1636 segments issus des meilleurs canaux de la base de données sont utilisés pour chacune des deux classes, dans la prédiction de l'épilepsie. Le tableau 4.1 ci-après présente les quatre canaux les plus performants, sélectionnés sur la base de l'exactitude moyenne de celles obtenues par les cinq classificateurs du projet. Cette analyse a été réalisée sur les 409 segments de chaque classe et pour chaque canal. La validation croisée a également été appliquée lors de la sélection des meilleurs canaux de la base CHB-MIT prétraitée. Toutefois, il est important de noter que les numéros liés aux noms des canaux de cette base sont différents de ceux de la base de données CHB-MIT originale.

Tableau 4.1 Quatre meilleurs canaux de la base de données CHB-MIT prétraitée

Numéro du Canal EGG	Nom du Canal EGG	Exactitudes des meilleures combinaisons par canal (%)					Exactitude Moyenne (%)	
		Extraction + Réduction + Classification : Exactitude						
4	CZ-PZ	DWT	+	SRD	+	LDA	: 96.577	99.1932
		AR Burg	+	PCA	+	KNN	: 99.8778	
		SWT	+	PCA	+	RF	: 99.8778	
		SWT	+	PCA	+	SVM	: 100	
		SWT	+	PCA	+	ANN	: 99.6333	
3	C4-P4	SWT	+	SRD	+	LDA	: 97.4328	99.291
		AR Burg	+	PCA	+	KNN	: 99.8778	
		AR Burg	+	SRD	+	RF	: 99.8778	
		AR Burg	+	SRD	+	SVM	: 99.8778	
		AR Burg	+	PCA	+	ANN	: 99.3888	
9	FP1-F3	DWT	+	SRD	+	LDA	: 97.4328	99.4377
		AR Burg	+	PCA	+	KNN	: 99.8788	
		AR Burg	+	SRD	+	RF	: 100	
		SWT	+	SRD	+	SVM	: 99.8778	
		DWT	+	SRD	+	ANN	: 100	
14	FZ-CZ	DWT	+	SRD	+	LDA	: 99.511	99.8044
		AR Burg	+	PCA	+	KNN	: 99.8778	
		DWT	+	ICA	+	RF	: 99.8778	
		AR Burg	+	SRD	+	SVM	: 99.8778	
		DWT	+	PCA	+	ANN	: 99.8778	

#### 4.1.1.5 Description du processus d'arrangement des canaux choisis pour la prédiction de l'épilepsie

Une fois ces 4 canaux sélectionnés, une autre étape cruciale consiste à définir la manière dont les canaux seront arrangés ensemble pour l'entraînement et le test des systèmes de détection d'épilepsie dans la partie logicielle.

##### 1. Segmentation et sélection des meilleurs canaux

- Chaque canal contient un total de 409 segments multicanaux pour chacune des deux classes.
- Quatre canaux ont été sélectionnés pour le diagnostic de l'épilepsie

Tableau 4.2 Segmentation des meilleurs canaux de la base de données CHB-MIT dans chacune des deux classes

Meilleurs canaux	Longueur segment				
	1	2	3	...	2560
<b>Canal 4 (CZ-PZ)</b>	Segment_1: $3.69 \times 10^{-5}$	$3.85 \times 10^{-5}$	$4.00 \times 10^{-5}$	...	$2.56 \times 10^{-5}$
	Segment_2: $3.38 \times 10^{-5}$	$3.07 \times 10^{-5}$	$2.91 \times 10^{-5}$	...	$1.31 \times 10^{-5}$
	...	...	...	...	...
	Segment_409: $9.57 \times 10^{-6}$	$1.11 \times 10^{-5}$	$1.04 \times 10^{-5}$	...	$4.88 \times 10^{-6}$
<b>Canal 3 (C4-P4)</b>	Segment_1: $-5.27 \times 10^{-6}$	$-3.32 \times 10^{-6}$	$-6.06 \times 10^{-6}$	...	$-3.61 \times 10^{-5}$
	Segment_2: $1.04 \times 10^{-5}$	$1.07 \times 10^{-5}$	$1.07 \times 10^{-5}$	...	$-4.49 \times 10^{-6}$
	...	...	...	...	...
	Segment_409: $5.26 \times 10^{-5}$	$4.04 \times 10^{-5}$	$5.06 \times 10^{-5}$	...	$1.15 \times 10^{-5}$
<b>Canal 9 (FP1-F3)</b>	Segment_1: $-7.52 \times 10^{-5}$	$-6.23 \times 10^{-5}$	$-4.32 \times 10^{-5}$	...	$1.86 \times 10^{-5}$
	Segment_2: $1.82 \times 10^{-5}$	$2.64 \times 10^{-5}$	$-3.07 \times 10^{-5}$	...	$-9.47 \times 10^{-5}$
	...	...	...	...	...
	Segment_409: $4.75 \times 10^{-5}$	$5.57 \times 10^{-5}$	$5.84 \times 10^{-5}$	...	$-1.04 \times 10^{-5}$
<b>Canal 14 (FZ-CZ)</b>	Segment_1: $-7.62 \times 10^{-6}$	$-7.62 \times 10^{-6}$	$5.27 \times 10^{-6}$	...	$4.20 \times 10^{-5}$
	Segment_2: $2.21 \times 10^{-5}$	$1.50 \times 10^{-5}$	$1.31 \times 10^{-5}$	...	$4.94 \times 10^{-5}$
	...	...	...	...	...
	Segment_409: $-3.71 \times 10^{-6}$	$-5.27 \times 10^{-6}$	$-8.40 \times 10^{-6}$	...	$-9.96 \times 10^{-6}$

## 2. Regroupement des segments en fonction des canaux choisis

Pour chaque segment multicanal EEG, les sous-segments monocanaux du même indice qui le composent sont regroupés.

Tableau 4.3 Regroupement des canaux du même indice dans chacune des deux classes

Itération	Segment	Segments par canal	Longueur segment				
			1	2	3	...	2560
1	1	Canal 4 (CZ-PZ)	Segment_1: 3.69x10 <sup>-5</sup>	3.85x10 <sup>-5</sup>	4.00x10 <sup>-5</sup>	...	2.56x10 <sup>-5</sup>
	2	Canal 3 (C4-P4)	Segment_1: -5.27x10 <sup>-6</sup>	-3.32x10 <sup>-6</sup>	-6.06x10 <sup>-6</sup>	...	-3.61x10 <sup>-5</sup>
	3	Canal 9 (FP1-F3)	Segment_1: -7.52x10 <sup>-5</sup>	-6.23x10 <sup>-5</sup>	-4.32x10 <sup>-5</sup>	...	1.86x10 <sup>-5</sup>
	4	Canal 14 (FZ-CZ)	Segment_1: -7.62x10 <sup>-6</sup>	-7.62x10 <sup>-6</sup>	5.27x10 <sup>-6</sup>	...	4.20x10 <sup>-5</sup>
2	5	Canal 4 (CZ-PZ)	Segment_2: 3.38x10 <sup>-5</sup>	3.07x10 <sup>-5</sup>	2.91x10 <sup>-5</sup>	...	1.31x10 <sup>-5</sup>
	6	Canal 3 (C4-P4)	Segment_2: 1.04x10 <sup>-5</sup>	1.07x10 <sup>-5</sup>	1.07x10 <sup>-5</sup>	...	-4.49x10 <sup>-6</sup>
	7	Canal 9 (FP1-F3)	Segment_2: 1.82x10 <sup>-5</sup>	2.64x10 <sup>-5</sup>	-3.07x10 <sup>-5</sup>	...	-9.47x10 <sup>-5</sup>
	8	Canal 14 (FZ-CZ)	Segment_2: 2.21x10 <sup>-5</sup>	1.50x10 <sup>-5</sup>	1.31x10 <sup>-5</sup>	...	4.94x10 <sup>-5</sup>
...	...	...	...	...	...	...	...
	...	...	...	...	...	...	...
	...	...	...	...	...	...	...
409	1633	Canal 4 (CZ-PZ)	Segment_409: 9.57x10 <sup>-6</sup>	1.11x10 <sup>-5</sup>	1.04x10 <sup>-5</sup>	...	4.88x10 <sup>-6</sup>
	1634	Canal 3 (C4-P4)	Segment_409: 5.26x10 <sup>-5</sup>	4.04x10 <sup>-5</sup>	5.06x10 <sup>-5</sup>	...	1.15x10 <sup>-5</sup>
	1635	Canal 9 (FP1-F3)	Segment_409: 4.75x10 <sup>-5</sup>	5.57x10 <sup>-5</sup>	5.84x10 <sup>-5</sup>	...	-1.04x10 <sup>-5</sup>
	1636	Canal 14 (FZ-CZ)	Segment_409: -3.71x10 <sup>-6</sup>	-5.27x10 <sup>-6</sup>	-8.40x10 <sup>-6</sup>	...	-9.96x10 <sup>-6</sup>

### 3. Calcul des caractéristiques pour les 1636 segments

Après la deuxième étape, tous les segments monocanaux passent par les méthodes d'extraction des caractéristiques afin de produire les vecteurs de caractéristiques qui seront utilisés pour l'entraînement et le test du modèle. Pour chacune des deux classes, le premier segment multicanal EEG correspond donc aux quatre premiers vecteurs (de 1 à 4), le deuxième correspond aux quatre vecteurs suivants (de 5 à 8), et ainsi de suite, jusqu'au dernier segment multicanal EEG qui correspond aux quatre derniers vecteurs (de 1633 à 1636), comme le montre le tableau 4.4 suivant.

Tableau 4.4 Regroupement des caractéristiques SWT des quatre meilleurs canaux pour fusion

Segment EEG	Vecteurs de caractéristiques par segment monocanal		Valeurs des caractéristiques				
	Numéro	Nom	$X_{S_1}$	$X_{S_2}$	$X_{S_3}$	...	$X_{S_6}$
1	1	Canal 4 (CZ-PZ)	21.729	0.0035	0.0167	...	3.7135
	2	Canal 3 (C4-P4)	22.160	0.0036	0.0160	...	3.7177
	3	Canal 9 (FP1-F3)	22.683	0.0035	0.0150	...	3.6686
	4	Canal 14 (FZ-CZ)	23.248	0.0034	0.0137	...	3.5718
2	5	Canal 4 (CZ-PZ)	23.804	0.0033	0.0123	...	3.4331
	6	Canal 3 (C4-P4)	24.307	0.0032	0.0112	...	3.3007
	7	Canal 9 (FP1-F3)	24.732	0.0032	0.0104	...	3.1595
	8	Canal 14 (FZ-CZ)	25.074	0.0033	0.0099	...	3.0269
...	...	...	...	...	...	...	...
	...	...	...	...	...	...	...
	...	...	...	...	...	...	...
409	1633	Canal 4 (CZ-PZ)	13.200	0.4921	0.5497	...	1.6496
	1634	Canal 3 (C4-P4)	13.198	0.4921	0.5499	...	1.6496
	1635	Canal 9 (FP1-F3)	13.196	0.4921	0.5502	...	1.6497
	1636	Canal 14 (FZ-CZ)	13.194	0.4921	0.5505	...	1.6498

#### 4. Fusion des caractéristiques

Avant d'être appliqués à l'entraînement ou le test des classificateurs, les 4 vecteurs de caractéristiques issus d'un même segment multicanal (1 à 4, 5 à 8, 9 à 12, etc.) sont fusionnés ensemble pour produire un vecteur de caractéristiques plus grand (de taille  $4 \times 6 = 24$ ), comme le montre le tableau 4.5 suivant.

Tableau 4.5 Fusion (concaténation) des caractéristiques des meilleurs canaux

Itération	Vecteurs de Caractéristiques des meilleurs canaux			
	[1 ... 6	7 ... 12	13 ... 18	19 ... 24]
1	[1 ... 6] [Canal 4 : 21.729 ... 3.7135, Canal 3 : 22.160 ... 3.7177, Canal 9 : 22.683 ... 3.6686, Canal 14 : 23.248 ... 3.5718]	[1 ... 6]	[1 ... 6]	[1 ... 6]
2	[Canal 4 : 23.804 ... 3.4331, Canal 3 : 24.307 ... 3.3007, Canal 9 : 24.732 ... 3.1595, Canal 14 : 25.074 ... 3.0269]			
...	[Canal 4 : ... .. Canal 3 : ... .. Canal 9 : ... .. Canal 14 : ... .. ]			
409	[Canal 4 : 13.200 ... 1.6496, Canal 3 : 13.198 ... 1.6496, Canal 9 : 13.196 ... 1.6497, Canal 14 : 13.194 ... 1.6498]			

Dans ce cadre, un seul segment monocanal produit six caractéristiques. Comme 4 canaux transformés en 4 segments sont utilisés pour entraîner et tester le modèle, cela conduit à la production de 24 caractéristiques au total pour chaque segment multicanal EEG. Ces 24 caractéristiques, une fois traitées par les méthodes de réduction de dimensionnalité du projet, sont ensuite utilisées comme entrées pour entraîner le modèle, enrichissant ainsi l'information disponible pour la classification.

#### 4.1.1.6 Choix du meilleur canal EEG pour décrire toute la base dans le cas de l'implémentation matérielle

La dernière phase de cette section consiste à sélectionner le meilleur canal pour l'implémentation matérielle. À partir des résultats préliminaires, cela devrait être le 14<sup>ème</sup> canal puisqu'il est le plus performant dans le cadre de l'analyse logicielle. Toutefois, l'exactitude associée à ce canal a été obtenue avec la méthode d'estimation spectrale autorégressive et la transformée en ondelettes discrète, qui ne sont pas appliquées dans l'implémentation matérielle. Face à cela, un autre tri a été effectué parmi les 23 canaux, en se basant sur l'exactitude moyenne des cinq classificateurs du projet, l'ondelette stationnaire, sur les 818 segments de la base, tout en accordant une attention particulière à la performance des classificateurs spécifiques du système matériel, à savoir le réseau de

neurones (ANN) et les machines à vecteurs de support (SVM). La validation croisée a également été appliquée durant ce test. En comparaison avec la précédente sélection de canaux, le 9<sup>ème</sup> canal (FP1-F3) s'avère être le meilleur pour l'implémentation matérielle puisqu'en plus d'offrir les meilleures performances pour les classificateurs ANN et SVM comme le 4<sup>ème</sup> canal, il donne aussi d'excellente performance pour tout le reste des classificateurs du projet. Le résultat des meilleurs canaux pour l'ondelette SWT se trouve dans le tableau 4.6 suivant.

Tableau 4.6 Meilleurs canaux pour l'implémentation matérielle du projet

Numéro du Canal EGG	Nom du Canal EGG	Exactitudes des meilleures combinaisons par canal (%)					Exactitude Moyenne (%)	
		Extraction + Réduction + Classification : Exactitude						
1	FP1-F7	SWT	+	SRD	+	LDA	: 92.0538	98.1907
		SWT	+	ICA	+	KNN	: 99.8778	
		SWT	+	SRD	+	RF	: 99.8778	
		SWT	+	ICA	+	SVM	: 99.8778	
		SWT	+	SRD	+	ANN	: 99.2665	
4	CZ-PZ	SWT	+	SRD	+	LDA	: 90.5868	97.9951
		SWT	+	ICA	+	KNN	: 99.8778	
		SWT	+	PCA	+	RF	: 99.8778	
		SWT	+	PCA	+	SVM	: 100	
		SWT	+	PCA	+	ANN	: 99.6333	
9	FP1-F3	SWT	+	PCA	+	LDA	: 93.2763	98.533
		SWT	+	ICA	+	KNN	: 99.8778	
		SWT	+	SRD	+	RF	: 99.8778	
		SWT	+	SRD	+	SVM	: 99.8778	
		SWT	+	SRD	+	ANN	: 99.7555	
13	FT9-FT10	SWT	+	SRD	+	LDA	: 88.7531	97.5061
		SWT	+	ICA	+	KNN	: 99.6333	
		SWT	+	PCA	+	RF	: 99.8778	
		SWT	+	PCA	+	SVM	: 99.7555	
		SWT	+	PCA	+	ANN	: 99.511	

## **4.1.2 Prétraitement de la base de données de l'Université de Bonn : Choix des classes**

### 4.1.2.1 Formation de la classe non-épileptique

Comme indiqué dans le premier chapitre, les classes non-épileptiques A et B de la base de données de l'Université de Bonn ont été choisies et combinées pour former une seule classe non-épileptique, afin d'amener les modèles à différencier des données non-épileptiques des données épileptiques. Ainsi, 50% des enregistrements EEG de la classe A (non-épileptiques yeux ouverts), 50% des enregistrements EEG de la classe B (non-épileptiques yeux fermés) et 100 % des enregistrements EEG de la classe E (épileptiques) de la base de données de l'Université de Bonn sont sélectionnés pour servir à l'entraînement et au test des modèles. Les deux classes non-épileptiques (A et B) forment à présent une seule classe AB qui contient 100 enregistrements et qui est utilisée avec tous les 100 autres enregistrements de la classe épileptique E pour prédire les patients malades de ceux qui ne le sont. Les paires de classes A et E, et B et E sont aussi utilisées dans la prédiction en logiciel à des fins de comparaison pour classer patients sains éveillés contre patients malades et patients sains endormis contre patients malades.

### 4.1.2.2 Fusion, rééchantillonnage et segmentation des données de la base de l'Université de Bonn

Au départ, les données de la base de l'Université de Bonn étaient segmentées en blocs de 4096 échantillons chacun. Afin de réaliser une analyse cohérente entre les deux bases de données utilisées dans le projet, il a été nécessaire d'adopter la même taille de fenêtre pour les deux, soit 2560 échantillons. Cela a impliqué trois étapes distinctes pour resegmenter les données de la base de l'Université de Bonn : premièrement, les enregistrements ou sous-ensembles de données ont été réunis pour former un enregistrement unifié des données de la base (la fusion). Ensuite, l'enregistrement unifié de la base de données de l'Université de Bonn a été rééchantillonné à la même fréquence de la base de données CHB-MIT, et enfin, les données rééchantillonnées ont été à nouveau

découpées en segments de 2560 échantillons, de manière équivalente à la base de données CHB-MIT. Les étapes du traitement se déroulent comme suit :

- Concaténation séquentielle par classe, où les segments de chaque classe sont fusionnés (concaténés) selon leur ordre d'origine de (1 à 100) pour ne former qu'un signal unique pour chaque classe.
- Rééchantillonnage du signal formé, où le facteur de rééchantillonnage ( $R = 256 \text{ Hz} / 173.61 \text{ Hz} = 1.47$ ).
- Avec la nouvelle fréquence d'échantillonnage, la durée du segment n'est plus 4097 mais  $4097 \times 1.47 = 6022$ . Le signal concaténé de chaque classe est ensuite découpé à nouveau selon la taille de fenêtre définie dans le projet, à savoir 2560 échantillons. Ainsi, la segmentation a généré alors 235 segments par classe, soit 470 segments au total pour les deux classes. Ce nombre est obtenu selon les données précédentes :  $100 \times 4097 \times 1.47 / 2560 = 235$ .

#### 4.1.2.3 Filtrage et normalisation des signaux EEG de la base de données de l'Université de Bonn

La différence de bande passante utile pour capturer les informations pertinentes des signaux cérébraux pour les deux bases utilisées ont favorisé l'utilisation de deux filtres pour filtrer séparément les bases, malgré que la fréquence utilisée est la même pour les deux bases de données. Ainsi, pour implémenter le filtre approprié à la base de données de l'Université de Bonn, les données EEG obtenues des classes AB et E sont passées par un filtre IIR passe-bande de Butterworth de fréquences de coupure de 0.5 Hz et 40 Hz, d'ordre 9 afin de nettoyer les signaux EEG des artéfacts qu'ils peuvent contenir. Ce filtre est aussi construit à l'aide de l'outil filterDesigner de l'environnement de Matlab. Puis la normalisation z-score est appliquée sur les signaux EEG filtrés comme pour la base de données CHB-MIT.

## 4.2 EXTRACTION DES CARACTÉRISTIQUES ET RÉDUCTION DE DIMENSIONNALITÉ

Les données prétraitées des deux bases de données (CHB-MIT et Université de Bonn) ont été soumises aux différentes méthodes d'extraction des caractéristiques précitées dans le second chapitre, puis combinées avec PCA et ICA, afin de produire les vecteurs de caractéristiques réduits  $X_r$ , qui seront utilisés comme entrées des classificateurs du projet. L'idée de comparer les performances des classificateurs avec et sans réduction de dimension (SRD) permet de mesurer l'impact réel des techniques de réduction de dimension (RD) sur la qualité des caractéristiques extraites. En appliquant directement les caractéristiques du signal EEG aux classificateurs sans passer par la RD, l'intégrité des caractéristiques originales extraites est préservée. Cela permet de vérifier si les méthodes de RD apportent une véritable valeur ajoutée ou si elles compliquent inutilement le traitement sans améliorer les résultats.

Pour les méthodes basées sur les ondelettes, la variance est utilisée pour extraire les caractéristiques pertinentes à partir des cinq niveaux de détails et de la dernière approximation, en utilisant l'ondelette Daubechies 4 (db4). Alors que pour le modèle autorégressif (AR) de Burg, ce sont les six premiers coefficients du polynôme qui sont retenus comme caractéristiques pertinentes du signal EEG.

Après l'extraction des caractéristiques et leur traitement par les méthodes de réduction de dimension, les caractéristiques réduites sont ensuite fournies aux cinq classificateurs utilisés dans ce projet pour leur apprentissage.

## 4.3 CLASSIFICATION DES SIGNAUX EEG : DÉTECTION DE LA CRISE

Une fois les caractéristiques réduites, elles sont ensuite appliquées simultanément aux différents classificateurs du projet, à savoir : à l'analyse en composantes principales (LDA), au k-plus proche voisin (KNN), à la forêt aléatoire (RF), aux machines à vecteurs de supports (SVM) et au réseau de neurone (ANN).

La classification constitue la dernière étape du processus de détection et s'effectue généralement en deux grandes phases principales : l'entraînement du modèle et les tests

pour vérifier son apprentissage. Au cours de cette phase finale, la validation croisée est utilisée pour renforcer la fiabilité du modèle et améliorer sa capacité à généraliser efficacement sur des données non vues.

#### **4.3.1 Validation croisée**

La validation croisée est une technique utilisée pour évaluer les performances d'un modèle d'apprentissage automatique surtout lorsque la base de données est de petite taille. Cette technique consiste à scinder un ensemble de données en plusieurs sous-ensemble de données ou « folds » de manière à utiliser une portion pour l'entraînement et une portion pour le test. Voici les étapes typiques d'une validation croisée :

1. Division des données : L'ensemble de données est divisé en plusieurs parties de taille égale (par exemple 5 folds).
2. Entraînement et test : Pour tester un sous-ensemble de données ou fold, le modèle est entraîné sur tous les autres folds restants comme montré à la figure 4.3. Cette opération est répétée  $k$  fois pour tester tous les folds. À chaque itération ou séquence, un fold est mis de côté pour le test (couleur orange) et les quatre autres sont utilisés pour l'entraînement du modèle (couleur bleu). Cela permet de s'assurer que le modèle est évalué sur les données qu'il n'a pas vu lors de l'entraînement en parcourant également toute la base de données.
3. Calcul de la performance : Les performances du modèle choisies (comme l'exactitude, la précision, etc.) sont ensuite moyennées sur tous les folds pour obtenir une évaluation globale. De cette manière, il est possible de minimiser le surajustement ou le sous-ajustement du modèle à partir de l'estimation complète des performances globales obtenue pour le modèle.

