

République Algérienne Démocratique et Populaire  
Ministère de l'enseignement supérieur et de la recherche scientifique



Université Abou Bekr Belkaid  
FACULTE DE TECHNOLOGIE  
DEPARTEMENT DE GENIE BIOMEDICAL  
LABORATOIRE DE RECHERCHE EN GENIE  
BIOMEDICAL



## THÈSE

Pour obtenir le titre de  
**Docteur en Génie Biomédical**  
De l'université de Tlemcen, Faculté de Technologie  
Spécialité : "Electronique Biomédicale"

*Présentée par*

**BELAID BOUMEDYEN**

---

**Développement d'outils d'analyse corrélative entre le signal  
Electroencéphalogramme (EEG) et le signal Electrocardiogramme (ECG) pour  
l'aide au diagnostic médical**

---

Devant le jury composé de :

M. DEBBAL Sidi Mohammed

*Professeur, Université Abou-Bekr Belkaid de Tlemcen*

Président

M. HADJ SLIMANE Zine-Eddine

*Professeur, Université Abou-Bekr Belkaid de Tlemcen*

Directeur de Thèse

M. Djebbari Abdelghani

*MCA, Université Abou-Bekr Belkaid de Tlemcen*

Examineur

Mme. Slimane Zohra

*MCA, Centre Universitaire BelhadjBouchaib de Ain Temouchent*

Examinatrice

# Remerciement

Je tiens à remercier avant tous, le bon Dieu qui ma a donné la force et la patience tout au long de la préparation de cette thèse.

Je tiens spécialement à remercier mon directeur de thèse Mr **HADJ SLIMANE Zine-Eddine** Professeur à la Faculté de Technologie de Tlemcen et lui exprimer ma gratitude pour sa disponibilité et son soutien pendant ces années de recherche. Je le remercie également pour ses remarques constructives qu'il m'a fournies ainsi que pour ses précieux conseils afin de mener mes travaux vers leur aboutissement. Ce modeste travail a été réalisé au sein du laboratoire de recherche du Génie Biomédical relevant du Département de Génie Électrique et Électronique de la Faculté de Technologie auprès de l'Université Abou-bekr Belkaïd de Tlemcen, qui m'a favorisé au mieux les conditions à une recherche fructueuse.

J'adresser ma plus vive gratitude aux membres de mon jury. Mr **Sidi Mohammed DEBBAL** Professeur à l'université de Tlemcen, Mr **DJEBBARI Abdelghani** MCA à l'université de Tlemcen, ainsi que Mme **Slimane Zohra** MCA au centre universitaire Ain Temouchent, qui ont eu la gentillesse d'accepter la lourde tâche de rapporteurs auprès du jury; je les remercie tout particulièrement pour l'attention et le temps qu'ils y ont consacrés pour lire et évaluer ce manuscrit.

Mes pensées vont également vers M<sup>elle</sup> **Naima HABIBES** MAA à l'université de Tlemcen , Mr **BENHABIB Choukri** MCA à l'université de Tlemcen et Mr **MELIANI Sidi Mohammed** MCA à l'université de Tlemcen , qui étaient toujours à l'écoute et qui étaient surtout présent à l'appel quand j'en avais besoin de leurs aide scientifique ainsi que leur soutien moral de ce fait je ne les remercie jamais assez pour leurs qualités scientifiques ainsi que humaines.

Je remercie également l'ensemble des personnes avec qui j'ai partagé mes années de recherches au sein du laboratoire de génie biomédical qui était un agréable de travailler en leur compagnie.

Merci également à toutes les personnes dont l'amitié m'a apporté des moments de réconfort et distraction nécessaires lors du déroulement d'un tel projet

Je ne remercierai jamais assez mes parents qui m'ont prouvé une fois de plus leur présence, leur amour et leur soutien.

Que ceux que j'ai oubliés dans cette longue litanie me pardonnent.

Enfin j'adresse mes remerciements les plus sincères à tous ceux qui ont contribués de près ou de loin à la concrétisation de ce travail.

**Boumedyen BELAID**

# Dédicace

---

*Je dédie ce travail à :*

*La mémoire de mon très cher grand-père **CHIKHI DJELLOUL**,*

*Mes parents aucun hommage ne pourrait être à la hauteur de L'amour et de l'affection dont ils ne cessent de me combler. Je vous dédie ce travail en témoignage de mon profond amour. Puisse Dieu, le tout puissant, vous préserver et vous accorder santé, longue vie et bonheur.*

*Mon petit frère, mes adorables sœurs.*

*A ma petite douce nièce Lina.*

*A ma très chère Lasgaa N, depuis que je t'ai connu, tu n'as cessé de me soutenir et de m'épauler, tu me voulais toujours meilleur, je te prie de trouver dans ce travail l'expression de mon estime et mon sincère attachement.*

*A mes chères Karima et Houria En témoignage de l'attachement et de*

*L'affection que je porte pour vous.*

*Toute ma famille,*

*A tous mes amis de proches : Soufiane, Yahia, Hicham et Mohammed,*

*Tous mes professeurs et ceux qui ont contribué à la réussite de ce travail*

*Qu'ils trouvent dans ce modeste travail l'expression de mon Affection*

***BOUMEDYEN***

INTRODUCTION GENERALE.....	1
----------------------------	---

## **Chapitre I : Anatomie cardio-cérébrale**

I.1. Introduction.....	5
I.2. Anatomie cérébrale.....	6
I.2.1. Potentiel cérébral et Potentiel d'action.....	8
I.2.2. Electroencéphalographie (EEG).....	10
I.2.3. Les capteurs.....	12
I.2.4. Rythmes cérébraux.....	15
I.2.5. Technique d'examen.....	16
I.3. Anatomie Cardique.....	17
I.3.1. La circulation sanguine.....	19
I.3.2. Physiologie de contraction du cœur.....	21
I.3.3. Chronologie de l'excitation électrique du cœur.....	23
I.3.4. Electrocardiogramme.....	24
I.3.5. Caractéristiques du signal électrocardiogramme (ECG).....	26
I.3.5.1. Rythme Cardiaque.....	26
I.3.5.2. Caractéristiques fréquentielles.....	26
I.3.5.3. Caractéristiques des ondes et des segments du signal ECG.....	26
I. 3.6. Technique d'enregistrement de l'ECG.....	29
I.3.6.a. Dérivations électrocardiographiques standards D I, II, III d'Einthoven.....	30
I.3.6.b. Les dérivations unipolaires de Goldberger.....	30
I.3.6.c. Les dérivations unipolaires précordiales de Wilson.....	31

I.3.7. Artefacts visibles sur les signaux physiologiques.....	32
I.3.7.a. Bruit non physiologique.....	32
I.3.7.b. Bruits physiologique.....	33
I.3.8. Relation cœur cerveau.....	34
I.4. Conclusion.....	36
 <b>Chapitre II : Etude et réalisation d'un système de monitoring en temps réel et d'analyse spectrale des signaux EEG et ECG pour la détection des crises d'épilepsie.</b>	
II.1. Introduction.....	37
II.2. Architecture de système et circuit d'acquisition.....	38
II.2.1. Circuit Analogique du signal ECG.....	38
II.2.1.a. L'amplificateur d'instrumentation.....	39
II.2.1.b. Suiveur.....	43
II.2.1.c. Filtre passe Haut.....	44
II.2.1.d. Amplificateur.....	44
II.2.1.e. Filtre passe bas.....	45
II.2.1.f. Circuit d'offset.....	46
II.2.2. Circuit Analogique EEG.....	46
II.2.2.a. L'amplificateur d'instrumentation.....	47
II.2.2.b. Circuit de rejection mode commun.....	48
II.2.2.c. Filtre Passe Bande.....	48
II.2.2.d. Amplificateur.....	49
II.2.2.e. Circuit d'offset.....	50
II.2.3. Circuit d'alimentation.....	50
II.2.4. Carte Arduino.....	50
II.2.4.a. Les avantages.....	52

II.2.4.b. Adaptation de l'Arduino pour notre Application.....	53
II.2.5. Module Bluetooth.....	55
II.2.6. Module Radio fréquence XBee.....	57
II.2.7. Terminal et Interface Graphique sur PC.....	58
II.2.8. Interface Graphique sur PC.....	59
II.2.9. Afficheur LCD graphique 128*64.....	60
II.2.10. Tracés et analyses fréquentielles des signaux acquis sur l'interface.....	61
II.2.11. Densité spectrale de puissance.....	65
II.2.12. Représentation temps-fréquence et temps-échelle.....	66
II.2.12.a. Transformée de Fourier a court-terme.....	66
II.2.12.b. Transformée en ondelettes continues.....	67
II.2.13. Tracés et analyses fréquentielles des signaux acquis sur l'Arduino et l'afficheur LCD.....	69
II.5. Conclusion.....	73

### **Chapitre III :**

#### **Etude de l'influence des crises d'épilepsie sur les signaux Electroencéphalogramme (EEG) et Electrocardiogramme (ECG)**

III.1. Introduction.....	75
III.2. Travaux réalisés sur la détection des crises d'épilepsie.....	76
III.3. Description de la base de données.....	77
III.4. Réseaux de neurones artificiels (RNA).....	79
III.4.1. Historique.....	80
III.4.2. Propriétés des réseaux de neurones.....	84
III.4.3. Apprentissage du réseau de neurones.....	84

III.5. K le plus proche voisin (KNN).....	87
III.6. Description de la méthode Proposée.....	88
III.6.1.Extraction des Paramètres.....	90
III.6.2. Apprentissage et classification.....	91
III.6.2.1. Phase d'apprentissage du Réseau de neurones.....	91
III.6.2.2. Phase d'apprentissage du KNN.....	93
III.6.3. Phase de test.....	94
III.7. Résultats et interprétation.....	96
III.7.1. Résultats avec réseau de neurones artificiel.....	96
III.7.2. Résultats avec le classifieur KNN.....	101
III.8. Conclusion.....	103

**Chapitre IV : Etude d'un module de détection des crises d'épilepsie Basé sur les paramètres des signaux EEG et ECG**

IV.1. Introduction.....	105
IV.2. Transformée en ondelette.....	106
IV.2.1. Transformée en ondelette continue.....	108
IV.2.2. Transformée en ondelette discrète.....	108
IV.3. Caractérisation de la crise d'épilepsie.....	109
IV.3.1. Décomposition de l'ondelette continue.....	109
IV.3.2. Densité spectrale de puissance.....	110
IV.3.3. Transformé de Fourier à court terme.....	111
IV.3.4. Entropie.....	113
IV.3.4. Cohérence quadratique.....	114
IV.4. Description de la méthode proposée.....	115
IV.4.1. Décomposition en ondelette discrète.....	116

IV.4.2. Extraction des paramètres.....	119
IV.4.3. Algorithme de classification.....	123
IV.4.3.1. Réseaux de neurones artificiels.....	124
IV.4.3.2. Arbre de décision.....	124
IV.4.4. Apprentissage supervisé et classification.....	125
IV.5. Résultats et interprétation.....	126
IV.5.1. Résultats avec réseau de neurones artificiel.....	126
IV.5.2. Résultats obtenus en utilisant l'arbre de décision.....	128
IV.6. Conclusion.....	133

**Chapitre V : Approche pour la prédiction des crises d'épilepsie basée sur la corrélation entre les paramètres du signal ECG et du signal EEG**

V.1. Introduction.....	135
V.2. Travaux réalisés sur la prédiction des crises d'épilepsie.....	136
V.3. Méthode.....	137
V.3.1. Base de données.....	137
V.3.2. Description de la méthode proposée.....	138
V.3.2.1. Détection des ondes ECG (fin de l'onde T et début l'onde P).....	139
V.3.2.2. Détection de l'intervalle TP.....	140
V.3.2.3. Segmentation des signaux EEG.....	140
V.3.2.4. Mesure des Energie de l'intervalle TP et les segments EEG.....	141
V.3.2.5. Corrélation entre les énergies.....	141
V.4. Résultats et discussion.....	143
V.5. Conclusion.....	154
CONCLUSION GENERALE.....	155



# Liste des Figures

Figure I.1 : Système nerveux central, vue Sagittale.....	6
Figure I.2 : Lobes et scissures du cortex.....	7
Figure I.3 : Cerveau de l'être humain, vue frontale à gauche, vue coronale à droite.....	7
Figure I.4 : Le neurone et ses constituants.....	9
Figure I.5 : Propagation de l'influx nerveux.....	9
Figure I.6 : Potentiel d'Action.....	10
Figure I.7 : (A) cellule pyramidale avec potentiels postsynaptiques excitateurs et potentiels post-synaptiques inhibiteurs, (B) Dipôle représentant un champ de charge.....	11
Figure I.8 : Le premier électroencéphalogramme à un canal chez un humain.....	11
Figure I.9 : (A) système d'électrode international 10-20 pour 75 électrodes. (B) système d'électrode international 10-20 pour 21 électrodes.....	12
Figure I.10 : Electrodes conventionnelles.....	13
Figure I.11 : Electrodes aiguilles.....	13
Figure I.12 : Electrodes cupules.....	13
Figure I.13 : Exemple de d'enregistrement de 5 seconds d'un signal EEG multicanaux réel.....	14
Figure I.14 : Ondes cérébrales normales typiques dans l'EEG .....	15
Figure I.15 : Position du cœur dans la cage thoracique.....	18
Figure I.16 : Vue antérieure du cœur et des principaux vaisseaux sanguins.....	18
Figure I.17 : Coupe frontale du cœur en vue antérieure, montrant les structures internes.....	19
Figure I.18 : Les couches de la paroi du cœur et les membranes péricardiques.....	21
Figure I.19 : potentiel d'action cardiaque.....	21
Figure I.20: la Voie de conduction du cœur.....	23

Figure I.21 : Système de conduction du cœur. À gauche : Représentation anatomique du cœur humain avec les zones du système de conduction. Droite : Les potentiels d'action.....	24
Figure I.22 : Séquence d'excitation cardiaque dans le cas d'une Propagation normale de l'activité électrique dans le cœur.....	25
Figure I.23 : Représentation d'un signal ECG typique avec la notation des différentes ondes et intervalles.....	28
Figure I.24 : Dérivations d'Einthoven.....	30
Figure I.25 : Dérivation unipolaire de Goldberger.....	31
Figure I.26 : Dérivations unipolaires précordiales de Wilson.....	32
Figure I.27 : Exemple d'un signal ECG réel induit par 50 Hz avec l'artefact de la ligne de base.....	33
Figure I.28 : Exemple d'un signal EEG interrompu par une activité haute fréquence associé avec l'effet de mastication.....	33
Figure I.29 : Régulation nerveuse du battement et de la force de contraction.....	35
Figure II.1 : Schéma Bloc de Système.....	38
Figure II.2 : Schéma Bloc du circuit analogique pour la détection du signal ECG.....	39
Figure II.3 : Schéma Electrique du circuit pour une dérivation d'ECG.....	39
Figure II.4 : Schéma équivalent de la tension mode commun et différentielle .....	40
Figure II.5: Schéma équivalent d'un amplificateur différentiel.....	41
Figure II.6: Structure d'un amplificateur d'instrumentation.....	42
FigureII.7 : Schéma électrique d'un amplificateur d'instrumentation de type INA114.....	43
FigureII.8 : Diagramme de Bode du filtre RC.....	44
FigureII.9 : Diagramme de Bode du filtre passe bas Sallen Key.....	45
FigureII.10 : Schéma Bloc de circuit analogique de l'EEG.....	46
FigureII.11 : Schéma électrique du Circuit de détection du signal EEG.....	47
FigureII.12 : Diagramme de Bode du filtre passe bas.....	48

FigureII.13 : Diagramme de Bode du filtre passe haut.....	49
FigureII.14 : Schéma électrique de l'alimentation.....	50
FigureII.15 : Structure de la liaison de la carte Arduino avec PC et le module Bluetooth.....	51
FigureII.16 : Présentation d'une carte Arduino UNO.....	51
FigureII.17 : Structure du Programme Arduino.....	52
FigureII.18 : Organigramme du programme de numérisation du signal.....	54
FigureII.19: Schéma de liaison l'ensemble Arduino,XBee et PC.....	58
Figure II.20: Tracé des signaux EEG & ECG sur un Smartphone.....	58
Figure II.21 : Face principale de l'interface graphique. ....	59
Figure II.22: Tracer des Signaux EEG&ECG sur l'interface graphique.....	60
Figure II.23 : Spécifications d'afficheur LCD graphique 128*64.....	61
Figure II.24: Tracés des signaux ECG pour le sujet 1 et 2 avec leurs spectres.....	62
Figure II.25: Tracés des signaux ECG filtrés pour le sujet 1 et 2 avec leurs spectres correspondants.....	63
Figure II.26 : Tracés des signaux EEG pour le sujet 1 et 2 avec leurs spectres.....	64
Figure II.27 :Tracés des signaux EEG filtrés pour le sujet 1 et 2 avec leurs spectres correspondants.....	64
Figure II.28 : Tracés de la densité spectral de puissance pour les signaux EEG et ECG.....	66
Figure II.29: Tracés des transformées de Fourier à court terme pour les deux signaux.....	67
Figure II.30 : Tracés des ondelettes de base avec leurs spectres.....	68
Figure II.31: Tracés des Transformée en ondelettes continues pour les signaux EEG et ECG..	69
FigureII.32 : Tracés des signaux EEG et ECG sur l'afficheur LCD graphique avec leurs spectres et fréquences dominantes correspondants calculés par la carte Arduino.....	70
Figure II.33: Cohérence entre les signaux EEG et ECG de notre système.....	72
Figure II.34 : Cohérence entre l'EEG et le signal ECG d'un patient sans crise d'épilepsie.....	72
Figure II.35 : Cohérence entre l'EEG et le signal ECG d'un patient avec crise d'épilepsie.....	72

Figure III.1 : Enregistrement simultané du signal ECG et EEG.....	79
Figure III.2 : Composants essentiels d'un neurone représentés sous forme simplifiée.....	80
Figure III.3 : Modèle de Mc Culloch et Pitts.....	81
Figure III.4 : Structure multicouche (MLP).....	82
Figure III.5 : Différentes formes de la fonction d'activation.....	83
Figure III.6 : Apprentissage supervisé.....	85
Figure III.7 : Apprentissage non supervisé.....	85
Figure III.8 : Fonction d'erreur avec minimum local et absolu.....	87
Figure III.9 : Un objet est classé par un vote majoritaire de ses voisins.....	88
Figure III.10 : Schéma bloc du processus de détection des crises.....	89
Figures III.11 : Histogramme de la classification pour le réseau de neurones artificiels (ANN)...	98
Figure III.12 :Performance des différentes topologies MLP3 et LMPE3 durant la phase d'apprentissage.....	99
Figure III.13 : Apprentissage et validation des performances des structures MLP3 et MLPE3.....	101
Figures III.14 : Histogramme de la classification pour les classifieurs KNN et RNA.....	103
Figure IV.1 : Pavage temps-fréquence pour la transformée en ondelette discrète.....	108
Figure IV.2 : Transformée en ondelettes continues pour deux segments EEG.....	109
Figure IV.3 : Transformée en ondelettes continues pour deux segments ECG.....	110
Figure IV.4 : Densité spectral de puissance pour les deux segment EEG.....	111
Figure IV.4 : Densité spectral de puissance pour les deux segment ECG.....	111
Figure IV.5 : Transformées de Fourier à court terme pour les deux Segments EEG non épileptiques.....	112

Figure IV.6 : Transformées de Fourier à court terme pour les deux Segments ECG non épileptique.....	113
Figure IV.7 : Entropie calculée pour les deux segments à travers tous les canaux.....	114
Figure IV.8 : Moyenne de la cohérence quadratique calculée pour les deux segments à travers tous les canaux.....	115
Figure IV.9 : Schéma bloc du processus de détection des crises.....	115
Figure IV.10 : décomposition en ondelettes discrète à 4 niveaux.....	117
Figure IV.11 : exemple de décomposition en ondelette discrète a 4 niveaux.....	118
Figure IV.12 : exemple de décomposition en ondelette discrète a 4 niveaux.....	119
Figure IV.13 : exemple de Energie calculée pour deux segments.....	121
Figure IV.14 : Exemple de l'écart type calculée pour deux segments.....	122
Figure IV.15 : Cohérence calculée entre les coefficients des signaux EEG et ECG.....	123
Figure IV.16 : Représentation de l'arbre de décision.....	125
Figure IV.17 : Apprentissage et validation des performances du réseau <i>RNA – D1</i> .....	127
Figure IV.18 : Erreur de classification par l'arbre de décision.....	129
Figure IV.19 : Histogramme des paramètres les plus importants.....	129
Figure IV.20 : Moyenne de l'importance de chaque paramètre sur les 24 canaux.....	130
Figure IV.21: Arbre de décision pour les paramètres $x_6$ et $x_7$ .....	131
Figure IV.22: Histogramme du taux de classification pour chaque détail et approximation utilisés par le classifieur RNA et AD.....	132
FigureV.1 : Exemple d'enregistrement des signaux EEG et ECG annoté.....	138
FigureV.2 : Schéma Bloc de l'algorithme proposé.....	139
Figure V.3 : Extraction et calcule des énergies à partir des signaux ECG et EEG.....	140
FigureV.4 : Corrélation entre les signaux EEG et ECG calculée sur une période de 78 secondes prise 20 minutes et 5 minutes avant l'apparition des crises d'épilepsie.....	143

Figure V.5 : Exemple d'une série simultanée réelle des énergies des intervalles T-P et segments EEG avec leurs diagrammes de dispersion correspondant. Les coefficients de Pearson et de Spearman sont calculés pour le canal 19 (P7-T7), 20 minutes avant la crise.....	144
Figure V.6 : Exemple d'une série simultanée réelle des énergies des intervalles T-P et segments EEG avec leurs diagrammes de dispersion correspondant. Les coefficients de Pearson et de Spearman sont calculés pour le canal 19 (P7-T7), 5 minutes avant la crise.....	144
Figure V.7: Résultats de corrélation entre les énergies obtenues à partir des enregistrements 1 à 4 à travers tous les canaux du signal EEG (avec et sans crises épileptiques).....	145
Figure V.8: Coefficient de corrélation de Pearson représenté en termes de médiane et d'écart-type des enregistrements 1 à 4 de tous les canaux du signal EEG (5 et 20 minutes avant la crise).....	147
Figure V.9: Coefficient de corrélation de Spearman représenté en termes de médiane et d'écart-type des enregistrements 1 à 4 de tous les canaux du signal EEG (5 et 20 minutes avant la crise).....	147
Figure V.10: Erreur de classification par l'algorithme de l'arbre de décision.....	148
Figure V.11: Taux de prédiction pour chaque Nombre d'arbre.....	148
Figure V.12: Structure de l'arbre de décision.....	150
Figure V.13: Histogramme des canaux les plus importants dans le process de prédiction.....	150
Figure V.14 : Représentation chronologique des étapes utilisées pour identifier la corrélation dans le domaine fréquentiel entre les signaux ECG et EEG avant et pendant la crise.....	151
Figure V.15 : Coefficients de la cohérence quadratique (MSC) et de la densité spectrale de puissance (CPSD) obtenues à partir du signal EEG canal FZ-CZ (canal 17).....	153

## Liste des Tableaux

Tableau I.1 : noms et les bandes fréquentielle des ondes cérébrales.....	15
Tableau I.2 : Les vitesses de conduction dans le tissu cardiaque.....	24
Tableau I.3 : les amplitudes normales pour différentes dérivations.....	27
Tableau I.4 : durées des Intervalles du signal ECG.....	29
Table II.1 : standard Bluetooth.....	56
Table II.2 : Une évaluation statistique comparative de la cohérence entre les signaux ECG et EEG avec et sans crise d'épilepsie et obtenue à partir de notre base de données et de la base de données CHB-MIT.....	73
Tableau III.1 : Nomenclature des électrodes utilisées.....	79
Tableau III.2 : Comparaison entre les éléments de base du neurone biologique et du neurone artificiel.....	81
Tableau III.3 : Paramètres extraits à partir des signaux ECG et EEG avec leurs vecteurs assignés.....	90
Tableau III.4 : Topologies de réseaux de neurones utilisées obtenus à partir différents nombres de couche cachées et fonction d'apprentissage.....	92
Tableau III.5 : Topologies de réseaux de neurones utilisées obtenus à partir différentes fonctions d'activations.....	93
Tableau III.6 : Paramètres des différentes distances utilisées pour le classifieur KNN.....	94
Tableau III.7 : Matrice de confusion.....	96
Tableau III.8 : Performance des classificateurs avec structure MLP.....	96
Tableau III.9 : Performance des classificateurs avec structure MLPE.....	97
Table III.10 : Matrice de confusion de la structure CG-MLPE3.....	98
Table III.11 : Matrice de confusion de la structure CG-MLP3.....	98
Table III.12: Performances de classification des structure MLP avec différentes fonctions d'activation.....	100

Table III.13: Performances de classification des structure MLP avec différentes fonctions d'activation.....	100
Tableau III.14: Analyse des performances des classifieurs KNN (sans ECG).....	102
Tableau III.15: Analyse des performances des classifieurs E-KNN (avec ECG).....	102
Table IV.1 : Caractéristiques extraites depuis les signaux ECG et EEG avec leurs vecteurs assignés.....	120
Tableau IV.2 : La performance de classification par réseau de neurones.....	126
Tableau IV.3 : matrice de confusion de réseaux de neurone <i>RNA – D1</i> .....	127
Tableau IV.4 : La performance de classification pat l'arbre de décision.....	128
Tableau IV.5 : Résultats de l'évaluation de notre algorithme de détection des crises par rapport à la méthode "Iosif " et la méthode de "Varum".....	133
Tableau V.1 : Le résumé de tous les calculs des coefficients de corrélation Spearman et Pearson.....	146
Tableau V.2 : La performance de classification des quatre meilleurs nombres d'arbre de décision.....	149
Tableau V.3 : matrice de confusion pour l'algorithme de décision avec 43 arbres.....	149

## **INTRODUCTION GENERALE**

Le cerveau de l'être humain est constitué des milliards de neurones, ils interagissent entre eux en envoyant et recevant des messages afin de bien contrôler l'état, la fonction et la physiologie de tous les organes constituant le corps. Chaque neurone est considéré comme un petit dipôle électrique qui possède une polarisation bien définie, cette polarisation décrit l'état de la cellule nerveuse (repos ou activité). La distribution spatiale parallèle et l'organisation en colonne perpendiculaire à la surface du cortex cérébrale des cellules nerveuses permet l'addition des potentiels postsynaptiques des neurones sous-jacents générés par un grand nombre de dipôle. Il existe des potentiels postsynaptiques inhibiteurs et excitateurs. Cependant cette sommation des potentiels postsynaptiques engendre un champ électrique très important qui peut être observé et recueilli sur le crâne à travers des électrodes. Il s'agit de l'électroencéphalogramme (EEG), le signal EEG représente non seulement la fonction cérébrale, mais aussi l'état de l'ensemble du corps. En 1875, un scientifique qui s'appelle Richard Caton de Liverpool a placé deux électrodes d'un galvanomètre sur le scalp d'un être humain et devenu le premier qui a enregistré l'activité cérébrale dans une forme de signal électrique (Raoul, 2017). En 1920, le neuropsychiatre allemand Hans Berger était le premier qui a démontré l'existence des signaux électroencéphalogramme de l'être humain. Ensuite la technique du EEG a continué d'évoluer à travers plusieurs recherches effectuées par un très grand nombre de chercheurs. Actuellement, l'électroencéphalographie est devenue un outil indispensable lors du diagnostic des anomalies cervicales, elle fournit une information dynamique et précieuse sur l'état du cerveau sur des durées allant jusqu'à plusieurs jours. Le signal EEG regroupe plusieurs ondes cérébrales appelées rythmes cérébraux, elles sont caractérisées par leur fréquence, amplitude, morphologie et la topographie (frontale, temporale). L'EEG contribue au diagnostic de plusieurs maladies neurologiques tel que l'épilepsie, il correspond au premier examen le plus efficace pour la prise en charge des patients avec épilepsie. Cette maladie est un trouble chronique du système nerveux central qui peut entraîner des crises fréquentes. Elle touche environ 50 millions de personnes à travers le monde. Plus de 30% des patients épileptiques souffrent de crises non traitables par les médicaments, elle peut avoir une influence directe négative sur la qualité de vie des patients avec leurs familles en raison des effets secondaires liés au traitement, éprouvant de multiples difficultés psychologiques ou sociales sous forme de dépression et de restriction sociale, des troubles de la mémoire ou des blessures associées aux

crises, des affections associées aux malaises psychiques et de l'isolement social. En plus de ces effets négatifs, le budget annuel élevé consacré aux activités de soins de santé liées aux coûts d'investigation, de traitement et d'hospitalisation des patients épileptiques ne peut être ignoré.

Les progrès de la technologie et de l'informatisation au cours de ces dernières décennies ont renforcé considérablement l'amélioration de la qualité de vie des personnes souffrant des crises d'épilepsie. Pour cela des modules d'acquisition du signal EEG sans fil et miniaturisé à long terme ont été fréquemment réalisés pour un suivi à distance de longue durée sans la présence du médecin sur scène. Beaucoup d'études ont été menées sur la détection et la prédiction de la crise d'épilepsie. Nous mentionnons en particulier celle de Varun Bajaj et al (2012) qui ont fait une étude sur la classification des signaux EEG (épileptiques ou non épileptique) basé essentiellement sur l'utilisation de la décomposition en mode empirique, Ali et al (2004) ont proposé un module de détection de l'apparition de la crise spécifique au patient, en utilisant une décomposition en ondelettes pour construire un vecteur caractéristique qui capte la morphologie et la distribution spatiale d'une portion du signal EEG, puis détermine si ce vecteur est représentatif de crise ou non à l'aide du classifieur (SVM).

Récemment, Plusieurs travaux sont proposés dans la littérature qui utilise la fusion d'information, en introduisant d'autre signaux physiologiques. Nous prenons l'exemple du signal ECG, dont des chercheurs ont constaté que la plupart des taux de rythme cardiaques des patients augmentent de plus de 10 battements par minute et qu'un petit nombre de patients diminuent de plus de 10 battements par minute avant l'apparition des crises. Parmi ces études nous citons en particulier Kaat et al (2017), qui ont proposé une étude sur la détection automatisée des crises d'épilepsie basée sur l'ECG et le PPG portables en milieu hospitalier. En introduisant le signal ECG à côté du signal EEG, Iosif et al (2015), ont pu détecter les crises d'épilepsie à l'aide des signaux EEG et ECG pour la surveillance, l'analyse et la prise en charge informatisées des patients épileptiques. Aussi Ali et al (2009) ont combiné le signal ECG avec les signaux EEG pour une meilleure détection des crises d'épilepsie.

Diverses autres applications ont été dérivées de l'analyse des électroencéphalogrammes (EEG) et électrocardiogramme (ECG), et qui s'intéressent à la détection des événements épileptiques et à leur prédiction. Worawich et al (2014) ont présenté une étude préliminaire à travers les signaux EEG et le signal ECG pour la prédiction des crises épileptiques basée sur la transformation de Hilbert Huang, ils ont pu déterminer la relation qui existe entre la variation

du rythme cardiaque avec la crise d'épilepsie, ils ont réussi à détecter le début de la crise dans les 130 s qui précède l'apparition de la crise.

L'objectif de ce présent travail est déterminé l'efficacité ainsi que l'importance qui peut apporté par la fusion des enregistrements simultanés de l'activité électrique cérébrale et cardiaque. Cette étude peut être considérée comme un aide au diagnostic pour les patients souffrant des crises d'épilepsie. Ainsi ce travail est structuré en cinq chapitres

Dans le premier chapitre, nous ferons une présentation générale au préalable de l'électrophysiologie cardiaque et cérébrale, avec un aperçu de l'origine des signaux électrophysiologiques correspondants. Nous décrivons également la physiologie de contrôle liant le cerveau avec le cœur.

Les signaux cardiaques (ECG) et cérébraux (EEG) sont deux signaux importants indiquant des états sains et malades du corps et de l'esprit qui ont besoin directement de surveillance à long terme. Pour cela le deuxième chapitre comporte une description détaillée des étapes essentielles permettant la mesure en temps réel de ces deux signaux. Nous faisons une explication de l'ensemble de la chaîne d'acquisition constituant d'un circuit électronique permettant la détection correcte des activités électriques désirées à côté des modules électroniques dédiés à la transmission sans fils des données. Nous terminons ce chapitre par un traitement numérique des données acquises sur une interface conçue sous Matlab avec une comparaison entre nos signaux et les signaux obtenus de la base de données Physionet (PhysioBank database, 2016; Goldberger et al., 2000). Ce qui nous permet d'atteindre l'objectif de réaliser une base de données médicale personnelle, ce qui rend notre système autonome sans recours à d'autres bases de données afin de tester nos algorithmes.

Dans le chapitre trois une exploitation des paramètres pertinents extraits depuis des deux signaux pour une classification performante sera l'objet d'une étude préliminaire qui affirme l'utilité du signal ECG comme une information complémentaire à côté des signaux EEG pour une reconnaissance de crise fiable. Notons que dans cette partie la phase de caractérisation est effectuée à travers une étape d'extraction des paramètres à partir du domaine temporel uniquement. Deux types de classificateurs ont été évalués pour la détection de crise.

Le quatrième chapitre est considéré comme une étude approfondie de ce qui a été présenté dans le chapitre précédent, une extension a été effectuée de l'ensemble des paramètres entre en jeu dans le processus de classification par l'extraction d'autres paramètres depuis le domaine fréquentiel. L'étude a été réalisée sur plusieurs niveaux à travers l'application de la transformée en

ondelettes discrètes, en introduisant chaque vecteur caractéristique correspond à chaque coefficient obtenus par la détection dans deux classifieurs distincts. La performance de détection obtenu par ce process permettra d'améliorer beaucoup plus le taux de reconnaissance de crise. Cela confirme également ce que nous avons mentionné auparavant concernant l'importance du signal ECG à côté du signal EEG.

Enfin dans le cinquième chapitre nous passons de la détection de la crise à sa prédiction à travers une étude statistique. Trois méthodes seront proposées afin de quantifier la relation qui existe entre les deux activités durant et avant la crise. Dans la première méthode, une exploration sera faite sur les relations existantes entre les énergies ; énergie du segment TP et les segments EEG correspondants afin de voir si ces énergies sont corrélées ou pas d'une part et de comprendre la variation de cette corrélation avant et durant la crise d'autre part. L'évaluation du degré de cette corrélation est obtenue par les deux coefficients statistiques Spearman et Pearson qui confirme cette existence de relation. L'utilisation de l'algorithme de l'arbre de décision pour la prédiction de crise entre l'EEG et l'ECG fait l'objet de la deuxième méthode. Nous avons mis en place une autre méthode pour l'évaluation de la relation qui lie les deux signaux dans le domaine fréquentiel exprimée par la cohérence quadratique et la densité spectral de puissance est également présentée dans ce chapitre. Le résultat montre que cette cohérence peut être considéré comme un indice significatif pour indiquer tôt l'apparition des crises. Rappelons que toutes les méthodes proposées ont été testé sur des enregistrements obtenus à partir de la base de données CHB-MIT Scalp EEG, disponible gratuitement sur Physionet. (PhysioBank database, 2016 ; Goldberger et al., 2000).

## **Chapitre I : Anatomie cardio-cérébrale**

### **I.1. Introduction**

Le cerveau, entité principale du système nerveux central, et siège de la pensée, reste encore aujourd'hui parmi les plus complexes et les plus mystérieux de tous les organes du corps humain. Il contrôle toutes les fonctions du corps et reçoit les messages à travers les cinq sens. Au cours des dernières décennies, les connaissances sur le fonctionnement du cerveau ont évolué de façon importante, en raison du développement de plusieurs techniques d'enregistrement. L'Électroencéphalographie (EEG) constitue l'outil principal pour mesurer l'activité électrique cérébrale recueillie sur le scalp. Elle correspond au champ électrique généré par un grand nombre de neurone cortical. Le tracer de l'EEG se présente sous forme de rythmes ou ondes cérébrales (Alpha, Bêta, Delta, Thêta et Gamma ) qui dépendent de l'emplacement des électrodes avec l'état de vigilance du sujet. Et il est également utilisé pour l' aide au diagnostic des lésions cérébrale et d'autres maladies tel que l'épilepsie. Leur interprétation est difficile ce qui nécessite une véritable spécialisation médicale. Les systèmes d'acquisitions des données modernes, les nouvelles conceptions des électrodes et les calculateurs puissants ont permis l'enregistrement simultané de dizaines de neurones pour des longs durées avec une analyse plus complexe des donnés, donnant par conséquence la naissance de la neuroscience computationnels.

Le cœur humain est un muscle creux capable de se contracter entre 60 et 100 fois par minute. La plupart des diagnostics d'anomalie cardiaque dépendent de l'électrocardiogramme (ECG). Il représente la mesure non invasive de l'activité électrique du cœur. Cette activité peut être enregistré facilement en temps réel et reproduite sur un papier millimétré à partir de deux électrodes placées de chaque côté du cœur nommé dérivation. La dépolarisation et la repolarisation du myocarde sont à l'origine du mécanisme de contractilité du cœur. Le tracé relevé présente un aspect caractéristique correspond à la propagation de l'influx dans le myocarde. Chaque cycle cardiaque est constitué des ondes nommées (onde P, Q, R, S, T et U). L'analyse de ces ondes comprend leurs durées et leurs morphologies, contribue au diagnostic médical pour l'identification d'éventuelles anomalies dans le fonctionnement cardiaque.

Dans ce chapitre on s'intéresse à la présentation et la description du système cardio-encéphalographie, en se basant sur l'anatomie de chaque organe constituant le système, Nous

décrivons ensuite l'origine et le principe d'enregistrement de chaque signal électrique, et nous terminerons par l'illustration de la relation entre ces deux systèmes.

## I.2. Anatomie Cérébrale

L'encéphale est la partie du système nerveux central (SNC), elle se compose de trois éléments :

Le tronc cérébral : qui représente un prolongement de la moelle épinière, qui sert à contrôler l'activité des organes tel que le cœur et les poumons.

Le cervelet : permettant la coordination et la synchronisation de tout le mouvement du corps, situé sous le cerveau, et à l'arrière du tronc cérébral.

Le cerveau représente 2% du poids de notre corps (environ 1400g). Il consomme 20 à 30% de l'énergie du corps. Il est protégé par le crâne et le liquide céphalo-rachidien dans lequel il baigne et qui circule à son contour dans les méninges. (Figure I.1) (Belaid, 2014).

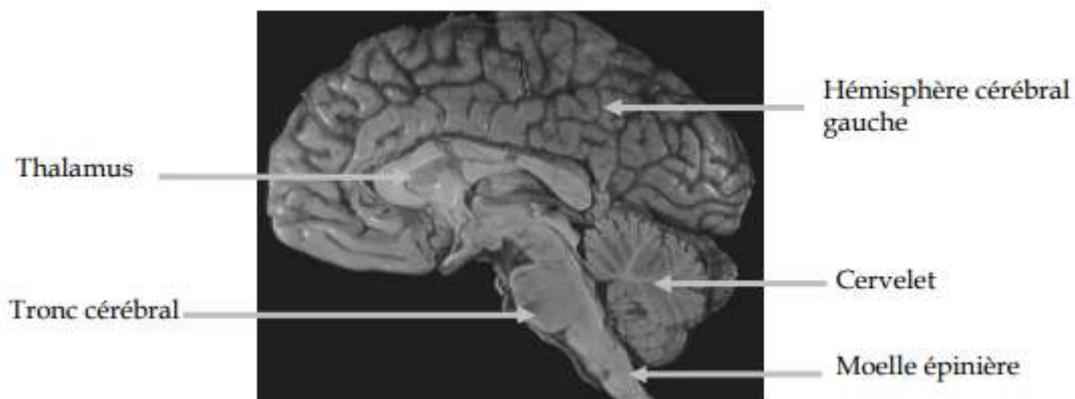


Figure I.1 : Système nerveux central, vue Sagittale.

Le cerveau est constitué de deux hémisphères, le droit et le gauche. Chacun possède une surface lisse appelé circonvolutions cérébrales. Chaque hémisphère contrôle la moitié du côté opposé du corps qui est subdivisée par scissures en plusieurs lobes (Figure I.2) :

- Scissures ou sillon centrale, entre les lobes frontaux et pariétaux ;
- Scissures en arrière, entre les lobes pariétaux et occipitaux ;
- Scissures ou sillon latéral, entre lobes frontaux, pariétaux et temporaux.

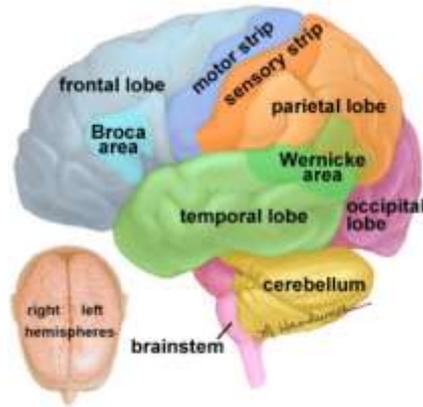


Figure I.2 : Les lobes et scissures du cortex (Tonya, 2016).

L'encéphale comprend deux types de tissu nerveux : la substance grise (MG) et la substance blanche (MB), avec le liquide céphalo-rachidien et la méninge (Figure I.3).

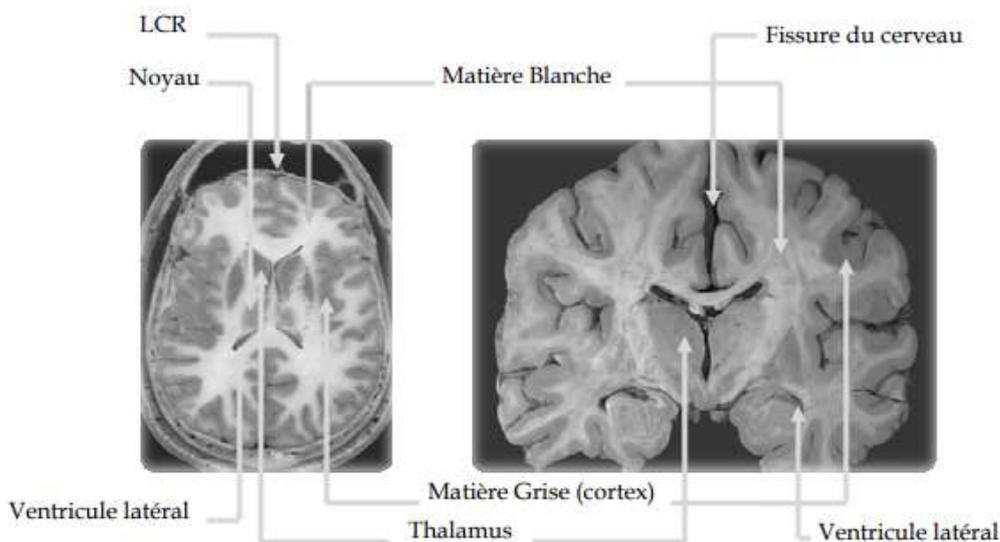


Figure I.3 : Cerveau de l'être humain, vue frontale à gauche, vue coronale à droite (Kamel, 2012).

La matière grise Correspond au corps cellulaire de neurones, réparti en couche superficielle épais d'une épaisseur qui varie entre 2 à 5 mm. Elle permet le déclenchement des réponses à travers la réception des stimulations périphériques, l'élaboration, coordination des mouvements volontaires et l'analyse des messages. Elle possède une fonction sensitive et sensorielle (la mémoire, la conscience, les émotions, etc.). Les neurones formant la matière grise peuvent s'organisé en six différentes couches, à savoir : la couche moléculaire, le granulaire interne et externe, le pyramidale interne et la couche polymorphe.

Les neurones envoient leurs prolongements, ou axones, vers l'intérieur du cerveau. Comme ces prolongements apparaissent plus clairs sur la coupe, ils constituent ce qu'on appelle la substance blanche (Matière blanche). Elle représente en quelque sorte le câblage de l'encéphale. Elle est considérée comme la partie responsable de la transmission des informations, tandis que la matière grise responsable au traitement des informations.

De même, on peut trouver plusieurs fibres constituant la matière blanche :

- ✓ Les fibres d'association : qui ont des longueurs variables et qui sert à l'établissement de la liaison entre différentes régions dans le même hémisphère.
- ✓ Les fibres commissurales : unissant les deux hémisphères entre eux.
- ✓ Les fibres de projection : projetant le cortex sur le noyau gris centraux.

La méninge est une couche protectrice qui se constitue de trois membranes :

- La membrane interne : qui contient la structure veineuse assurant la circulation du sang du cerveau vers le cœur.
- La membrane intermédiaire.
- La membrane externe : qui assure la protection des couches sous-jacentes grâce à sa composition dure et à sa forte résistance.

En dernier nous avons le liquide céphalo-rachidien, noté LCR, est un liquide transparent constitué de l'eau. Il assure la protection et la nourriture de tout le système central nerveux. (Arnaud, 2010. Kamel, 2012. Belaid ,2014).

### **I.2.1. Potentiel cérébral et Potentiel d'action**

Le cerveau est constitué de 1000 milliards de neurone, dont 10 milliards sont repartis sur la couche cortical. Tous ces neurones sont reliés entre eux par  $10^{12}$  connections synaptiques et avec  $10^{18}$  de neurotransmetteurs.

Les neurones avec une grandeur qui varie entre 5 à 150  $\mu\text{m}$ , sont chargés du traitement de l'information au sein du cerveau (Figure I.4). La structure de liaison entre eux peut s'exister sous forme de deux types de prolongement :

- **Les dendrites** : qui reçoivent les signaux émis par d'autres neurones et grâce à l'axone, le signal résultant peut être transmis à d'autres neurones.

- **Axones** : qui sont une sorte de pont interneurons qui transmettent les informations vers les synapses.
- **Synapses** : qui représentent l'extrémité de l'axone, c'est là que les informations se transmettent de cellule en cellule (Geoffray, 2005. Belaid,2014).

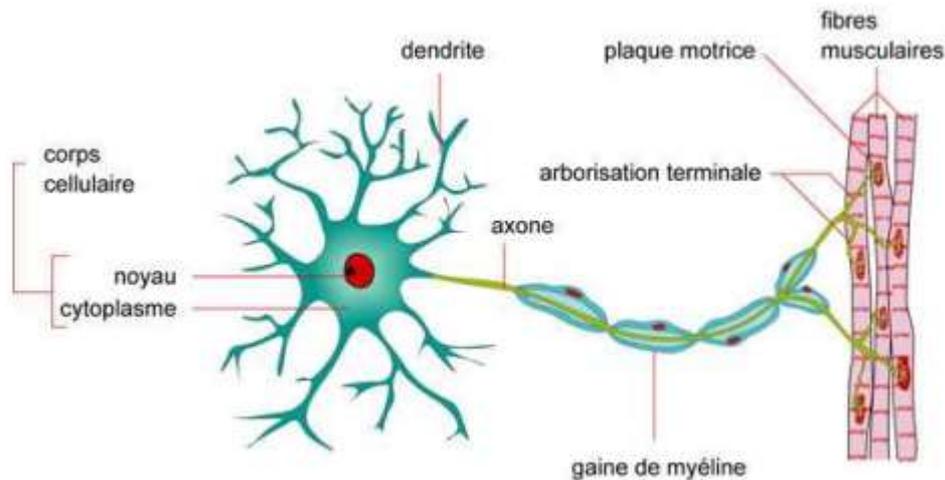


Figure I.4 : Le neurone et ses constituants (Arnaud, 2010).

L'origine des potentiels cérébraux est basée sur les propriétés électrophysiologiques intrinsèques du système nerveux. Quand un neurone est au repos, une différence de potentiel existe entre le milieu interne et externe de la cellule nerveuse. Ce potentiel est de l'ordre de -75 mV, due au déséquilibre constant en ions Potassium ( $K^+$ ) et Sodium ( $Na^+$ ) maintenue par la pompe d'ions (Figure I.5).