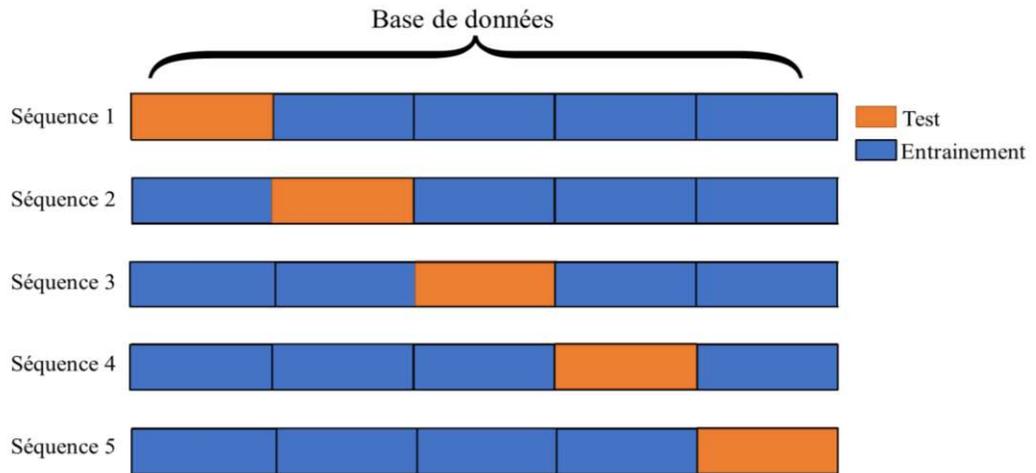


Figure 4.3 Schéma illustrant la validation croisée k-Fold avec k=5

#### 4.3.2 Composition des différents modèles de classification

Cinq algorithmes ou modèles différents de classification sont utilisés pour détecter la crise d'épilepsie. D'abord analyse discriminante linéaire (LDA), la méthode de K-plus proches voisins (KNN) dont le nombre de voisin k choisi est 1, puisqu'il a donné de meilleure performance que d'autre nombre de voisins tels que 3, 5 ou 7, la forêt aléatoire (RF) où le nombre d'arbres de la forêt est 100, la machine à vecteurs de support SVM utilisant un noyau gaussien et enfin un réseau de neurone multicouche (MLP), ayant une seule couche cachée à 10 neurones, sont utilisés dans l'implémentation logicielle du projet.

Une fois que les caractéristiques extraites des signaux EEG sont fournies aux classificateurs, une série de processus d'entraînement et de test rentre en jeu afin d'évaluer toutes les combinaisons possibles qu'on peut construire avec les cinq classificateurs (soit  $45 = 3 \times 3 \times 5$ ) comme illustré à la figure 4.4. Un tableau général retraçant toutes les combinaisons et un tableau sélectif représentant uniquement les meilleures combinaisons obtenues avec chacun des cinq classificateurs du projet sont créés. Les meilleures combinaisons (extraction, réduction et classification) sont obtenues par un tri se basant sur la performance de chaque classificateur. Donc, pour chacun des classificateurs, les

combinaisons générant l'exactitude la plus élevée est choisie. Cela est réalisé pour les deux bases de données, car il y a de forte chance que celles-ci ne permettent pas la sélection des mêmes combinaisons parmi tant de choix possibles. Puis les meilleures combinaisons implémentables sur puce FPGA obtenues pour ANN et SVM sont sauvegardées pour l'implémentation matérielle de la crise.

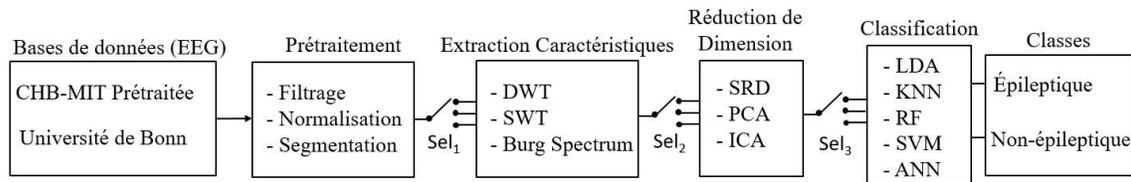


Figure 4.4 Diagramme bloc décrivant les 45 systèmes évalués individuellement pour la détection de la crise épileptique

#### 4.4 RÉSULTATS DES DIFFÉRENTES COMBINAISONS D'ALGORITHMES DE DÉTECTION DE CRISES D'ÉPILEPSIE

Dans la suite, sont présentées les meilleures sélections obtenues pour les différentes combinaisons réalisées par l'environnement logiciel, pour chacune des bases de données utilisées.

Toutes les métriques de performance présentées dans le troisième chapitre ne sont pas présentées ici ; seules la matrice de confusion et l'exactitude qui sont prises en compte. Il est possible de calculer les autres métriques comme la précision et le rappel en utilisant les formules appropriées du chapitre 3.

Pour la base de données de l'Université de Bonn, les classes concernées par cette analyse sont les classes combinées AB et E ; la classe A et la classe B sont aussi analysées séparément afin de les comparer contre le résultat de la classe combinée AB. Des commentaires sur ces résultats s'ensuivront dans la section réservée à discussions pour le quatrième chapitre.

Pour ce premier test, les classificateurs sont analysés séparément, c'est-à-dire qu'ils sont évalués sur des ensembles de données distincts pour l'entraînement et pour le test.

#### 4.4.1 Classification à l'aide la base de données CHB-MIT

Tableau 4.7 Matrice de confusion des meilleures combinaisons trouvées avec la base de données CHB-MIT pour les cinq classificateurs du projet, nombre de canaux : 4 (4, 3, 9, 14), nombre de segments testés par classe : 409, validation croisée (5-folds)

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 406	FN: 3
	Épileptique	FP: 1	TP: 408

Combinaison de : AR Burg + PCA + LDA  
Exactitude : 99.511 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 407	FN: 2
	Épileptique	FP: 2	TP: 407

Combinaison de : SWT + PCA+ KNN  
Exactitude : 99.511 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 409	FN: 0
	Épileptique	FP: 2	TP: 407

Combinaison de : AR Burg + PCA + RF  
Exactitude : 99.7555 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 404	FN: 5
	Épileptique	FP: 0	TP: 409

Combinaison de : SWT + SRD + SVM  
Exactitude : 99.3888 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 409	FN: 0
	Épileptique	FP: 0	TP: 409

Combinaison de : SWT+ SRD +ANN  
Exactitude : 100 %

#### 4.4.2 Classification à l'aide la base de données de l'Université de Bonn : AB vs E

Tableau 4.8 Matrice de confusion des meilleures combinaisons trouvées avec les classes AB et E de la base de données de l'Université de Bonn pour les cinq classificateurs du projet, nombre de segments testés par classe : 235, validation croisée (5-folds)

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 157	FN: 78
	Épileptique	FP: 0	TP: 235

Combinaison de : AR Burg + SRD + LDA  
Exactitude : 83.4043 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 235	FN: 0
	Épileptique	FP: 0	TP: 235

Combinaison de : AR Burg + PCA + KNN  
Exactitude : 100 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 234	FN: 1
	Épileptique	FP: 0	TP: 235

Combinaison de : DWT+ SRD + RF  
Exactitude : 99.7872 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 235	FN: 0
	Épileptique	FP: 2	TP: 233

Combinaison de : DWT+ ICA + SVM  
Exactitude : 99.5745 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 235	FN: 0
	Épileptique	FP: 0	TP: 235

Combinaison de : SWT+ SRD +ANN  
Exactitude : 100 %

#### 4.4.3 Classification à l'aide la base de données de l'Université de Bonn : A vs E

Tableau 4.9 Matrice de confusion des meilleures combinaisons trouvées avec les classes A et E de la base de données de l'Université de Bonn pour les cinq classificateurs du projet, nombre de segments testés par classe : 235, validation croisée (5-folds)

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 177	FN: 58
	Épileptique	FP: 5	TP: 230

Combinaison de : DWT+ ICA + LDA  
Exactitude : 86.5957 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 235	FN: 0
	Épileptique	FP: 0	TP: 235

Combinaison de : SWT + ICA + KNN  
Exactitude : 100 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 235	FN: 0
	Épileptique	FP: 0	TP: 235

Combinaison de : SWT+ SRD+ RF  
Exactitude : 100 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 235	FN: 0
	Épileptique	FP: 1	TP: 234

Combinaison de : Ar Burg + ICA + SVM  
Exactitude : 99.7872 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 234	FN: 1
	Épileptique	FP: 0	TP: 235

Combinaison de : DWT+ PCA +ANN  
Exactitude : 99.7872 %

#### 4.4.4 Classification à l'aide la base de données de l'Université de Bonn : B vs E

Tableau 4.10 Matrice de confusion des meilleures combinaisons trouvées avec les classes B et E de la base de l'Université de Bonn pour les cinq classificateurs du projet, nombre de segments testés par classe : 235, validation croisée (5-folds)

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 235	FN: 0
	Épileptique	FP: 40	TP: 195

Combinaison de : SWT+ SRD + LDA  
Exactitude : 91.4894 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 235	FN: 0
	Épileptique	FP: 0	TP: 235

Combinaison de : DWT+ PCA + KNN  
Exactitude : 100 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 235	FN: 0
	Épileptique	FP: 1	TP: 234

Combinaison de : Ar Burg + PCA + RF  
Exactitude : 99.7872 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 235	FN: 0
	Épileptique	FP: 2	TP: 233

Combinaison de : Ar Burg + PCA + SVM  
Exactitude : 99.5745 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 235	FN: 0
	Épileptique	FP: 0	TP: 235

Combinaison de : Ar Burg + SRD +ANN  
Exactitude : 100 %

## 4.5 ENSEMBLE D'APPRENTISSAGE

L'ensemble d'apprentissage est formé de 5 meilleurs modèles de classification. La décision de l'ensemble est obtenue par le vote de majorité, comme illustré à la figure 4.5.

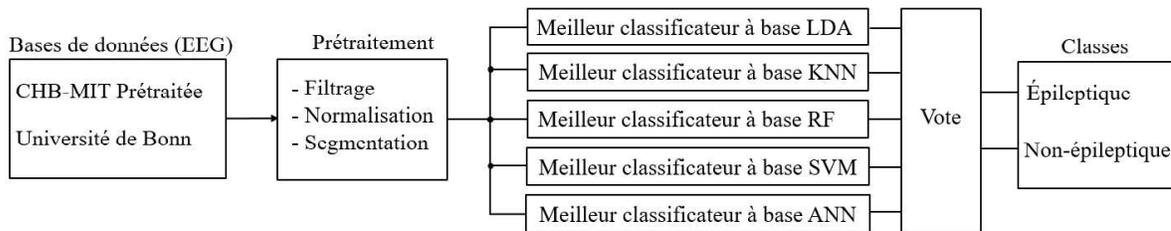


Figure 4.5 Vote de majorité appliqué sur les cinq classificateurs du projet

Bien que les entrées caractéristiques de chaque classificateur soient souvent différentes les unes des autres (figure 4.5), la prédiction collective n'est pas pour autant difficile à réaliser. Comme la validation croisée est aussi utilisée pour le vote de majorité, nous nous sommes assurés que les cinq systèmes apprennent, à chaque étape, avec les mêmes données d'entraînement et testent les mêmes données de test. Autrement dit, les cinq systèmes votent simultanément pour le  $i^{\text{ème}}$  segment de façon itérative pour couvrir tous les segments de l'ensemble de test. Une matrice de confusion est générée à partir du résultat du vote de majorité, permettant ensuite de calculer l'exactitude moyenne de la validation croisée.

Que les modèles aient bien appris ou non, qu'ils aient pris la bonne décision ou non, l'étiquette (classe) définitive, considérée comme correcte par le système, sera celle prédite par la majorité des classificateurs, c'est-à-dire par au moins trois d'entre eux, même ils ont tort. Ce n'est donc pas l'étiquette d'un seul classificateur qui sera retenue, même si ce classificateur à raison. Cela renforce la nécessité de s'assurer que les données sont bien prétraitées et les algorithmes bien réglés de façon à garantir une bonne performance des modèles.

Puisque le vote est souvent utilisé pour améliorer la prédiction de plusieurs modèles qui ont des problèmes de sous apprentissage, par conséquent, il peut s'avérer non nécessaire si tous les classificateurs donnent une exactitude de 100% ou proche. Mais pour des

classificateurs donnant des pourcentages de réussite supérieurs à 50 % et inférieurs à 95%, il peut s'avérer très utile.

Toutefois, ce projet vérifie l'utilité du vote majoritaire quant à sa fiabilité pour la prédiction efficace de la crise. Puisqu'un médecin devra faire confiance à un algorithme qui l'aidera à prendre une décision éclairée, l'idée est qu'au lieu que cette tâche délicate et de la plus haute importance soit confiée à un seul modèle d'apprentissage machine, elle est confiée à plusieurs. De plus, puisque ces outils (les algorithmes) doivent être précis dans leur analyse en tant qu'experts, il convient alors d'entraîner les différents modèles de classification suivant différentes règles afin de les diversifier. D'où l'importance de la combinaison des différentes techniques de détection de crise (technique d'extraction des caractéristiques, technique de réduction de dimension et technique de classification) et de la sélection des meilleurs triplets produits par le système pour déceler la crise.

De cette manière, et dans le cas où un expert-machine ferait une mauvaise prédiction au sujet d'un quelconque patient, quatre autres experts sont là pour l'aider et compenser sa performance, puisqu'ils n'abordent pas le problème de la même façon, ce qui augmente la fiabilité de la prédiction. D'où l'importance du vote de majorité. Les résultats de cette approche pour chaque base de données seront présentés et commentés dans les lignes suivantes.

#### **4.5.1 Résultats comparatifs du vote majoritaire pour l'ensemble des classificateurs LDA, KNN, RF, SVM et ANN**

Pour comparer les deux bases de données du projet, et étant donné que la base de données de l'Université de Bonn contient moins de segments par classe que la base de données CHB-MIT, seulement 235 segments par classe ont été retenus pour les deux bases de données, afin de tester la robustesse des meilleurs algorithmes de classification du projet à l'aide du vote majoritaire. Lors du vote, la validation croisée a été appliquée de manière à valider toute la base de données de 470 segments et de faire en sorte que les résultats obtenus reflètent la performance réelle des modèles. Pour chacune des bases de données utilisées, les

résultats sont présentés sous forme de matrice de confusion avec l'exactitude déjà calculée comme le montre le tableau 4.11 ci-dessous.

#### 4.5.1.1 Résultats du vote majoritaire pour les cinq classificateurs LDA, KNN, RF, SVM et ANN avec la base de données CHB-MIT

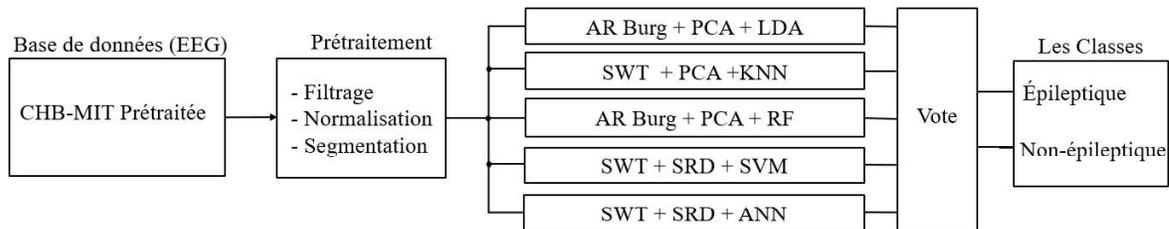


Figure 4.6 Vote de majorité appliqué sur la base de données CHB-MIT

Tableau 4.11 Matrice de confusion des prédictions de chacun des 5 meilleurs classificateurs avec la base de données CHB-MIT, nombre de canaux : 4 (4, 3, 9, 14), nombre de segments testés par classe : 235, validation croisée (5-folds)

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 232	FN: 3
	Épileptique	FP: 1	TP: 234

Combinaison de : AR Burg + PCA + LDA  
Exactitude : 99.1489 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 233	FN: 2
	Épileptique	FP: 2	TP: 233

Combinaison de : SWT+ PCA + KNN  
Exactitude : 99.1489 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 233	FN: 2
	Épileptique	FP: 1	TP: 234

Combinaison de : AR Burg + PCA + RF  
Exactitude : 99.3617 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 235	FN: 0
	Épileptique	FP: 1	TP: 234

Combinaison de : SWT + SRD+ SVM  
Exactitude : 98.7872 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 233	FN: 2
	Épileptique	FP: 0	TP: 235

Combinaison de : SWT+ SRD +ANN  
Exactitude : 99.5745 %

Tableau 4.12 Matrice de confusion du vote de majorité pour la base de données CHB-MIT

		a) Avec LDA, KNN, RF, SVM, ANN		b) Avec KNN, SVM, ANN	
		Classe réelle		Classe réelle	
		Non-épileptique	Épileptique	Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 235	FN: 0	TN: 235	FN: 0
	Épileptique	FP: 0	TP: 235	FP: 0	TP: 235
		Exactitude : 100 %		Exactitude : 100 %	

Pour la base de données CHB-MIT, l'exactitude obtenue pour le vote de majorité est de 100% avec les cinq classificateurs du projet (tableau 4.12a); cependant, une telle performance peut aussi être atteinte avec uniquement 3 classificateurs (tableau 4.12b). Comparativement à la prédiction de chacun des classificateurs pour le vote de majorité: LDA : 99.1489%, KNN : 99.1489%, RF : 99.3617%, SVM : 99.7872% et ANN : 99.5745% (voir tableau 4.11), il semble que le vote de majorité a prouvé son efficacité dans l'amélioration de la performance (exactitude) et par la même occasion, la robustesse de la prédiction, car le vote de majorité était capable d'aller chercher une performance supérieure à la prédiction du meilleur classificateur tout en augmentant la fiabilité de la prédiction (grâce à l'utilisation de plusieurs prédictions au lieu d'une seule, celle de SVM).

#### 4.5.1.2 Résultats du vote majoritaire pour les cinq classificateurs LDA, KNN, RF, SVM et ANN avec la base de données de l'Université de Bonn (Classe AB et E)

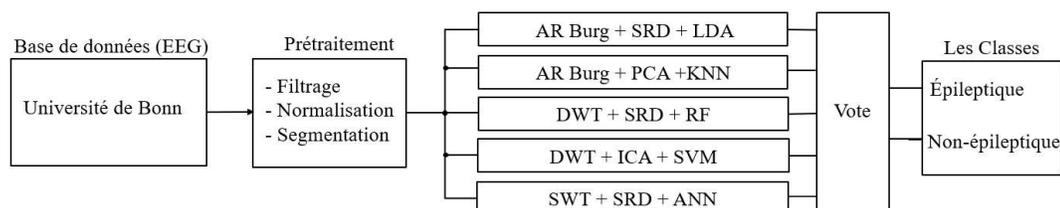


Figure 4.7 Vote de majorité appliqué sur la base de données de l'Université de Bonn

Tableau 4.13 Matrice de confusion des prédictions de chacun des 5 meilleurs classificateurs avec la base de données de l'Université de Bonn (Classe AB et E), nombre de segments testés par classe : 235, validation croisée (5-folds)

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 155	FN: 80
	Épileptique	FP: 0	TP: 235

Combinaison de : AR Burg + SRD + LDA  
Exactitude : 82.9787 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 234	FN: 1
	Épileptique	FP: 1	TP: 234

Combinaison de : AR Burg + PCA + KNN  
Exactitude : 99.5745 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 231	FN: 4
	Épileptique	FP: 0	TP: 235

Combinaison de : DWT+ SRD + RF  
Exactitude : 99.1489 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 233	FN: 2
	Épileptique	FP: 3	TP: 232

Combinaison de : DWT+ ICA + SVM  
Exactitude : 98.9362 %

		Classe réelle	
		Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 234	FN: 1
	Épileptique	FP: 1	TP: 234

Combinaison de : SWT+ SRD + ANN  
Exactitude : 99.5745 %

Pour la base de données de l'Université de Bonn, l'exactitude obtenue pour le vote de majorité est de 99.3617% avec les cinq classificateurs du projet (tableau 4.14a); cependant, avec uniquement 3 classificateurs comme KNN, SVM et ANN, le vote de majorité passe à 99.7872% (tableau 4.14b). Comparativement à la prédiction de chacun des classificateurs pour le vote de majorité: LDA : 82.9787%, KNN : 99.5745%, RF : 99.1489%, SVM : 98.9362% et ANN : 99.5745% (voir tableau 4.13), il semble que le vote de majorité a prouvé son efficacité dans l'amélioration de la performance (exactitude) et par la même occasion, la robustesse de la prédiction, car le vote de majorité était capable d'aller chercher une performance supérieure à la prédiction des meilleurs classificateurs tout en augmentant la fiabilité de la prédiction (grâce à l'utilisation de plusieurs prédictions au lieu uniquement celle de KNN ou d'ANN).

Tableau 4.14 Matrice de confusion du vote de majorité pour la base de l'Université de Bonn

		a) Avec LDA, KNN, RF, SVM, ANN		b) Avec KNN, SVM, ANN	
		Classe réelle		Classe réelle	
		Non-épileptique	Épileptique	Non-épileptique	Épileptique
Prédiction	Non-épileptique	TN: 233	FN: 2	TN: 235	FN: 0
	Épileptique	FP: 1	TP: 234	FP: 1	TP: 234
		Exactitude : 99.3617 %		Exactitude : 99.7872 %	

## 4.6 DISCUSSIONS DES DIFFÉRENTS RÉSULTATS OBTENUS

### 4.6.1 Comparaison de l'exactitude moyenne obtenue pour la classification en logiciel des classes A vs E, B vs E et AB vs E pour la base de données de l'Université de Bonn

Les résultats de la classification des signaux EEG à l'aide des classes non-épileptiques AB, A et B, et la classe épileptique E sont présentés respectivement dans les tableaux 4.8, 4.9 et 4.10. Tous les résultats sont très satisfaisants. Contre toute attente, la classification en logiciel avec la classe combinée AB et la classe E a montré des performances légèrement inférieures que celle réalisée avec les classes A vs E et B vs E de la base de données de l'Université de Bonn. L'exactitude moyenne calculée avec les cinq classificateurs du projet pour toutes ces paires de classes s'est révélée être de 96.5532% pour la classification entre la classe combinée AB et la classe E, 97.2340% entre la classe A et la classe E, et 98.1702% entre la classe B et la classe E. Il semble que l'efficacité des algorithmes de classification n'est pas trop affectée par le fuseau de sommeil. Les écarts de performance les plus importants ont été observés avec le classificateur LDA, qui a obtenu 83.4043% pour la paire AB vs E, contre 86.5957% pour A vs E et 91.4894% pour B vs E. Cela met en évidence l'importance d'un bon prétraitement des données et d'un bon réglage des outils utilisés. Cependant, si la quantité de données change, d'autres réglages peuvent s'avérer nécessaires pour garantir la continuité de performance de la classe combinée AB, comparativement aux classes non-épileptiques.

#### 4.6.2 Décision par vote à la majorité

Dans le cadre de ce projet, l'utilisation d'un ensemble de classificateurs et la prise de décision par vote majoritaire se sont révélés être un atout majeur pour renforcer la robustesse des prédictions. Selon les résultats présentés dans les tableaux 4.11 et 4.13, l'exactitude moyenne des cinq classificateurs du projet est de 98.8042% pour la base de données CHB-MIT et de 96.0425% pour la base de données de l'Université de Bonn. Presque tous les modèles ont montré d'excellentes performances sur les deux bases de données utilisées. Cependant, bien qu'aucun classificateur n'ait pu obtenir une performance de 100%, le vote de majorité a fait preuve de grande fiabilité, en permettant d'obtenir des performances supérieures à celles des meilleurs classificateurs individuels, tout en incluant la prédiction de plusieurs modèles au lieu d'un seul. Cette approche a renforcé la robustesse de la prédiction de la crise d'épilepsie pour les deux bases de données (voir tableaux 4.12a, 4.12b et 4.14b).

De plus, parmi tous les classificateurs du projet, il semble que les meilleurs classificateurs à utiliser pour la prédiction par vote majoritaire sont les K plus proches voisins (KNN), les machines à vecteurs de support (SVM) et enfin le réseau de neurones (ANN), car la prédiction par vote majoritaire à l'aide de ces derniers a été très satisfaisante (voir tableaux 4.12 et 4.14). Toutefois, dépendamment du traitement appliqué, il se peut que ces résultats changent.

Comme mentionné au début de la section sur l'ensemble d'apprentissage, le vote n'est pas nécessairement synonyme de meilleure classification. Il peut améliorer la classification comme il peut la dégrader, et le nombre de classificateurs utilisés a un impact direct et significatif sur le résultat final. Au lieu d'utiliser un grand nombre de classificateurs de diverses performances (tableaux 4.12a et 4.14a), il est préférable d'utiliser un nombre réduit de classificateurs performants (comme 3 par exemple, tableaux 4.12b et 4.14b), afin de s'assurer que la prédiction ne sera pas affectée par le nombre excessif de classificateurs (tableau 4.14a), mais qu'elle soit plutôt robuste, fiable et précise, comme le montre le tableau 4.14b.