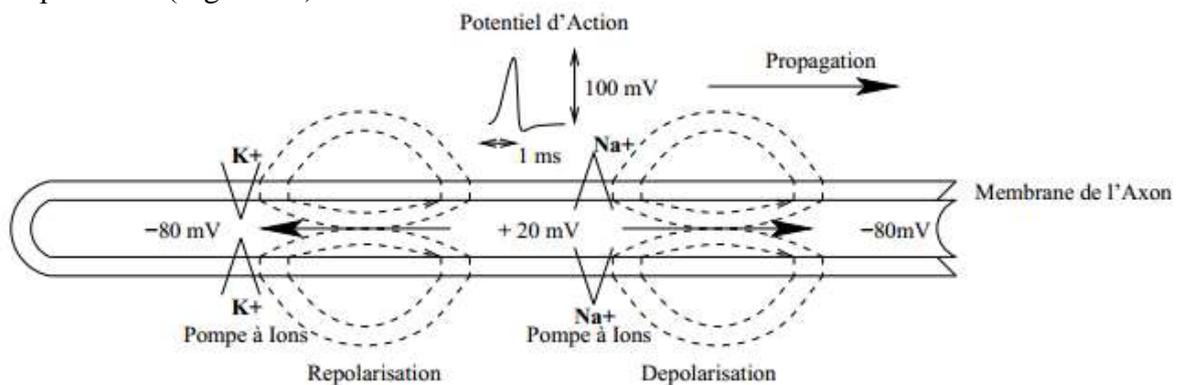


Figure I.5 : Propagation de l'influx nerveux (Geoffray, 2005).

Lors de la dépolarisation et sous l'action du neurotransmetteur, la propagation du flux nerveux commence avec l'apparition du Potentiel "Post Synaptique (PPS) et l'accumulation des ions dans la cellule grâce à la perméabilité de la membrane aux ions ( $K^+$  et  $Na^+$ ). Le potentiel à l'intérieur de la cellule augmente d'une dizaine de millivolts pour une durée de quelques

secondes. L'accumulation de plusieurs potentiels post synaptique résulte l'augmentation du potentiel interne de la cellule qui dépasse un certain seuil, et qui par la suite donne la naissance du potentiel d'action (PA) dont le neurone entre dans la phase d'émission. La cellule se dépolarise et le potentiel interne passe rapidement de  $-70\text{mV}$  à  $+40\text{mV}$  (les canaux ioniques sont ouverts), la deuxième étape consiste à la phase de la repolarisation (les canaux sont fermés). Le phénomène se reproduit au voisinage dans un délai très bref (quelque millisecondes), ce qui assure la propagation de l'influx toute au long de l'axone vers les autres neurones à travers les synapses. Ces derniers considérés comme une interface chimique capable d'assurer la liaison entre les neurones. Cette opération nécessite une quantité d'énergie fournie notamment par le cycle d'oxydation ATP (Geoffray, 2005).

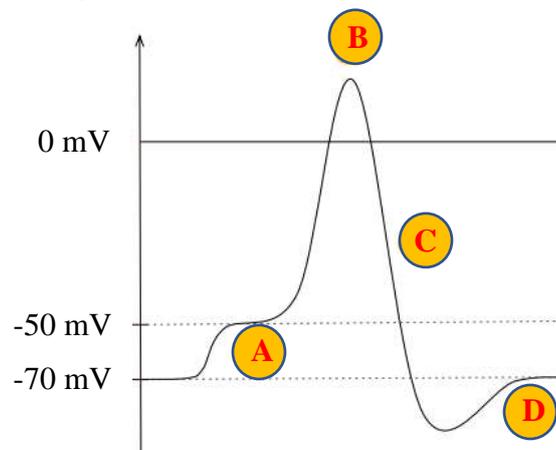


Figure I.6 : Potentiel d'Action (André, 2010).

### I.2.2. Electroencéphalographie (EEG)

L'électroencéphalogramme (EEG) est l'enregistrement de l'activité électrique du cerveau effectué sur la surface de la tête. Il s'agit d'une différence de potentiel entre deux points différents. Elle correspond au champ électrique généré par les cellules pyramidales. Chaque cellule pyramidale est considérée comme un dipôle du fait d'une polarisation (+) du soma et (-) de l'apex (Figure I.7). Etant donné que les cellules pyramidales sont disposées d'une manière parallèle et organisées en colonnes fonctionnels perpendiculairement au cortex cérébral, ce qui permet une sommation de tous ces dipôles, qui résulte en fin de compte un champ magnétique suffisant pour être détecté à la surface du scalp (Kaminska et al, 2006).

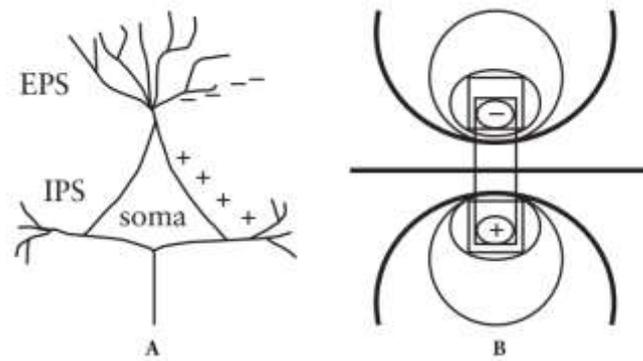


Figure I.7 : (A) cellule pyramidale avec potentiels postsynaptiques excitateurs et potentiels post-synaptiques inhibiteurs, (B) Dipôle représentant un champ de charge (William et al, 2008).

En 1875 un jeune assistant de physiologie anglais nommé Caton enregistra pour la première fois l'activité électrique cérébrale d'un singe, lors de l'ouverture de la boîte crânienne du singe, et à l'aide d'un galvanomètre, il remarque la présence des courants électriques important au niveau de la partie occipitale du cerveau, et cela lorsqu'il a exposé la rétine a un flash lumineux.

En 1929, le physiologiste allemand Hans Berger commença son étude de cette activité sur l'homme, il a réussi a enregistré l'activité électrique cérébral d'une manière non invasive (sans ouvrir la boîte crânienne) (figure1.8), la technique consiste à mesurée la différence de potentiel entre deux points différents à travers des électrodes posés sur le scalp, puis amplifié ces oscillations électriques de quelques dizaines de microvolts (Crouzeix, 2001. Geoffray, 2005).

Ensuite Hans Berger a suivi l'examen des EEG humain dont les lésions cérébrales, la tumeur cérébrale, l'épilepsie et l'étude de la localisation des dysfonctionnements cérébraux.

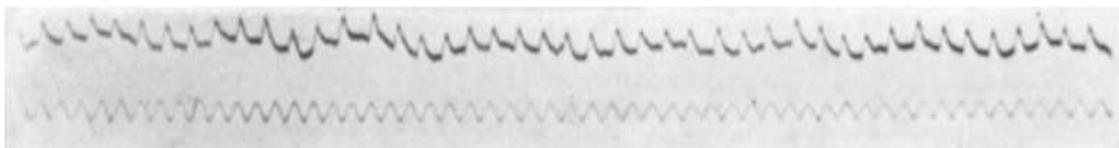


Figure I.8 : Le premier électroencéphalogramme à un canal chez un humain (Raoul et al, 2017).

En 1932, un groupe d'inventeurs allemands avec des enquêteurs américains ont réussis à construire les premiers amplificateurs destinés à l'enregistrement de l'activité cérébrale. Ouvrants l'enregistrement dites multicanaux qui couvraient des grandes régions du cerveau (Raoul et al, 2017).

L'arrangement symétrique de l'électrode à travers la totalité de la surface du scalp peut fournir un résumé temporel et spatial du déclenchement synchrone de dizaines de millions de neurones constituant le cerveau. Le placement des électrodes a été standardisé par un système international noté 10-20 qui utilise des repères anatomiques sur le crâne. Un minimum de 21 électrodes est recommandé pour l'étude clinique, bien que l'EEG numérique ait maintenant la capacité d'accepter un plus grand nombre d'électrode (Figure I.9). Les désignations F<sub>P</sub> (Front polaire), F (frontal), T (Temporal), O (Occipital), C (Central), et P (Pariétal) sont utilisées dans le système 10-20. Les nombres suivant les lettres soit l'hémisphère gauche (les nombres impairs), soit l'hémisphère droit (les nombres pairs). La désignation Z reflète l'emplacement de l'électrode sur la ligne médiane, exemple : CZ signifie la ligne médiane centrale. Une référence d'oreille homolatérale peut être utile pour des décharges plus généralisées. (William et al, 2008).

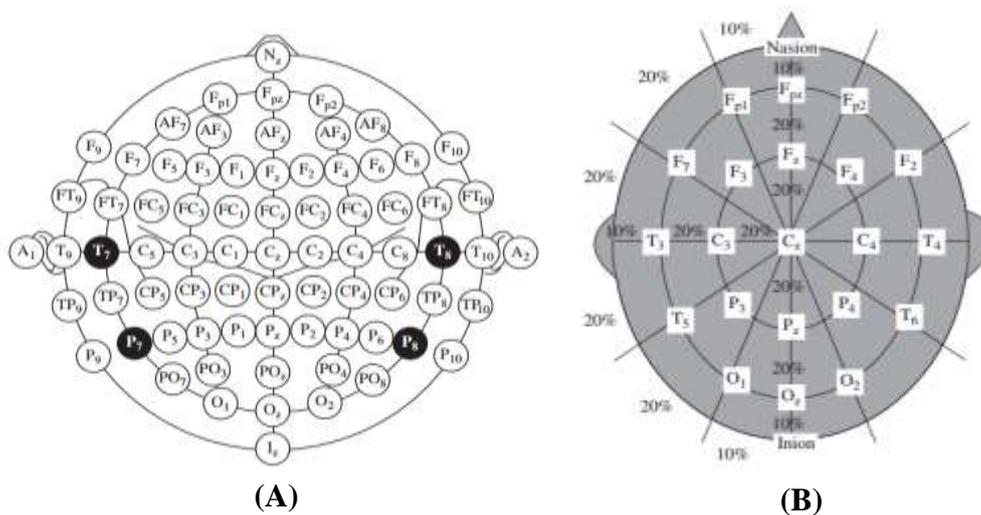


Figure I.9 : (A) système d'électrode international 10-20 pour 75 électrodes. (B) système d'électrode international 10-20 pour 21 électrodes (André, 2010).

### I.2.3. Les capteurs

Il existe trois types de capteur ou électrode, à savoir :

- **Electrodes conventionnelles :**

Les électrodes de type Grey-Walter sont constituées d'une tige d'argent, recouverte d'un tampon de tissu imbibé d'une solution saline. Elles sont montées sur un support stabilisateur qui leur permet de tenir droites sur le scalp et sont maintenues par un petit crochet qui vient s'agripper sur une des lanières du "casque".

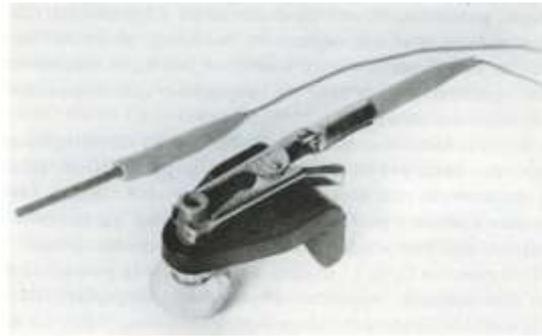


Figure I.10 : Electrodes conventionnelles.

- **Electrodes aiguilles :** Leurs extrémités sont piquées dans l'épaisseur du scalp (aiguilles sous-cutanées à usage unique). Au prix d'une petite douleur, ces électrodes offrent un contact électrique de bonne qualité et une résistance peau/ électrode pratiquement constante. Leur usage s'impose lorsqu'il est impératif de recueillir l'EEG dans des conditions techniques optimales, par exemple pour l'évaluation des comas profonds.



Figure I.11 : Electrodes aiguilles.

- **Electrodes cupules :**

Ces électrodes sont remplies de pâte conductrice et sont collées sur le scalp. Ces électrodes sont reliées à l'appareil d'enregistrement au moyen de simples fils isolés. Il est nécessaire de s'assurer de la continuité électrique et de la bonne qualité de l'interface électrochimique (électrode - électrolyte - peau). Ces électrodes sont utilisées pour les enregistrements prolongés (par exemple en télémétrie ou au cours du sommeil)

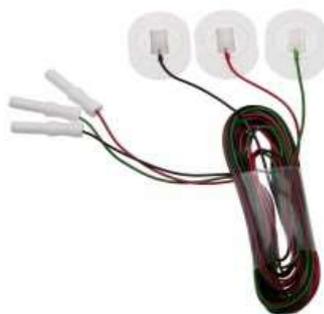


Figure I.12 : Electrodes cupules.

Les fluctuations électriques provoquées par l'activité cérébrale sont enregistrées comme EEG et sont généralement dans la gamme de -50 à 50  $\mu\text{V}$ . Les clignements des yeux ont une amplitude plus élevée et ont souvent des tensions supérieures à 100  $\mu\text{V}$ . La Figure I.13 illustre un exemple réel de 5 seconde d'enregistrement du signal EEG à partir de 23 sites (23 électrodes), échantillonné à 256 Hz (James,2003. PhysioBank,2016).

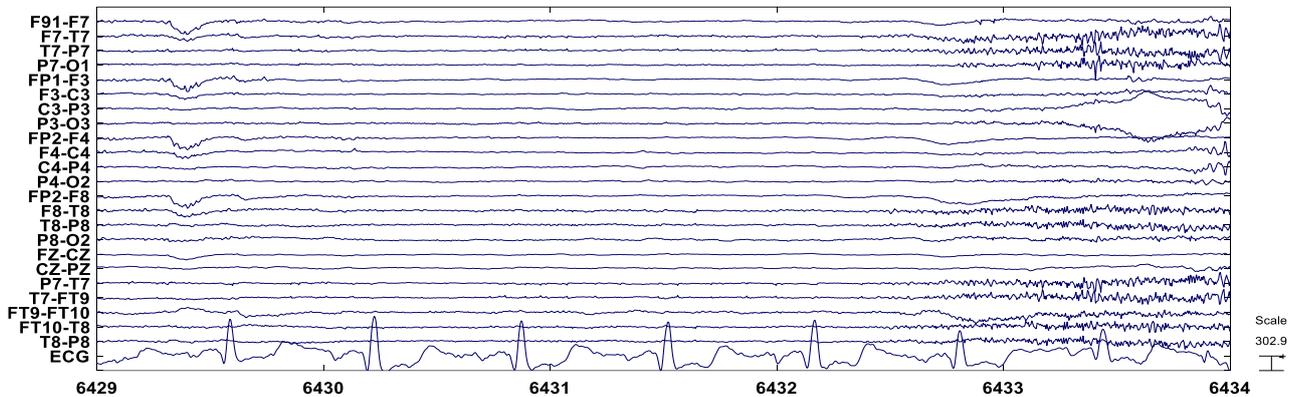


Figure I.13 : Exemple de d'enregistrement de 5 seconds d'un signal EEG multicanaux réel (PhysioBank, 2016).

Pour les équipements modernes Les enregistrements des signaux EEG sont effectués à l'aide d'électrodes à haute conductance (avec une impédance inférieure à 5 kW). Afin d'améliorer la connectivité des électrodes avec le scalp un gel peut être utilisé. Les électrodes sont déjà positionnées au casque, ce qui permet un ajustement facile et rapide autour de la tête du sujet. L'EEG peut enregistrer ;

- En référence à une électrode passive commune (enregistrement monopolaires) généralement placées au niveau des lobes d'oreille (A1 et A2).
- Ou bien différentielle entre des paires d'électrode (enregistrement bipolaire) (Freeman, 2013).

La plupart des troubles cérébraux sont diagnostiqués par inspection visuelle des signaux EEG et l'analyse est un processus rationnel et systématique nécessitant une série d'étapes ordonnées caractérisant l'activité électrique enregistrée en termes de descripteurs ou de caractéristiques et de mesures spécifiques, comme :

- La fréquence.
- Le voltage
- La forme de l'onde
- La disposition des électrodes sur le scalp.

- La Manière d'occurrence (aléatoire, continue, répétitif).
- La réactivité (yeux ouverts, calcul mental, stimulation, sensorial, mouvement).
- Et la cohérence interhémisphérique

La période entre la découverte d'EEG en 1929 et la fin des années 1960, l'EEG a été principalement inspectée visuellement jusqu'à ce que l'équipement numérique soit disponible, ce qui a permis d'appliquer l'analyse de Fourier pour extraire le contenu spectral (Martijn, 2011).

### I.2.4. Rythmes cérébraux

L'activité électrique du cortex cérébral est souvent appelée comme rythme, les signaux enregistrés qui présentent un comportement oscillatoire et répétitif. Ces rythmes se superpose pour produire le tracé global enregistré. Cependant il existe une diversité de rythmes qui dépend de plusieurs facteurs tel que : l'état mental du sujet et le degré de vigilance (éveil, sommeil, rêve). Les rythmes sont caractérisés par leur amplitude et leur bande fréquentielle (Figure I.14). L'analyse fréquentielle de l'EEG permet de mettre en évidence 5 rythmes comme l'illustre le tableau 1. (Carlos et al, 2012).

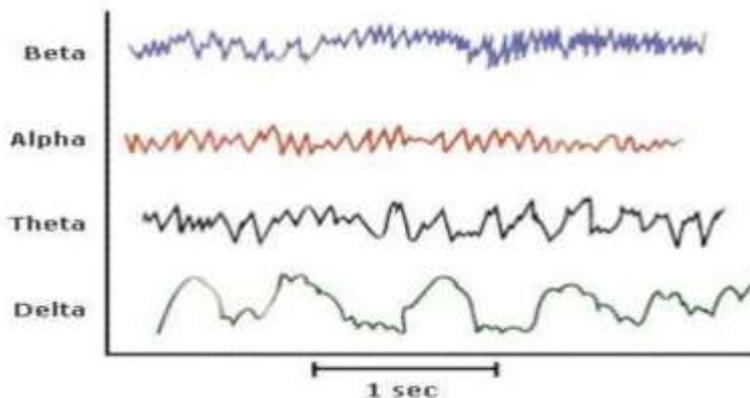


Figure I.14 : Ondes cérébrales normales typiques dans l'EEG (Carlos et al, 2012).

Nom de l'onde	La fréquence de l'onde
Delta	0-4 Hz
Thêta	4-8 Hz
Alpha	8-12 Hz
Beta	12-30 Hz
Gamma	30-80 Hz

Tableau 1.1 : noms et les bandes fréquentielle des ondes cérébral (André, 2010).

Concernant les Ondes Alpha, elles sont captées sur la partie postérieure de la tête, correspond à l'état éveillé au repos avec les yeux fermés. Comme illustré dans le tableau, le rythme alpha considérée comme rythme régulier possède une fréquence assez faible qui s'étend de 8 à 12 Hz, avec une amplitude faible de l'ordre de 25 jusqu'au 60  $\mu\text{V}$ . durant cette étape les ondes alpha prennent le contrôle du cerveau, et elle est considérée comme phase de neutralité avec l'absence de toute sorte de stress.

Nous avons également les Ondes Bêta qui sont captées sur les aires centrales et frontales du cerveau, correspond à la gamme fréquentielle qui s'étale de 12 jusqu'au 30Hz avec une amplitude relativement faible (de 10 à 30  $\mu\text{V}$ ). Ce rythme est produit lors de l'état de veille normale avec des yeux ouverts associé avec une concentration dirigée vers le monde extérieur.

Les Ondes Delta Elles sont les plus lentes ondes cérébrales, leur fréquence varie dans une plage étroite (de 0 à 4 Hz) avec une amplitude forte. Elles sont Obtenues dans l'état de sommeil lent, lorsque notre cerveau entre dans l'état delta, cela déclenche la libération d'une hormone de croissance forte importante.

Nous avons également les Ondes Thêta qui sont produites soit lors de la première phase du sommeil lent, soit dans un état de profonde relaxation (complètement étendus), cet état est connu aussi par l'état crépusculaire, puisqu'elle situe entre la phase de la veille et le sommeil. Les informations fournis de cette étape restent limitées étant donné que les gens ne peuvent maintenir cet état que pendant une brève période de temps. Leur fréquence compris entre 4 et 8 Hz.

Pour terminer nous avons les ondes Gamma qui sont présentes dans chaque partie du cerveau, elles traduisent généralement une activité mentale intense de haut niveau. Quand le cerveau doit traiter simultanément l'information de différents secteurs, l'activation d'une fréquence de 40Hz favorise l'information entre les secteurs exigés pour un traitement simultané (Belaid, 2014).

### **I.2.5. Technique d'examen**

L'EEG est un examen facile à réaliser, réalisable en laboratoire, au lit du patient, avec une unité de soins, pour des durées longues qui peuvent atteindre plusieurs jours. Il peut être immédiatement interprété. À côté des données statiques de la neuroradiologie, il apporte des données dynamiques permettant d'apprécier le fonctionnement cérébral. Un enregistrement est fait avec le patient éveillé et au repos, mais souvent dans des conditions comme : le sommeil, l'hyperventilation et la stimulation par des impulsions lumineuses qui sont utilisées pour révéler des activités intermittentes comme l'épilepsie ou un autre dysfonctionnement temporaire du

cerveau, notant que 50 millions de personnes souffrent de l'épilepsie à travers le monde entier. L'EEG est progressivement devenu un outil clinique pratique de grande importance pour le diagnostic des maladies et des troubles fonctionnels dans le cerveau (Masse, 2013). La plupart des maladies, des blessures et des troubles fonctionnels qui affectent le cerveau influencent également l'EEG. Il est possible de détecter une perturbation fonctionnelle dans le cerveau et de juger de son degré de sévérité, de localisation et de propagation. Il est considéré comme un outil indispensable qui sert à la localisation des sources de l'activité électrique cérébrale avec la caractérisation des fonctions des structures cérébrales dans leur organisation tant spatiale que temporelle. Il présente un intérêt majeur pour la recherche sur les processus mentaux (Anders et al, 1981. Kaminska et al, 2006).

L'EEG présente trois avantages principaux par rapport aux autres méthodes :

- C'est un examen non invasif, avec la possibilité d'effectuer l'expérience avec des sujets humains normaux ;
- Il possède une résolution temporelle très élevée (millisecondes), ce qui permet un suivi continu de la dynamique temporelle de tous les processus cérébraux ;
- C'est un examen qui n'est relativement pas coûteux.

Il faut noter qu'il est possible de trouver des situations où l'enregistrement de l'activité électrique cérébrale est accompagnée avec un ou plusieurs autres signaux physiologiques tels que ; le signal respiratoire, le signal électromyogramme (EMG), l'ECG (voir Figure I.13 ) etc. C'est une nouvelle technique qui exploite la fusion d'information entre plusieurs systèmes organiques et plusieurs signaux physiologiques afin d'améliorer le diagnostic d'une part et de déterminer l'existence d'éventuelle liaison entre eux. Dans cette thèse on s'intéresse à la fusion entre l'activité cérébrale (signal EEG) et l'activité cardiaque (signal ECG). Dans ce qui suit nous allons décrire le système cardiovasculaire.

### **I.3. Anatomie Cardiaque**

Le cœur est un organe musculaire creux intra thoracique de forme conique (12 cm de longueur, 9cm de largeur et d'une épaisseur de 6cm), il se situe un peu à gauche du centre de la cavité thoracique entre les poumons. Cette zone est appelée médiastin. La base du cœur en forme de cône est la plus haute, derrière le sternum, où les grands vaisseaux entrent ou sortent de cette partie. L'apex (pointe) du cœur pointe vers le bas et se trouve juste au-dessus du diaphragme à gauche de la ligne médiane (voir Figure I.15).

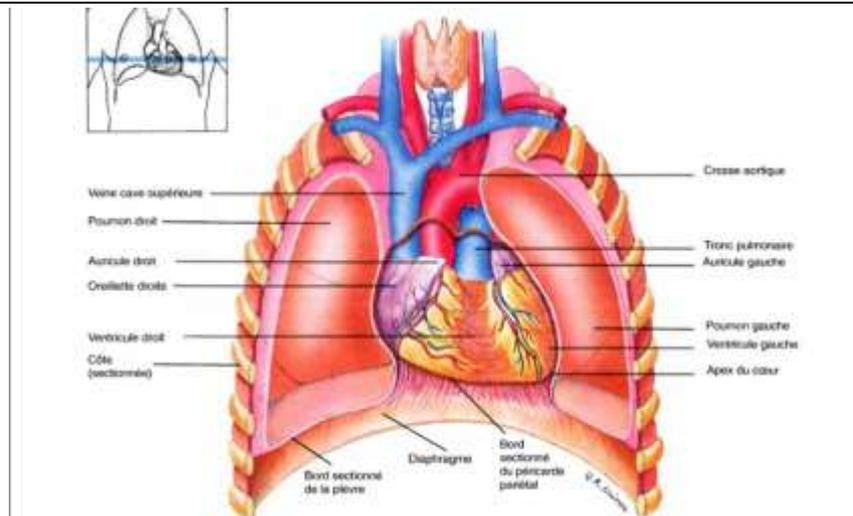


Figure I.15 : Position du cœur dans la cage thoracique (Tortora et al, 1993).

Le cœur est l'élément central du système cardiovasculaire qui assure la circulation du sang dans l'organisme à travers les vaisseaux sanguins. Il permet d'alimenter le corps entier en oxygène et en nutriments d'une manière continue et sous pression adéquate. La propulsion du sang à travers l'organisme est assurée par deux types de vaisseaux : les artères et les veines. Le débit de propulsion peut atteindre 5 litres par minutes. (Kholkhal, 2016. Valerie et al, 2007).

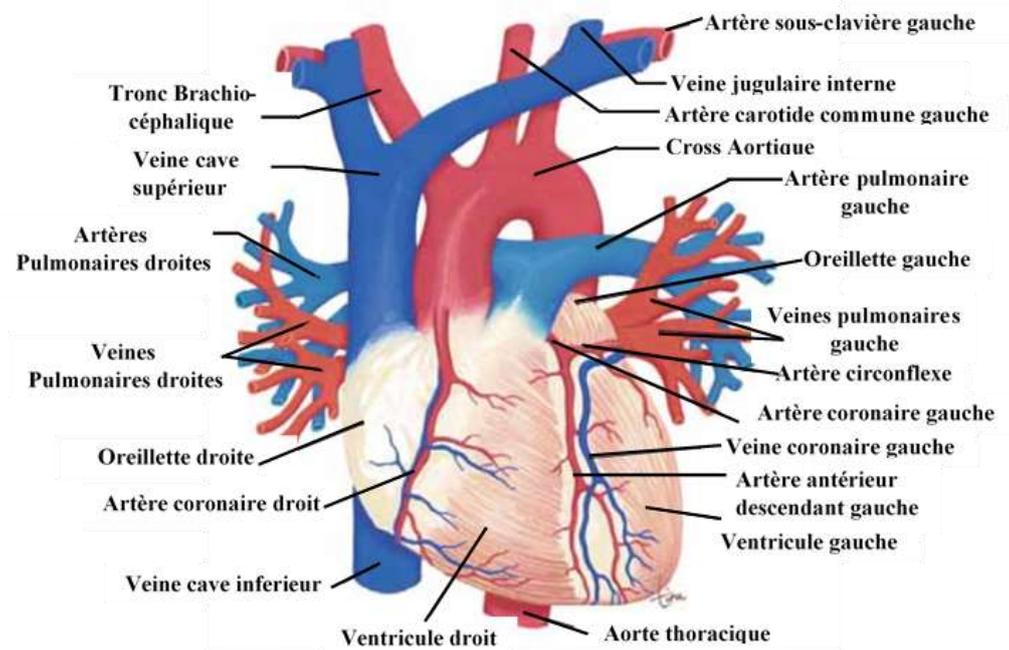


Figure I.16 : Vue antérieure du cœur et des principaux vaisseaux sanguins (Valerie et al, 2007).

Le cœur pèse environ 250 à 350 grammes, formé de trois parois de l'intérieur vers l'extérieur : l'endocarde, le myocarde et le péricarde. Il est composé de deux parties gauche et droite, chacune est constituée d'une oreillette en haut à paroi fine et un ventricule en bas à paroi épaisse. Le septum divise l'oreillette en ventricule gauche de l'oreillette et en ventricule droit,

afin d'éviter le passage du sang entre les deux moitiés constituant le cœur. Le passage du sang depuis les oreillettes et les ventricules se fait d'une manière unidirectionnel grâce aux valvules (tricuspides et bicuspidés) comme le montre la figure1.16.

Les oreillettes et les ventricules présentent quatre chambres (cavité), dans lesquels le phénomène mécanique et périodique du pompage du sang aura lieu. Le remplissage, la contraction (systole), la propulsion et le relâchement, ce sont les quatre phases indispensables afin de satisfaire l'irrigation du corps par le sang. (Hadj Slimane, 2006. Abdelliche, 2011)

- L'oreillette droite transmet au ventricule droit le sang reçu depuis les veines cave supérieur et inférieur.
- Le ventricule droit : transmet le sang provenant de l'oreillette droite vers les poumons.
- L'oreillette gauche transmet au ventricule gauche le sang provenant des veines pulmonaires.
- Le ventricule gauche transmet le sang provenant de l'oreillette gauche vers le système (Bachir, 2017).

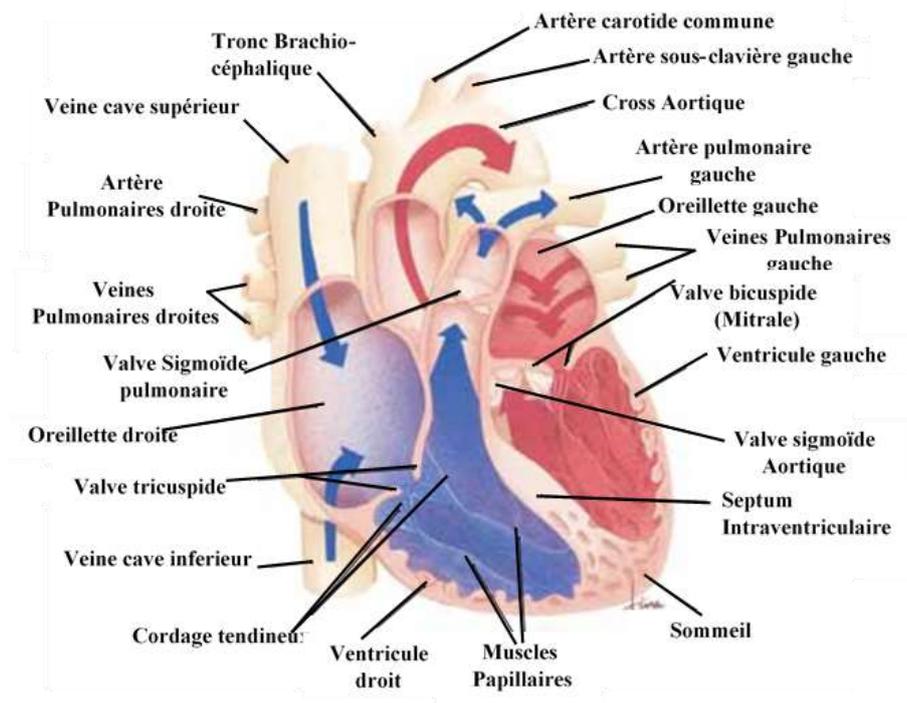


Figure I.17 : Coupe frontale du cœur en vue antérieure, montrant les structures internes (Valerie et al, 2007).

### I.3.1. La circulation sanguine

Deux types de circulations du sang assure une bonne irrigation en sang de tous les organes du corps qui sont :

- La petite circulation concerne la partie droite du cœur. Le sang riche en  $CO_2$  expulsé par le ventricule arrive aux poumons, à ce niveau s'effectue l'échange gazeux. Les poumons détachent le dioxyde carbone ( $CO_2$ ) et attachent le dioxygène ( $O_2$ ). le retour du sang vers l'oreillette gauche est assuré par les quatre vaines pulmonaires. On dit encore qu'il s'agit de la circulation pulmonaire.
- La grande circulation concerne la partie gauche du cœur. Le ventricule gauche propulse le sang oxygéné vers l'aorte. Ce dernier s'occupe à travers ses branches d'alimenter le cœur, et de distribuer le sang vers tous les autres organes du corps sous une pression importante. Il s'agit de la circulation Systémique.

L'ensemble des composants du cœur entrent en jeu afin d'accomplir une révolution cardiaque (battement cardiaque). Ce dernier comprend plusieurs étapes à savoir :

Tout d'abord l'oreillette se remplit du sang provenant des veines. C'est la phase diastole, ensuite la valve auriculo-ventriculaire s'ouvre et l'oreillette entre à la phase systolique, elle propulse le sang dans la cavité ventriculaire puis se relâche (diastole) jusqu'au prochain battement. La valve auriculo-ventriculaire se ferme (le bruit cardiaque B1), au même temps la valve entre le ventricule et l'artère s'ouvre, permettant l'éjection du sang (systole ventriculaire). Dès que le ventricule termine la propulsion, la valve artérielle se ferme (produisant le bruit cardiaque B2).

Pour terminer le sang revient à l'oreillette via les veines cave pulmonaire, et ce cycle recommence. Notons que toutes les étapes s'effectuent dans les deux moitiés du cœur et cela dure environ une seconde avec une manière synchrone et simultanée. Le mécanisme repose sur la contraction qui entraîne une différence de pression entre les cavités, permettant l'ouverture et la fermeture des valves. L'action de ces derniers résulte du remplissage et de l'éjection du sang. (Abdelliche, 2011).

Les parois du cœur sont constituées par plusieurs tissus (voir Figure I.18), à savoir :

- Le myocarde : c'est un tissu musculaire qui se compose de cellules musculaire cardiaque spécialisé (conductrices et contractiles).
- L'endocarde : c'est une couche mince qui englobe l'intérieur des cavités cardiaques.

Le cœur est enfermé dans les membranes péricardiques, dont il existe trois couches, qui sont :

- Le péricarde fibreux : c'est la couche la plus externe. Un sac de conjonctif fibreux fort qui s'étend inférieurement sur le diaphragme et supérieurement sur les bases des grands vaisseaux qui entrent et sortent du cœur.

- Le péricarde séreux : c'est une membrane plissée. Le pli donne deux couches ; la pariétale et la viscérale.
- Espace péricardique : contient un liquide séreux qui empêche la friction durant le battement (Valerie et al, 2007).

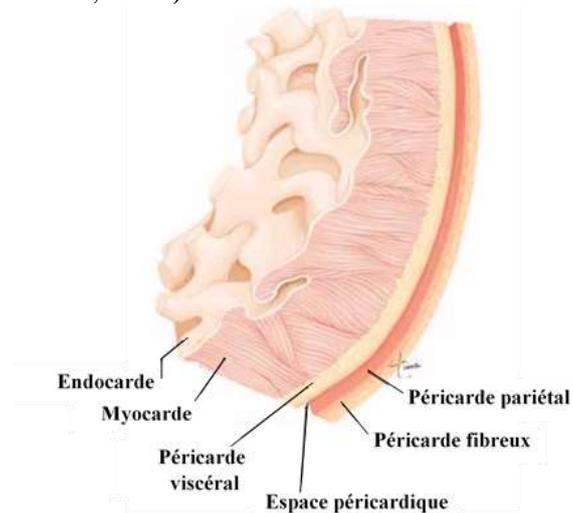


Figure I.18 : Les couches de la paroi du cœur et les membranes péricardiques. (Valerie et al, 2007).

### I.3.2. Physiologie de contraction du cœur

Chaque Cytoplasme d'une cellule joue le rôle d'une barrière physique face à ses constituants qui sont chargé négativement (les polyphosphates et les autres substances ionique). Cependant, les ions tels que  $K^+$  et  $Cl^-$  peuvent traverser facilement la membrane. On trouve ces ions dans les deux milieux (intra et extra cellulaire). Ils sont distribués de tel sort qu'elles forment un gradient entre les deux secteurs, qui résulte en fin de compte à un potentiel de repos à environs -90 mv polarisé négativement vers l'intérieur de la cellule (Kholkhal, 2016).

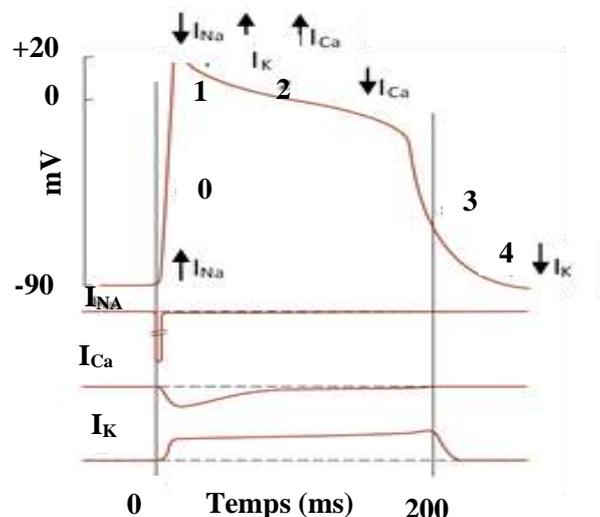


Figure I.19 : Potentiel d'action cardiaque. (Kim, 2010).

La stimulation produit un potentiel d'action propagé responsable à l'initiation de la contraction. Bien que les potentiels d'action varient parmi les cardiomyocytes dans différentes régions du cœur. La dépolarisation se déroule rapidement et un dépassement du potentiel zéro est présent, comme dans le muscle squelettique et le nerf, mais ceci est suivi par un plateau avant que le potentiel de la membrane ne revienne à la ligne de base. La dépolarisation dure environ 2 ms, mais la phase plateau et la repolarisation durent 200 ms ou plus. La repolarisation n'est donc pas complète tant que la contraction n'est pas terminée. Comme dans d'autres tissus excitables, les changements dans la concentration de  $K^+$  externe affectent le potentiel de membrane au repos du muscle cardiaque, alors que les changements dans la concentration de  $Na^+$  externe affectent l'amplitude du potentiel d'action (Kim et al, 2010).

Le potentiel d'action présente ainsi 5 phases successives (Figure I.19) :

- Phase 0 : dépolarisation rapide due à l'ouverture des canaux  $Na^+$ , similaires à ceux qui se produisent dans le muscle nerveux et squelettique.
- Phase 1 : repolarisation rapide due à la fermeture des canaux  $Na^+$  et ouverture des canaux  $K^+$ .
- Phase 2 : ouverture des canaux  $Ca^{+2}$  plus lente et prolongée provoque un plateau prolongé.
- Phase 3 : La repolarisation finale.
- Phase 4 : fermeture des canaux  $Ca^{+2}$  et une lente augmentation de  $K^+$  à travers les canaux  $K^+$ .

Accouplement excitation-contraction : ce terme utilisé pour la première fois en 1952, décrit un processus physiologique qui transforme une impulsion électrique en une contraction mécanique. Sous l'effet de la stimulation électrique d'une cellule musculaire, une activité mécanique est apparue (contraction). Sachant que le fonctionnement du cœur est automatique une impulsion électrique est générée lors de chaque battement, et elle se propage sous forme de stimulation toutes au long des fibres musculaire constituant le myocarde entraînant par la suite la contraction. L'origine de cette impulsion est le nœud sinusal (SA). Il est considéré comme un pacemaker naturel. Les cellules composant le pacemaker ont une longueur entre 5-10  $\mu m$ . La propagation de cette stimulation est effectuée à l'aide d'un système de conduction qui permet la synchronisation de la contraction des ventricules et d'oreillettes (Figure I.20. (Dabbagh et al, 2014. Abdelliche et al. 2011. Feneck, 1994).

Le système de conduction est composé par :

- Un nœud Sinusal ou sino-auriculaire (SA) qui se situe dans la partie haute de l'oreillette droite.
- D'un nœud auriculo-ventriculaire (AV) qui est situé dans la partie postérieure droite du septum inter-oreillette.
- D'un faisceau auriculo-ventriculaire, ou encore faisceau de His, qui est relié avec le nœud auriculo-ventriculaire.
- Des branches droites et gauches du faisceau de His dont l'extension du faisceau de His est sous forme de deux branches, ou la branche gauche entre en contact avec le système de Purkinje
- D'un réseau de Purkinj qui contient des fibres qui se propagent à toutes les parties du myocarde ventriculaire.

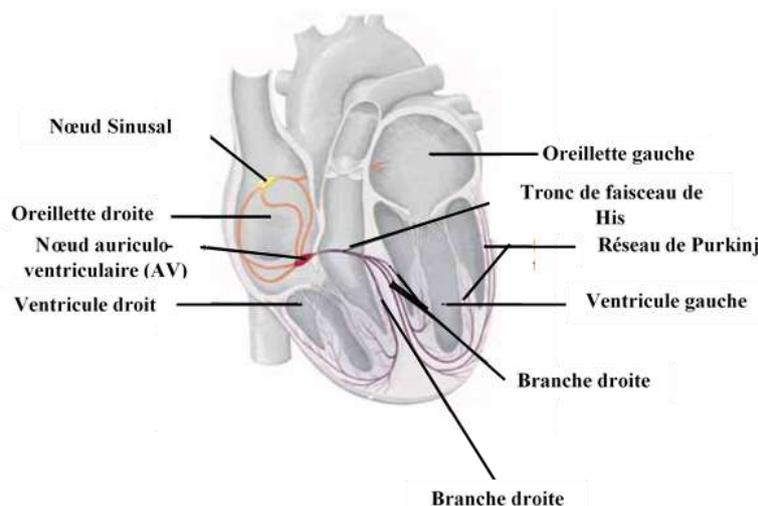


Figure I.20: La Voie de conduction au cœur (Valerie et al, 2007).

### I.3.3. Chronologie de l'excitation électrique du cœur

La dépolarisation initiée dans le nœud SA se propage à travers les oreillettes entraînant leur contraction (systole auriculaire). La dépolarisation auriculaire est complète au environ de 0,1 s (voir tableau I.2), puis converge sur le nœud AV qui correspond au point de passage électrique entre l'oreillette et le ventricule. A ce niveau l'excitation fait un retard de 0.1 s avant qu'elle soit propagée à travers le faisceau de His vers les ventricules. Ensuite l'onde de dépolarisation continue à se diffuser rapidement dans les fibres conductrices constituant le réseau de Purkinje à toutes les parties des ventricules en 0.08 à 0.1s, entraînant la contraction ventriculaire (systole ventriculaire). Il faut noter que la dépolarisation du muscle ventriculaire commence au côté gauche de la cloison interventriculaire et se déplace d'abord vers la droite à travers la partie médiane du septum. L'onde de dépolarisation se propage ensuite dans le septum jusqu'au

sommet du cœur. Les cellules se repolarisent et le muscle cardiaque se décontracte (diastole), le cycle cardiaque est terminé et le cœur se prépare pour un nouveau cycle.

Tissus	Vitesse de conduction (m/s)
Nœud sinusal (SA)	0.05
Voies atriales	1
Nœud auriculo-ventriculaire (AV)	0.05
Faisceau de His	1
Réseau de Purkinj	4
Muscle Ventriculaire	1

Tableau I.2 : Les vitesses de conduction dans le tissu cardiaque (Kim et al, 2010).

### I.3.4. Electrocardiogramme

La dépolarisation et la repolarisation sont des événements qui génèrent un champ électrique. Ce champ peut être détecté par des électrodes placées sur la peau. Durant le déplacement de ce front d'excitation à travers le muscle cardiaque se forment divers potentiels qui se différencient par leur forme, taille, morphologie et leur direction. Le tracé de la somme de ces événements électrique est caractérisé par l'apparition de plusieurs formes d'ondes, c'est l'électrocardiogramme ECG (Stefan et al, 2000). (Voir Figure I.21).

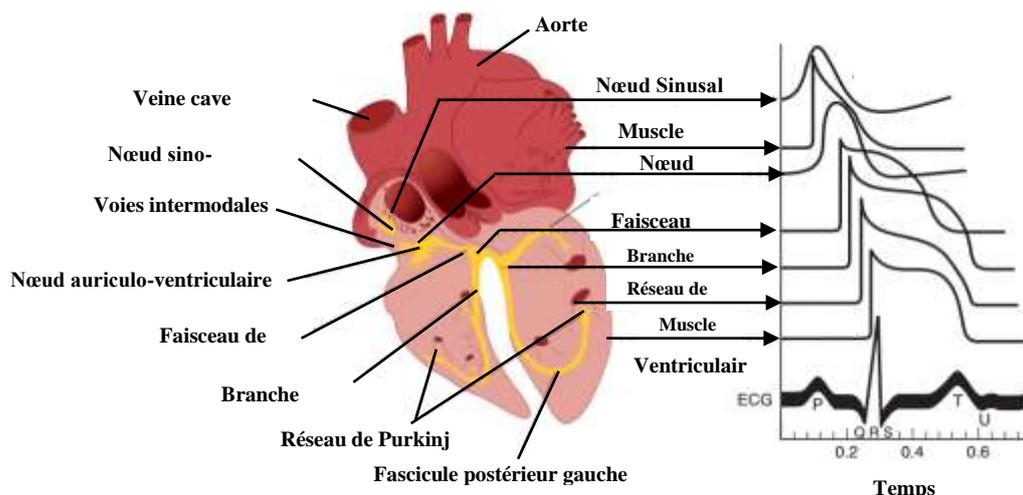


Figure I.21 : Système de conduction du cœur. À gauche : Représentation anatomique du cœur humain avec les zones du système de conduction. Droite : Les potentiels d'action transmembranaires typiques pour l'ensemble des constituants intervenant dans la génération du signal ECG (Kim et al,2010).

L'impulsion du nœud sinusal SA n'est pas détectable sur l'ECG, mais l'onde de dépolarisation myocardique atriale est vue comme l'onde P, elle a une amplitude qui peut aller jusqu'au 25 mV dans le cas normal. Ensuite l'onde de dépolarisation atteint le nœud auriculo-ventriculaire avec un délai qui permet le remplissage de ventricule, pendant ce retard l'ECG revient au silence électrique a la ligne de base, il s'agit du segment PR (courte période de silence). La dépolarisation ventriculaire est visible sur l'ECG en tant que complexe QRS. En même temps, la repolarisation auriculaire progresse et cela génère également un champ électrique, mais il est trivial contrairement à la dépolarisation ventriculaire et est généralement perdu dans l'activité électrique de la dépolarisation ventriculaire. L'onde Q représente le début de dépolarisation du septum intraventriculaire. Le reste des deux ventricules se contracte simultanément et comprend le complexe QRS. Après cette dépolarisation, il y a une autre pause qui correspond au segment ST, et qui commence à la fin de l'onde S et dure jusqu'au début de l'onde T. cette dernière représente la repolarisation ventriculaire. Finalement l'onde U qui représente une déflexion inconstante et informelle (Feneck et al, 1994).

L'apparition des différentes ondes relatives au potentiel d'action et aux parties participées au cycle cardiaque sont données par la Figure I.22.

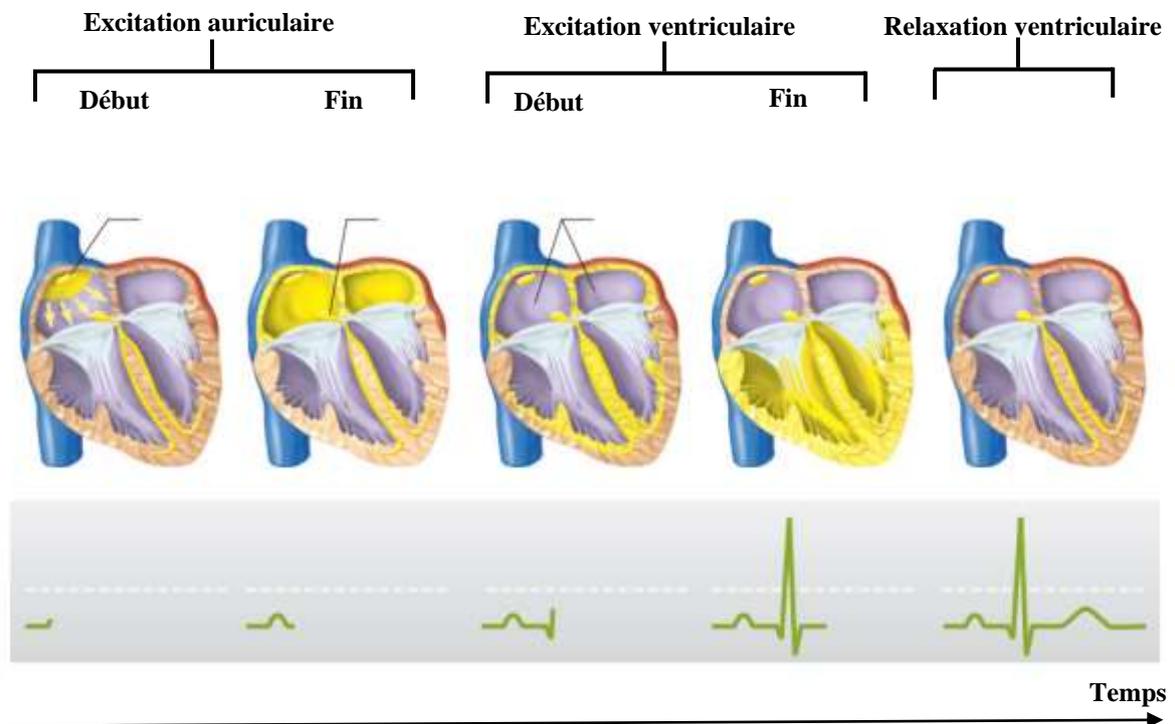


Figure I.22 : Séquence d'excitation cardiaque dans le cas d'une Propagation normale de l'activité électrique dans le cœur (Kim et al, 2010)

### **I.3.5. Caractéristiques du signal électrocardiogramme (ECG)**

L'ensemble de l'ECG doit être examiné de façon systématique et avec soin afin d'éviter les erreurs. Dès 1959, Goldman a démontré qu'une mauvaise interprétation de variantes normales peut conduire à une invalidité cardiaque. Même aujourd'hui, des interventions diagnostiques et thérapeutiques mal avisées peuvent être basées sur des variantes normales. On peut tirer depuis l'analyse du signal ECG plusieurs paramètres permettant la caractérisation de l'état physiologique de l'activité cardiaque. (Chapelon, 2004. Kim et al, 2010. Gertsch, 2004).