## **CHAPITRE 5**

### **IMPLÉMENTATION MATÉRIELLE SUR CIRCUIT FPGA**

Dans ce chapitre est présentée l'implémentation matérielle des systèmes de détection de la crise d'épilepsie ainsi que les performances obtenues pour les deux bases de données utilisées. Cette partie présente également la comparaison des performances des implémentations logicielle (Matlab) et matérielle (XSG) pour les différentes bases de données et les algorithmes de classification SVM et MLP. La robustesse et l'efficacité des systèmes de détection sont aussi commentées à la fin aussi bien que les pistes d'optimisation de ce dernier.

#### **5.1 PLATEFORME DE DÉVELOPPEMENT DU SYSTÈME MATÉRIEL ET PUCE UTILISÉE**

Dans cette section, sont présentées la plateforme sur laquelle est construite l'architecture du système matériel, ainsi que la puce FPGA utilisée pour tester le fonctionnement de cette architecture, à savoir : l'outil de programmation Xilinx System Generator (XSG) et la carte de développement Nexys-4, munie d'une puce FPGA Artix-7.

##### **5.1.1 Xilinx System Generator (XSG)**

L'outil de programmation Xilinx System Generator (XSG) est une extension de l'environnement Matlab/Simulink qui permet de concevoir des systèmes numériques destinés aux circuits FPGA de AMD/Xilinx, en utilisant un ensemble de blocs graphiques tels que les blocs d'addition et de soustraction (AddSub), de multiplication (Mult ou CMult), de comparaison (Relational), etc. Une fois le diagramme du design achevé, il peut être simulé et vérifié dans l'environnement Matlab/Simulink, puis transféré sous forme d'un module préconçu (IP) pour des projets Vivado ou exécuté sur un circuit FPGA grâce à la cosimulation matériel (JTAG). L'outil XSG fournit deux grands outils clés : des blocs pour construire le

modèle et un générateur du modèle matériel en langage HDL. Le principal défi avec l'outil XSG est l'agencement et la configuration des blocs, lors de la conception du modèle.

### 5.1.2 Circuit FPGA et carte de développement Nexys-4

De la définition anglaise « Field Programmable Gate Array », l'acronyme FPGA désigne un réseau de portes logiques programmables formé de circuits numériques reconfigurables permettant la réalisation de systèmes numériques très complexes. Un circuit FPGA est généralement constitué de blocs logiques programmables (CLB) reliés entre eux par des réseaux d'interconnexion configurables et entourés par des blocs d'entrée/sortie (IOB) pour communiquer avec l'extérieur. L'avantage de ce circuit, comparativement à un circuit DSP, est qu'il fait du traitement parallèle, ce qui augmente sa vitesse de traitement comparativement au circuit DSP qui fait du traitement séquentiel.

La carte de développement Nexys-4 est l'une des versions de faibles coûts des dispositifs logiques programmables, composée d'une puce FPGA (Artix-7 XC7A100T-CSG324), d'afficheurs et d'autres éléments périphériques. Ses différentes entrées/sorties sont illustrées à figure 5.1 ci-dessous et leurs rôles sont décrits dans tableau 5.1 ci-après.

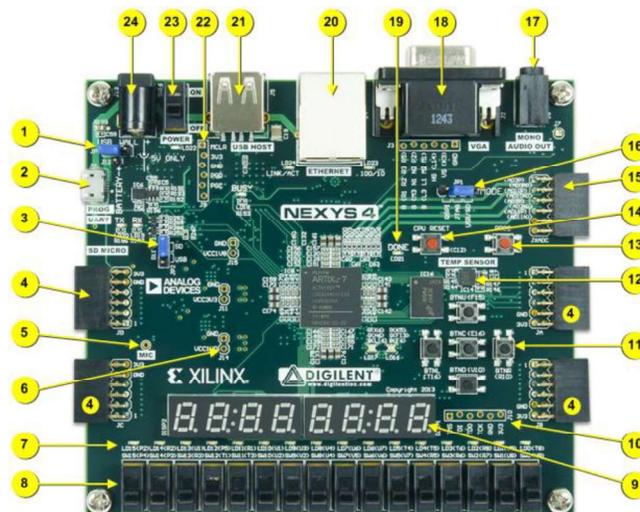


Figure 5.1 Architecture de la carte Nexys-4 (Diligent, 2024)

Tableau 5.1 Description des composants de la carte Nexys-4 (Diligent, 2024)

Description du composant		Description du composant	
1	Jumper de sélection d'alimentation	13	Bouton de réinitialisation de la carte FPGA
2	Port USB partagé UART/JTAG	14	Bouton de réinitialisation du processeur
3	Jumper de configuration externe (SD/USB)	15	Port Pmod à signal analogique (XADC)
4	Ports Pmod	16	Jumper mode de programmation
5	Microphone	17	Connecteur audio
6	Point d'essai alimentation électrique	18	Connecteur VGA
7	DEL	19	DEL de programmation FPGA
8	Interrupteurs à glissière	20	Connecteur Ethernet
9	Affichage à huit chiffres à 7 segments	21	Connecteur hôte USB
10	Port JTAG pour câble externe	22	Port de programmation PIC24 (utilisation usine)
11	Cinq boutons poussoirs	23	Interrupteur d'alimentation
12	Capteur de température	24	Prise d'alimentation

## 5.2 IMPLÉMENTATION MATÉRIELLE D'UN DÉTECTEUR DE CRISES ÉPILEPTIQUES

Le diagramme d'implémentation matérielle du système de détection de la crise d'épilepsie est présenté à la figure 5.2. Le signal EEG passe d'abord par le bloc « Transformée en ondelettes Stationnaire (SWT) » composé de filtres passe-haut et passe-bas qui décomposent le signal original en des coefficients de détails et d'approximation. Ensuite, par le bloc de « Sélection de vecteurs caractéristiques » qui calcule la variance de chaque sous-bande de décomposition afin d'envoyer les caractéristiques aux blocs de réduction de dimensionnalité (SRD). Enfin, au classificateur MLP pour la classification à l'aide du réseau de neurones et au bloc du classificateur SVM pour celle des machines à vecteurs de support.

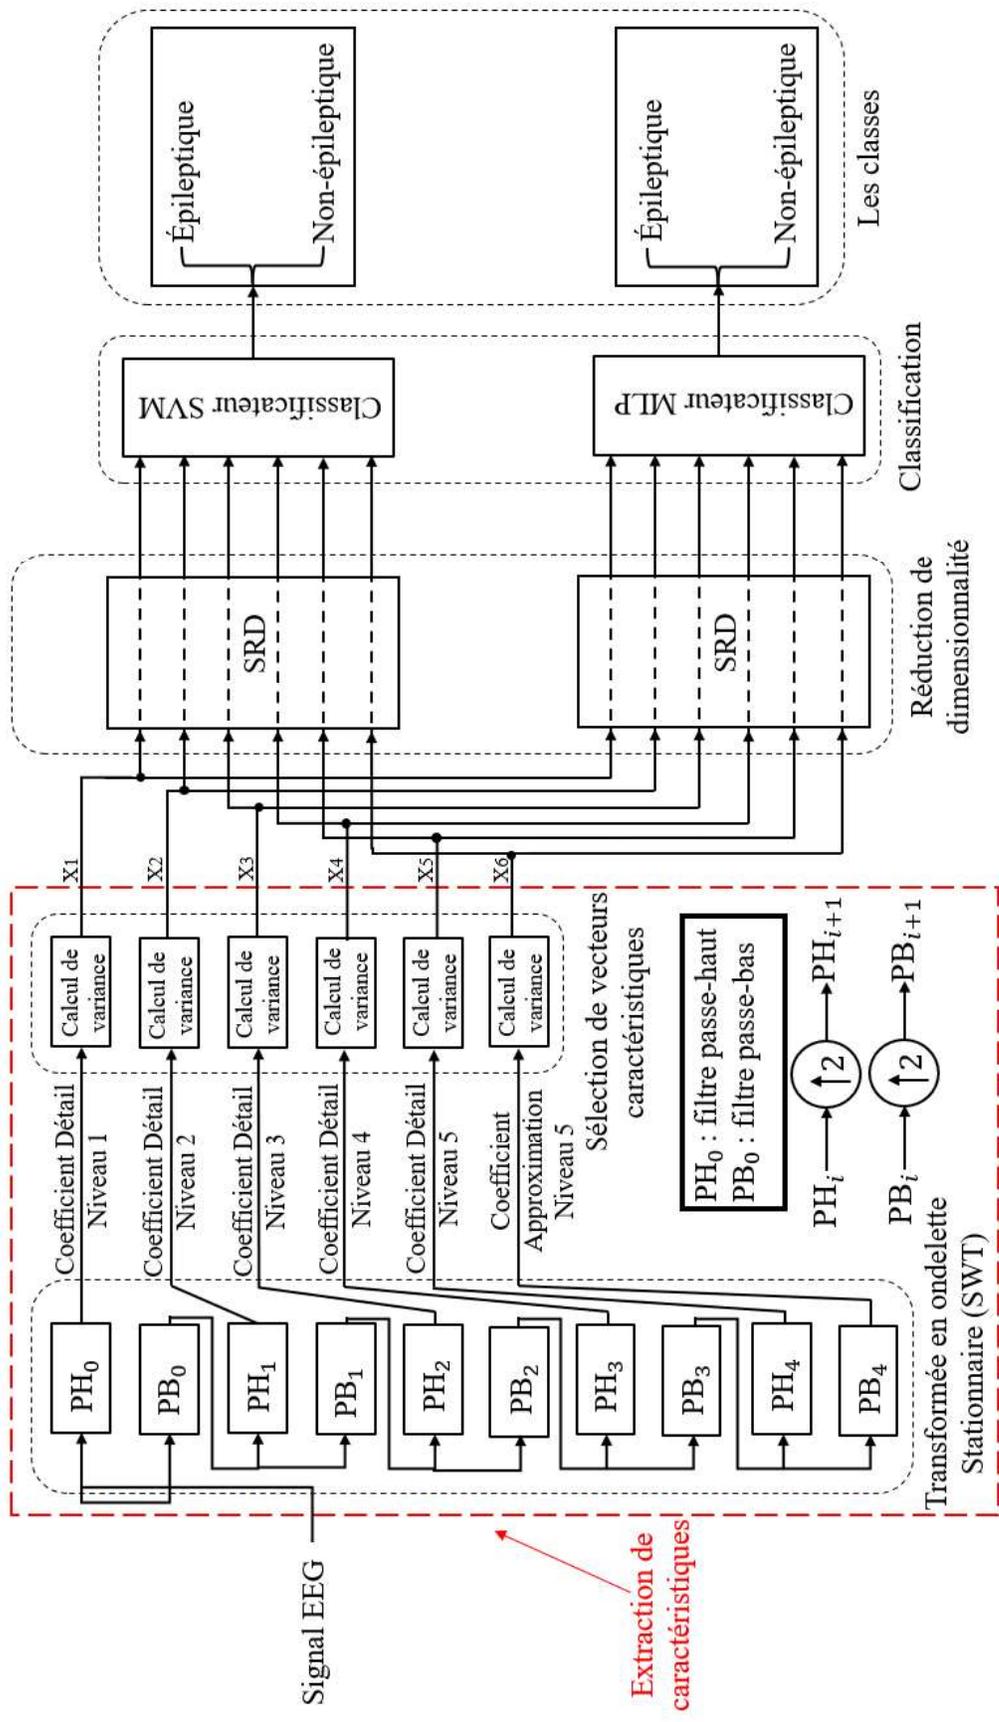


Figure 5.2 Diagramme d'implémentation matérielle des modèles de classification de la crise d'épilepsie

Les deux blocs SRD de la figure 5.2 n'interviennent pas sur les signaux, il est présenté à titre illustratif afin de compléter la chaîne de détection. D'ailleurs, ce terme a été utilisé lors de l'implémentation logicielle afin de vérifier les performances des classificateurs lorsqu'aucune méthode de réduction de dimension n'est utilisée. Et, il a été prouvé que les méthodes de réduction de dimensionnalité ne sont pas cruciales pour détecter l'épilepsie lorsque le nombre de caractéristiques est assez limité. Elles deviennent plus importantes lorsque le nombre des caractéristiques sont assez considérables, mais ce n'est pas le cas ici, puisqu'il n'y en a que six (6).

L'implémentation matérielle de l'algorithme de la détection matérielle fonctionne de la même façon que l'implémentation logicielle. La seule différence est que l'entraînement ne se fait pas dans l'environnement Xilinx System Generator (XSG) ; par conséquent, le modèle peut être entraîné par logiciel (avec Matlab) avant d'être implémenté sous Xilinx Système Generator (XSG). La figure 5.3 montre l'architecture du système proposé réalisé à l'aide des blocs Xilinx System Generator (XSG). Les différents composants des deux systèmes de détection de la crise d'épilepsie et leur fonctionnement sont détaillés dans la suite. Le premier est basé sur le classificateur SVM et le second sur le classificateur MLP.

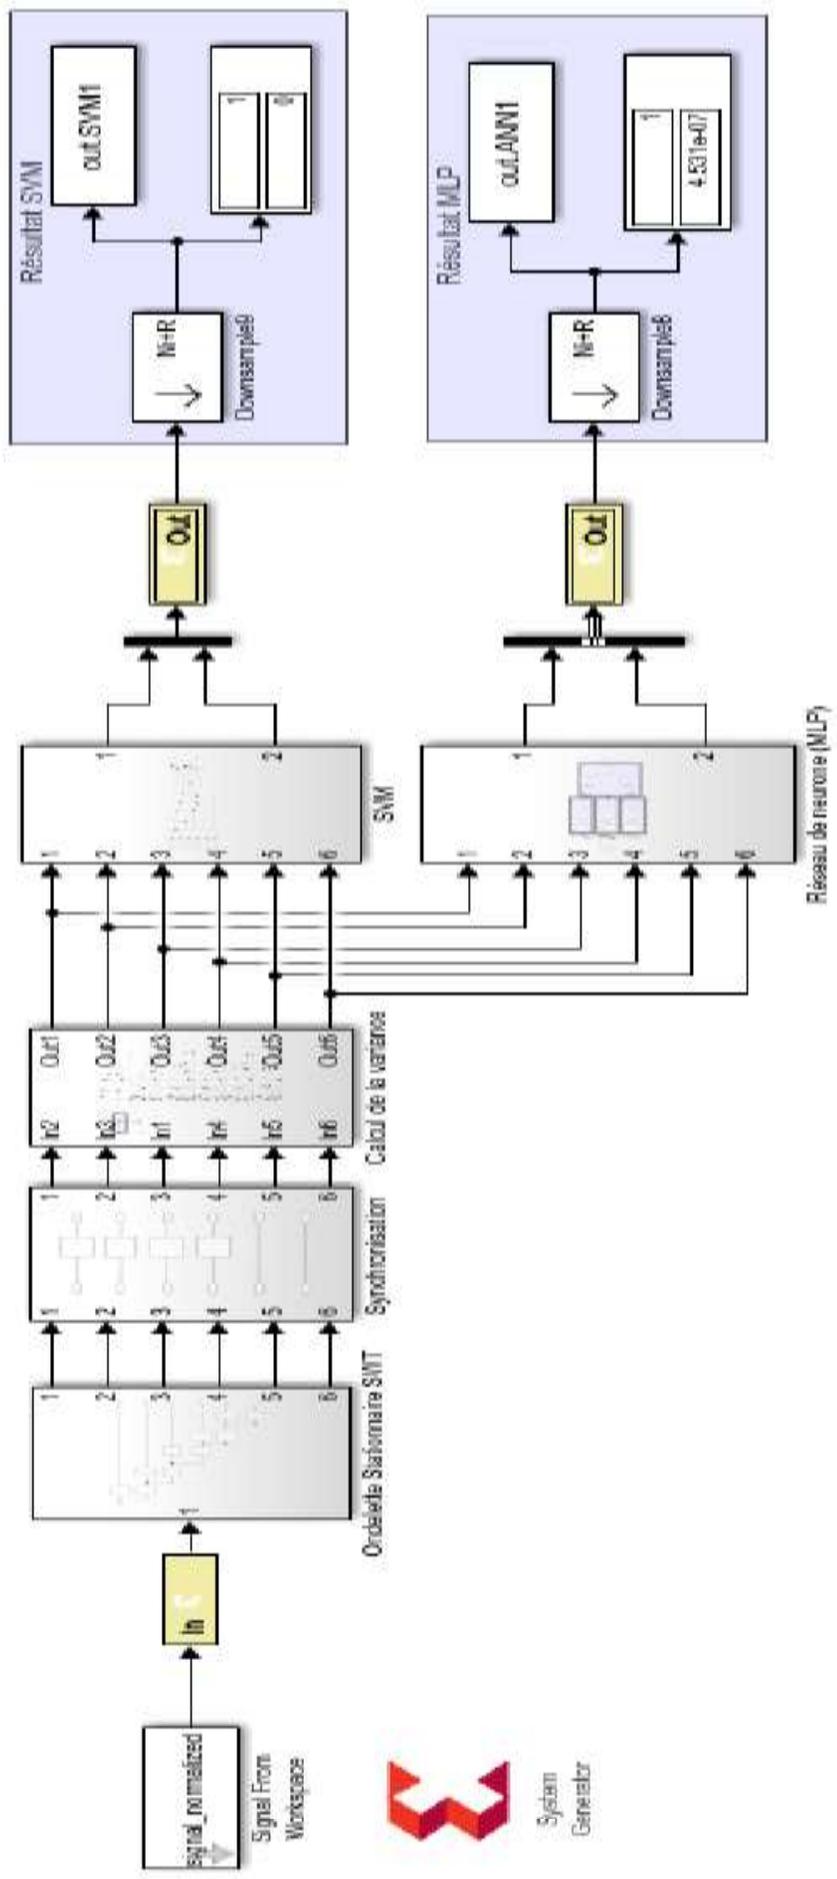


Figure 5.3 Implémentation matérielle de deux systèmes de détection de la crise d'épilepsie réalisée avec des blocs XSG. Le premier est basé sur le classificateur SVM et le second, sur le classificateur MLP

### 5.2.1 L'acquisition du signal EEG par les blocs XSG

Comme mentionné dans le quatrième chapitre de ce document, le signal EEG doit d'abord subir une étape de prétraitement avant de passer par les autres étapes de détection de la crise. Cette étape est réalisée par logiciel dans le cas de ce projet. Cela dit, les données EEG utilisées dans ce chapitre ont été prétraitées par MATLAB avant d'être appliquées aux différents blocs de Xilinx. Aussi, pour simuler le fonctionnement du système, des blocs XSG (en bleu, cachés pour l'instant à l'intérieur des blocs en gris dans la figure 5.3) sont utilisés pour modéliser l'architecture matérielle. Les blocs Simulink ordinaires (en blanc) permettent la lecture des données à partir des supports de stockage ainsi que la visualisation des résultats de traitement de chaque sous-système.

Ainsi, pour acquérir le signal EEG, l'architecture dispose du bloc Simulink « Signal From Workspace » qui permet de lire le signal prétraité à partir de l'espace de travail de Matlab. Le signal filtré et normalisé passe par le bloc de la passerelle d'entrée « Gateway In » dans lequel la fréquence d'échantillonnage et le format de quantification doivent être définis.

Le bloc « System Generator » permet de définir la fréquence de traitement (calcul) des blocs XSG, générer une cosimulation (JTAG), créer les modules IP pour projet Vivado, déterminer les ressources matérielles disponibles et utilisées sur la puce, et enfin sert de contrôleur pour les blocs XSG. La figure 5.4 ci-après présente les différents paramètres de configuration de ce bloc.

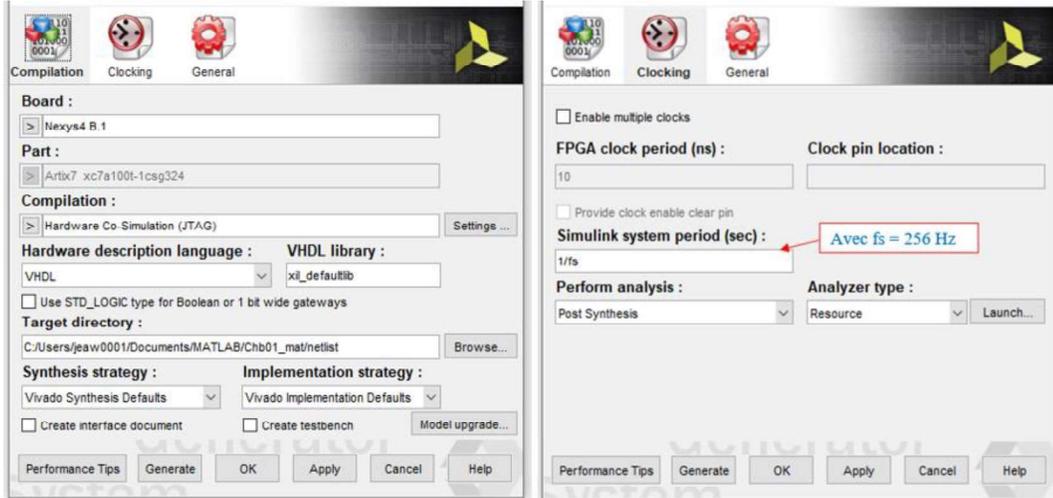


Figure 5.4 Fenêtres de configuration du bloc « System Generator »

### 5.2.2 Transformée en ondelette stationnaire (SWT)

La figure 5.5 représente l'implémentation matérielle de la transformée en ondelette stationnaire (SWT), telle que décrit par le diagramme de la figure 2.3 du présent document.

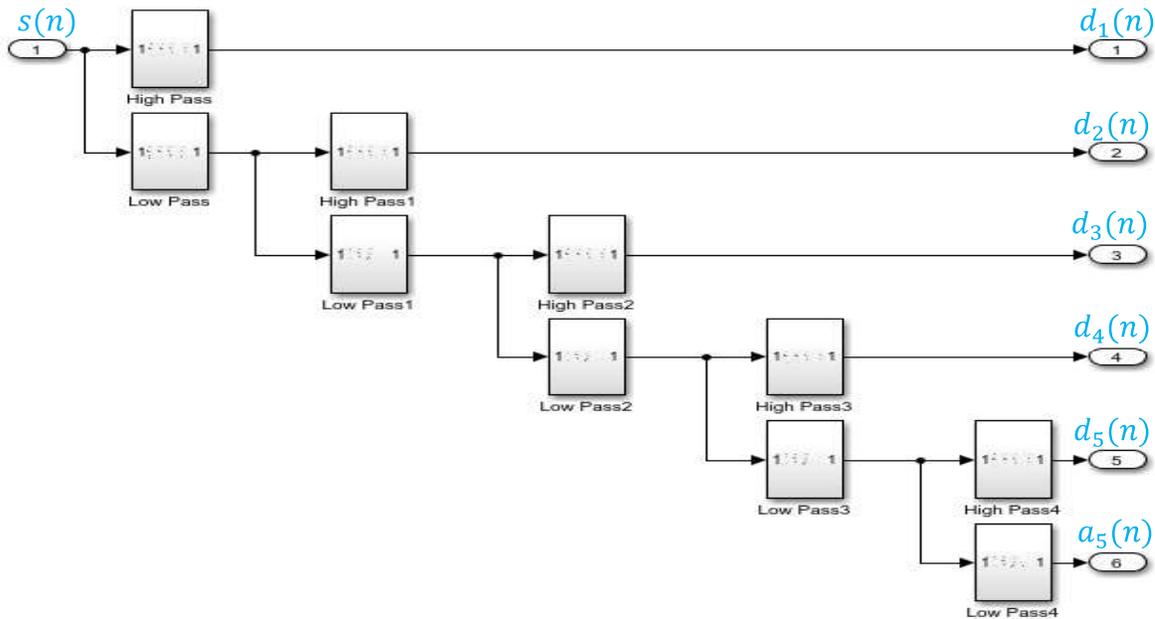


Figure 5.5 Architecture de la transformée en ondelette stationnaire (SWT) réalisée avec des blocs XSG

La transformée SWT est utilisée pour extraire les caractéristiques pertinentes du signal EEG. Elle est implémentée à l'aide d'un ensemble de filtres passe-haut (pour extraire les détails du signal EEG) et de filtres passe-bas (pour extraire les approximations du signal EEG). Ainsi, à l'aide de cette architecture, le signal EEG de départ  $s(n)$  est décomposé en six autres signaux ou sous-bandes, dont cinq détails et une approximation. Pour la réalisation de cette partie, la simplification de l'architecture et la réduction des ressources matérielles, l'ondelette Daubechies 2 (db2) est utilisée avec un niveau de décomposition égal à cinq. L'extraction des caractéristiques pertinentes est obtenue par le calcul des variances de chacun des signaux de détails et du signal d'approximation.

Les filtres passe-haut comme les filtres passe-bas de la figure 5.5 précédente sont réalisés à l'aide des blocs d'addition, de multiplication et des retards. L'architecture est identique pour les deux filtres d'une même itération. La différence entre le filtre passe-haut et le filtre passe-bas réside uniquement dans leurs fonctions de transfert qui sont définies par les coefficients des filtres. Les figures 5.6 et 5.7 suivantes présentent l'architecture respective du filtre passe-haut et du filtre passe-bas de l'itération initiale du présent système de détection de crises d'épilepsie réalisée à l'aide des blocs XSG. Les coefficients de ces filtres sont obtenus à l'aide de la fonction « wfilters » de Matlab.

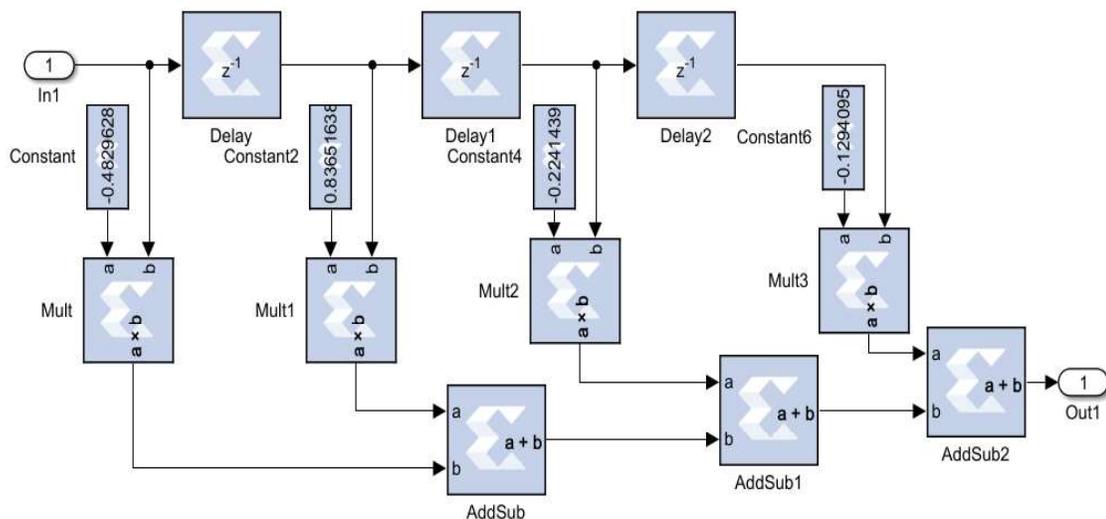


Figure 5.6 Architecture du filtre passe-haut (Meddah et al., 2020)

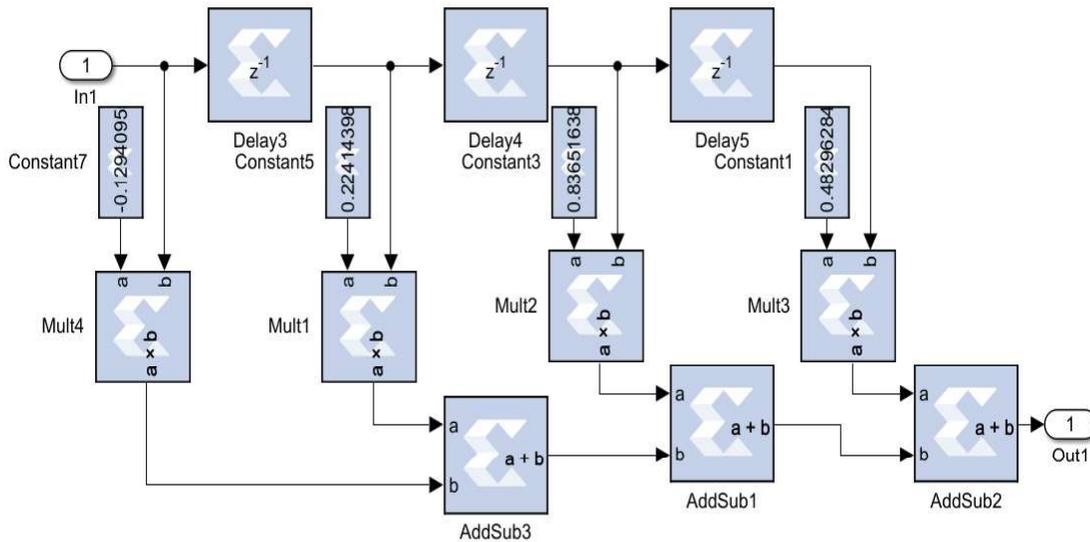


Figure 5.7 Architecture du filtre passe-bas (Meddah et al., 2020)

Les paires de filtres des autres itérations gardent la même architecture à l'exception des blocs de délai qui doublent de valeur à chaque itération. Donc, ils prennent successivement 1, 2, 4, 8 et 16.

### 5.2.3 La synchronisation des sous-bandes

L'architecture utilisée pour synchroniser les sorties des différentes sous-bandes de décomposition du signal EEG est celle de la figure 5.8 suivante. Comme déjà mentionné plus haut, les filtres passe-haut et passe-bas sont composés de blocs de retards, d'addition et de multiplication. Les blocs d'addition et de multiplication ne posent aucun problème de déphasage des différents signaux de détails et d'approximation ; cependant, les blocs de retards de cette architecture présentent un grand défi pour avoir en même temps tous les six signaux afin de réaliser le calcul des variances et de produire le bon vecteur de caractéristiques du segment traité. En effet, chaque retard engendre un décalage du signal qui le traverse, comparativement à un circuit sans retard, et ce décalage augmente à mesure de la profondeur de la décomposition. Et comme les différentes sous-bandes sont obtenues à partir des filtres placés en cascades, les retards, et donc les décalages, varient différemment pour

chacune des sous-bandes. Pour corriger ces décalages, toutes les sorties doivent être synchronisées. Cela est réalisé en ajoutant des retards dans les lignes qui en avaient peu, sans en ajouter dans les lignes qui en avaient trop, de manière à avoir le même nombre de retards cumulés pour toutes les sorties, c'est la synchronisation.

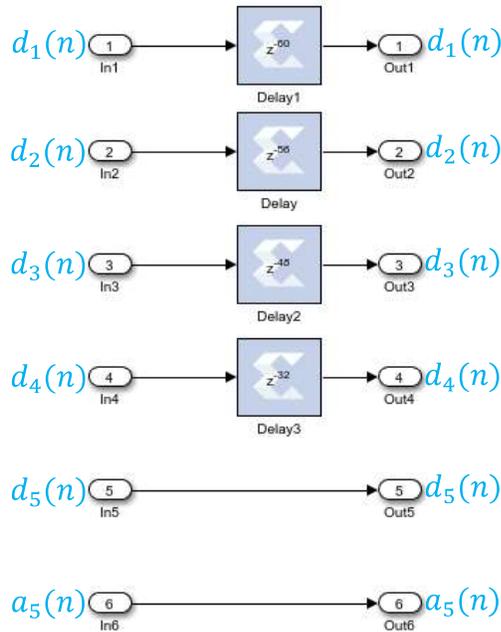


Figure 5.8 Synchronisation des sorties des filtres de la SWT

#### 5.2.4 Sélection de caractéristiques

L'idée derrière la sélection de caractéristiques, et surtout le choix de la variance comme caractéristique pertinente des détails et de l'approximation du signal EEG, est que les caractéristiques varient en fonction de l'état du patient et que la variance du signal a tendance à être plus élevée en présence de la crise qu'en temps normal. La formule utilisée habituellement pour le calcul de la variance, d'un signal détail  $d_i(n)$  par exemple, est la suivante :

$$\sigma_{d_i}^2 = \frac{1}{N_{d_i}} \sum_{n=0}^{N_{d_i}-1} (d_i(n) - \mu_{d_i})^2 \quad (5.1)$$

où  $\mu_{d_i}$  est la moyenne du  $i^{\text{ième}}$  signal de détail  $d_i(n)$  et  $N_{d_i}$  est son nombre d'échantillon (longueur). Cependant, l'application de cette formule nécessite le calcul de la moyenne  $\mu_{d_i}$  avant de calculer la variance  $\sigma_{d_i}^2$ , ce qui entraîne un délai. Pour remédier à cela, la formule alternative suivante est utilisée, car elle permet de calculer la variance en même temps que la moyenne (Meddah et al., 2020).

$$\sigma_{d_i}^2 = \frac{1}{N_i} \sum_{n=0}^{N-1} d_i^2(n) - \left( \frac{1}{N_i} \sum_{n=0}^{N-1} d_i(n) \right)^2 \quad (5.2)$$

La figure 5.9 ci-dessous présente l'architecture du calcul de la variance implémentée selon l'équation 5.2.

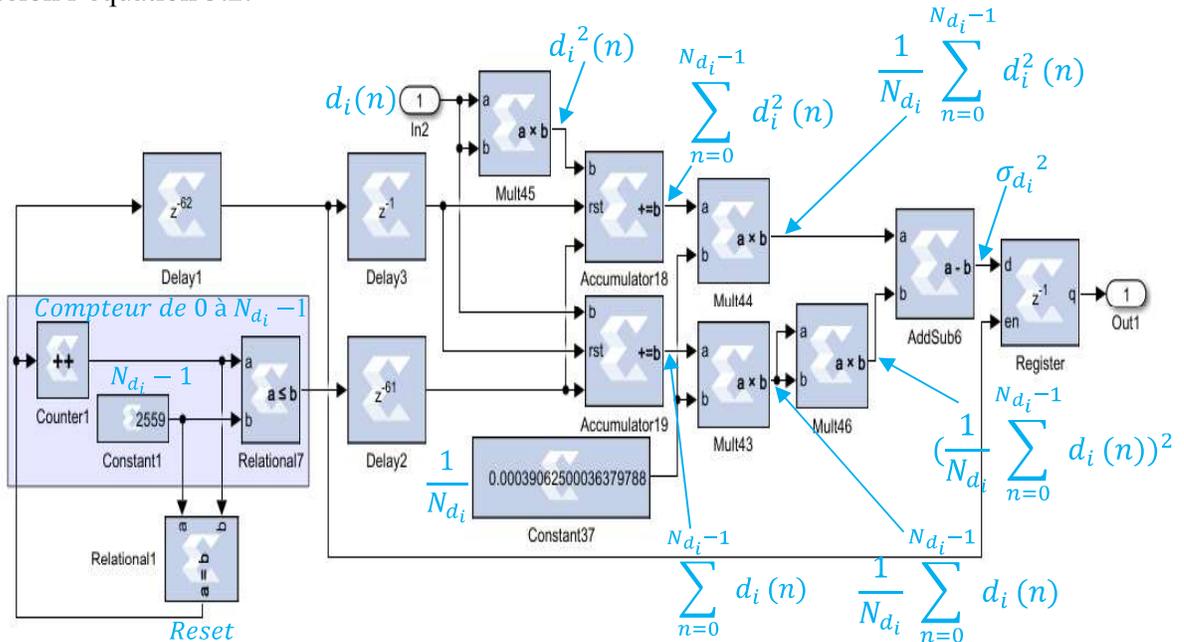


Figure 5.9 Architecture du bloc calculant la variance des sous-bandes du signal EEG (Meddah et al., 2020)

Une fois l'exécution démarrée, le compteur commence à compter. Cependant, pendant les 60 premiers cycles, le bloc de « Calcul de la variance » ne procède à aucun calcul. Cela est dû au bloc « Delay2 », qui retarde l'exécution du calcul jusqu'à ce que toutes les sous-bandes du bloc d'extraction de caractéristiques soient synchronisées. Cette synchronisation

permet d'aligner correctement les différentes sorties des sous-bandes avant de commencer le traitement.

Une fois les données prêtes, après le délai imposé par « Delay2 », le calcul des variances peut commencer. Le système traite alors les 2560 échantillons nécessaires pour calculer la variance. Les 60 premiers échantillons sont ignorés car ils sont erronés en raison des problèmes de synchronisation. Pour garantir que les 2560 échantillons sont utilisés correctement, deux autres retards, « Delay1 » et « Delay3 », sont ajoutés à la fin du comptage des échantillons (au Reset). Ces retards permettent aux blocs de « Calcul de la variance » d'utiliser tous les 2560 échantillons du segment en cours dans le calcul de la variance avant de réinitialiser le calcul et de commencer un nouveau segment.

Un registre est placé à la fin des blocs de calcul des variances. Il bloque la sortie jusqu'à ce que le calcul soit terminé, c'est-à-dire lorsque le compteur atteint 2559 et que le retard « Delay1 » a déjà retardé l'activation pour compenser le temps perdu. À ce moment-là, le registre transmet la dernière valeur de la variance calculée. Le retard « Delay3 » ajoute un dernier délai avant la réinitialisation du calcul, afin de s'assurer que le calcul du nouveau segment commence correctement, sans utiliser le dernier échantillon du segment précédent.

Comme le registre ne transmette d'informations que lorsqu'il reçoit une impulsion et que sa sortie reste figée sur la dernière valeur qui la traverse jusqu'à la prochaine impulsion, seule cette sortie (la dernière variance) produite participe dans la classification. Durant tout le traitement de l'autre segment, cette variance sera maintenue aussi bien que le résultat de la catégorisation des classificateurs jusqu'à ce que les valeurs des variances changent, lorsque le compteur atteindra une autre valeur de 2559 plus le retard défini par Delay1 et se réinitialise. Ce processus se répète jusqu'à la fin du temps d'opération défini dans la plateforme.

Pendant ce temps, une fois que le vecteur de caractéristiques composé de six (6) variances est calculé, ce dernier est fourni aux deux classificateurs qui utilisent les variances produites pour classifier le segment en cours. Habituellement, bien avant de fournir ces

informations aux classificateurs, celles-ci devraient passer, selon le besoin de chacun des classificateurs, par une méthode de réduction de dimensionnalité. Comme la réduction de dimensionnalité n'est pas prise en compte dans cette partie du projet, les caractéristiques calculées sont fournies directement aux classificateurs SVM et MLP. En d'autres mots, les variances des différentes sous-bandes servent d'entrées aux classificateurs SRD-SVM et SRD-MLP, et ce sont celles-là qui vont faciliter la séparation des périodes sans convulsions de celles contenant les convulsions ou des patients malades des patients sains.

### 5.2.5 Détection de la crise épileptique à l'aide du classificateur (SVM)

Tous les blocs réalisés jusqu'ici avaient pour objectif de calculer les caractéristiques pertinentes et distinctes du signal EEG pour les fournir ensuite aux classificateurs afin qu'ils établissent la séparation en produisant une sortie de « 1 » si le patient est épileptique ou de « 0 » si le patient est non-épileptique. Cette section passe en revue l'algorithme de SVM utilisé et son implémentation dans Xilinx System Generator.

#### 5.2.5.1 Classificateur SVM

La technique SVM implémentée dans ce projet est inspirée de (Boujelben & Bahoura, 2018) qui a travaillé sur un détecteur automatique de sifflements utilisant une combinaison d'algorithmes MFCC et SVM. L'architecture SVM appliquée est celle de la version optimisée dans laquelle les coefficients (le vecteur poids  $w$  et le biais  $b$ ) de la fonction de décision de la méthode SVM sont d'abord déterminés hors ligne sur Matlab avant d'être appliqués à XSG.

La décision de classer une observation  $x$  dans l'espace des caractéristiques est définie par la fonction :

$$d(x) = \text{sign}(w^T x + b) = \text{sign}(x^T w + b). \quad (5.3)$$

Cette équation peut s'écrire sous la forme matricielle suivante :

$$d(x) = \text{sign} \left( [x_1 \ x_2 \ \dots \ x_6] \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_6 \end{bmatrix} + b \right), \quad (5.4)$$

où  $x$  est le vecteur d'entrée correspondant au vecteur des caractéristiques (les six variances). Les paramètres ( $w$  et  $b$ ) ont été déterminés à l'aide de la fonction « fitlinear » de Matlab puis ils sont donnés à XSG après la phase d'entraînement.

Grâce à la fonction de décision  $d(x)$ , l'algorithme SVM classe un segment à prédire appartenant à la classe A (-1), si le résultat de la combinaison linéaire est inférieur à zéro (0), et à la classe B (+1) dans le cas contraire. La figure 5.10 suivante illustre l'algorithme SVM basé sur l'équation 5.4, réalisé avec des blocs Xilinx System Generator.

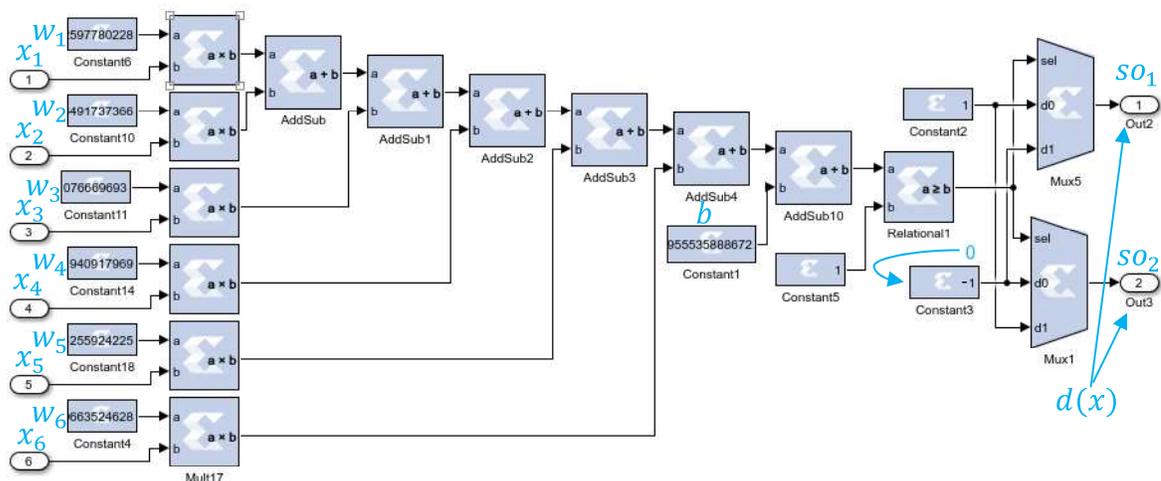


Figure 5.10 Implémentation du classificateur SVM à l'aide des blocs XSG (Boujelben & Bahoura, 2018)

Afin de faciliter l'analyse de SVM et MLP, le (-1) de la prédiction SVM a été remplacé par zéro et deux sorties ont été utilisées à la place d'une seule. Les sorties «  $so_1$  » et «  $so_2$  » de la figure 5.10 sont utilisées pour permettre de comparer visuellement le résultat du SVM comparativement au résultat du réseau de neurones pour chaque segment EEG traité par l'implémentation matérielle comme le montre la figure 5.2 ci-dessus. Les résultats obtenus pour chaque segment EEG traité par les deux classificateurs de l'implémentation matérielle peuvent être lus de la manière suivante :

Tableau 5.2 Interprétation des résultats de SVM et de MLP

	Non-épileptique	Épileptique
$so_1$	1	0
$so_2$	0	1

Les résultats de la classification des signaux EEG à l'aide de SVM se trouvent après la démarche d'implantation du réseau de neurones (MLP) sur Xilinx System Generator (XSG).

### 5.2.6 Détection de la crise épileptique à l'aide du réseau de neurones (ANN)

L'implémentation du réseau de neurones MLP avec les blocs XSG se fait en 2 étapes fondamentales : la création d'un modèle ANN en utilisant la boîte à outils « nnstart » dans Matlab / Simulink et la reproduction du fonctionnement du prototype généré par l'outil « nnstart » avec les blocs XSG.

#### 5.2.6.1 Préparation des données pour l'entraînement du prototype du réseau de perceptron multicouche

Pour entraîner le modèle à l'aide de cette boîte à outils, 100 segments par classe ont été sélectionnés, formant ainsi un total de 200 segments par base de données. Ces segments sont utilisés pour entraîner le modèle ANN en appliquant la validation croisée à 5-folds. À partir de ces données, un vecteur d'entrées caractéristiques (Inputs) et un vecteur de données cibles (Targets) sont créés pour entraîner le modèle à l'aide de la boîte à outils « nnstart ».

#### 5.2.6.2 Création du prototype de ANN à l'aide de la boîte à outils de « nnstart »

Une fois que les vecteurs d'entrée et de sortie sont créés, la première étape est de faire appel à la boîte à outils du réseau de neurones de Matlab en invoquant la commande « nnstart » et ainsi apparaît la fenêtre de dialogue de la figure 5.11 suivante. Le reste du travail pour compléter la création du prototype consiste à donner à l'application les données d'apprentissage représentées par le vecteur d'entrée (Inputs) et le vecteur de sorties (Targets)

correspondants, à choisir le nombre de neurones de la couche cachée du réseau, la répartition de données pour l'entraînement, la validation et le test du réseau MLP. La dernière étape de la création du prototype consiste à générer le diagramme Simulink. La figure 5.12 représente le diagramme du prototype créé à l'aide des caractéristiques obtenues à partir de XSG.

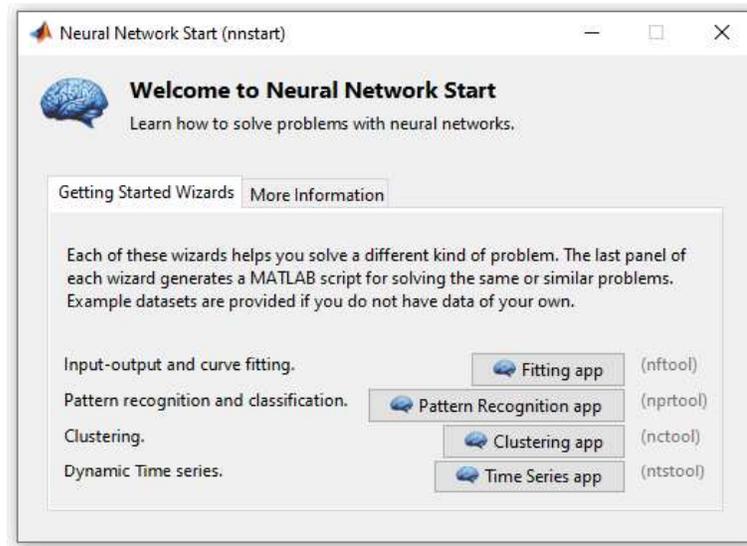


Figure 5.11 Boîte à outils du Neural Network Start (nnstart)

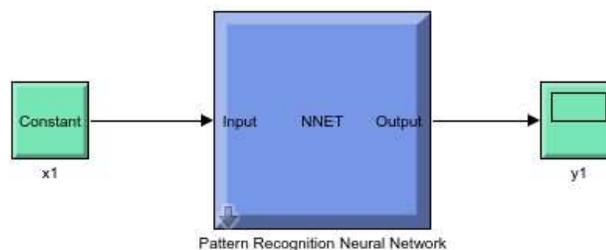


Figure 5.12 Prototype du réseau de neurones créé à l'aide de la boîte à outils « nnstart »

### 5.2.6.3 Reproduction du prototype généré par la boîte à outils « nnstart » avec les blocs de Xilinx System Generator (XSG)

Toutes les structures créées à l'aide de XSG pour l'implantation matérielle du système de détection de l'épilepsie à l'aide du réseau de neurones sont basées sur les différents diagrammes de blocs explicatifs que contient le prototype du réseau de neurones. Ses

composantes de niveaux inférieurs sont présentées et détaillées dans les sous sections suivantes.

**a) PROCESS INPUT 1 : NORMALISATION DES ENTRÉES**

Le bloc « Process Input 1 » est le deuxième bloc du prototype contenant l'un des blocs les plus importants du réseau de neurone du nom de « mapminmax ». Le premier bloc (en vert à gauche) est un bloc de constante de Simulink qui contient des exemples d'entrées caractéristiques utilisés pour simuler le fonctionnement du réseau. La figure 5.13a montre l'intérieur du prototype du réseau MLP et la figure 5.13b, celle du bloc « Process Input 1 ».