#### **I.3.5.1. Rythme Cardiaque**

Le rythme auriculaire est régulier, les intervalles P-P ne variant pas de plus de 0,15 s au repos, toutes les ondes devraient être identiques, le changement du rythme aura lieu lors d'une activité physique ou bien lors d'un changement psychologique tel que la colère, ainsi la fréquence cardiaque varie d'un sujet à un autre, et correspond au nombre de battements par minute (contraction par minute), comprise entre 60 et 100 battements par secondes.

#### **I.3.5.2. Caractéristiques fréquentielles**

Plusieurs composantes fréquentielles du signal ECG peuvent être relevé suivant ses constituants, ainsi :

- L'ECG occupe une bande fréquentielle qui s'étale de la fréquence zéro jusqu'à 100 Hz.
- Une gamme basse fréquence entre 0.5 et 10 Hz correspond à l'onde P et l'onde T.
- Le complexe QRS peut être caractérisé par une bande de fréquence plus importante variant entre 10 et 15 Hz
- La plage fréquentielle entre 0.5 et 7 Hz correspond au contenu de la ligne de base, qui est contaminée par plusieurs artéfacts tel que le mouvement lors de l'enregistrement (Bachir ,2017).

#### **I.3.5.3. Caractéristiques des ondes et des segments du signal ECG**

Chaque onde constituant le signal ECG possède une morphologie et une amplitude suivant les dérivations utilisées (Chapelon, 2004. Abdelliche, 2011) :

- L'onde P : son contour est arrondi et peut être positive, négative ou diphasique en fonction de la direction du vecteur et en fonction de l'âge du sujet, son amplitude est maximale en D1 et D2 environ 0.2mV, la durée de cette onde ne doit pas dépasser 0.12 s dans le cas normal.

- Le complexe QRS : dépend de l'orientation et de la projection sur le plan, il est toujours négatif en aVR, positive en D2, il existe une prédominance de négativité de QRS en précordiales droites et une prédominance de positivité de QRS en précordiales gauches. La durée du complexe compris entre 0,06 et 0,10 s, chez l'enfant elle est de l'ordre 0.09 s. on note qu'à côté du type de dérivation utilisé l'amplitude du complexe QRS dépend aussi de l'âge, sexe morphologie thoracique et situation des électrodes précordiale par rapport au cœur, les amplitudes sont résumées dans le tableau suivant :

Amplitude QRS en dérivations périphériques	Amplitude de QRS en dérivations précordiales
R en D1 < 1.5 mV	R en V1 ≤ 0,5 mV
R en D2 < 23 mV	R en V6 ≤ 2,5 mV
R en D3 < 18 mV	R en V2 ≤ 2,5 mV
R en (aVL) < 1,2 mV	R/S en V1 < 1
R en (aVF) < 2.1 mV	R/S en V5 > 1
Q en D1 < 0.3 mV	R/S en V6 > 2
Q en D3 < 0.5 mV	R/S en V7 > 3
Q en (aVF) < 0.35 mV	S en V1 + R en V5 < 3.5 mV

Tableau I.3 : les amplitudes normales pour différentes dérivations (Abdelliche, 2011. Chapelon, 2004).

L'onde T : une onde monophasique asymétrique caractérisée par une déflexion lente avec un aspect accentué chez les enfants, elle peut être diphasique dans les dérivations D3, aVL, aVF et les précordiales droites et moyennes. Son amplitude décroît avec l'âge, elle possède des amplitudes élevées en V2 et V4 contrairement en D1, D2 et dans les dérivations précordiales gauches. Sa durée est environ 0.2 s et son amplitude est calculée à travers le rapport R/T, ce dernier doit être compris entre 2 et 10 dans le cas normal.

- L'onde U : n'est toujours pas identifiable, généralement elle visible en D2 lorsqu'il s'agit d'un enfant ou bien lors de l'apparition d'une tachycardie, sa durée compris entre 0.16 et 0.25 s avec une amplitude faible (5 à 50% de l'onde T) et plus élevées en V2 et V3 (jusqu'au 0.2 mV).

- Intervalle PR : c'est le temps de conduction auriculo-ventriculaire (espace entre le SA et myocarde ventriculaire).
- Intervalle ST : il se situe sur la ligne de base (isoélectrique) avec possibilité de décalage vers le haut ou le bas, il correspond à la barrière de séparation entre la repolarisation et dépolarisation ventriculaire, il commence au point J jusqu'à la fin de l'onde T.
- Intervalle QT : s'étend entre le début de l'onde Q jusqu'à la fin de l'onde T, le segment peut être mesuré en D2, V2, V5, sa durée est calculée en fonction de RR par la formule de Bezett :  
 $QT\ corrigé = QT/RR$  Où QT corrigé correspond à une valeur inférieure 0.39 s pour l'homme et 0.44 s pour la femme dans les conditions stables et à une fréquence de 60 battements par seconde.
- Intervalle QU : situé entre le début du complexe QRS et la fin de l'onde U, il est mesuré seulement si l'onde U est bien observée, plus souvent dans les dérivations précordiales.

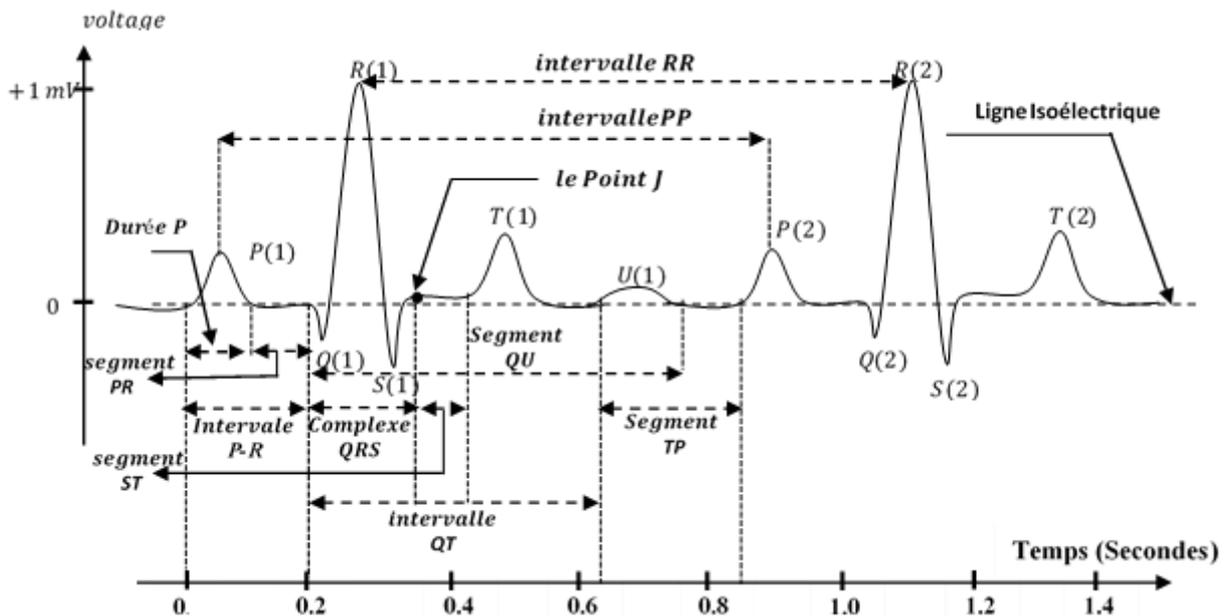


Figure I.23 : Représentation d'un signal ECG typique avec la notation des différentes ondes et intervalles.

Intervalles	Moyennes	Plage	Événements dans le cœur pendant l'intervalle
Intervalle RR	0.18	0.12-0.20	Dépolarisation artérielle Conduction à travers le Nœud AV

Durée du QRS	0.08	Jusqu'au 0,10	Dépolarisation ventriculaire Repolarisation artérielle
Intervalle QT	0.40	Jusqu'au 0,43	Dépolarisation ventriculaire Avec repolarisation ventriculaires
Intervalle ST (QT -QRS)	0.32	....	Repolarisations ventriculaires durant l'onde T
Intervalle QU	0.56	0.44-0.68	

Tableau I.4 : durées des Intervalles du signal ECG (Kim et al, 2010).

Pour un sujet normal les intervalles entre les différentes ondes sont indiqués au Tableau I.4 en dessus.

### I. 3.6. Technique d'enregistrement de l'ECG

La technique d'enregistrement a connu plusieurs étapes évolutives depuis la découverte du potentiel généré par l'activité musculaire cardiaque en 1842 par Carlo Matteucci , suivi par les travaux de John Burden Sanderson et Frederick Page en 1878, qui consiste à la détection à la détection des phases du complexe QRS et l'onde T. Augustus Waller et E. Marey stipulent que l'activité électrique cardiaque peut être recueillie sur la surface de la peau, en réalisant alors le premier électrocardiogramme en 1887. Willem Einthoven a établi les Cinq déflexions P, Q, R, S et T. Wilson introduit les dérivations unipolaires en 1932, Kossman propose les dérivations unipolaires précordiales en 1935, convention américano-britannique sur les positions officielles v1 à V6, 1942 le triangle d'Goldberger a été modifié, il a réussi de réaliser le premier tracé sur 12 voies (Abdelliche, 2011. Sende, 2003).

Le signal ECG peut être enregistré à partir des électrodes posées sur différents points précis et bien situés sur la peau, et cela sur les deux plans : sur le plan frontal par des dérivations périphériques, et sur le plan horizontal par des dérivations précordiales. Aujourd'hui, l'enregistrement de l'ECG est standardisé par des normes internationales afin de garantir la reproductibilité ainsi que la standardisation de lecture, de présentation et l'interprétation de l'ECG. Un papier millimétré est nécessaire pour l'enregistrement de l'ECG, on trouve sur l'axe horizontal le temps exprimé en seconde, pour chaque 1 mm nous avons une durée de 0.04 s. Sur l'axe vertical on trouve l'amplitude exprimé en mv, où pour chaque 1 mm nous avons une amplitude de 1 mV.

Généralement l'enregistrement du signal ECG s'effectue au repos, où le patient est allongé et les électrodes sont placées. Le temps nécessaire pour accomplir le diagnostic peut atteindre

quelque minute. Lors de l'existence d'une pathologie permanente, ce type d'enregistrement est efficace, le médecin peut alors localiser sur le tracé l'anomalie rapidement (exemple d'infarctus myocardique). Cependant, il y a d'autres pathologies qui apparaissent d'une manière intermittente, dans ce cas l'ECG au repos ne sera pas utile. Pour cela le médecin doit faire appel à la technique d'Holter. Cette technique consiste à placer un appareil ambulateur après avoir placé les électrodes sur le corps. Le patient retourne chez lui et exerce ses occupations habituelles. L'appareil est capable d'enregistrer sur sa mémoire interne l'activité cardiaque pendant 24 heures (y compris la phase nocturne). Le médecin analysera ensuite l'enregistrement ce qui permet de localiser d'éventuelles pathologies (Abdelliche, 2011. Sende, 2003).

### I.3.6.a. Dérivations électrocardiographiques standards D I, II, III d'Einthoven

Ce sont des dérivations bipolaires dans le plan frontal. Elles examinent l'évolution temporelle de la différence de potentielle entre les deux bras et la jambe. L'idée d'Einthoven est inspirée à partir de la loi de Kirchhoff, à travers les trois électrodes il réalisa un triangle dans laquelle se situe le cœur, on pourra donc avoir trois différences de potentielle nommées  $D_1$ ,  $D_2$  et  $D_3$ , la configuration d'Einthoven est illustrée par la Figure I.24.

- La dérivation I ( $D_1$ ) : Mesure bipolaire entre bras gauche (+) et bras droit (-).
- La dérivation II ( $D_2$ ) : Mesure bipolaire entre jambe gauche (+) et bras droit (-).
- La dérivation III ( $D_3$ ) : Mesure bipolaire entre jambe gauche (+) et bras gauche (-).

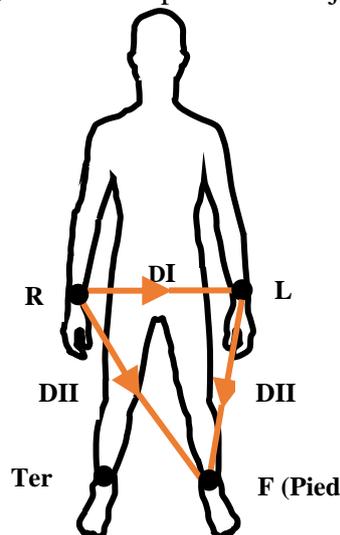


Figure I.24 : Dérivations d'Einthoven

### I.3.6.b. Les dérivations unipolaires de Goldberger

Elles sont aussi des dérivations dans le plan frontal. Goldberger a relié deux électrodes à travers des résistances, à ce moment ces deux électrodes servent d'électrode de référence par rapport

à l'électrode restante(figure), et la dénomination des électrodes deviennent : aVR, aVL et aVF, où la lettre «a» indique que le signal est amplifié, et «V» signifie que la dérivation est unipolaire est amplifié, R,L ,F représentent respectivement Right (droite), Let (gauche) et foot (pied)( Hadj slim, 2006, Kholkhal, 2016).

- aVR : entre (bras gauche + pied) et bras droite.
- aVL : entre (bras droite + pied) et bras gauche.
- aVF : entre (bras droite + bras gauche) et pied.

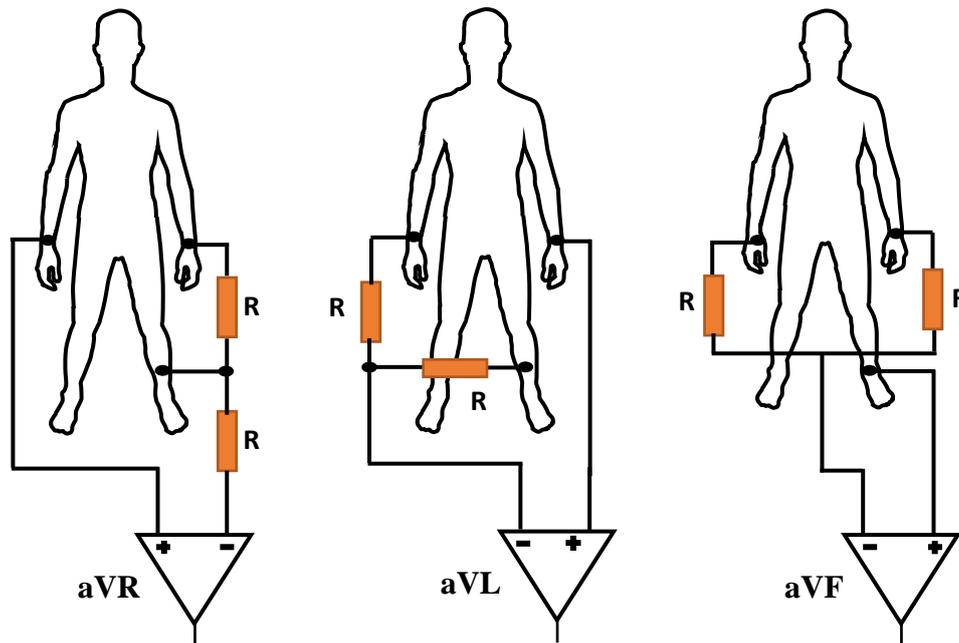


Figure I.25 : Dérivation unipolaire de Goldberger.

### I.3.6.c. Les dérivations unipolaires précordiales de Wilson

Elles sont enregistrées à partir du thorax le long d'une ligne à peu près horizontale (F). Ces dérivations précordiales permettent de visualiser tout particulièrement les vecteurs à orientation dorsale, ces vecteurs ne produisent que des déflexions minimales.

On reconnaît six types de dérivations précordiales :

- V1 : électrode placée au 4<sup>ème</sup> espace intercostale à droite du sternum
- V2 : électrode placée au 4<sup>ème</sup> à gauche du sternum

- V3 : électrode placée à la moitié de la distance, entre V2 et le mamelon
- V4 : électrode placée sous le mamelon à l'intersection de la ligne horizontale passant par le 5<sup>ème</sup> espace intercostal gauche et de la ligne medio - claviculaire
- V5 : électrode placée à mi-distance entre le mamelon et la ligne axillaire antérieure
- V6 : électrode placée sur la ligne axillaire moyenne.

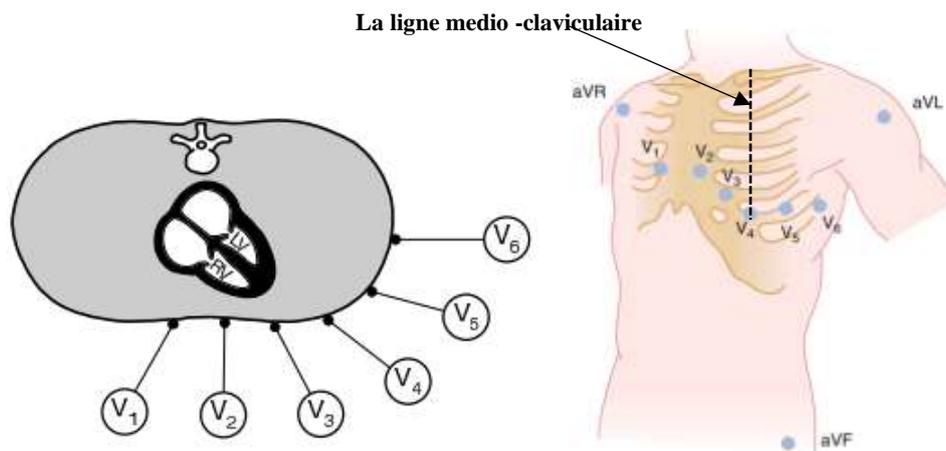


Figure I.26 : Dérivations unipolaires précordiales de Wilson (Kim, 2010)

### I.3.7. Artefacts visibles sur les signaux physiologiques

Tous les signaux électro physiologiques sont mêlés de plusieurs sources de bruit indésirables (physiologique et non physiologique), et qui peuvent influencer particulièrement la morphologie des ondes et résultent généralement d'une déformation totale de l'allure du signal à cause de ses faibles amplitudes. Ce sont des artefacts qui peuvent conduire à un diagnostic erroné en fin de compte. On résume les sources de bruit comme suit :

#### I.3.7.a. Bruit non physiologique

L'appareil médical dédié à la détection et l'enregistrement d'une activité électrophysiologique nécessite une source d'alimentation permanente lors du fonctionnement de l'appareil médical, cette source correspond à la tension du secteur, elle peut se propager dans l'air à travers l'effet de l'interférence électromagnétique et peut associer avec le tracé et avec la même harmonie du secteur. Il s'agit du 50Hz (réseau électrique européen) ou 60Hz (réseau électrique américain) (figure 1.26). Comme solution préventif le concepteur de l'appareil généralement utilise un circuit d'amplification avec un gain de rejection en mode commun trop élevé, des électrodes à

impédance supérieur à  $5\text{ K}\Omega$ , une isolation optique et électromagnétique entre la partie détection et alimentation. Comme solution curatif un filtre réjecteur est indispensable afin d'éliminer cette harmonie. Il faut noter que la mauvaise application des électrodes peut entraîner un mauvais contact peau-électrodes, ce qui provoque un mouvement des électrodes, et en fin un bruit sur tracé.

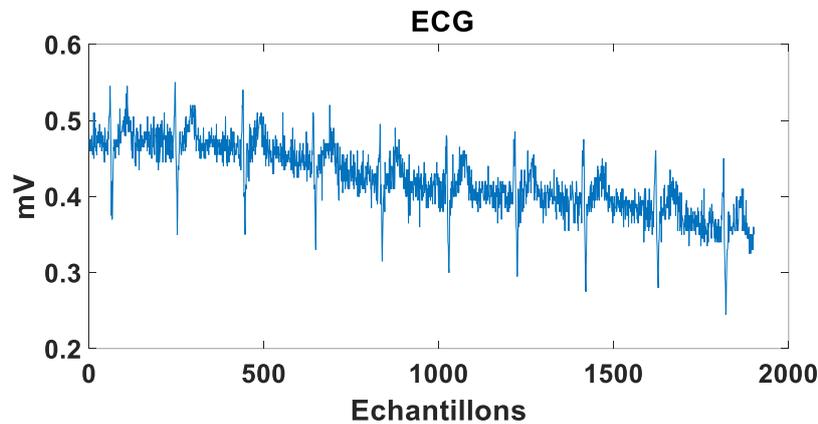


Figure I.27 : Exemple d'un signal ECG réel induit par 50 Hz avec l'artefact de la ligne de base.

### I.3.7.b. Bruits physiologique

Les artefacts physiologiques inclus les contractions des muscles tels que les muscles du scalp, le clin d'œil et l'activité musculaire de la mâchoire peuvent induire le signal EEG. Cette dernière résulte d'une activité à haute fréquence observée sur les tracés de l'EEG (Figure I.28). Le bruit dus à l'activité respiratoire à côté de l'activité peut aussi influencer sur le signal ECG par l'apparition des oscillations sur le tracé de l'ECG accompagné avec un mouvement oscillatoire de la ligne de base.

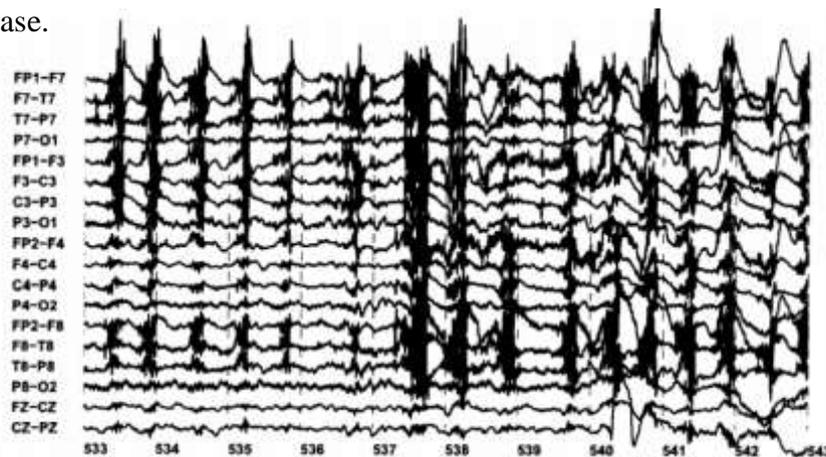


Figure I.28 : Exemple d'un signal EEG interrompu par une activité haute fréquence associée avec l'effet de mastication.

### **I.3.8. Relation cœur cerveau**

Nous avons vu auparavant que le cerveau représente le centre de la pensée et contrôle toutes les fonctions du corps. Bien que le cœur génère et maintient son propre rythme, le taux de contraction peut être modifié pour s'adapter à différentes situations. Le système nerveux peut entraîner les changements nécessaires dans la fréquence cardiaque ainsi que dans la force de contraction.