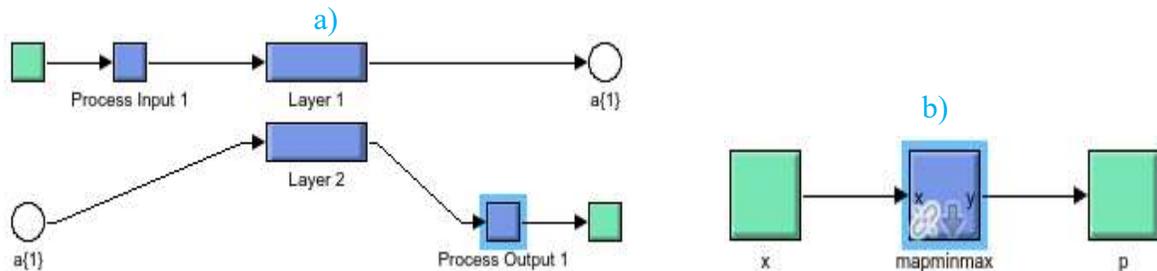


Figure 5.13 a) Intérieur du bloc : Pattern Recognition Neural Network, b) Intérieur du bloc : Process Input 1

**b) BLOC « MAPMINMAX »**

Il s'agit d'un bloc de normalisation qui a pour fonction de faire évoluer les données de caractéristiques dans l'intervalle  $[-1, 1]$  de manière que les valeurs du vecteur d'entrée restent systématiquement comprises entre -1 et 1. Les parties composant le bloc de normalisation pour le prototype sont présentées à la figure 5.14.

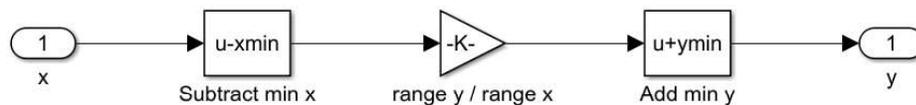


Figure 5.14 Intérieur du bloc « mapminmax » ou bloc de normalisation

La formule utilisée pour normaliser le vecteur d'entrée est donnée par la connexion des sous blocs qui le composent (figure 5.14). Cette formule peut être exprimée par :

$$y = (x - x_{min}) \times \frac{(y_{max} - y_{min})}{(x_{max} - x_{min})} + y_{min} \quad (5.5)$$

où  $y$  est valeur normalisée,  $y_{max}$  est la plus grande valeur de l'intervalle de normalisation, à savoir 1;  $y_{min}$  est la plus petite valeur de l'intervalle de normalisation, à savoir -1;  $x$  est le signal d'entrée ou la valeur d'origine,  $x_{max}$  et  $x_{min}$  correspondent respectivement à la valeur maximale et minimale de chaque sous-bande dans l'ensemble des données d'apprentissage. Donc, pour chaque jeu de données (vecteurs de caractéristiques) d'apprentissage et étant donné que les sous-bandes utilisées sont au nombre de six, il y aura six blocs de normalisation dans lesquels chacun aura un  $x_{max}$  (la plus grande valeur de cette sous-bande) et aussi un  $x_{min}$  (la plus petite valeur de cette sous-bande) comme illustrés dans le tableau suivant.

Tableau 5.3 Exemple de données (vecteurs de caractéristiques) d'apprentissage du prototype de MLP

$x_{min_{D1}}$ D1	$x_{min_{D2}}$ D2	$x_{min_{D3}}$ D3	$x_{min_{D4}}$ D4	$x_{min_{D5}}$ D5	$x_{min_{A5}}$ A5
0,00087284	0,00136757	0,00243431	0,004445098	0,008222856	1,559243109
0,00087743	0,00137323	0,00244364	0,004461785	0,008253801	1,558248122
0,00088782	0,00138788	0,00246912	0,004508099	0,008339707	1,56447521
0,00090168	0,0014079	0,00250438	0,004572486	0,008459233	1,573101872
0,00091965	0,00143429	0,00255135	0,004658525	0,008619035	1,584389368
$x_{max_{D1}}$	$x_{max_{D2}}$	$x_{max_{D3}}$	$x_{max_{D4}}$	$x_{max_{D5}}$	$x_{max_{A5}}$

Étant donné que  $y_{max}$  et  $y_{min}$  sont connus, la formule précédente peut s'écrire de la manière suivante :

$$y = \frac{2 (x - x_{min})}{(x_{max} - x_{min})} - 1 \quad (5.6)$$

À présent, la normalisation de la valeur de l'entrée  $x$  ne dépend que de la valeur maximale et minimale de l'ensemble de données à savoir  $x_{max}$  et  $x_{min}$ .

Étant donné que les paramètres  $x_{max}$  et  $x_{min}$  sont connus pour chaque jeu de données utilisé, l'opération  $2/(x_{max} - x_{min})$  a été réalisée hors ligne avant même l'entraînement du modèle afin d'alléger les opérations de Xilinx System Generator (XSG). La valeur obtenue pour cette opération est ajoutée au reste de l'équation afin de compléter la formule de départ sur XSG. L'équation implémentée avec des blocs XSG peut alors s'écrire de la manière suivante :

$$y = k * (x - x_{min}) - 1 \quad (5.7)$$

avec  $k = 2/(x_{max} - x_{min})$ , mais calculé sur Matlab.

Le diagramme correspondant à la normalisation selon la formule de l'équation 5.7, appliquée sur Xilinx System Generator, est illustré à la figure 5.15 et ceux correspondant à toutes les sous-bandes de décomposition sont présentés à la figure 5.16.

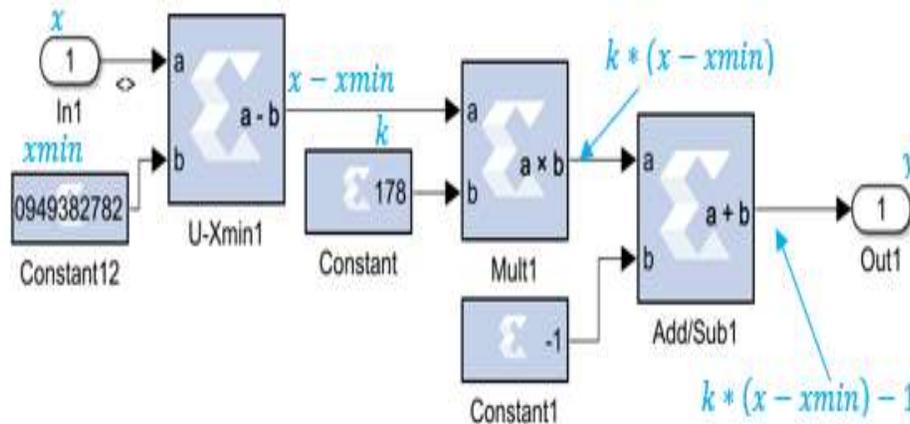


Figure 5.15 Intérieur du bloc de normalisation du « mapminmax » de XSG

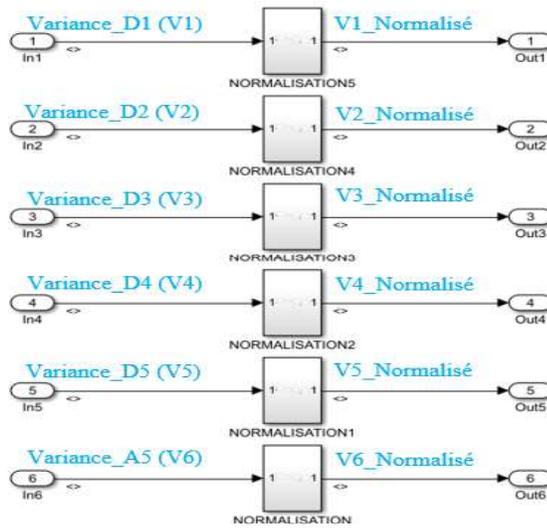


Figure 5.16 Bloc complet de « mapminmax » ou de normalisation réalisée avec XSG

c) COUCHE DE NEURONE CACHÉE (LAYER 1)

La couche cachée du prototype, (layer 1) de la figure 5.13a, est présentée à la figure 5.17a suivante. Les blocs «  $p\{1\}$  », « Delays 1 » et «  $a\{1\}$  » ne contiennent aucun circuit à l'intérieur; ils agissent comme des buffers uniquement. Les blocs d'utilité sont « W » contenant les différents poids des neurones de la couche cachée, « b », les biais et « tansig » qui est la fonction d'activation de la couche cachée. La figure 5.17b présente les contenus des blocs « W » et la figure 5.18, le contenu de « tansig ». Le bloc « b » identifié «  $b\{1\}$  » de la figure 5.17a est tout simplement un bloc de constante contenant les trois valeurs de biais correspondant à chacun des neurones de la couche cachée.

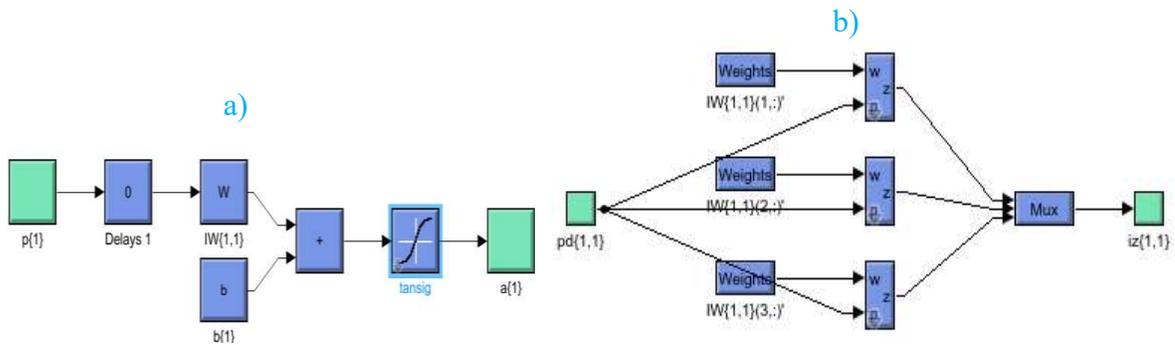


Figure 5.17 a) Couche cachée du prototype, b) Somme pondérée des neurones cachés

où « pd{1,1} » de la figure 5.17b est un vecteur de 6 dimensions de même que « IW{1,1}(n,:) » , avec n représentant le nombre de neurones de la couche cachée.

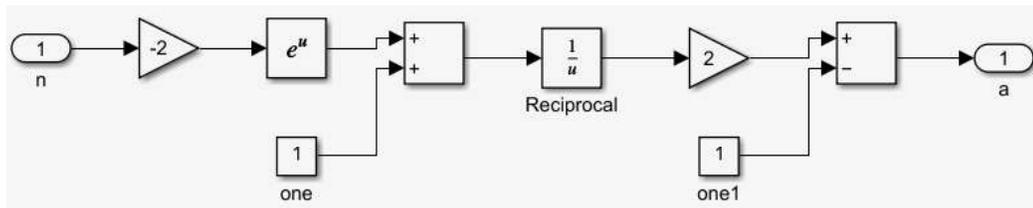


Figure 5.18 Fonction d'activation tangente hyperbolique du prototype

La somme pondérée de chaque neurone de la couche cachée, réalisée avec les blocs XSG, est présentée à figure 5.19.

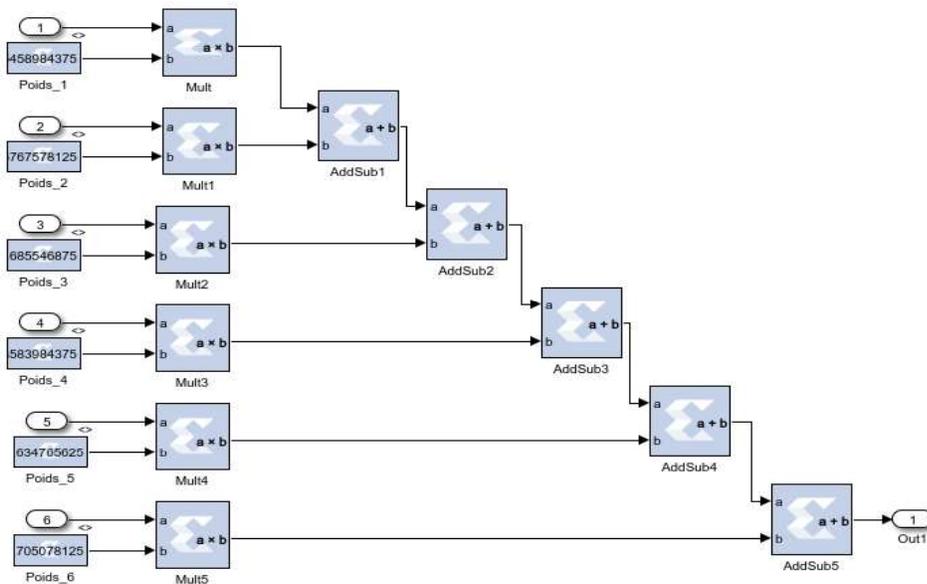


Figure 5.19 Somme pondérée du neurone cachée réalisée sur XSG

La figure 5.18 précédente réalise la fonction d'activation tangente hyperbolique suivante :

$$a(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (5.8)$$

Pour éviter l'implémentation de la fonction exponentielle et l'opération de division, nous avons opté pour un schéma basé sur la table de correspondance, tel qu'indiqué à la

figure 5.20 suivante. Ce schéma effectue le calcul de l'activation à partir de la mémoire ROM (Bahoura, 2014).

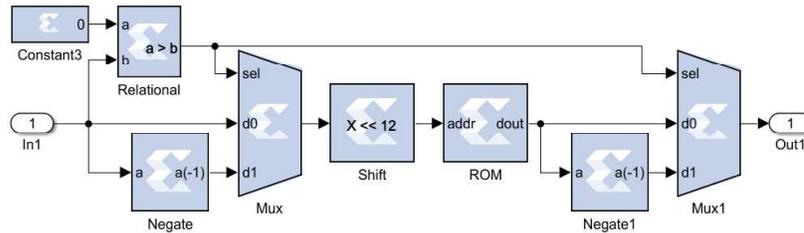


Figure 5.20 Fonction d'activation tangente hyperbolique réalisée sur XSG (Bahoura, 2014)

**d) COUCHE DE NEURONE DE SORTIE (LAYER 2)**

La couche de sortie n'est pas trop différente de la couche d'entrée. Le processus reste le même, seulement le nombre de neurones dans cette couche est déterminé par le nombre de sorties (Target). La structure de cette dernière pour le prototype est présentée dans les figures 5.21a et 5.21b ci-dessous, en revanche, sa fonction d'activation est présentée un peu plus bas.

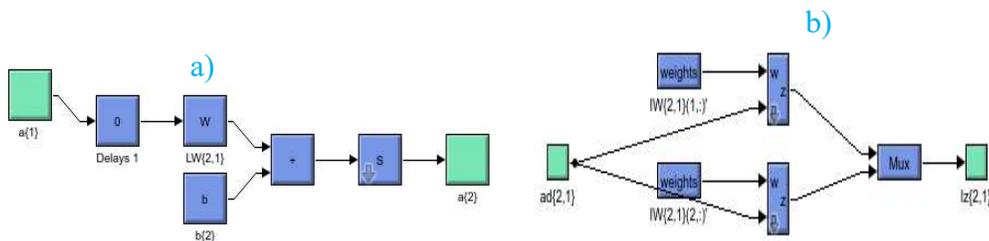


Figure 5.21 a) Couche de sortie du prototype, b) Neurones de sortie du prototype

Comme pour la figure 5.17a, ce sont seulement les blocs « W », « b » et « S » de la figure 5.21a qui sont les plus importants, le reste des blocs ne sont qu'uniquement des buffers. Le bloc « b » identifié « b{2} » contient les deux valeurs de biais pour les deux neurones de la couche de sortie. Le bloc « S », la fonction « Softmax », est expliqué un peu plus bas.

La figure 5.21b précédente montre l'intérieur du bloc « W » de la figure 5.21a. Le bloc « ad{2,1} » est tout simplement un vecteur à 3 dimensions contenant les sorties des trois neurones de la couche cachée. De même, les deux vecteurs poids « IW{2,1}{1,:}' » et « IW{2,1}{2,:}' » associés chacun aux deux neurones de la couche de sorties contiennent

chacun les trois poids qui seront multipliés respectivement par les trois signaux du bloc « ad{2,1} ». La figure 5.22 suivante présente la somme pondérée d'un neurone de sortie réalisée avec les blocs XSG.

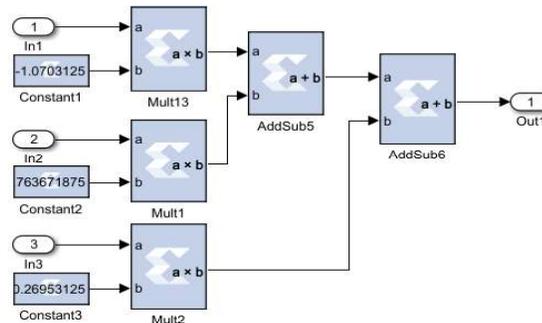


Figure 5.22 Implémentation d'un neurone de sortie avec les blocs XSG

e) *FONCTION D'ACTIVATION DE LA COUCHE DE SORTIE : LA FONCTION SOFTMAX*

La fonction Softmax est une version améliorée du sigmoïde utilisée pour la classification neuronale multi-classe qui normalise les sorties d'un réseau pour que leur somme soit égale à 1. Elle permet ainsi d'interpréter les résultats de classification comme des probabilités. La figure 5.23 suivante est l'architecture de la fonction Softmax du prototype. L'architecture de la fonction Softmax réalisée avec des blocs XSG est présentée à la figure 5.24 suivante. L'architecture de cette figure a été réalisée en interprétant chaque bloc du diagramme de la figure 5.23 suivante. Il s'agit d'une implémentation directe du diagramme de la figure 5.23. La formule de la fonction « softmax » a déjà été présentée dans le troisième chapitre de ce mémoire.

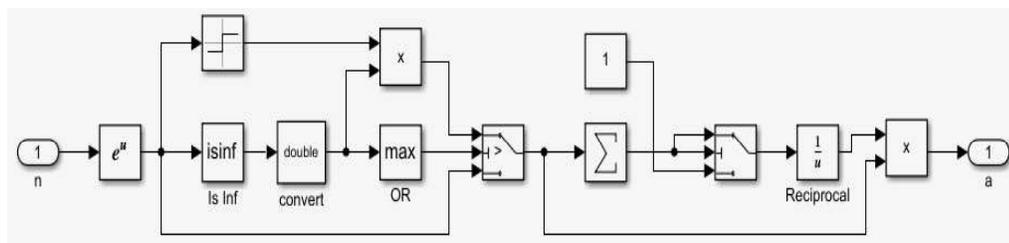


Figure 5.23 Fonction d'activation softmax du prototype

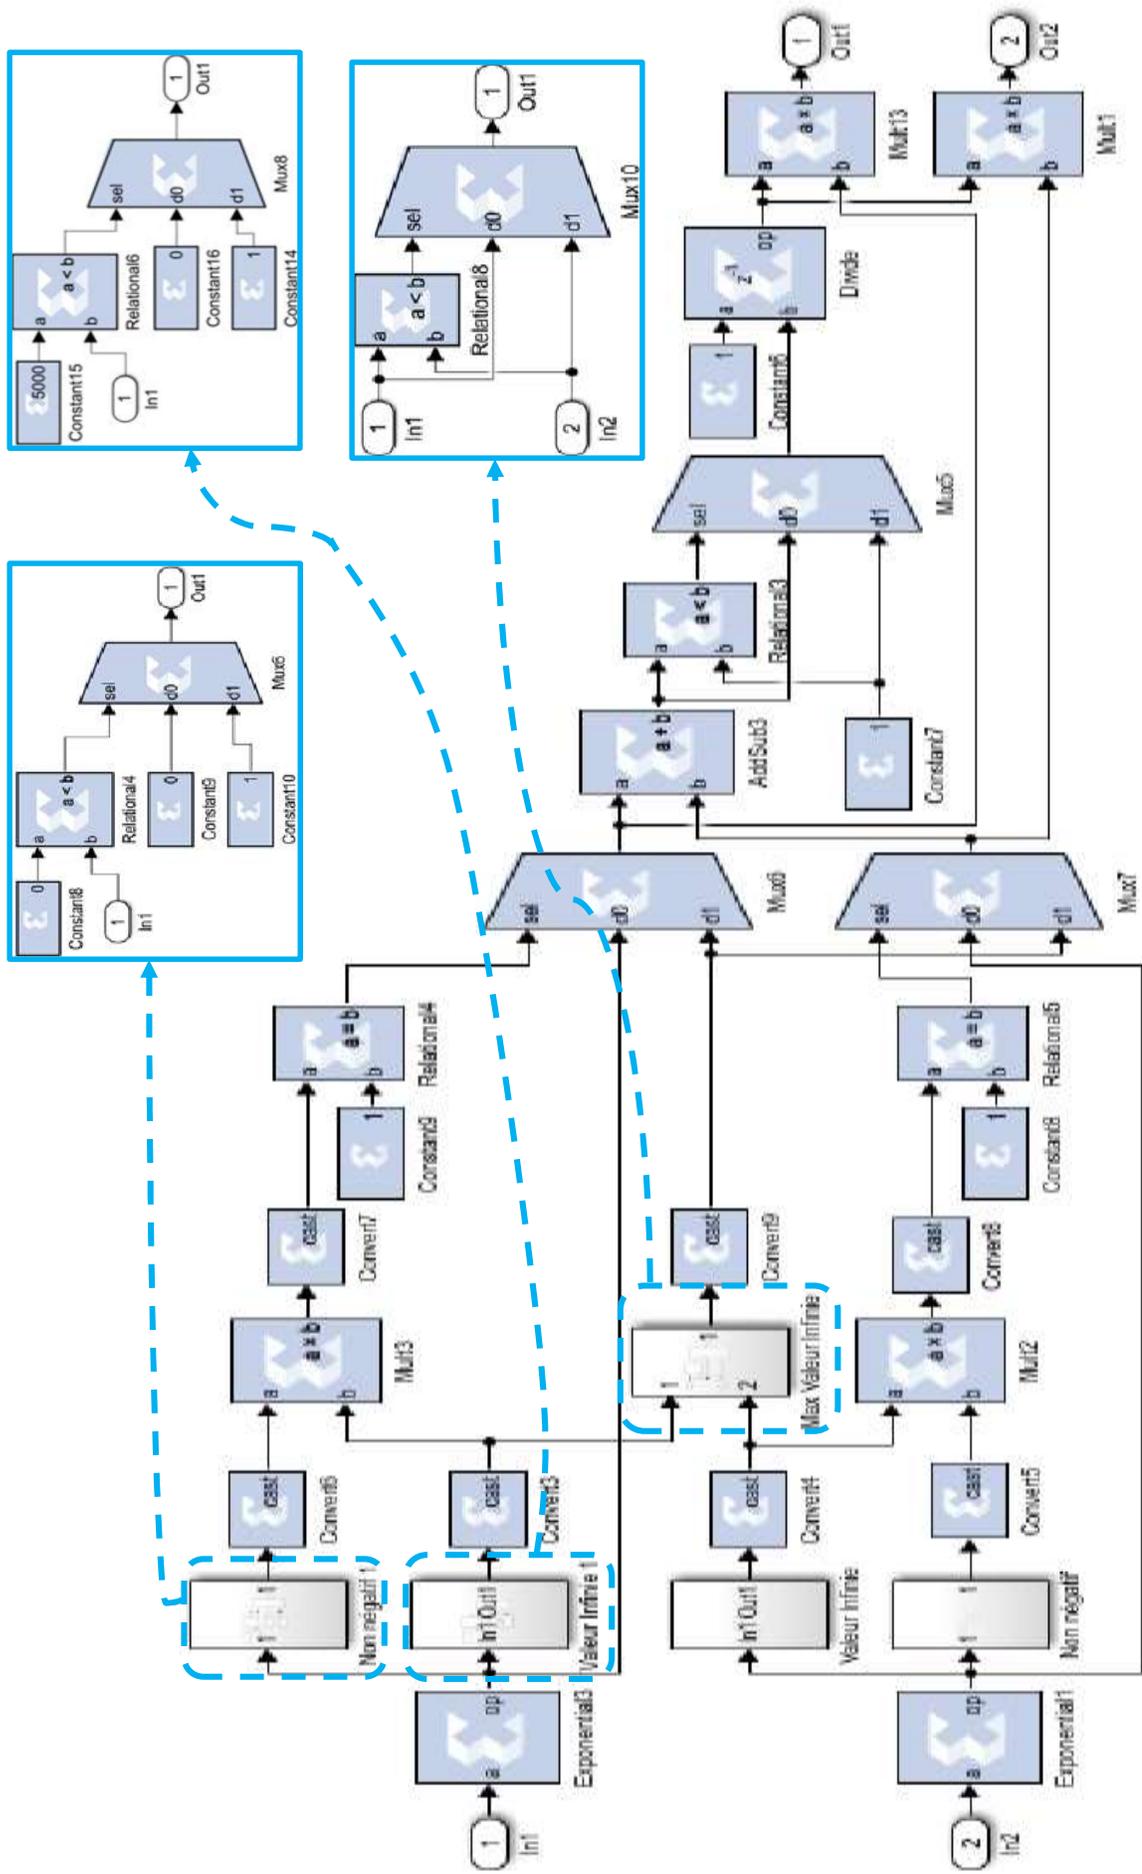


Figure 5.24 Implémentation de la fonction softmax avec les blocs XSG

La valeur infinie a été choisie arbitrairement égale à 5000, une valeur supérieure à la valeur maximale que la ROM peut coder, soit  $2^{12} = 4096$ .

Enfin, le prototype de ANN se termine avec le bloc « Process Output 1 » qui contient uniquement un buffer à l'intérieur.

#### **f) IMPLÉMENTATION DU RÉSEAU DE NEURONES**

Le système complet du réseau de neurones MLP réalisé avec les blocs XSG à partir du prototype généré par la boîte à outils « nnstart » de la figure 5.11 est formé de l'ensemble des blocs XSG présentés plus haut ; la structure finale de celui-ci est présentée à la figure 5.25 ci-dessous.

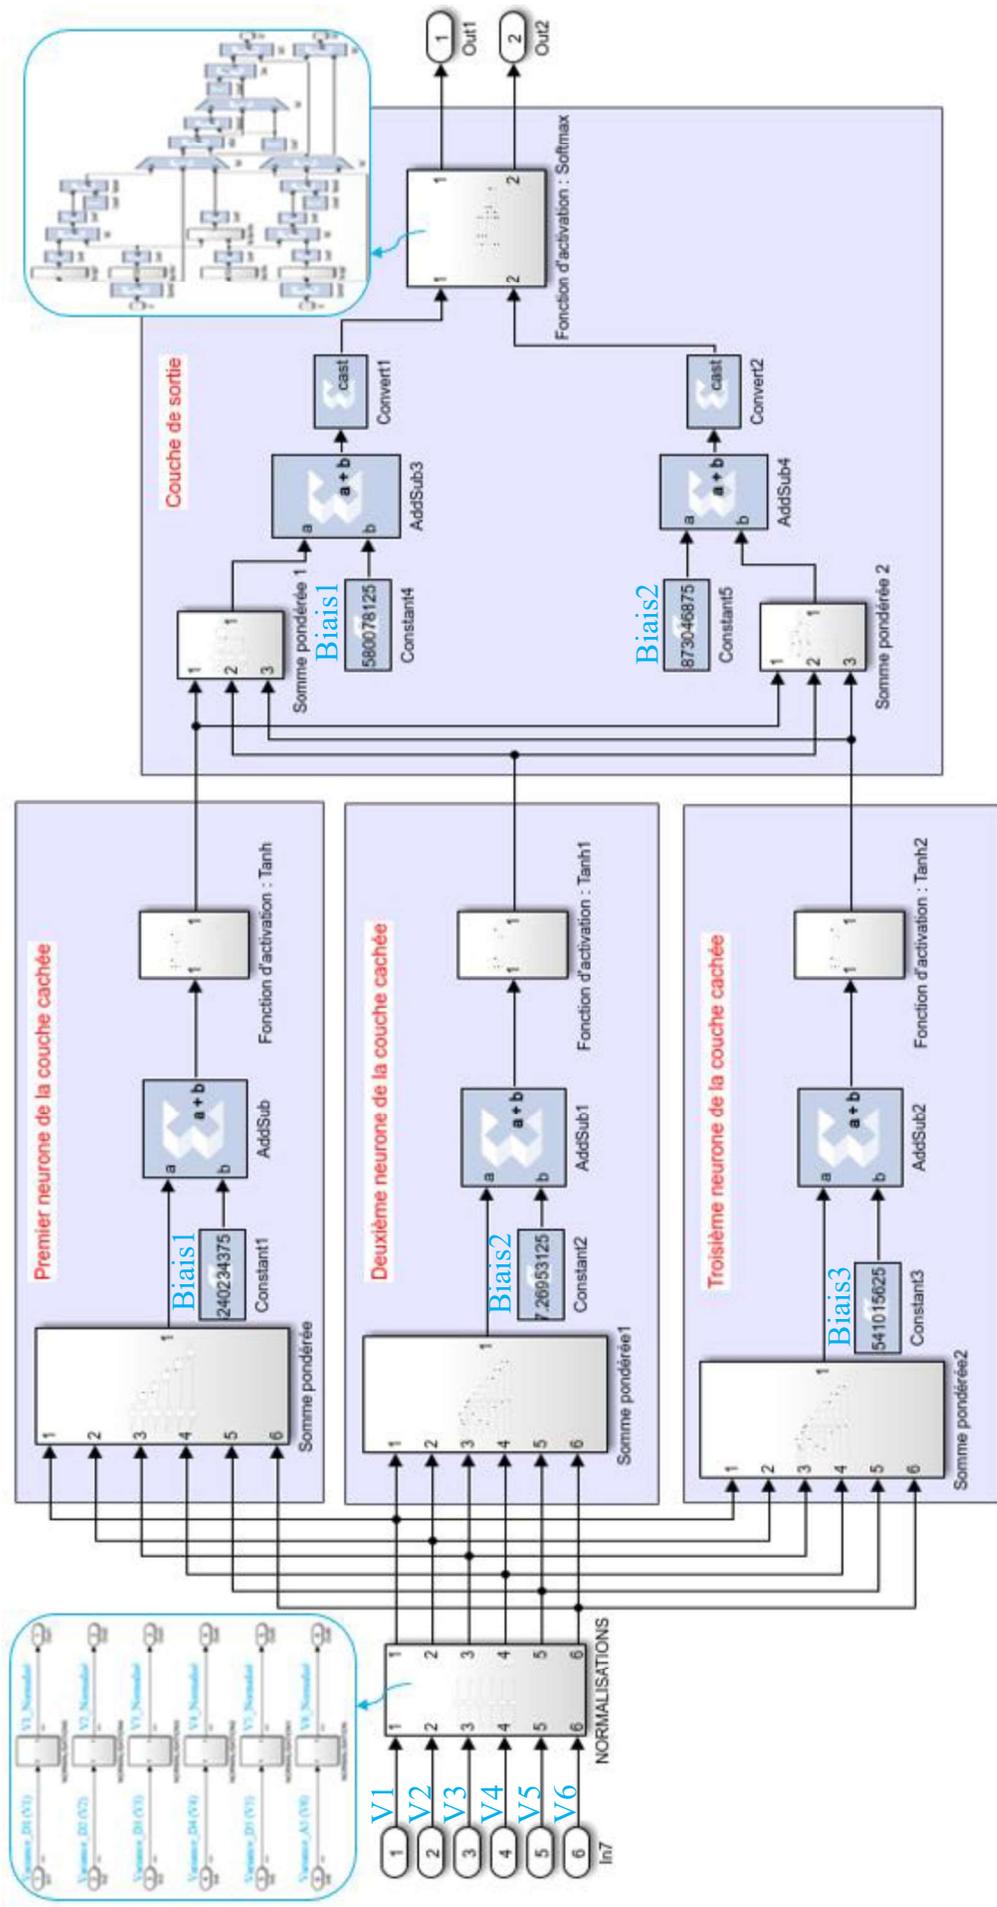


Figure 5.25 Architecture matérielle finale du réseau de neurones MLP formé de 6 entrées, 3 neurones à la couche cachée et 2 neurones à la couche de sorties

### **5.3 RÉSULTATS DE LA CLASSIFICATION DES SIGNAUX EEG OBTENUS AVEC L'IMPLEMENTATION MATERIELLE**

Deux classificateurs sont utilisés dans l'implémentation matérielle de la crise épileptique : les machines à vecteurs de support (SVM) et le réseau de perceptron multicouche (MLP) ou réseau de neurones (ANN). Dans cette partie sont présentés respectivement les résultats du SVM suivis de ceux d'ANN d'abord pour la base de données CHB-MIT ensuite pour celle de l'Université de Bonn. L'analyse commence avec l'implémentation logicielle du système tout en tenant compte des nouvelles restrictions imposées par l'implémentation matérielle afin de comparer leur performance.

#### **5.3.1 Limitations et restrictions dues à l'implémentation matérielle : Adaptation des paramètres des classificateurs pour une implémentation efficace sur FPGA**

L'utilisation des différentes bases de données, du nombre d'échantillons et de segments à traiter pour chaque base de données, ainsi que les ressources limitées de la puce FPGA, nous ont conduit à la nécessité de procéder à plusieurs ajustements pour garantir une implantation optimale du système de détection matériel. Ces ajustements ont affecté plusieurs paramètres, à savoir : l'extraction des caractéristiques, la réduction de la dimensionnalité et les paramètres clés des classificateurs.

- Extraction des caractéristiques : transformée en ondelettes stationnaire (SWT) utilisant l'ondelette de Daubechies 2 (db2), avec un niveau de décomposition égal à 5 avant de calculer la variance.
- Réduction de dimensionnalité : SRD (sans réduction de dimensionnalité).
- Noyau du SVM : linéaire.
- Nombre de neurones à la couche cachée de ANN : trois (3).
- Nombre de segments testés pour les deux bases de données : 200, dont 100 non-épileptiques et les autres 100 épileptiques.

- Pour la base de données CHB-MIT, seul le canal FP1-F3 est utilisé afin de pallier à des problèmes de complexité d'architecture et de consommation excessive de ressources matérielles si les quatre canaux de la base de données CHB-MIT devaient être utilisés.

Face à ces ajustements, il convient alors de réentraîner par logiciel les modèles SVM et ANN afin de vérifier leur taux de réussite pour ces nouvelles caractéristiques et limitations afin d'évaluer Matlab et XSG sur les mêmes contraintes et limitations et de faire une comparaison juste de leurs résultats produits.

### **5.3.2 Méthodes utilisées pour évaluer les performances des implémentations matérielles des classificateurs SVM et ANN**

Pour vérifier le taux d'exactitude des classificateurs SVM et ANN à base de blocs XSG et produire les matrices de confusion correspondantes, l'environnement de Matlab et Xilinx System Generator ont été utilisés.

Tout d'abord, Matlab a été utilisé pour entraîner les modèles, et ses résultats sont sauvegardés pour comparaison avec ceux de Xilinx System Generator. L'outil XSG, à son tour, utilise les paramètres générés par Matlab pour vérifier le fonctionnement du système matériel et produit des résultats pour les comparer à ceux de Matlab.

Lors de la vérification de l'implémentation matérielle, la validation croisée a été employée avec 5-folds. À chaque séquence, les deux modèles (SVM et MLP) sont entraînés sur les mêmes données (dans Matlab). Puis, les paramètres des modèles (les coefficients de l'équation décisionnelle de SVM, les poids et biais du réseau de neurones), les résultats de l'implémentation logicielle (prédictions partielles de chaque classificateur), ainsi que les segments testés durant cette séquence ont été sauvegardés pour servir dans les tests ultérieurs sur Xilinx System Generator (XSG).

Après l'entraînement, les performances de la classification logicielle (matrice de confusion) ont été déterminées à partir des prédictions partielles des classificateurs pour les

cinq séquences de la validation croisée. Les matrices de résultats des tests ont ensuite été organisées « fold » par « fold » (ou séquence par séquence) dans Matlab, en attendant les résultats correspondants de XSG.

Tout de suite après la classification logicielle, débute la classification matérielle avec les informations de chaque séquence ou fold obtenue par Matlab. D'abord le premier fold est relancé sur Matlab dans le but d'actualiser les paramètres de XSG avant de l'exécuter. Une fois l'exécution matérielle terminée pour cette séquence, ses résultats sont enregistrés sur Matlab et une nouvelle séquence est lancée sur Matlab pour actualiser les paramètres de XSG afin de catégoriser de nouvelles étiquettes. Ce processus se répète jusqu'à parcourir tous les 5 folds et cela pour chaque base de données utilisée.

Lors de cette exécution, tous les 40 segments de tests (200 segments / 5 folds = 40 segments/fold) de la séquence sélectionnée sont fusionnés pour former un seul signal. L'architecture XSG est responsable de découper les 2560 échantillons de chaque segment grâce à un compteur qui active un registre pour mettre en sortie la variance obtenue une fois que le seuil de 2560 est atteint; puis le bloc calculant la variance est réinitialisé pour calculer une nouvelle variance pour 2560 autres échantillons, comme c'est expliqué à la sous-section « 5.2.4 Sélection de caractéristiques ».

Après l'exécution sur XSG, les résultats produits pour une séquence donnée sont immédiatement récupérés et sont utilisés pour produire la matrice de confusion pour XSG sur Matlab et de ce fait comparer la précision ou la fiabilité du modèle matériel. La matrice de confusion globale de XSG est également déterminée à partir des résultats de toutes les séquences.

Dans la suite sont présentés les résultats obtenus et leur analyse se fera à la partie réservée à discussions.

### 5.3.3 Résultats de la classification du SVM et de MLP pour la base de données CHB-MIT (canal FP1-F3) : Comparaison des implémentations logicielle-matérielle

Cette partie présente les résultats de la classification logicielle et matérielle de la détection de la crise épileptique pour la base de données CHB-MIT (canal FP1-F3) ; l'analyse de ces résultats se fera dans la partie discussions qui se trouve à la fin de ce chapitre.

#### 5.3.3.1 Résultats de la classification logicielle de SVM et de MLP pour la base de données CHB-MIT (canal FP1-F3)

Les matrices de confusion de l'implémentation logicielle de SVM et de MLP de la base de données CHB-MIT sont présentées respectivement dans les tableaux 5.4 et 5.5 suivants. Les résultats de la partie matérielle sont présentés un peu plus bas.

Tableau 5.4 Matrices de confusion de SVM pour la classification logicielle avec la base de données CHB-MIT (canal FP1-F3)

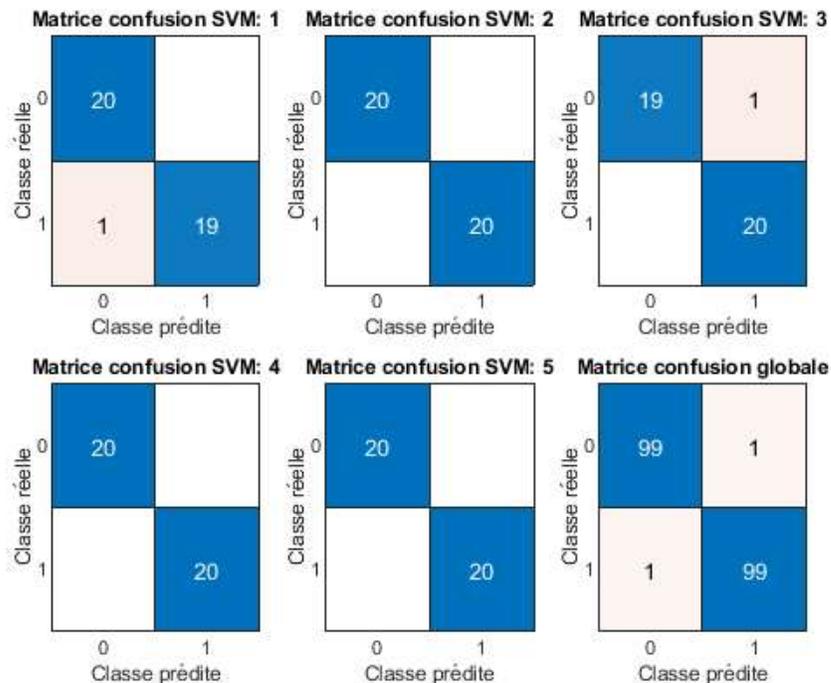
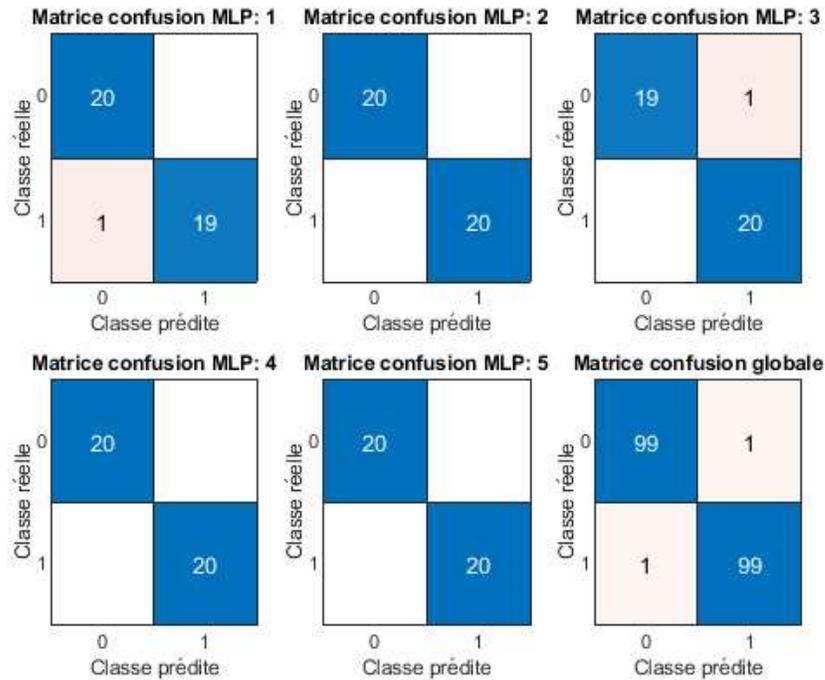


Tableau 5.5 Matrice de confusion MLP pour la classification logicielle avec la base de CHB-MIT (canal FP1-F3)



### 5.3.3.2 Résultats de la classification matérielle de SVM et de MLP pour la base de données CHB-MIT

Dans les tableaux 5.6 et 5.7 ci-après sont présentées respectivement les matrices de confusion de SVM et de MLP pour l'implémentation matérielle du projet. Seulement une seule étiquette de plus est mal-classée pour le SVM, et deux de plus le sont pour le MLP. L'analyse de ces résultats sera approfondie ultérieurement.

Tableau 5.6 Matrice de confusion SVM pour la classification matérielle avec la base de données CHB-MIT (canal FP1-F3)

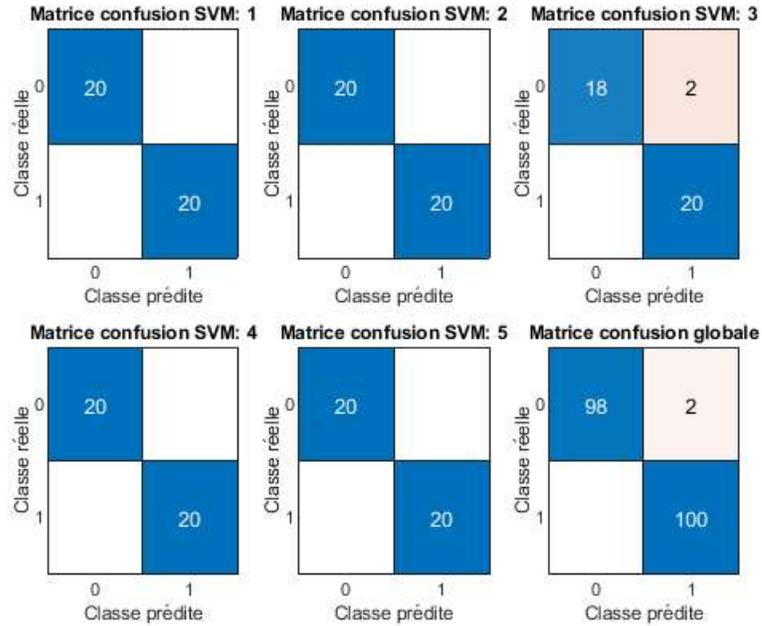
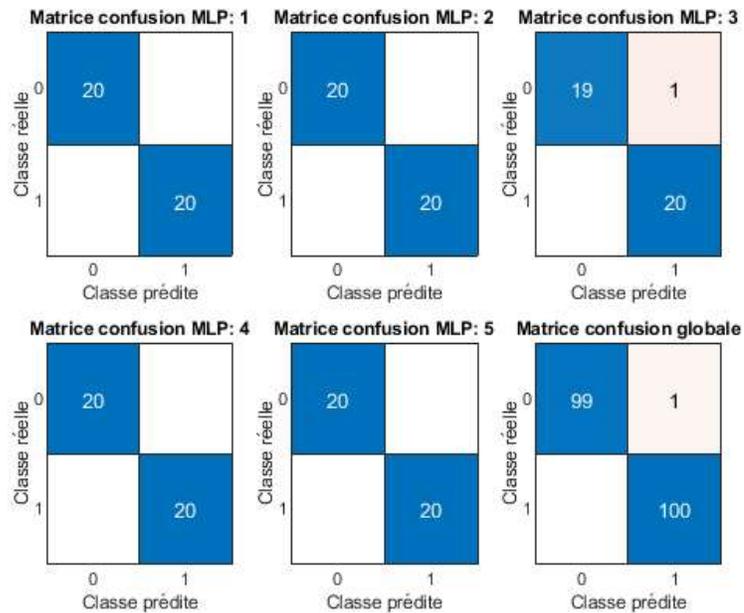


Tableau 5.7 Matrice de confusion MLP pour la classification matérielle avec la base de données CHB-MIT (canal FP1-F3)



### 5.3.4 Résultats de la classification du SVM et de MLP pour la base de données de l'Université de Bonn : Comparaison des implémentations logicielle-matérielle

Cette partie présente les résultats de la classification logicielle et matérielle de la détection de la crise épileptique pour la base de données de l'Université de Bonn; l'analyse de ces résultats se fera dans la partie discussions qui se trouve à la fin de ce chapitre.

#### 5.3.4.1 Résultats de la classification logicielle de SVM et de MLP pour la base de données de l'Université de Bonn

Les matrices de confusion de l'implémentation logicielle de SVM et de MLP de la base de données de l'Université de Bonn sont présentées respectivement dans les tableaux 5.8 et 5.9 suivants. Les résultats de la partie matérielle sont présentés un peu plus bas.