La moelle du cerveau contient les deux centres cardiaques, le centre de l'accélérateur et le centre inhibiteur. Ces centres envoient des impulsions au cœur le long des nerfs autonomes. Il faut noter que le système nerveux autonome a deux divisions : sympathique et parasympathique.

- Les impulsions sympathiques du centre de l'accélérateur le long des nerfs sympathiques augmentent la fréquence cardiaque et la force de contraction pendant l'exercice et les situations stressantes
- Les impulsions parasympathiques du centre inhibiteur le long des nerfs vagues diminuent la fréquence cardiaque. Au repos, ces impulsions ralentissent la dépolarisation du nœud SA elles ralentissent également le cœur après la fin de l'exercice.

Le sang contient de l'oxygène, que tous les tissus doivent recevoir en permanence et avec une pression artérielle normale. Par conséquent les changements dans ces deux grandeurs (pression artérielle et le taux d'oxygène dans le sang) représentent l'information lue par la moelle afin de générer des stimulus pour la régulation de la fréquence cardiaque.

Les pressorecepteurs et chémorécepteurs sont situés dans les artères carotides et l'arc aortique qui détectent les changements de la teneur en oxygène du sang. Les récepteurs de pression des sinus carotidiens et des sinus aortiques détectent les changements de la pression artérielle

Les nerfs sensoriels des récepteurs carotidiens sont les nerfs glossopharyngiens et les nerfs sensoriels des récepteurs de l'arc aortique sont les nerfs vagues. L'ensemble de ces deux constituent le système de régulation de la fréquence cardiaque, cette dernière est un processus de réflexe.

Une personne qui se lève soudainement d'une position couchée peut ressentir la tête étourdie pendant quelques instants à cause de la diminution brutale de la pression artérielle au niveau du cerveau. Cette baisse est détectée par pressorecepteurs situés dans un endroit stratégique (sur le chemin du cerveau dans un sinus carotidien), qui entraîne par la suite une chute d'impulsions générées par pressorecepteurs. Ces impulsions voyagent le long des nerfs glossopharyngiens

vers la médullaire. La diminution de la fréquence des impulsions stimule le centre de l'accélérateur, ce dernier génère des impulsions portées par les nerfs sympathiques vers le nœud SA, le nœud AV et le myocarde ventriculaire. Au fur et à mesure que la fréquence cardiaque et la force augmentent, la pression sanguine vers le cerveau passe à la normale et la sensation de vertige passe à ce moment. Ainsi le cœur reçoit plus d'impulsions parasympathiques du centre inhibiteur le long des nerfs vagues vers le nœud SA et le nœud AV. ces impulsions ralentissent le rythme cardiaque à un rythme normal de repos.

Il faut noter que Le cœur sera aussi l'effecteur dans un réflexe stimulé par une diminution de la teneur en oxygène du sang, Les récepteurs aortiques sont responsables de détecter le taux d'oxygène dès que le sang quitte le cœur. L'arc réflexe dans cette situation serait (1) les chémorécepteurs aortiques, (2) les nerfs vagues (sensoriels), (3) le centre de l'accélérateur dans la médullaire, (4) les nerfs sympathiques, et (5) le muscle cardiaque, qui augmentera son taux et force de contraction pour faire circuler plus d'oxygène pour corriger l'hypoxie

Rappelons que L'hormone adrénaline sécrétée par la médullosurrénale dans des situations stressantes a pour fonction d'augmenter à la fois la fréquence cardiaque et la force de contraction afin de fournir plus de sang oxygéné aux tissus ayant besoin de plus d'oxygène.

Nous avons également expliqué cette partie afin de montrer l'existence d'une relation entre les deux activités (cérébrale et cardiaque) d'une part et de faire une étude (dans ce qui vient) sur leur tracés électrophysiologiques et déterminer d'éventuelle relations entre les deux.

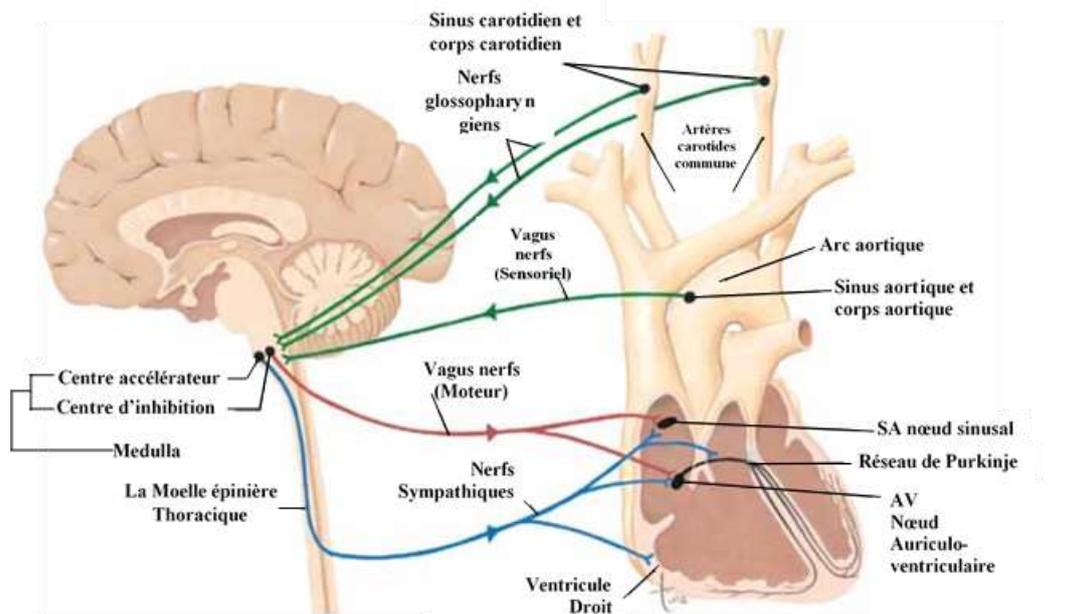


Figure I.29 : Régulation nerveuse du battement et de la force de contraction (Valerie, 2007).

## **I.4. Conclusion**

A travers ce chapitre nous avons consacré la première partie pour le cerveau en donnant une description structurelle anatomique et fonctionnelle du système cérébral. Nous avons ensuite introduit la notion de l'électroencéphalographie, en expliquant l'origine de l'activité cérébrale avec la technique permettant la détection et l'enregistrement de l'EEG. La technique consiste à placer des électrodes sur le scalp avec une distribution spatiale standardisée (système 10-20). La méthode d'analyse de l'EEG nécessite un enregistrement pour des longues durées et dans des différentes situations (sommeil, éveil, yeux fermé ou ouvert), l'interprétation des tracés fait l'objet de diagnostic pour plusieurs anomalies tel que l'épilepsie. La deuxième partie est consacrée pour le cœur, ce dernier correspond à l'élément moteur du système cardiovasculaire. Une description anatomique et fonctionnelle du cœur nous a permis de comprendre l'activité électrique du cœur et les méthodes utilisées afin de pouvoir enregistrer cette activité, il s'agit de l'ECG (électrocardiogramme). Douze dérivations sont utilisées pour acquérir le signal électrophysiologique à travers des électrodes posées sur les membres ainsi que sur le thorax (électrodes précordiales). Nous avons exposé la morphologie d'un ECG en précisant les intervalles et les durées qui correspondent à des cas normaux (non pathologiques). Ensuite nous avons présentés les problèmes induits par les différents bruits et artefacts pouvant influencer sur ces signaux électrophysiologiques. Finalement nous avons exposé une partie dans laquelle la relation entre les deux systèmes (cardio vasculaire et cérébrale) est illustrée avec un schéma explicatif.

## **Chapitre II : Etude et réalisation d'un système de monitoring en temps réel et d'analyse spectrale des signaux EEG et ECG pour la détection des crises d'épilepsie**

### **II.1. Introduction**

L'évolution des technologies de télécommunication a largement contribué dans le développement des systèmes modernes, elle permet une acquisition et une analyse précise des signaux électrophysiologiques tels que les signaux d'électrocardiogramme (ECG) et d'encéphalogramme (EEG). Ce sont des signaux électriques qui varient au cours du temps, Il s'agit de différence de potentiel caractérisé par ; une forme, un contenu fréquentielle et amplitude spécifique pour chaque activité biologique. La connaissance de ces paramètres qui entre en jeu peuvent être employés pour sélectionner quel type de circuit convient afin d'acquérir le mieux possible le signal.

Ce chapitre est consacré à l'étude des facteurs techniques qui conditionnent d'une manière générale la mesure, l'enregistrement en temps réel, la transmission sans fil des données et l'analyse des activités électriques cardiaque et cérébrale en vue de créer une base de données médicale. L'activité électrique cérébrale est recueillie à partir des électrodes placées sur le scalp par rapport à une électrode de référence, tandis que l'activité cardiaque est obtenue à travers des électrodes placées sur les membres supérieurs par rapport à une électrode de référence. Un microcontrôleur inclus dans une carte électronique de type Arduino permettant la digitalisation et l'analyse spectral des signaux. Un afficheur graphique LCD 128\*64. Un module Bluetooth assure la transmission sans fils des données. Un module Xbee radio fréquence permettre d'augmenter encore en plus la distance de transmission à travers sa longue portée via la modulation des ondes radio fréquences. Finalement une interface graphique et une terminale pour un éventuelle traitement et affichage en temps réel.

Une analyse spectrale est effectuée pour l'ensemble des signaux électrophysiologiques acquis sur l'interface graphique à l'aide de l'environnement de programmation Matlab, elle concerne le calcul de la transformée de Fourier Rapide(FFT), la densité spectrale de puissance (PSD), la représentation temps-fréquence (transformée de Fourier à court terme (TFCT)) et en fin la représentation temps-échelle (transformée en ondelettes continue (TOC)).

A la fin de ce chapitre nous proposons également le calcul de la cohérence quadratique noté « MSC » comme paramètre important traduisant la relation entre les signaux ECG et EEG dans le domaine fréquentiel et qui peut être utiliser comme un discriminateur pertinent lors de la classification des crises d'épilepsie.

## II.2. Architecture de système et circuit d'acquisition

Nous présentons un schéma bloc qui permet d'avoir une idée sur le principe et les dispositifs électronique utiles afin d'acquérir le mieux possible les signaux désirées. Le schéma bloc du système de surveillance EEG et ECG sans fil suggéré est présenté par la Figure II.1.

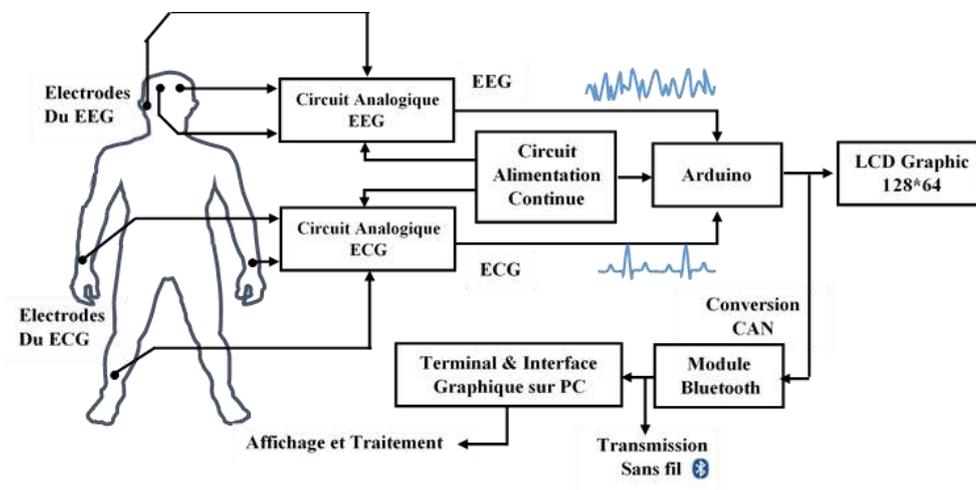


Figure II.1 : Schéma Bloc de Système.

Dans ce qui suit nous allons :

- Expliquer le rôle et le fonctionnement de chaque bloc (définition, propriétés)
- Décrire les caractéristiques des composants et des circuits utilisés pour la mesure et la mise en forme des signaux EEG et ECG.
- présenter le type et le protocole de communication.

### II.2.1. Circuit Analogique du signal ECG

Le circuit analogique permettant la détection du signal ECG est subdivisé en 7 étapes essentielles illustrées par la Figure II.2, où chaque étape représente un étage qui doit remplir une fonction électronique bien déterminée.

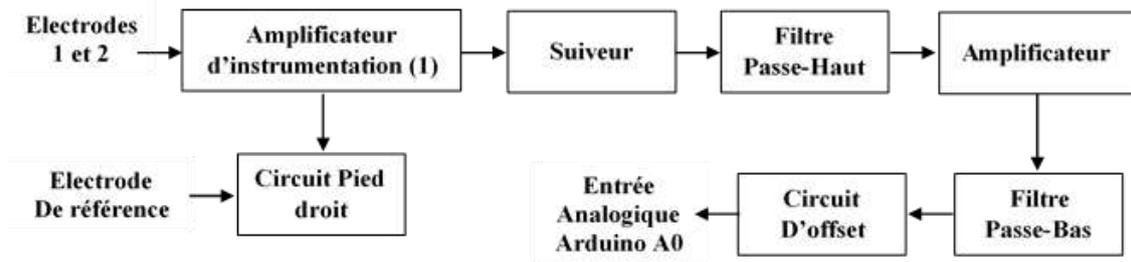


Figure II.2 : Schéma Bloc du circuit analogique pour la détection du signal ECG.

Schéma électrique du circuit permettant la détection de l'activité cardiaque (signal ECG) est présentée dans la Figure II.3.

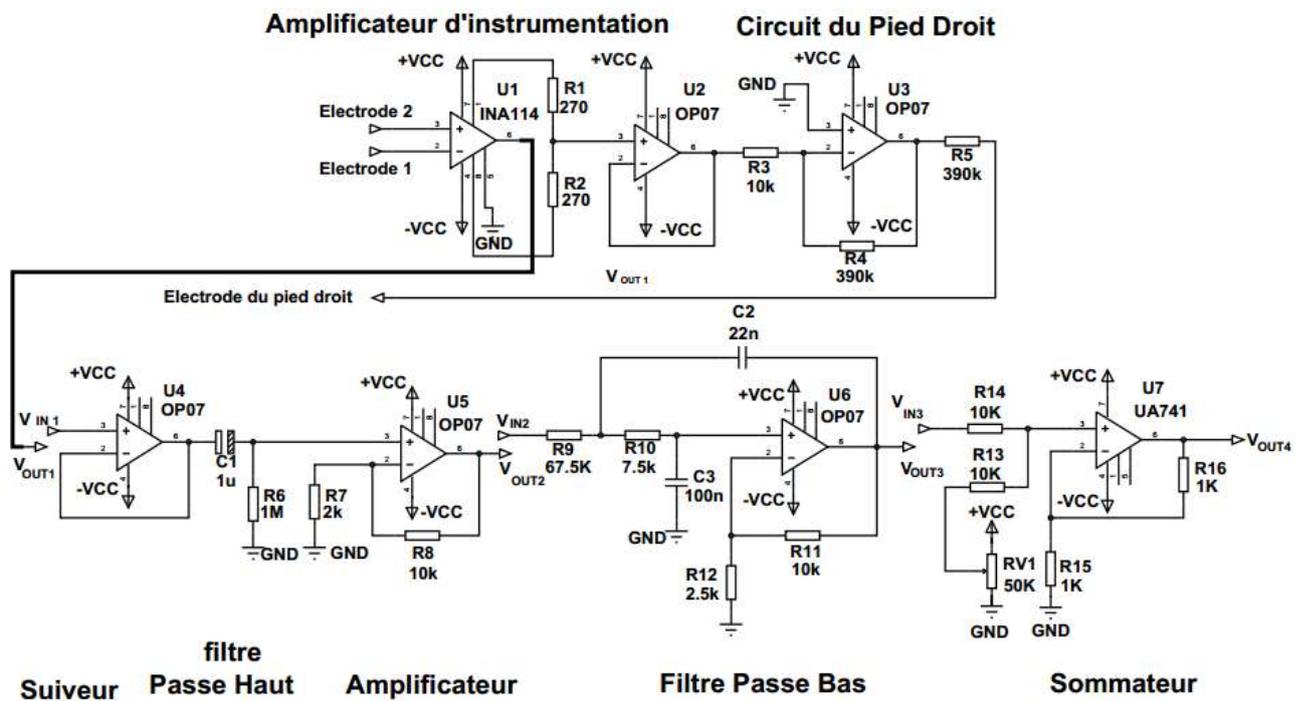


Figure II.3 : Schéma Electrique du circuit pour une dérivation d'ECG.

### II.2.1.a. L'amplificateur d'instrumentation

Comme nous avons vu au chapitre 1 lorsque le muscle cardiaque se contracte, il donne naissance et une tension et un courant correspond à la dépolarisation du myocarde. Cette tension est obtenue par le calcul de la différence de potentielle entre deux points (capteur). Cette tension est donnée par :

$$V_d = V_{e1} - V_{e2} \quad (II.1)$$

Les ondes électromagnétiques peuvent influencer la tension délivrée par le capteur. Souvent les ondes apparaissent sous forme des tensions superposées à celle générées par le capteur. L'origine de cet effet est essentiellement d'une part le couplage capacitif des fils du secteur avec les fils du capteur et d'autre part l'interférence magnétique des fils de liaisons. Par conséquent Sur les deux extrémités du fil de liaison d'un capteur on trouve une tension commune appelée **tension de mode commun**, son amplitude peut être plus important à celle fournit par le capteur, elle s'exprime par :

$$V_{mc} = \frac{V_{e1} + V_{e2}}{2} \text{ (II.2)}$$

D'après ce qui est mentionnés on peut représenter le générateur équivalent de ce système par la Figure II.4.

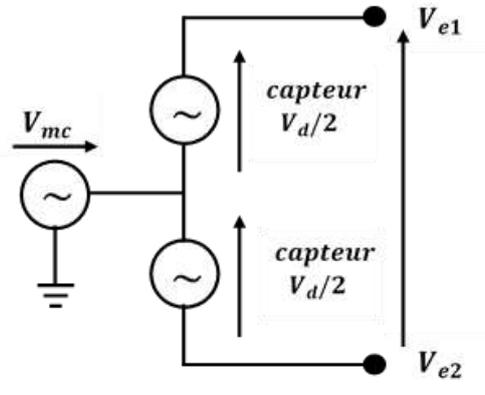


Figure II.4 : Schéma équivalent de la tension mode commun et différentielle

Afin de détecter de la tension issue du capteur, Nous utilisons un amplificateur différentiel présenté par la Figure II.5.

La tension de sortie est donnée par :

$$V_S = V_{e1} * A_1 - A_2 V_{e2} \text{ (II.3)}$$

Par l'utilisation des équations précédentes et en remplaçant dans ces expressions et dans celle de  $V_S$  , on obtient :

$$V_S = \frac{A_1 + A_2}{2} V_d + (A_1 - A_2) V_{mc} \text{ (II.4)}$$

Où :

- $\frac{A_1 + A_2}{2}$ : Correspond au gain en mode différentiel.
- $(A_1 - A_2)$  : représente le gain en mode commun.

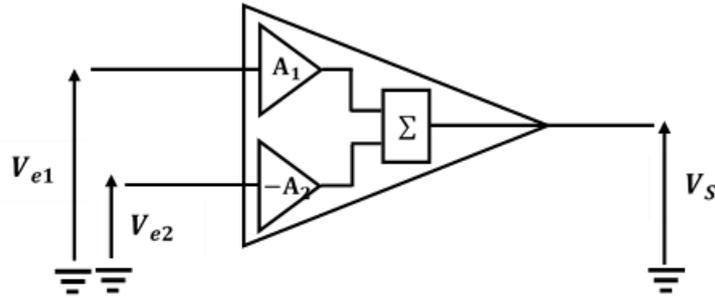


Figure II.5: Schéma équivalent d'un amplificateur différentiel.

L'amplification du mode différentiel doit être la plus élevée possible, en revanche l'amplification de mode commun doit être la plus minime possible, on parle donc de la qualité de l'amplificateur différentiel avec un taux de rejection en mode commun **TRMC** le plus grand possible.

En général, les signaux captés par les électrodes (de l'ordre de quelques microvolts à quelques millivolts) sont trop faibles et superposés sur une tension en mode commun de taille souvent beaucoup plus grande. D'où la nécessité d'un amplificateur d'instrumentation, ce dernier joue le rôle le plus important dans toutes la chaine d'acquisition. Il permet d'extraire le signal utile d'une part et également réduit le bruit d'interférence au niveau le plus bas possibles d'autre part. Cet amplificateur possède des caractéristiques importantes dont une impédance d'entrée élevée, un fort rejet en mode commun, un faible décalage de sortie et une faible impédance de sortie, une tension d'offset minime et faible bruit.

Un amplificateur d'instrumentation est un composant à gain en tension différentielle, son rôle est de fournir en sortie, une tension proportionnelle à la différence des deux tensions d'entrée.

La structure de base d'un amplificateur d'instrumentation est donnée par la Figure II.6, il comprend trois amplis-op et quelques résistances. Les amplis-op 1 et 2 forment des configurations sans inversion fournissant une impédance d'entrée et un gain en tension élevés. Le troisième est utilisé comme amplificateur différentiel à gain unitaire. Le gain de tension est en fonction de la résistance nommée  **$R_G$**

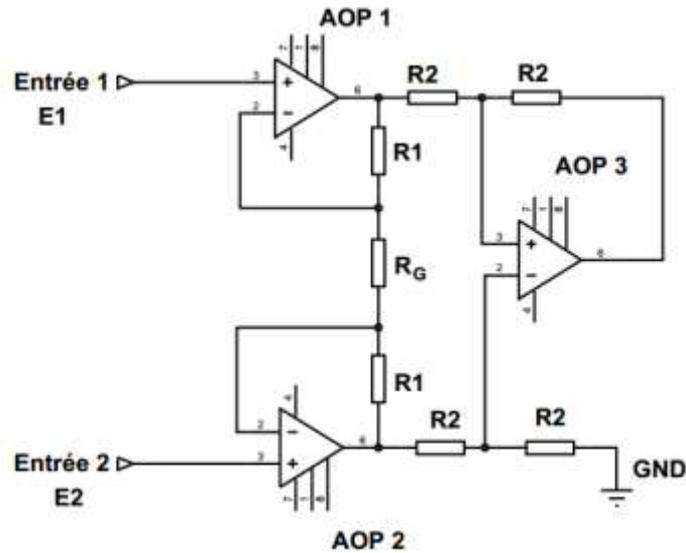


Figure II.6: Structure d'un amplificateur d'instrumentation.

La tension de sortie est donnée par la relation suivante :

$$V_S = \left(1 + \frac{R_1 + R_1}{R_G}\right) (E_1 - E_2) \quad (\text{II.5})$$

Alors le gain en boucle fermée est donné par :

$$A = \left(1 + \frac{2R}{R_G}\right) \quad (\text{II.6})$$

Pour notre application nous avons sélectionné un amplificateur d'instrumentation de type INA 114 qui est composé de 3 amplificateurs opérationnel Figure II.7. Il comprend des caractéristiques adéquate et approprié pour la fonction d'acquisition ;

- Une tension de continue d'offset très faible (environ  $50\mu V$ ).
- Un taux de rejection en mode commun élevé (115 dB).
- Une large fourchette d'alimentation ( $\pm 2.25$  au  $\pm 18 V$ ).
- Un gain variable allant de 1 jusqu'au 10000 à partir de la résistance externe  $R_G$ .

Pour plus de détail voir **annexe (1)**.

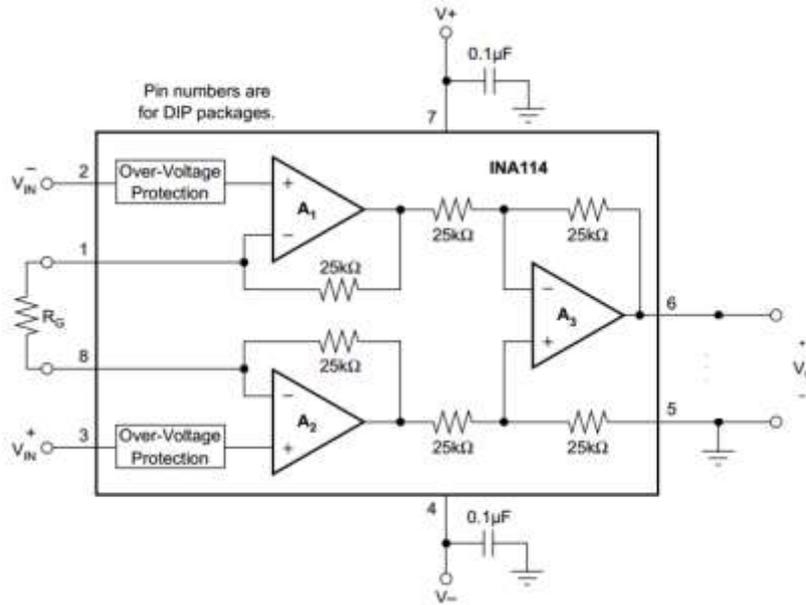


Figure II.7 : Schéma électrique d'un amplificateur d'instrumentation de type INA114.

Le gain dans cette structure est donné par :

$$V_0 = G_{ins} * (V_{IN}^+ - V_{IN}^-) \quad (\text{II.7})$$

$$G_{ins} = 1 + \frac{50K\Omega}{R_G} \quad (\text{II.8})$$

Pour notre application Nous avons sélectionnés une résistance  $R_G = 540\Omega$ , ce qui nous permet d'avoir un gain  $G_{ins} \approx 93$ . On a considéré que c'est une étape de pré-amplification parce que comme nous allons voir dans ce qui suit qu'il y a d'autres étapes d'amplification, et cela pour la simple raison de ne pas avoir de distorsion et de saturation des AOP due à l'amplification d'une seule fois avec un gain très important.

### II.2.1.b. Suiveur

Ce circuit représente un Suiveur de tension, qu'on utilise souvent pour ses excellentes qualités de circuit tampon : impédance d'entrée très élevée, impédance de sortie très basse, et un gain en tension égal à un, une contre réaction au maximum dans un suiveur de tension, tous ces facteurs nous ramène à une adaptation d'impédance optimal et garantie le transfert adéquat de l'énergie entre les étages.

$$\text{Donc; } V_{out} = V_{in} \quad (\text{II.9})$$

### II.2.1.c. Filtre passe Haut

Comme nous l'avons cité auparavant, la composante continue superposée au signal peut entrainer une saturation des AOP, ce qui influe directement sur le fonctionnement des autres étages, donc une opération de filtrage est nécessaire pour éliminer cette tension d'offset, nous avons choisis un simple filtre, constitué par la résistance  $R_6$  et la capacité  $C_1$ , il s'agit d'un filtre passe haut passif. La fréquence de coupure est donnée par :

$$f_c = \frac{1}{2 * \pi * R_6 * C_1} \quad (\text{II.10})$$

D'où  $f_c \approx 0.15 \text{ Hz}$

On peut découvrir la fréquence de coupure de ce filtre à travers son diagramme de **Bode** qui représente la réponse fréquentielle, on parle de la méthode graphique figure 2.8. Où  $f_c$  correspond à la chute de **3dB**.

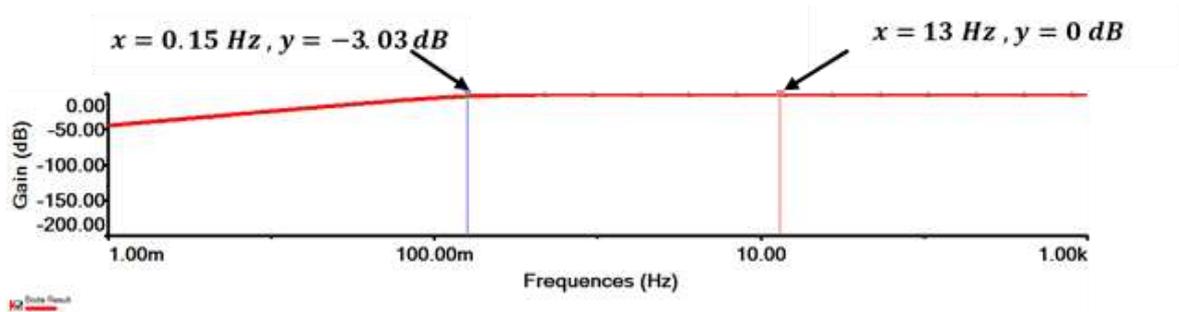


Figure II.8 : Diagramme de Bode du filtre RC.

### II.2.1.d. Amplificateur

À ce niveau notre signal est prêt à être amplifié, la configuration utilisée est un amplificateur à base d'AOP en montage non inverseur, il est caractérisé par une impédance d'entrée très élevée, une impédance de sortie pratiquement faible et enfin un gain en tension stable donné par :

$$G_{ampl} = \frac{V_{OUT2}}{V_{IN1}} = \left(1 + \frac{R_8}{R_7}\right) \quad (\text{II.11})$$

D'où le gain de cet étage est  $G_{ampl} = 6$ .

### II.2.1.e. Filtre passe bas

On sait pertinemment que le signal ECG et comme nous avons mentionnés auparavant possède un contenu fréquentielle varie entre 0 et 100 Hz, pour cette raison un filtre passe bas est envisageable afin d'éliminer toute composante fréquentielle hors de cette plage et qui est considérée comme bruit. La configuration utilisée est celle de **Sallen-Key** d'ordre deux. Les résistances  $R_9$  et  $R_{10}$  et les capacités  $C_2$  et  $C_3$  avec l'AOP  $U_6$  permet d'obtenir un filtre actif avec un gain  $G_{fil} = 5$ . Sa fonction de transfert est donnée par

$$H(s) = \frac{5/s^2 C_2 C_3}{\frac{R_9}{C_3 s} \left(1 - \frac{R_{11} + R_{12}}{12}\right) + R_9 \left(R_{10} + \frac{1}{C_2 s}\right) + \frac{1}{C_2 s} \left(R_{10} + \frac{1}{C_3 s}\right)} \quad (\text{II.12})$$

Donc la fréquence de coupure du circuit correspond à une chute de 3 dB est donné par :

$$\omega_c = \frac{1}{\sqrt{R_9 R_{10} C_2 C_3}} \quad (\text{II.13})$$

Donc :

$$f_c = \omega_c / 2\pi \approx 150 \text{ Hz} \quad (\text{II.14})$$

De le tracé de Bode de sa fonction de transfert ou encore la réponse fréquentielle du filtre est donnée par la Figure II.9.

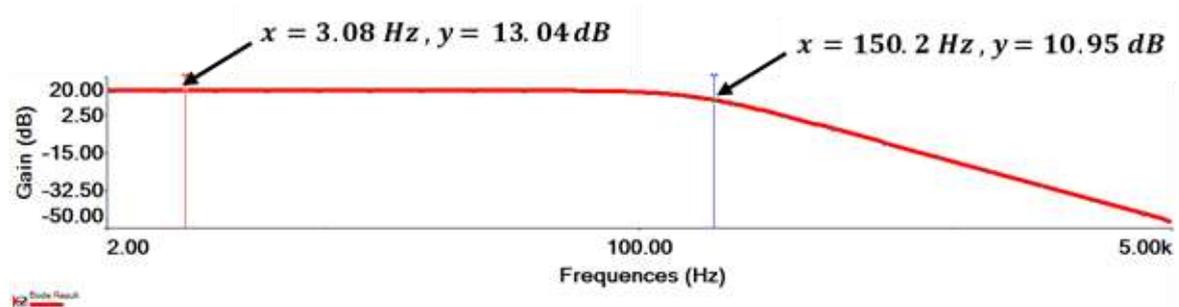


Figure II.9 : Diagramme de Bode du filtre passe bas Sallen Key.

### II.2.1.f. Circuit d'offset

Le signal possède une morphologie diphasique et suivant la polarisation du sujet a examiné, on peut trouver des situations ou une partie de signal ou la totalité du signal se trouve dans la zone négative, pour notre application cela présente un inconvénient majeur et il peut conduire à une dégradation de sa qualité. Comme nous allons voir dans ce qui suit l'étape de digitalisation sera effectuée par une carte Arduino. Cette dernière exige un signal totalement positif et compris entre 0V et 5V, où chaque tension inférieure à zéro est remplacée par un zéro tandis que chaque valeur supérieure à 5 volts est remplacée par 5 Volts. Pour cette raison L'étape finale du conditionnement du signal consiste à ajuster notre signal à un niveau bien déterminé (entre 0 et 5 volts).

Cette opération est assurée par un montage à base d'AOP en fonction Sommateur (voir figure 2.3), le potentiomètre RV1 joue le rôle important dans le réglage de la tension continue voulue et sera rajouter au signal afin de mettre signal dans une plage adéquate.

### II.2.2. Circuit Analogique EEG

Le circuit analogique permettant la détection du signal EEG est subdivisé en 7 étapes essentielles illustrées par la Figure II.10, où chaque étape représente un circuit qui doit remplir une fonction électronique bien déterminée.

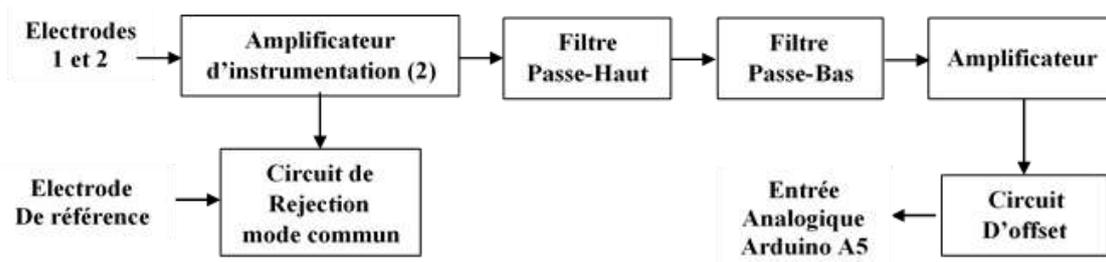
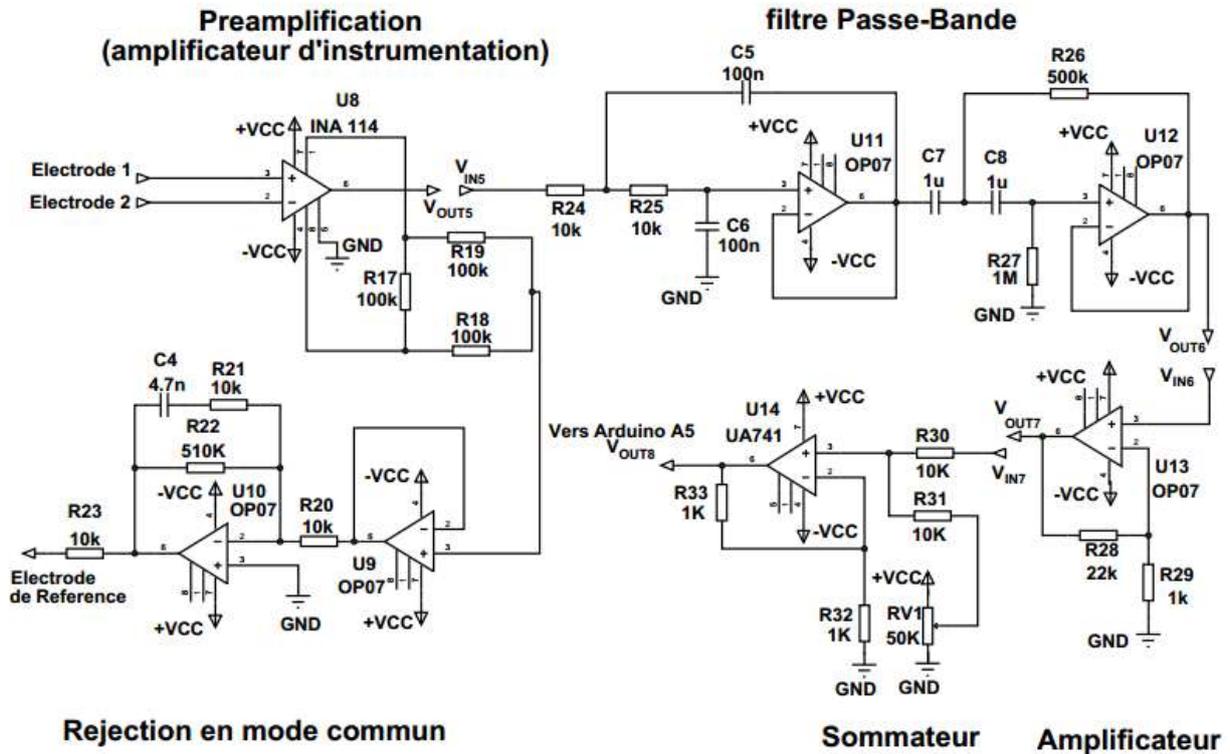


Figure II.10 : Schéma Bloc de circuit analogique de l'EEG.

Le circuit de détection du signal EEG est composé principalement d'un étage préamplificateur présenté par un amplificateur d'instrumentation, un circuit de rejection de tension en mode

commun, un filtre passe bande et un amplificateur. Le schéma électronique du circuit est illustré par la FigureII.11.



FigureII.11 :Schéma électrique du Circuit de détection du signal EEG.

### II.2.2.a. L'amplificateur d'instrumentation

Le signal EEG est caractérisé par son amplitude très faibles (quelques microvolts), la fonction d'amplification est indispensable afin de pouvoir subir les autres opérations nécessaires de conditionnement. Mais il faut noter qu'une amplification avec un gain élevé amplifiera aussi la tension **DC** avec la tension d'interférence présente dans le circuit, cela peut entrainer une distorsion du signal et une saturation au niveau de notre amplificateur. Pour remédier à ce problème, l'opération d'amplification devrait être subdivisée en plusieurs étapes. Pour cette raison nous avons mentionnés que l'amplificateur est considéré comme un étage de pré-amplification.

Le gain dans cette structure est donné par :

$$G_{ins} = 1 + \frac{50K\Omega}{R_G} \quad (II.15)$$

Une résistance  $R_G = 220\Omega$  est adaptée pour la détection du signal EEG, et par la suite le gain est environ  $G_{ins} \approx 227$ .

### II.2.2.b. Circuit de rejection mode commun

Le but de ce circuit est de réinjecter au corps toute sorte de bruit. Cela réduira l'interférence de mode commun sur le corps et renforcera le signal. Il peut atténuer l'interférence du secteur jusqu'à 100 fois plus que ce que l'amplificateur d'instrumentation peut faire seul. Le réglage du gain et de la bande passante est donné par l'équation (II.16) comme suit :

$$|G(S)| = \frac{R_{22}}{R_{20}} * \frac{1}{\sqrt{1+(R_{23}*C_4*2*\pi*f)}} \quad (II.16)$$

### II.2.2.c. Filtre Passe Bande

Le signal issu de l'amplificateur d'instrumentation  $OUT_1$  est injecté à l'entrée du circuit qui suit, La fonction suivante du circuit est Le filtrage. Notre filtre est constitué de deux filtres actifs, un filtre passe haut et filtre passe bas. Il permet le passage des fréquences appartient au signal utile. Toute fréquence hors plage devrait être atténué ou éliminé.

Le filtre passe bas est de l'ordre deux ayant une structure de Sallen-Key. Composé par les résistances  $R_{24}, R_{25}, C_5, C_6$  et l'amplificateur opérationnel  $U_{11}$ . La fonction du transfert du circuit est donnée par l'équation :

$$H(s) = \frac{1/R_{25}R_{24}C_5C_6}{s^2 + \left(\frac{1}{R_{24}C_5} + \frac{1}{R_{25}C_6}\right)s + \frac{1}{R_{25}R_{24}C_5C_6}} \quad (II.17)$$

Dans ce circuit  $R_{24}$  et  $R_{25}$  sont égaux, ainsi  $C_5$  égale à  $C_6$ , donc la fréquence de coupure du circuit correspond à une chute de 3 dB est donné par :

$$f_c = \omega_c / 2\pi = \frac{\sqrt{\sqrt{2}-1}}{2\pi} \frac{1}{R_{24}C_5} \approx 102.43Hz \quad (II.18)$$

le tracé de Bode de sa fonction de transfert ou encore la réponse fréquentielle du filtre est donnée par la Figure II.12

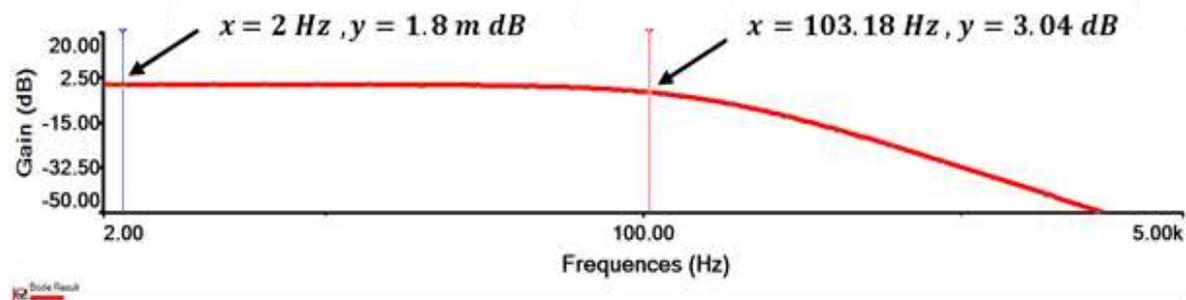


Figure II.12 : Diagramme de Bode du filtre passe bas.

Après le filtre passe bas, les condensateurs  $C_7, C_8$  et les résistances  $R_{26}, R_{27}$  forment un filtre passe haut d'ordre 2 de type Sallen-Key. Sa fonction principale est de réduire la tension continue et maintenir la ligne de base stable. La fonction du transfert de ce filtre est donnée par :

$$H(S) = \frac{S^2}{S^2 + \left(\frac{1}{R_{27}C_7} + \frac{1}{R_{26}C_8}\right)S + \frac{1}{R_{26}R_{27}C_7C_8}} \quad (\text{II.19})$$

La fréquence de coupure est donnée par :

$$f_c = \frac{\omega_c}{2\pi} = 0.23 \text{ Hz} \quad (\text{II.20})$$

La réponse fréquentielle du filtre est donnée par la Figure II.13 illustrée en dessous.

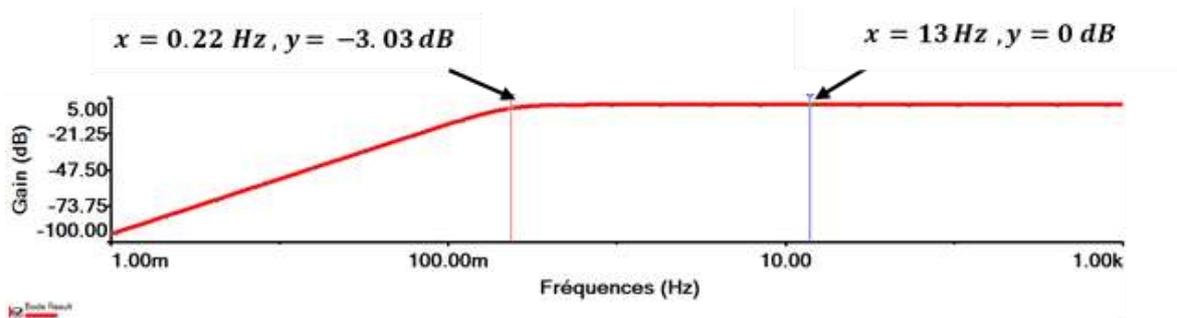


Figure II.13 : Diagramme de Bode du filtre passe haut.

#### II.2.2.d. Amplificateur

La tension récupérée à la sortie du filtre passe bande  $V_{OUT6}$  attaque un amplificateur à base d'AOP en montage non inverseur afin de pouvoir amplifier le signal, cette étape constitue l'opération finale du conditionnement de notre signal, la fonction du transfert de ce montage est donnée :

$$V_{OUT7} = \frac{R_{29}}{R_{29} + R_{28}} * V_{IN6} \quad (\text{II.21})$$

D'où

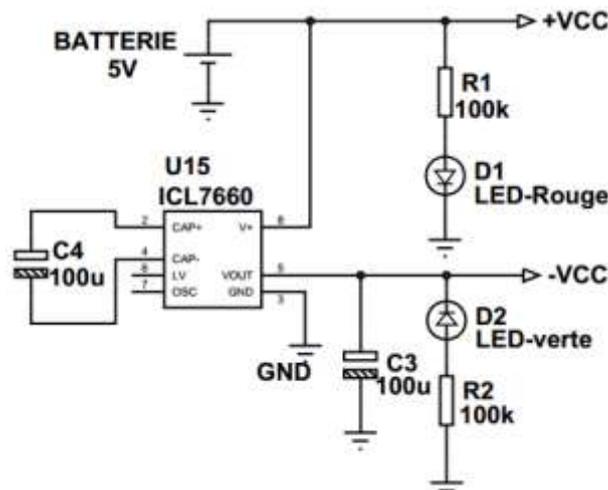
$$G_{amp} = \frac{V_{OUT7}}{V_{IN6}} = \left(1 + \frac{R_{28}}{R_{29}}\right) = 23 \text{ (II.22)}$$

### II.2.2.e. Circuit d'offset

Le même raisonnement qui s'est appliqué pour l'activité cardiaque s'applique pour l'EEG, pour cela le potentiomètre RV2 inclus dans un montage à base d'AOP en configuration sommateur garantie une bonne localisation du signal dans la bonne gamme de tension sans dépasser le seuil de 0 V et 5 Volts.

### II.2.3. Circuit d'alimentation

L'artefact de secteur est le plus commun des artefacts. Son amplitude est variable, étant alimenté par le secteur c'est la source d'un artefact de 50 Hz, et pour pouvoir remédier à ce problème on prévoit d'employer une batterie de **5 Volts** pour générer le  $\pm VCC$  via le circuit à base de régulateur de type **ICL 7660**. Enfin de compte l'alimentation symétrique est disponible afin d'alimenter d'une manière stable les amplificateurs opérationnels.

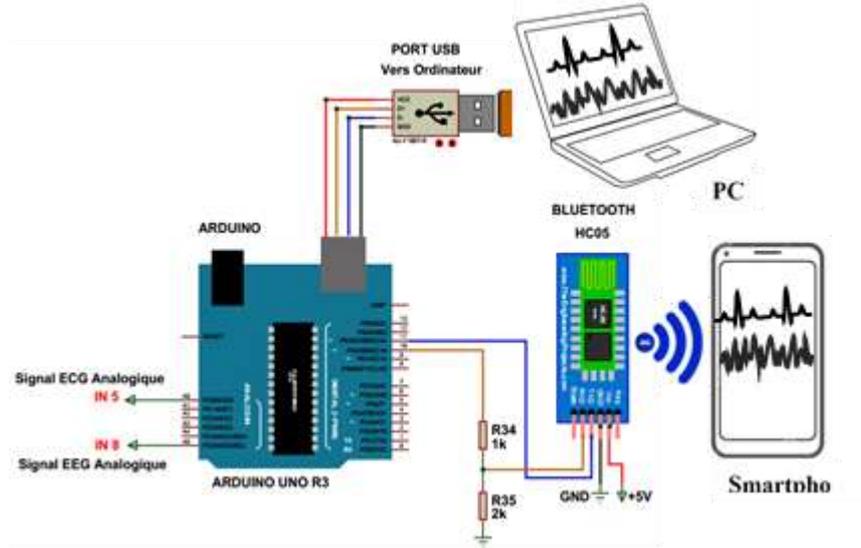


FigureII.14 : Schéma électrique de l'alimentation.