Tableau 5.8 Matrices de confusion de SVM pour la classification logicielle avec la base de données de l'Université de Bonn avec contrôle

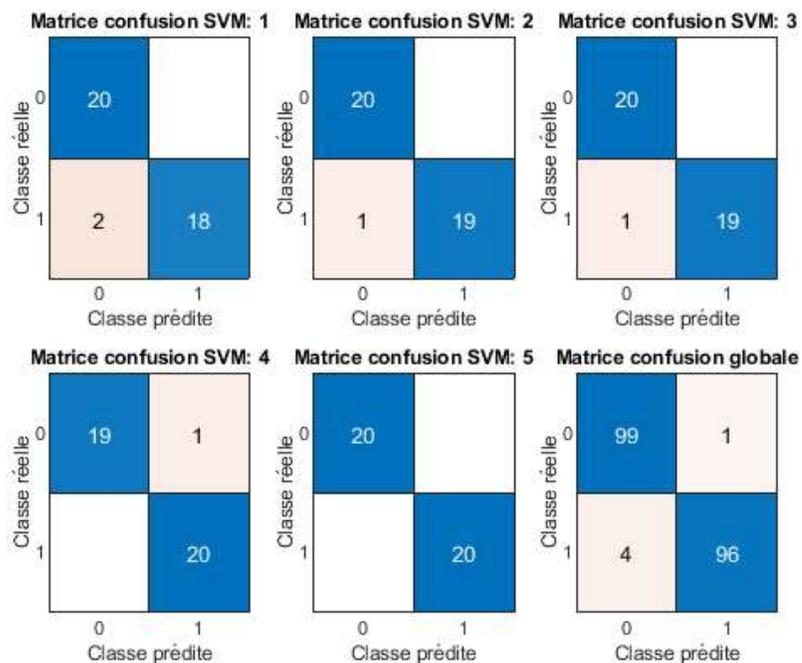
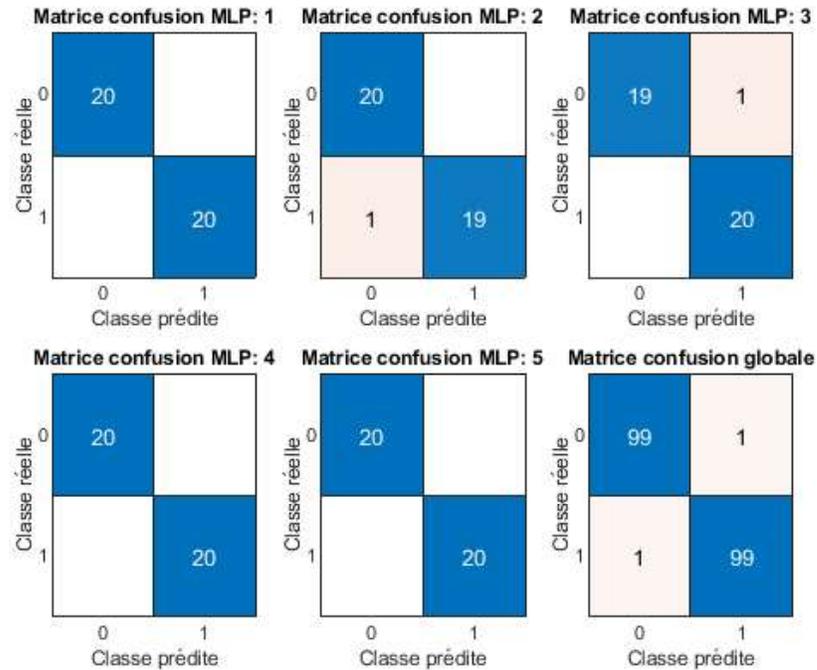


Tableau 5.9 Matrices de confusion de MLP pour la classification logicielle avec la base de données de l'Université de Bonn



#### 5.3.4.2 Résultats de la classification matérielle de SVM et de MLP pour la base de données de l'Université de Bonn

Dans les tableaux 5.10 et 5.11 ci-après sont présentées respectivement les matrices de confusion de SVM et de MLP pour l'implémentation matérielle du projet. L'analyse de ces résultats sera approfondie ultérieurement.

Tableau 5.10 Matrices de confusion de SVM pour la classification matérielle avec la base de données de l'Université de Bonn

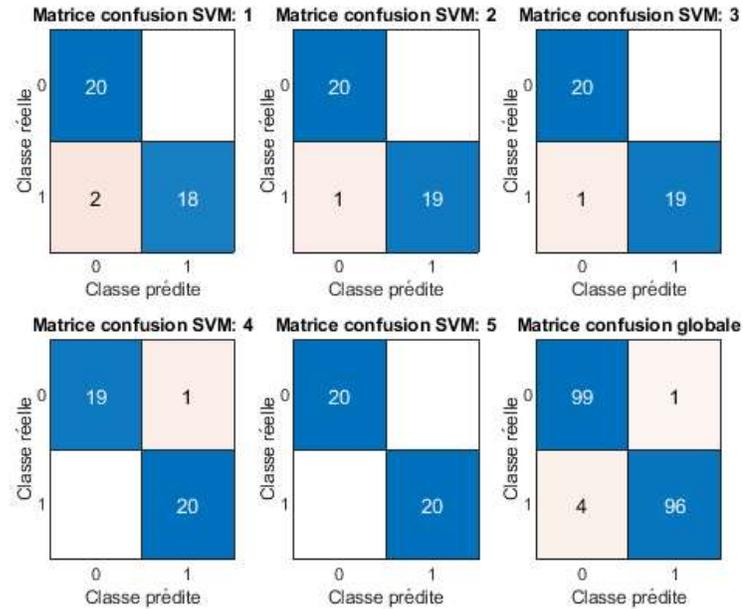
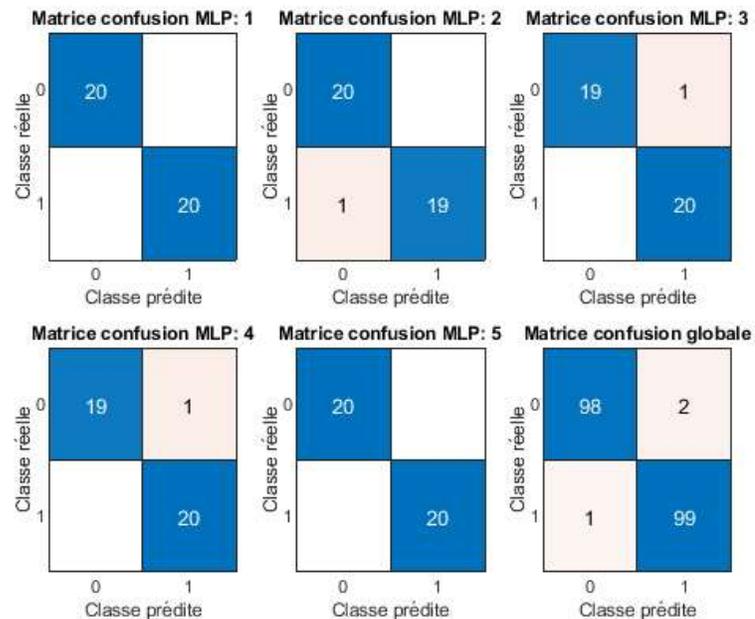


Tableau 5.11 Matrices de confusion de MLP pour la classification matérielle avec la base de données de l'Université de Bonn



## 5.4 COSIMULATION (JTAG) ET RESSOURCES MATÉRIELLES UTILISÉES

Le diagramme de la figure 5.26 ci-après représente l'architecture matérielle du système de détection de la crise d'épilepsie et son exécution sur la carte FPGA (la cosimulation JTAG). Pour tester cette architecture avec les deux bases de données, il faut juste téléverser le « bitstream » correspondant sur la puce de la carte via le bloc de cosimulation JTAG. Le tableau 5.12 ci-dessous illustre les ressources consommées par les deux modèles de classifications implémentés, à l'aide de l'outil Xilinx System Generator, sur la puce Artix-7 XC7A100T. La consommation des ressources matérielles est la même pour toutes les deux bases de données.

Tableau 5.12 Ressources matérielles consommées par l'architecture de détection proposée pour la puce Artix-7 XC7A100T de la Nexys-4

Sous-systèmes	Ressources			
	BRAMs (135)	DSPs (240)	LUTs (63400)	Registers (126800)
Calcul de la variance	0 (0%)	82 (34.2%)	1329 (2.1%)	630 (0.5%)
Synchronisation	0 (0%)	0 (0%)	145 (0.2%)	145 (0.1%)
Réseau de neurone (MLP)	0 (0%)	125 (52.1%)	14211 (22.4%)	32 (0.02%)
SVM	0 (0%)	22 (9.2%)	375 (0.6%)	0 (0%)
Ondelette Stationnaire (SWT)	0 (0%)	0 (0%)	13576 (21.4%)	1500 (1.2 %)
Total	0 (0%)	229 (95.4%)	29636 (46.7%)	2307 (1.8%)

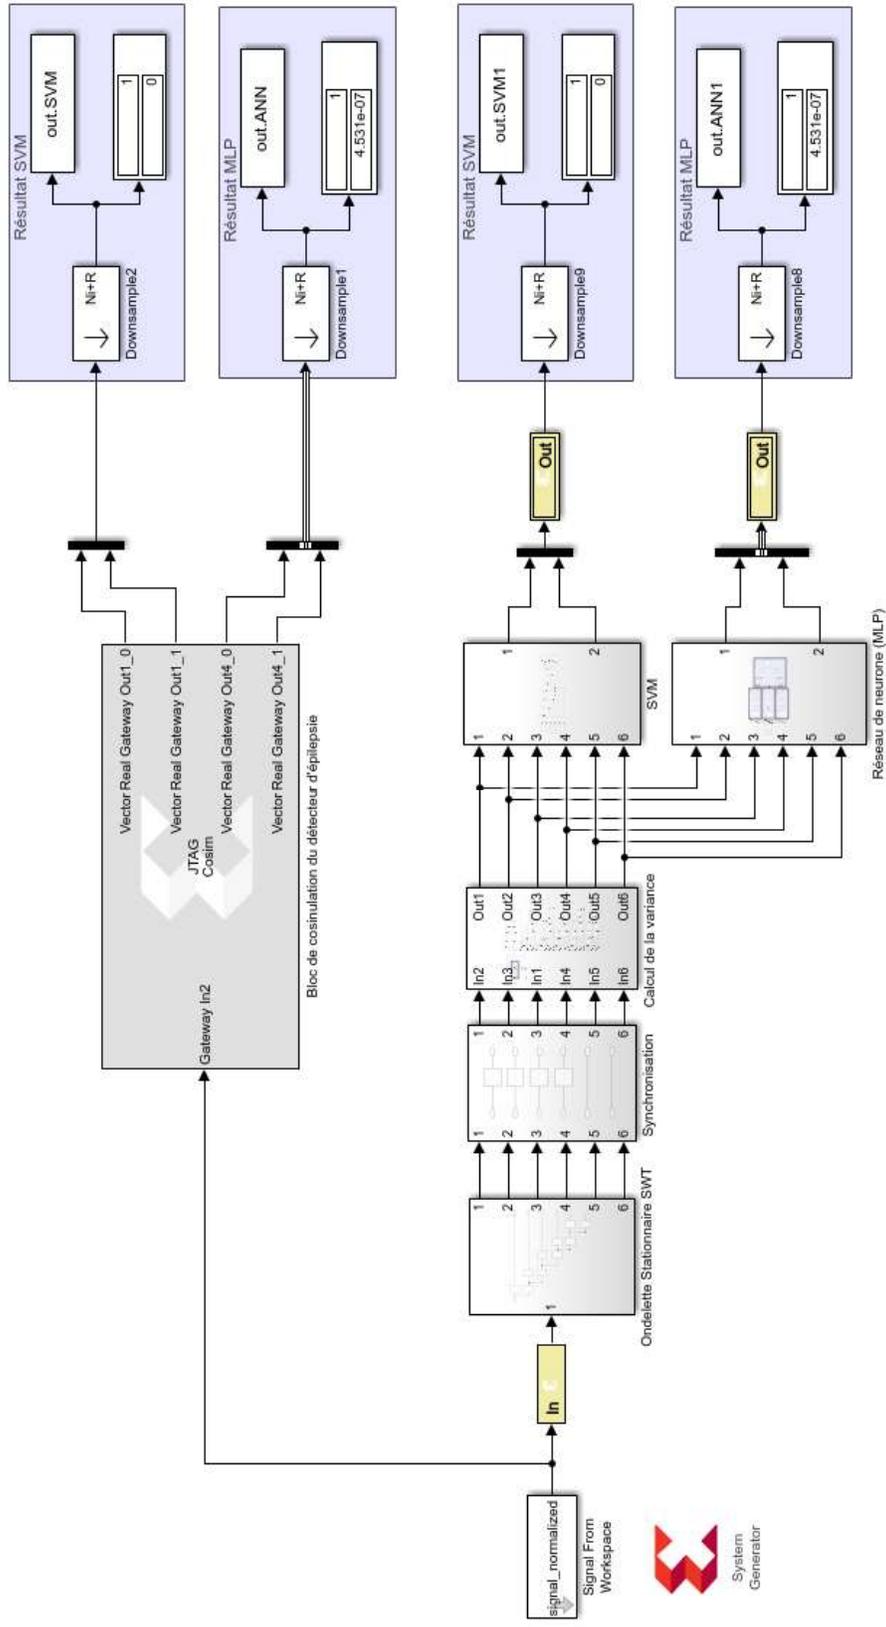


Figure 5.26 Architecture de base du détecteur et Cosimulation matériel (JTAG). Les blocs de sous-échantillonnage (« Downsample ») présentés dans les figures 5.3 et 5.26 sont utilisés pour ne prélever qu'une seule décision par segment de 2560 échantillons

## 5.5 DISCUSSIONS SUR LES DIFFÉRENTS RÉSULTATS DU CINQUIÈME CHAPITRE

### 5.5.1 Implémentation logicielle et matérielle

Les résultats des tableaux 5.4, 5.5 et 5.6, 5.7 comparent la performance (matrice de confusion) du logiciel par rapport au matériel pour les bases de l'hôpital pour enfants de Boston (CHB-MIT); et ceux de 5.8, 5.9 et 5.10, 5.11 comparent la performance pour la base de données de l'Université de Bonn. Bien qu'un taux d'exactitude de 100% du système de détection matérielle soit recherché, ce qui définira la fiabilité du système matériel développé, c'est sa précision ; c'est-à-dire sa capacité à reproduire de manière fiable le comportement du modèle prototype. Dans cette comparaison, l'objectif est d'obtenir une performance de prédiction matérielle (avec XSG) proche de la prédiction logicielle (avec Matlab).

Les résultats des implémentations matérielles des classificateurs SVM et MLP obtenus avec les bases de données CHB-MIT et de l'Université de Bonn montrent des performances extrêmement proches de celles des implémentations logicielles, soulignant ainsi l'efficacité de la démarche d'implémentation et le choix des formats de quantification des données.

Sur la base de données CHB-MIT, l'écart d'exactitude entre les implémentations logicielles et matérielles est inexistant pour le SVM (99% en logiciel contre 99% en matériel) et augmente de 0.5% pour le réseau MLP (99% en logiciel contre 99.5% en matériel). Ces faibles différences soulignent l'efficacité de l'implémentation matérielle, qui reste proche de la version logicielle en termes de précision. Il y a même amélioration de performance du côté matériel pour le MLP.

Pour la base de l'Université de Bonn, l'écart d'exactitude est aussi inexistant pour le SVM (97.5% en logiciel contre 97.5% en matériel), mais relativement faible pour le MLP, avec une perte de 0.5% (99% en logiciel contre 98.5% en matériel).

Ces résultats sont excellents car ils montrent que le SVM est très précis entre logiciel et matériel pour les deux bases de données utilisées. La précision est alors de 100% pour SVM. Par ailleurs, le MLP matériel est aussi précis comparativement au MLP logiciel avec un pas de  $\pm 0.5\%$ , soit ( $100\% \pm 0.5\%$ , pour le MLP matériel).

En somme, bien qu'une infirme perte d'exactitude ait été observée, les performances des modèles SVM et MLP en matériel sont globalement exceptionnelles, confirmant que l'implémentation matérielle constitue une alternative viable et efficace. Ces résultats illustrent la réussite de l'approche matérielle, avec des différences négligeables par rapport à l'implémentation logicielle, tout en offrant des avantages en termes de rapidité et d'efficacité énergétique.

### **5.5.2 Ressources matérielles utilisées**

Le système de détection matérielle de l'épilepsie consomme une quantité modérée de ressources disponibles sur la puce FPGA. Il consomme 2307 registres (Flip-Flops), soit 1.82% des registres disponibles, et 29636 LUTs, qui représentent 46.74% des LUTs disponibles sur la puce. Cependant, la consommation la plus élevée concerne les DSPs (processeurs des signaux numériques). En effet, le nombre de DSPs disponibles sur la puce Artix-7 XC7A100T est insuffisant pour réaliser le système de détection matérielle de l'épilepsie tel qu'il a été conçu. La consommation de DSPs augmente avec la taille du mot (le nombre de bits définis) dans les blocs de multiplication. Pour remédier à cette limitation, des blocs CLB (Configurable Logic Blocks) ont été utilisés à place de certains DSPs pour effectuer des opérations de multiplication tout en conservant une bonne résolution de conversion numérique. Cette optimisation a permis de réduire l'utilisation des DSPs à 229, soit 95.42% des DSPs disponibles sur la puce Artix-7 XC7A100T.

Les comparaisons des deux modèles développés dans la partie matérielle du projet montrent que le modèle SVM (Support Vector Machine) est moins gourmand en ressources matérielles que le réseau de neurones MLP (Multi-Layer Perceptron). En effet, le modèle SVM utilise seulement 22 DSPs (soit 9.17% des DSPs disponibles), contre 125 DSPs (soit 52.08%) pour le modèle MLP. Le modèle SVM consomme également 375 LUTs (soit 0.59% des LUTs disponibles), tandis que le réseau MLP utilise 14211 LUTs (soit 6.64%). De plus, le modèle SVM n'utilise aucun registre, alors que le MLP en utilise 32, soit 0.025% des registres disponibles. Le reste des ressources matérielles consommées

est utilisé par les autres blocs tels que le bloc de SWT, le bloc de Synchronisation et le bloc de Calcul de la variance.

En résumé, bien que le système de détection de l'épilepsie proposé soit efficace, il exige une quantité importante de DSPs, ce qui restreint l'utilisation de n'importe quelle puce FPGA pour son implémentation. Afin de contourner cette limitation sur la puce utilisée, des optimisations ont été appliquées, notamment en utilisant des blocs CLB à la place des DSPs pour certains blocs de multiplication. Cependant, une telle implémentation ne serait pas possible sur une puce FPGA à bas prix et faible consommation en puissance comme l'Artix-7 XC7A35T, qui dispose uniquement de 90 DSPs et 20800 LUTs. En comparaison, le modèle SVM est plus léger en termes de ressources matérielles que le modèle MLP, en raison de son faible recours aux DSPs, aux LUTs et aux registres, ce qui le rend plus adapté dans des contextes où les ressources matérielles sont limitées, comme c'est le cas pour la puce Artix-7 XC7A35T.



## CONCLUSION GÉNÉRALE

Dans ce projet, les deux systèmes de détection de la crise épileptique proposés ont été implémentés avec succès. Les différentes étapes de conception des systèmes de détection de l'épilepsie à partir de signaux EEG et des algorithmes d'apprentissage automatique ont été présentées et analysées. Les deux bases de données utilisées sont très adaptées pour recouvrir toutes les étiquettes utilisées tant par logiciel que par matériel dans ce projet ; car toutes les deux ont donné d'excellents résultats.

La réduction de dimensionnalité semble être très cruciale dans la détection efficace de l'épilepsie dépendamment du classificateur utilisé et la taille des vecteurs de caractéristiques. De même, l'ondelette stationnaire révèle être très efficace pour la détection par logiciel comme par matériel des crises d'épilepsie.

L'approche par ensemble de classificateurs est l'élément clé de ce projet qui ouvre la voie vers une méthode sûre pour des applications réelles et pratiques des systèmes de détection de l'épilepsie se basant sur le vote de majorité. Les systèmes proposés dans ce travail de recherche peuvent être vus comme un moyen de préparer des médecins-machines auxiliaires capable de diagnostiquer efficacement l'épilepsie. Il s'agit donc d'un détecteur robuste et adaptatif développé sur Matlab dont une portion du concept est reprise avec l'outil Xilinx System Generator (XSG) afin de confirmer la réalisation pratique du système de détection proposé. En d'autres termes, le système d'implémentation matérielle proposé cherche à montrer que l'analyse simultanée de plusieurs classificateurs est possible en matériel et rend, de ce fait, réalisable le vote de majorité en matériel. Il suffira d'ajouter un autre modèle de classification (par exemple, un autre modèle formé de SWT, de PCA et de SVM ou d'ANN) et d'un bloc de vote dans l'outil XSG pour compléter la chaîne de l'ensemble d'apprentissage en matériel et renforcer la détection matérielle de l'épilepsie.

L'implémentation matérielle s'est réalisée avec succès pour les deux bases de données utilisées et le canal FP1-F3 a permis d'avoir d'excellent résultat pour l'implémentation matérielle à l'aide de la base de données CHB-MIT. Toutefois, les ressources matérielles disponibles sur la puce Artix-7 XC7A100T restent une contrainte majeure à surmonter pour de futures applications pratiques. De ce fait, quoique réalisable sur Xilinx System Generator, la question d'utilisation efficace des ressources disponibles nous a fait opter pour un système dont les étapes de prétraitements sont toutes réalisées en logiciel. Cela nous a permis d'économiser du temps de conception, de réduire la complexité et la consommation excessive du système matériel. Plusieurs autres techniques ont été utilisées pour pallier à ce problème de consommation excessive des ressources de la puce utilisée, telles que le choix de la taille des vecteurs de caractéristiques, le type et le nombre de caractéristiques utilisés, l'utilisation des blocs CLBs à la place des DSPs, etc. Toutefois, l'utilisation judicieuse des ressources matérielles doit être encore explorée car davantage de traitements doivent être réalisés en matériel pour des architectures complexes.

Enfin, quoique tous les résultats obtenus sont très satisfaisants, des recherches supplémentaires sont nécessaires pour faire évoluer la détection de l'épilepsie au-delà d'une simple classification binaire. Il serait pertinent d'explorer de nouvelles pistes comme l'intégration d'autres algorithmes d'apprentissage automatique plus performants ou l'exploration d'autres techniques de l'intelligence artificielle comme l'apprentissage profond, afin d'améliorer l'exactitude du système. Par ailleurs, il sera crucial de développer un prototype qui exploite l'ensemble d'apprentissage proposé, en utilisant la prédiction par vote majoritaire (avec au moins trois modèles), pour détecter l'épilepsie à l'aide des dispositifs EEG portables basés sur les objets connectés (IoT). Ce défi, une fois relevé, pourrait ouvrir la voie à une détection robuste et fiable, en temps réel et à distance, des crises d'épilepsie.

## RÉFÉRENCES BIBLIOGRAPHIQUES

- Abdelhameed, A., & Bayoumi, M. (2021). A Deep Learning Approach for Automatic Seizure Detection in Children With Epilepsy. *Frontiers in Computational Neuroscience*, 15. <https://doi.org/10.3389/fncom.2021.650050>
- Abe, S. (2010). Feature Selection and Extraction. In: *Support Vector Machines for Pattern Classification. Advances in Pattern Recognition. Springer, London.* [https://doi.org/10.1007/978-1-84996-098-4\\_7](https://doi.org/10.1007/978-1-84996-098-4_7)
- Acharya, U. R., Fujita, H., Sudarshan, V. K., Bhat, S., & Koh, J. E. W. (2015). Application of entropies for automated diagnosis of epilepsy using EEG signals: A review. In *Knowledge-Based Systems* (Vol. 88, pp. 85–96). Elsevier B.V. <https://doi.org/10.1016/j.knosys.2015.08.004>
- Adeli, H., Ghosh-Dastidar, S., & Dadmehr, N. (2007). A Wavelet-Chaos Methodology for Analysis of EEGs and EEG Subbands to Detect Seizure and Epilepsy. *IEEE Transactions on Biomedical Engineering*, 54(2), 205–211. <https://doi.org/10.1109/TBME.2006.886855>
- Aggarwal, C. C. (2018). *Neural Networks and Deep Learning 1<sup>st</sup> E.* Springer International Publishing. <https://doi.org/10.1007/978-3-319-94463-0>
- Aghakhani, Y., Bagshaw, A. P., Bénar, C. G., Hawco, C., Andermann, F., Dubeau, F., & Gotman, J. (2004). fMRI activation during spike and wave discharges in idiopathic generalized epilepsy. In *Brain* (Vol. 127, Issue 5, pp. 1127–1144). <https://doi.org/10.1093/brain/awh136>
- Akut, R. (2019). Wavelet based deep learning approach for epilepsy detection. *Health Information Science and Systems*, 7(1). <https://doi.org/10.1007/s13755-019-0069-1>
- Alickovic, E., Kevric, J., & Subasi, A. (2018). Performance evaluation of empirical mode decomposition, discrete wavelet transform, and wavelet packed decomposition for automated epileptic seizure detection and prediction. *Biomedical Signal Processing and Control*, 39, 94–102. <https://doi.org/10.1016/j.bspc.2017.07.022>

- Ali, E., Angelova, M., & Karmakar, C. (2024). Epileptic seizure detection using CHB-MIT dataset: The overlooked perspectives. *Royal Society Open Science*, *11*(6). <https://doi.org/10.1098/rsos.230601>
- Ali, L. (2017). Sélection des mots clés basée sur la classification et l'extraction des règles d'association. <https://depot-e.uqtr.ca/id/eprint/8196/>
- Andrzejak, R. G., Lehnertz, K., Mormann, F., Rieke, C., David, P., & Elger, C. E. (2001). Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state. *Physical Review E - Statistical Physics, Plasmas, Fluids, and Related Interdisciplinary Topics*, *64*(6), 8. <https://doi.org/10.1103/PhysRevE.64.061907>
- Anuragi, A., Dilip Singh Sisodia, & Ram Bilas Pachori. (2022). Epileptic-seizure classification using phase-space representation of FBSE-EWT based EEG sub-band signals and ensemble learners \_ Elsevier Enhanced Reader. <https://doi.org/10.1016/j.bspc.2021.103138>
- ASPC. (2024, May). L'épilepsie au Canada. <https://www.canada.ca/fr/services/sante/publications/maladies-et-affections/epilepsie.html>
- Assia, Y., Radjah, E. K., & Benboudiaf, S. (2017). Intérêt du Suivi Thérapeutique Pharmacologique des Médicaments Antiépileptiques Classiques dans l'Adaptation Posologique et la Prévention de la Toxicité. <https://doi.org/10.13140/RG.2.2.22706.02241>
- Bahoura, M. (2014). FPGA implementation of high-speed neural network for power amplifier behavioral modeling. *Analog Integrated Circuits and Signal Processing*, *79*(3), 507–527. <https://doi.org/10.1007/s10470-014-0263-7>
- Bahoura, M., Ezzaidi, H., & Méthot, J. F. (2022). Filter group delays equalization for 2D discrete wavelet transform applications. *Expert Systems with Applications*, *200*. <https://doi.org/10.1016/j.eswa.2022.116954>
- Bahoura, M., & Simard, Y. (2012). Serial combination of multiple classifiers for automatic blue whale calls recognition. *Expert Systems with Applications*, *39*(11), 9986–9993. <https://doi.org/10.1016/j.eswa.2012.01.156>
- Begg, R., Daniel T H Lai, & M. Palaniswami. (2007). Computational intelligence in biomedical engineering. *CRC Press*. <https://doi.org/10.1201/9781420005899>

- Bigan, C. (1998). A system for neural networks detection and automatic identification of EEG epileptic events. *IEE Colloquium Intelligent Methods in Healthcare and Medical Applications*, 13–13. <https://doi.org/10.1049/ic:19981044>
- Blinowska, K. J., & Żygierewicz, J. (2021). *Practical Biomedical Signal Analysis Using MATLAB®*. CRC Press. <https://doi.org/10.1201/9780429431357>
- Boujelben, O., & Bahoura, M. (2018). Efficient FPGA-based architecture of an automatic wheeze detector using a combination of MFCC and SVM algorithms. *Journal of Systems Architecture*, 88, 54–64. <https://doi.org/10.1016/j.sysarc.2018.05.010>
- Bronzino, J. D., & Peterson, D. R. (2014). Principles of Electroencephalography. In *Biomedical Engineering Fundamentals* (pp. 921–932). CRC Press. <https://doi.org/10.1201/b15482-52>
- Cattan, G. (2019). De la réalisation d'une interface cerveau-ordinateur pour une réalité virtuelle accessible au grand public. <https://tel.archives-ouvertes.fr/tel-02357203>
- Cichosz, P. (2015). Data Mining Algorithms: Explained Using R. In *Data Mining Algorithms* (pp. 667–683). Wiley. <https://doi.org/10.1002/9781118950951.index>
- Deepa, B., & Ramesh, K. (2022, July 26). Preprocessed CHB-MIT SCALP EEG Database. <https://doi.org/10.21227/awcw-mn88>
- Diligent. (2024). Nexys 4 Reference Manual Nexys 4 Reference Manual-Digilent Reference. <https://digilent.com/reference/programmable-logic/nexys-4/reference-manual>. [https://digilent.com/reference/\\_media/reference/programmable-logic/nexys-4/nexys-4-0.png](https://digilent.com/reference/_media/reference/programmable-logic/nexys-4/nexys-4-0.png)
- Djeriri, Y. (2017). Les Réseaux de Neurones Artificiels. *September*. [https://www.researchgate.net/publication/319939107\\_Les\\_Reseaux\\_de\\_Neurones\\_Artificiels](https://www.researchgate.net/publication/319939107_Les_Reseaux_de_Neurones_Artificiels)
- Du, X., Song, W., & Munro, M. (2006). Semantics Recognition in Service Composition Using Conceptual Graph. *2006 IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology Workshops*, 295–298. <https://doi.org/10.1109/WI-IATW.2006.120>

- Elhosary, H., Zakhari, M. H., Elgammal, M. A., Kelany, K. A. H., Ghany, M. A. A. El, Salama, K. N., & Mostafa, H. (2021). Hardware Acceleration of High Sensitivity Power-Aware Epileptic Seizure Detection System Using Dynamic Partial Reconfiguration. *IEEE Access*, *9*, 75071–75081. <https://doi.org/10.1109/ACCESS.2021.3079155>
- Fatihah, C., Iliyasu, A. M., Abuhasel, K. A., Suciati, N., & Al-Qodah, M. A. (2014). Principal component analysis-based neural network with fuzzy membership function for epileptic seizure detection. *2014 10th International Conference on Natural Computation (ICNC)*, 186–191. <https://doi.org/10.1109/ICNC.2014.6975832>
- Fu, H., & Qi, K. (2022). Evaluation Model of Teachers' Teaching Ability Based on Improved Random Forest with Grey Relation Projection. *Scientific Programming*, 2022. <https://doi.org/10.1155/2022/5793459>
- Gaitatzis, A., Johnson, A. L., Chadwick, D. W., Shorvon, S. D., & Sander, J. W. (2004). Life expectancy in people with newly diagnosed epilepsy. *Brain*, *127*(11), 2427–2432. <https://doi.org/10.1093/brain/awh267>
- Gao, Y., Gao, B., Chen, Q., Liu, J., & Zhang, Y. (2020). Deep convolutional neural network-based epileptic electroencephalogram (EEG) signal classification. *Frontiers in Neurology*, *11*. <https://doi.org/10.3389/fneur.2020.00375>
- García-Gonzalo, E., Fernández-Muñiz, Z., Nieto, P. J. G., Sánchez, A. B., & Fernández, M. M. (2016). Hard-rock stability analysis for span design in entry-type excavations with learning classifiers. *Materials*, *9*(7). <https://doi.org/10.3390/ma9070531>
- Geethu, V., & Santhoshkumar, S. (2020). An Efficient FPGA Realization of Seizure Detection from EEG Signal Using Wavelet Transform and Statistical Features. *IETE Journal of Research*, *66*(3), 315–325. <https://doi.org/10.1080/03772063.2018.1491806>
- Ghazali, S., Alizadeh, M., Mazloum, J., & Baleghi, Y. (2022). Modified binary salp swarm algorithm in EEG signal classification for epilepsy seizure detection. *Biomedical Signal Processing and Control*, *78*. <https://doi.org/10.1016/j.bspc.2022.103858>
- Ghosh-Dastidar, S., Adeli, H., & Dadmehr, N. (2007). Mixed-Band Wavelet-Chaos-Neural Network Methodology for Epilepsy and Epileptic Seizure Detection. *IEEE Transactions on Biomedical Engineering*, *54*(9), 1545–1551. <https://doi.org/10.1109/TBME.2007.891945>

- Goldberger, A., Amaral, L., Glass, L., Hausdorff, J., Ivanov, P. C., Mark, R., Mietus, J. E., Moody, G. B., Peng, C. K., & Stanley, H. E. (2000). *Distributeur automatique PhysioBank*. <https://archive.physionet.org/cgi-bin/atm/ATM>
- Grace, P., Prince, K., Hemamalini, R. R., & Kumar, S. (2016). Epileptic seizure detection using EEG signals by means of stationary wavelet transforms (Vol. 9, Issue 4). <https://www.researchgate.net/publication/307969116>
- Guo, L., Rivero, D., Seoane, J. A., & Pazos, A. (2009). Classification of EEG signals using relative wavelet energy and artificial neural networks. *Proceedings of the First ACM/SIGEVO Summit on Genetic and Evolutionary Computation*, 177–184. <https://doi.org/10.1145/1543834.1543860>
- Guttag, J. (2010, June 9). Base de données EEG du cuir chevelu CHB-MIT. <https://physionet.org/content/chbmit/1.0.0/>
- Han, J., Micheline Kamber, & Jian Pei. (2012). *Data Mining Third Edition*. <https://doi.org/10.1016/C2009-0-61819-5>
- Hassan, A. R., Siuly, S., & Zhang, Y. (2016). Epileptic seizure detection in EEG signals using tunable-Q factor wavelet transform and bootstrap aggregating. *Computer Methods and Programs in Biomedicine*, 137, 247–259. <https://doi.org/10.1016/j.cmpb.2016.09.008>
- Hodel, J. (2022). Première crise épileptique et IRM. <https://neurologies.fr/premiere-crise-epileptique-et-irm-les-progres-de-lirm-anatomique-et-fonctionnelle-permettent-de-mieux-comprendre-les-crisis-et-leurs-origines/>
- Humairani, A., Atmojo, B. S., Wijayanto, I., & Hadiyoso, S. (2021). Fractal Based Feature Extraction Method for Epileptic Seizure Detection in Long-Term EEG Recording. *Journal of Physics: Conference Series*, 1844(1). <https://doi.org/10.1088/1742-6596/1844/1/012019>
- Hurri, J., Gävert, H., Särelä, J., & Hyvärinen, A. (1997). Librairie : FastICA. <https://research.ics.aalto.fi/ica/fastica/about.shtml>
- ICM. (2022, January). L'épilepsie : Causes, mécanismes biologiques, symptômes, diagnostics et traitements. <https://institutducerveau-icm.org/fr/epilepsie/>
- Ihle, M., Feldwisch-Drentrup, H., Teixeira, C. A., Witon, A., Schelter, B., Timmer, J., & Schulze-Bonhage, A. (2012). EPILEPSIAE - A European epilepsy database. *Computer Methods and Programs in Biomedicine*, 106(3), 127–138. <https://doi.org/10.1016/j.cmpb.2010.08.011>
- INSERM. (2018, March 1). Épilepsie. <https://www.inserm.fr/dossier/epilepsie/>

- Issaka, M. A. (2017). Analyse des signaux EEG pour la détection automatique des crises d'épilepsie par des méthodes paramétriques. <https://hal.science/tel-01504058>
- Jose, J. P., Sundaram, M., & Jaffino, G. (2020). FPGA Implementation of Epileptic Seizure Detection Using ELM Classifier. *2020 Sixth International Conference on Bio Signals, Images, and Instrumentation (ICBSII)*, 1–5. <https://doi.org/10.1109/ICBSII49132.2020.9167598>
- Kappel, S. L., Looney, D., Mandic, D. P., & Kidmose, P. (2017). Physiological artifacts in scalp EEG and ear-EEG. *Biomedical Engineering Online*, *16*(1), 103. <https://doi.org/10.1186/s12938-017-0391-2>
- Kay, S. M. (1993). Fundamentals of statistical signal processing. *Englewood Cliffs, N.J. : Prentice-Hall PTR*.
- Kay, S. M., & Marple, S. L. (1981). Spectrum analysis—A modern perspective. *Proceedings of the IEEE*, *69*(11), 1380–1419. <https://doi.org/10.1109/PROC.1981.12184>
- Kibria, H. B., & Matin, A. (2022). The Severity Prediction of The Binary And Multi-Class Cardiovascular Disease-A Machine Learning-Based Fusion Approach. <https://doi.org/10.48550/arXiv.2203.04921>
- Kramer, O. (2013). K-Nearest Neighbors (pp. 13–23). [https://doi.org/10.1007/978-3-642-38652-7\\_2](https://doi.org/10.1007/978-3-642-38652-7_2)
- Li, M., Chen, W., & Zhang, T. (2017). Classification of epilepsy EEG signals using DWT-based envelope analysis and neural network ensemble. *Biomedical Signal Processing and Control*, *31*, 357–365. <https://doi.org/10.1016/j.bspc.2016.09.008>
- Loiseau, P., Duché, B., & Loiseau, J. (1991). Classification of Epilepsies and Epileptic Syndromes in Two Different Samples of Patients. *Epilepsia*, *32*(3), 303–309. <https://doi.org/10.1111/j.1528-1157.1991.tb04656.x>
- Lyons, R. G. (2011). Understanding Digital Signal Processing Third Edition.
- Mallat, S. G. (1989). A Theory for Multiresolution Signal Decomposition: The Wavelet Representation. In *IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE: Vol. II* (Issue 7). Doi: 10.1109/34.192463.
- Manconi, A., Armano, G., Gnocchi, M., & Milanese, L. (2022). A Soft-Voting Ensemble Classifier for Detecting Patients Affected by COVID-19. *Applied Sciences (Switzerland)*, *12*(15). <https://doi.org/10.3390/app12157554>

- Marple, S. L., & Carey, W. M. (1989). Digital Spectral Analysis with Applications. *The Journal of the Acoustical Society of America*, 86(5), 2043–2043. <https://doi.org/10.1121/1.398548>
- Medani, T. (2016). Contribution à l'amélioration du modèle de source dans la méthode des éléments finis pour la résolution du problème direct en électroencéphalographie. <https://www.researchgate.net/publication/310830994>
- Meddah, K., Zairi, H., Bessekri, B., Cherrih, H., & Kedir-Talha, M. (2020). FPGA implementation of Epileptic Seizure detection based on DWT, PCA and Support Vector Machine. *2020 Second International Conference on Embedded & Distributed Systems (EDiS)*, 141–146. <https://doi.org/10.1109/EDiS49545.2020.9296466>
- Mula, M., & Monaco, F. (2011). Ictal and peri-ictal psychopathology. *Behavioural Neurology*, 24, 21–25. <https://doi.org/10.3233/BEN-2011-0314>
- Neligan, A., Bell, G. S., Johnson, A. L., Goodridge, D. M., Shorvon, S. D., & Sander, J. W. (2011). The long-term risk of premature mortality in people with epilepsy. *Brain*, 134(2), 388–395. <https://doi.org/10.1093/brain/awq378>
- Olokodana, I. L., Ludi, S., & Bryant, B. (2020). Kriging Methods to Exploit Spatial Correlations of EEG Signals for Fast and Accurate Seizure Detection in the IOMT. [https://digital.library.unt.edu/ark:/67531/metadc1707311/m2/1/high\\_res\\_d/OLOKODANA-DISSERTATION-2020.pdf](https://digital.library.unt.edu/ark:/67531/metadc1707311/m2/1/high_res_d/OLOKODANA-DISSERTATION-2020.pdf)
- Patnaik, L. M., & Manyam, O. K. (2008). Epileptic EEG detection using neural networks and post-classification. *Computer Methods and Programs in Biomedicine*, 91(2), 100–109. <https://doi.org/10.1016/j.cmpb.2008.02.005>
- Pittau, F., Grouiller, F., Spinelli, L., Seeck, M., Michel, C. M., & Vulliemoz, S. (2014). The role of functional neuroimaging in pre-surgical epilepsy evaluation. In *Frontiers in Neurology: Vol. 5 MAR*. Frontiers Media SA. <https://doi.org/10.3389/fneur.2014.00031>
- Proakis, J., & Manolakis, D. G. (2007). Digital signal processing: principles, algorithms, and applications, 4/E (Pearson Education India, Ed.).
- Rahman, R., Varnosfaderani, S. M., Makke, O., Sarhan, N. J., Asano, E., Luat, A., & Alhawari, M. (2021). Comprehensive Analysis of EEG Datasets for Epileptic Seizure Prediction. *2021 IEEE International Symposium on Circuits and Systems (ISCAS)*, 1–5. <https://doi.org/10.1109/ISCAS51556.2021.9401766>

- Reche, J. (2019). Nouvelle méthodologie hybride pour la mesure de rugosités sub-nanométriques. <https://tel.archives-ouvertes.fr/tel-02520554>
- Sahani, M. (2021). FPGA implementation of epileptic seizure detection using semisupervised reduced deep convolutional neural network. <https://www.sciencedirect.com/science/article/abs/pii/S1568494621005603>
- Saidi, A., Ben Othman, S., Kacem, W., & Ben Saoud, S. (2018). FPGA implementation of EEG signal analysis system for the detection of epileptic seizure. *2018 International Conference on Advanced Systems and Electric Technologies (IC\_ASET)*, 415–420. <https://doi.org/10.1109/ASET.2018.8379892>
- Sanei, S. (2013). Adaptive Processing of Brain Signals. Wiley. <https://doi.org/10.1002/9781118622162>
- Semmlow, J. L. (2004). Biosignal and Medical Image Processing : MATLAB-based applications.
- Shah, A. K., & Mittal, S. (2014). Invasive electroencephalography monitoring: Indications and presurgical planning. *Annals of Indian Academy of Neurology*, 17(SUPPL. 1). <https://doi.org/10.4103/0972-2327.128668>
- Shoeb, A., Edwards, H., Connolly, J., Bourgeois, B., Ted Treves, S., & Guttag, J. (2004). Patient-specific seizure onset detection. *Epilepsy and Behavior*, 5(4), 483–498. <https://doi.org/10.1016/j.yebeh.2004.05.005>
- Shoeb, A., & Guttag, J. (2010). Application of Machine Learning To Epileptic Seizure Detection. <https://icml.cc/Conferences/2010/papers/493.pdf>
- Shoeibi, A., Moridian, P., Khodatars, M., Ghassemi, N., Jafari, M., Alizadehsani, R., Kong, Y., Gorriz, J. M., Ramirez, J., Khosravi, A., Nahavandi, S., & Acharya, U. R. (2022). An overview of deep learning techniques for epileptic seizures detection and prediction based on neuroimaging modalities: Methods, challenges, and future works. In *Computers in Biology and Medicine* (Vol. 149). Elsevier Ltd. <https://doi.org/10.1016/j.compbiomed.2022.106053>
- Siuly, S., Li, Y., & Zhang, Y. (2016). Health Information Science EEG Signal Analysis and Classification Techniques and Applications. <http://www.springer.com/series/11944>
- Slimen, I. Ben, Boubchir, L., Mbarki, Z., & Seddik, H. (2020). EEG epileptic seizure detection and classification based on dual-tree complex wavelet transform and machine learning algorithms. *Journal of Biomedical Research*, 34(3), 151–161. <https://doi.org/10.7555/JBR.34.20190026>

- Sörnmo, & Laguna. (2005). Bioelectrical Signal Processing in Cardiac and Neurological Applications. *Elsevier*. <https://doi.org/10.1016/B978-0-12-437552-9.X5000-4>
- Stoica, P., & Moses, R. L. (1997). Introduction to Spectral Analysis.
- Subasi, A. (2007a). EEG signal classification using wavelet feature extraction and a mixture of expert model. *Expert Systems with Applications*, 32(4), 1084–1093. <https://doi.org/10.1016/j.eswa.2006.02.005>
- Subasi, A. (2007b). Selection of optimal AR spectral estimation method for EEG signals using Cramer-Rao bound. *Computers in Biology and Medicine*, 37(2), 183–194. <https://doi.org/10.1016/j.combiomed.2005.12.001>
- Subasi, A. (2019). Practical Guide for Biomedical Signals Analysis Using Machine Learning Techniques: A MATLAB Based Approach. <https://doi.org/10.1016/C2018-0-02414-7>
- Subasi, A., & Gursoy, M. I. (2010). EEG signal classification using PCA, ICA, LDA and support vector machines. *Expert Systems with Applications*, 37(12), 8659–8666. <https://doi.org/10.1016/j.eswa.2010.06.065>
- Subramaniam, N. P. (2021, June 15). Électrodes humides et sèches pour EEG. <https://sapienlabs.org/lab-talk/wet-and-dry-electrodes-for-eeeg/>
- Trinka, E., Rainer, L. J., Granbichler, C. A., Zimmermann, G., & Leitinger, M. (2023). Mortality, and life expectancy in Epilepsy and Status epilepticus—current trends and future aspects. *Frontiers in Epidemiology*, 3. <https://doi.org/10.3389/fepid.2023.1081757>
- Usman, S. M., Khalid, S., Akhtar, R., Bortolotto, Z., Bashir, Z., & Qiu, H. (2019). Using scalp EEG and intracranial EEG signals for predicting epileptic seizures: Review of available methodologies. In *Seizure* (Vol. 71, pp. 258–269). W.B. Saunders Ltd. <https://doi.org/10.1016/j.seizure.2019.08.006>
- Van de Velden, D., Stier, C., Kotikalapudi, R., Heide, E. C., Garnica-Agudelo, D., & Focke, N. K. (2023). Comparison of Resting-State EEG Network Analyses With and Without Parallel MRI in Genetic Generalized Epilepsy. *Brain Topography*, 36(5), 750–765. <https://doi.org/10.1007/s10548-023-00977-6>
- Wei, Z., Zou, J., Zhang, J., & Xu, J. (2019). Automatic epileptic EEG detection using convolutional neural network with improvements in time-domain. *Biomedical Signal Processing and Control*, 53. <https://doi.org/10.1016/j.bspc.2019.04.028>

- Wickramasuriya, D. S., Wijesinghe, L. P., & Mallawaarachchi, S. (2015). Seizure prediction using Hilbert Huang Transform on field programmable gate array. *2015 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, 933–937. <https://doi.org/10.1109/GlobalSIP.2015.7418334>
- Wijayanto, I., Hadiyoso, S., Aulia, S., & Atmojo, B. S. (2020). Detecting Ictal and Interictal Condition of EEG Signal using Higuchi Fractal Dimension and Support Vector Machine. *Journal of Physics: Conference Series*, 1577(1). <https://doi.org/10.1088/1742-6596/1577/1/012016>
- Wołczowski, A., & Zdunek, R. (2017). Electromyography and mechanomyography signal recognition: Experimental analysis using multi-way array decomposition methods. *Biocybernetics and Biomedical Engineering*, 37(1), 103–113. <https://doi.org/10.1016/j.bbe.2016.09.004>
- Wong, S., Simmons, A., Rivera-Villicana, J., Barnett, S., Sivathamboo, S., Perucca, P., Ge, Z., Kwan, P., Kuhlmann, L., Vasa, R., Mouzakis, K., & O'Brien, T. J. (2023). EEG datasets for seizure detection and prediction— A review. *In Epilepsia Open* (Vol. 8, Issue 2, pp. 252–267). John Wiley and Sons Inc. <https://doi.org/10.1002/epi4.12704>
- Wu, D., Wang, Z., Jiang, L., Dong, F., Wu, X., Wang, S., & Ding, Y. (2019). Automatic epileptic seizures joint detection algorithm based on improved multi-domain feature of cEEG and spike feature of aEEG. *IEEE Access*, 7, 41551–41564. <https://doi.org/10.1109/ACCESS.2019.2904949>
- Xiong, Z., Wang, H., Zhang, L., Fan, T., Shen, J., Zhao, Y., Liu, Y., & Wu, Q. (2021). A study on seizure detection of eeg signals represented in 2d. *Sensors*, 21(15). <https://doi.org/10.3390/s21155145>
- Zairi, H., Meddah, K., Cherrih, H., Bessekri, B., & Talha, M. K. (2022). FPGA-based Neural Network System for Epileptic Seizure Detection. *2022 2nd International Conference on Advanced Electrical Engineering (ICAEE)*, 1–6. <https://doi.org/10.1109/ICAEE53772.2022.9962009>
- Zeng, M., Zhang, X., Zhao, C., Lu, X., & Meng, Q. (2021). GRP-DNet: A gray recurrence plot-based densely connected convolutional network for classification of epileptiform EEG. *Journal of Neuroscience Methods*, 347. <https://doi.org/10.1016/j.jneumeth.2020.108953>
- Zhou, Z.-H. (2021). Linear Models. In *Machine Learning* (pp. 57–77). Springer Singapore. [https://doi.org/10.1007/978-981-15-1967-3\\_3](https://doi.org/10.1007/978-981-15-1967-3_3)

Zhu, F., Gao, J., Yang, J., & Ye, N. (2022). Neighborhood linear discriminant analysis. *Pattern Recognition*, 123.  
<https://doi.org/10.1016/j.patcog.2021.108422>

Zippo, A. G. (2014). *Neuronal Ensemble Modeling and Analysis with Variable Order Markov Models*. Contents.  
<https://www.researchgate.net/publication/225032422>