### II.2.4. Carte Arduino

Le but de ce travail est l'acquisition des signaux électrique qui proviennent : d'activités cardiaque et neuronale, comme nous l'avons vue ces signaux subissent des opérations de conditionnement et de mise en forme à l'aide d'un circuit électronique. Un enregistrement des signaux sur un pc et un smartphone est envisagé, pour numériser le signal et d'effectuer des opérations de traitement numérique. Nous utilisons une carte **Arduino** pour accomplir La procédure du passage de l'analogique vers le numérique et l'enregistrement de ces activités qui

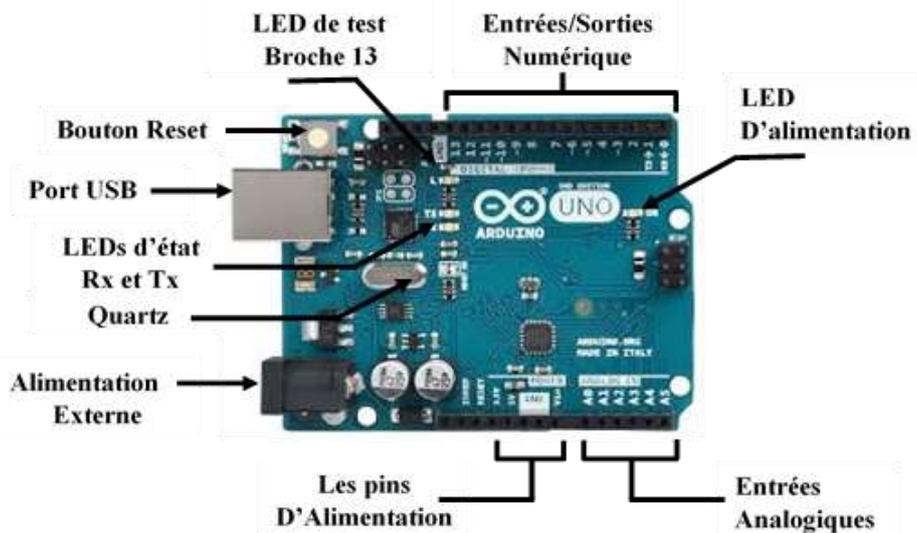
repose essentiellement sur l'acquisition temps réel sans fil à l'aide d'un module Bluetooth voir FigureII.15.



FigureII.15 : Structure de la liaison de la carte Arduino avec PC et le module Bluetooth.

Arduino est une plate-forme de prototypage d'objets interactifs à usage créatif constituée d'une carte électronique et d'un environnement de programmation, cet environnement matériel et logiciel permet à l'utilisateur de formuler ses projets par l'expérimentation directe Pont tendu entre le monde réel et le monde numérique(Michael, M et al,2011).

Nous avons utilisé une carte **Arduino** de type **UNO**(carte basique, aux dimensions voisines de celle d'une carte bancaire).



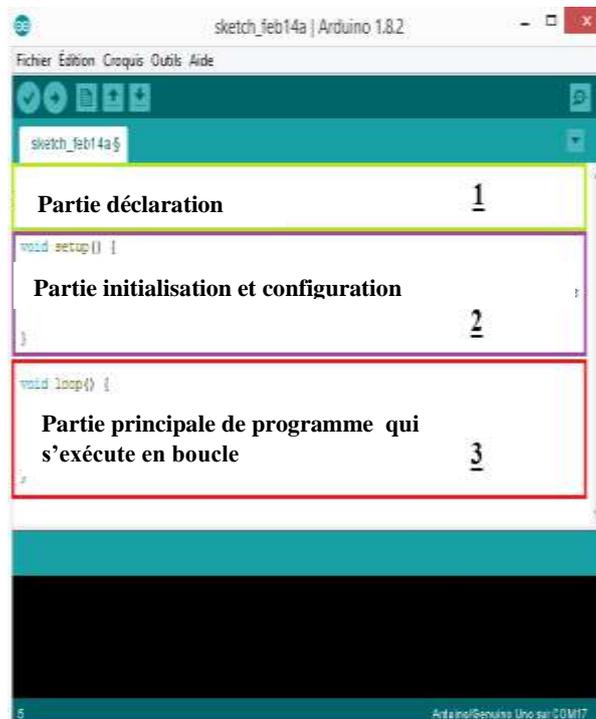
FigureII.16 : Présentation d'une carte Arduino UNO.

### II.2.4.a. Les avantages

- Pas cher.
- Environnement de programmation clair et simple.
- Multiplateforme : tourne sous Windows, Macintosh et Linux.
- Nombreuses bibliothèques disponibles avec diverses fonctions implémentées.
- Logiciel et matériel open source et extensible.
- Nombreux conseils, tutoriaux et exemples en ligne (forums, site perso etc...)
- Existence de « **shield** »

La carte **Arduino** repose sur un circuit intégré (un mini-ordinateur appelé également microcontrôleur), Le modèle **UNO** est une carte électronique dont le cœur est un microcontrôleur ATMEL de référence ATmega328. Le microcontrôleur ATmega328 est un microcontrôleur 8bits de la famille AVR dont la programmation peut être réalisée en langage C. associée à des entrées et sorties qui permettent à l'utilisateur de brancher différents types d'éléments externes :

- **Côté entrées** : des capteurs qui collectent des informations.
- **Côté sorties** : des actionneurs qui agissent sur le monde physique.



FigureII.17 : Structure du Programme Arduino.

Un programme **Arduino** comporte trois parties figure II.17 :

- La partie déclaration des variables (optionnelle)
- La partie initialisation et configuration des entrées/sorties : la fonction setup ()
- La partie principale qui s'exécute en boucle : la fonction loop () Dans chaque partie d'un programme sont utilisées différentes instructions issues de la syntaxe du langage **Arduino**(Arduino, 2016).

#### II.2.4.b. Adaptation de l'Arduino pour notre Application

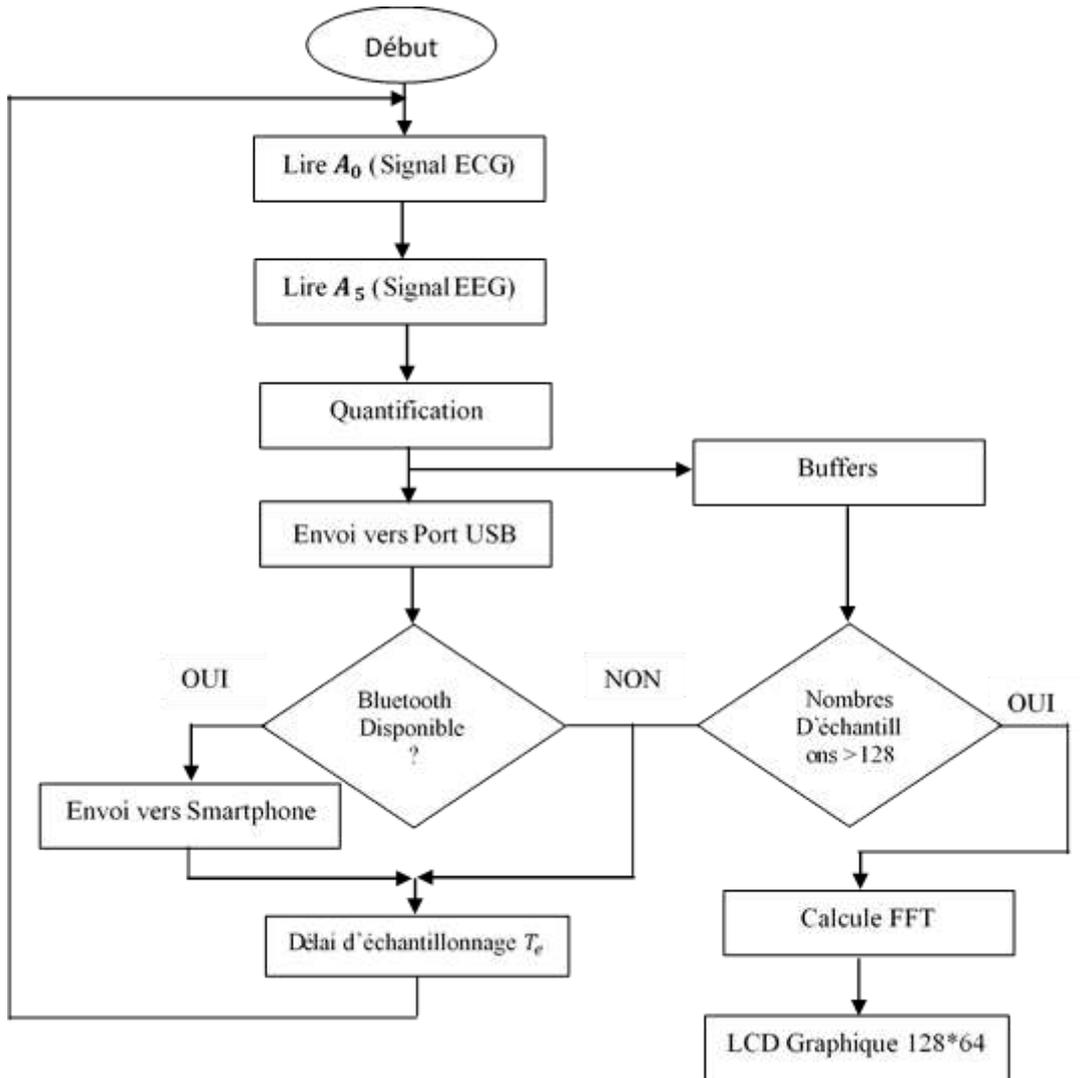
La partie de déclaration sur l'éditeur de programmation de notre carte contient principalement :

- Définition de l'entrée analogique  $A_0$  comme broche principale pour lire la variation du signal **ECG**
- Définition de l'entrée analogique  $A_5$  comme broche principale pour lire la variation du signal **EEG**.
- Déclaration des ports responsables à la voie de communication série avec le module Bluetooth associé (les broche numérique 10 et 11 correspondent respectivement aux broches de réception  $R_x$  et la broche de transmission  $T_x$ )
- Appelle la librairie dédiée à la communication série par la commande **#include<SoftwareSerial.h>**.
- Déclaration et réservation des espaces mémoire permettant le stockage des variables.

La deuxième partie consiste à l'initialisation des différents composants intervenant à l'opération d'acquisition et transmission temps réel, elle comporte la sélection du taux de transmission exprimé en **Baud**(bit/second), ce dernier correspond à la vitesse de transmission des données d'une manière série (c à d bit par bit). Il faut noter qu'il existe plusieurs vitesses de transmission standardisées par le constructeur. Rappelons aussi qu'afin d'assurer une transmission adéquate sans perte d'information, le taux de transmission doit être fixé sur la même valeur dans les deux extrémités du canal de communication. Comme nous avons deux voies série (connexion filaire par câble USB avec le Pc et connexion sans fil par Bluetooth avec Smartphone), il faut définir la vitesse de transmission pour les deux voies. Nous avons choisi d'établir la liaison série pour les deux voies avec un taux de **115200 Baud**. L'instruction permettant le choix est :

**Nom\_de\_la\_voie.begin(115200).**

La troisième partie représente la partie du programme la plus importante et indispensable afin d'atteindre l'objectif de cette application. Elle contient plusieurs instructions et opération qui se répètent de façons indéterminées formant une boucle infinie. Dans chaque itération un échantillon de chaque signal est relevé puis transmet vers les canaux de communication. Cette partie de ce programme est donnée par l'organigramme présenté par la figure (voir FigureII.18).



FigureII.18 : Organigramme du programme de numérisation du signal.

Les signaux EEG et ECG mesurés par les circuits décrits auparavant ont la propriété d'être continues Pour passer des grandeurs du monde réel (analogiques) à celles gérées par le microordinateur (numérique)Il y la nécessité de réaliser une conversion analogique numérique. Qui repose essentiellement sur trois phases :

- Echantillonnage.
- Quantification.
- Codage.

L'instruction chargée de faire la lecture et la conversion du signal est **AnalogRead(numéro d'entrée analogique)**. Rappelons aussi que la résolution de la conversion analogique numérique de cette Platform est donnée par 10 bits

Lorsque l'acquisition se fait au cours du temps, le deuxième critère important sera l'intervalle de temps que l'on va laisser s'écouler entre la prise de deux échantillons successifs. Cette saisie se faisant généralement à intervalles de temps réguliers, on parle alors de période d'échantillonnage ( $T_e$ ) ou de la fréquence d'échantillonnage ( $F_e$ ).

Afin de vérifier la condition de Shannon qui est  $F_e > 2 * 2F_{MAX}$  et qui assure par conséquent un bon échantillonnage sans avoir une perte d'information, cette condition évite le chevauchement lors de la reconstruction du signal. Cependant nous avons deux signaux à échantillonner sachant que le signal ECG possède une plage fréquentielle plus importante que celle du signal EEG, et donc la condition de Shannon devienne  $F_e > 2 * 2F_{MAX}$

Pour cela nous avons envisagé d'échantillonner les signaux avec une fréquence de  $F_e = 512 \text{ Hz}$ , cette fréquence conduit à un délai de  $T_e = 1.95 \text{ mS}$ . L'instruction permettant l'introduction la valeur du délai désiré est **delay(valeur)**.

### II.2.5. Module Bluetooth

Le nom « Bluetooth » (littéralement « dent bleue ») se rapporte au nom du roi danois Harald II (910-986), surnommé Harald II Blatand (« à la dent bleue »), à qui on attribue l'unification de la Suède et de la Norvège ainsi que l'introduction du christianisme dans les pays scandinaves

Bluetooth, défini par la norme IEEE 802.15.1, est une technologie LAN (Local Area Network) sans fil conçue pour connecter des périphériques mobiles ou fixes à l'aide d'une transmission radio à faible distance et à faible puissance. C'est une norme de technologie de communication sans fil à courte portée, utilisant un bande radio mondiale et sans licence - Bande industrielle, scientifique et médicale (ISM) à 2,4 GHz. Le Bluetooth a une capacité anti-interférence élevée : il utilise la technologie AFH (Adaptive Frequency-Hopping Spread) comme solution pour éviter les interférences avec d'autres technologies fonctionnant également sur la bande ISM de 2,4 GHz, comme téléphone sans fil, four à micro-ondes, WLAN, USB sans fil et Zigbee. Il peut fonctionner comme un périphérique esclave ou un périphérique maître. En tant qu'esclave, il ne

peut accepter que des connexions. En tant que maître, il peut initier une connexion (Janaka, E et al, 2012).

Le Bluetooth permet d'obtenir des débits de l'ordre de 1 Mbps en full-duplex, avec une portée d'une dizaine de mètres environ avec un émetteur de classe II et d'un peu moins d'une centaine de mètres avec un émetteur de classe I.

Le standard Bluetooth définit en effet 3 classes (Table II.1) d'émetteurs proposant des portées différentes en fonction de leur puissance d'émission :

<b>Classe</b>	<b>Puissance (affaiblissement)</b>	<b>Portée</b>
I	100mW (20dBm)	100 mètres
II	2.5mW (4dBm)	15-20 mètres
III	1mW (0dBm)	10 mètres

Table II.1 : Standard Bluetooth.

Nous avons sélectionnés le module Bluetooth HC-05 comme le dispositif approprié pour fournir une bonne performance de transmission sans fil pour. Il possède les caractéristiques suivantes :

- Facile à utiliser comme module Bluetooth SPP (Serial Port Protocole).
- Modulation complète avec émetteur-récepteur radio de 2.4 GHz
- Haut débit de 3 Mbps.
- Sensibilité typique -80dBm.
- La puissance de transmission RF 4dBm.
- Base tension 1.8 opération, 1.8 à 3.6 I/O.
- Interface UART avec débit en bauds programmable.
- Antenne intégrée.

Le brochage avec l'Arduino s'effectué à travers de pins de données numériques 10 et 11 et à l'aide deux résistances comme illustré dans la Figure II.15.

## II.2.6. Module Radio fréquence XBee

Nous avons réussi à faire la transmission des données électrophysiologique à travers un module Bluetooth, ce module favorise la mobilité et l'indépendance filaire des constituants de notre système dans un cercle d'environ 20 mètre de diamètre, on parle donc d'une faible portée. Quand il s'agit de concevoir des systèmes de communication sans fil pour des distances plus importantes le changement du module Bluetooth ainsi que la technologie utilisée est indispensable. Nous proposons d'exploiter la transmission radio fréquence en utilisant des modules XBee (un émetteur et un récepteur).

Le protocole de communication entre ces modules est le ZigBee basé sur les ondes radio. La certification ZigBee repose sur le standard **IEEE 802.15.4** qui définit les fonctionnalités et spécifications des réseaux sans fil à dimension personnelle.

XBee possède plusieurs spécifications, nous citons quelques un :

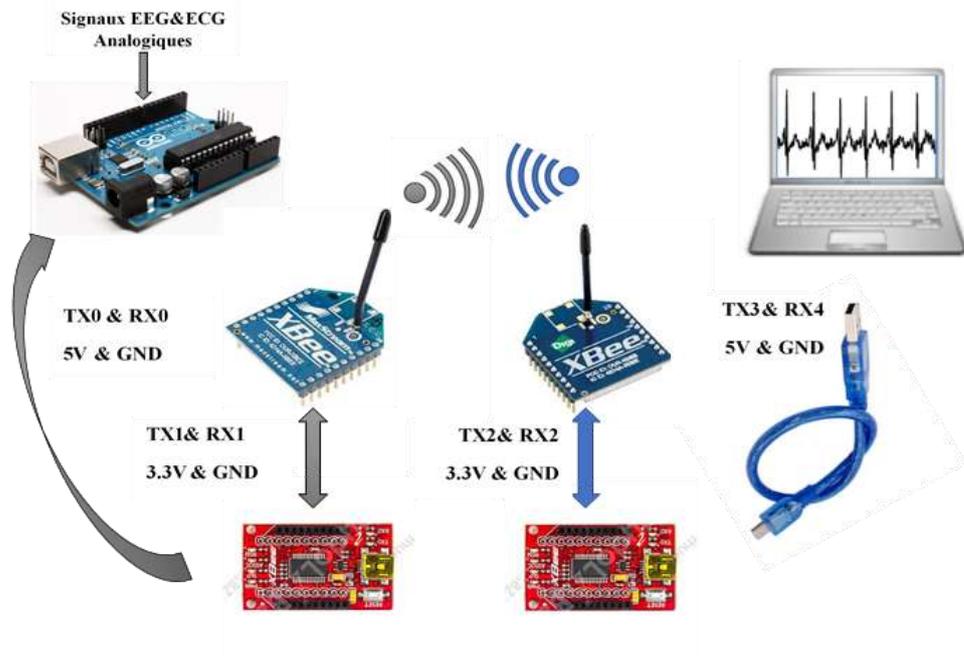
- Portées variées de 10mètre à 1000 mètre suivant la version.
- Faible débit :250Kbps
- Différentes topologies de liaison (point à point, multi points).
- Faible cout.
- Faible consommation (3.3V, 50mV).
- Clé de chiffrement de 128bits pour une communication sécurisée.

Ces modules peuvent être utilisés avec la carte Arduino via un adaptateurXbee-USB basé sur le convertisseur FT231X. L'adaptateur assure la compatibilité de communication entre la carte Arduino et le module radio fréquence.

Pour établir la communication sans fil avec l'ordinateur en utilisant le protocole ZigBee, on doit avoir :

- Deux modules XBee (émetteur et Récepteur).
- Deux adaptateurs.
- Une carte Arduino.

La figureII.19 illustre le schéma de raccordement des différents modules et composants



FigureII.19:Schéma de liaison l'ensemble Arduino, XBee et PC.

### II.2.7. Terminal et Interface Graphique sur PC

Après avoir bien définir les paramètres temporels et fréquentiels des signaux **EEG** et **ECG**, il est possible maintenant d'acquérir ces deux signaux en temps réel. On peut en effet tracés les signaux et leurs subir des opérations de traitements de signal sur un PC via un câble USB, et ceci à l'aide d'une interface graphique réalisée sous **Matlab**. Ou encore on peut les visualiser sur un Smartphone à l'aide d'une application sous Android (**Terminal Graphics**), et cela d'une façon sans fil via un module Bluetooth. L'allure des signaux acquis par le Module Bluetooth sur un smartphone est présentée par la Figure II.20 au-dessous :

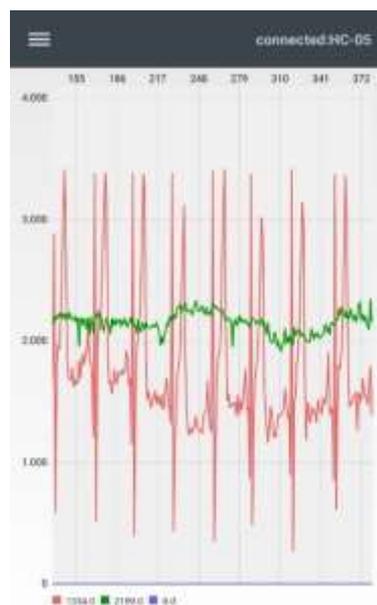


Figure II.20: Tracé des signaux EEG & ECG sur un Smartphone.

Où le tracer rouge correspond à l'activité cardiaque représentée par le signal ECG, tandis que le tracer vert décrit la variation de l'activité électrique cérébrale traduit par le signal EEG.

## II.2.8. Interface Graphique sur PC

Après avoir lancé le programme **Matlab** il devient possible de faire l'acquisition temps réel, en exécutant le programme principal qui permet à l'interface principale d'apparaître voir Figure II.21. Cette interface va fixer le protocole de communication **Arduino-pc** en faisant choisir le port série avec lequel la carte **Arduino** est connectée et choisir la vitesse de transmission de données exprimé en **baud**.



Figure II.21 :Face principale de l'interface graphique.

À ce moment le port est prêt à être utilisé par la carte **Arduino** après qu'on appuie sur le bouton 'ouverture du port'. Une autre fenêtre sera affichée dans laquelle les données seront tracées; cette figure contient plusieurs boutons voir Figure II.21

- Bouton tracer : pour commencer le tracer en temps réel.
- Bouton pause : afin de suspendre l'acquisition tout en gardant le tracé.
- Bouton filtrer : pour effectuer un filtre numérique (passe-bas).
- Tracer le spectre : permet de tracer le spectre en utilisant la transformée de Fourier rapide (**FFT**) afin de déterminer la bande fréquentielle du signal enregistré.
- Bouton enregistrer : assure la sauvegarde des données acquises.
- Bouton imprimer : permet de lancer l'impression des résultats obtenus.

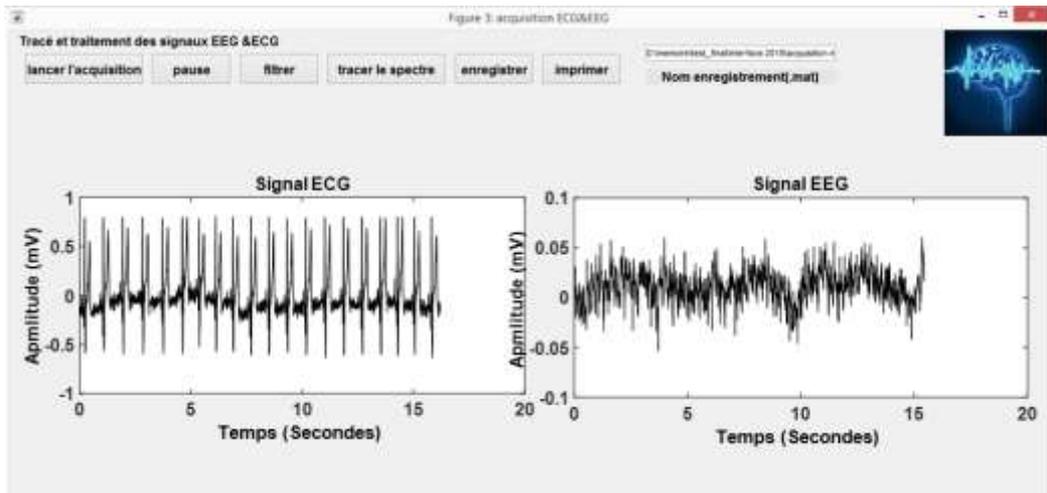


Figure II.22: Tracer des Signaux EEG&ECG sur l'interface graphique.

### II.2.9. Afficheur LCD graphique 128\*64

Nous avons pu afficher nos signaux enregistrés et leur FFT correspondant sans avoir besoin d'utiliser un PC. Comme illustré dans l'organigramme en dessus la carte Arduino stock une série d'échantillons, une fois on atteint les 128 échantillons la Transformer de Fourier Rapide (FFT) est calculée par le microcontrôleur de la plateforme Arduino et par la suite peut être tracer sur un afficheur graphique LCD . Nous sélectionnons le module LCD graphique 128\*64 pour de nombreuses raisons :

- Module pas cher et disponible.
- Possède une diagonale de 2,4 pouces.
- Alimentation de 5 Volts.
- Une interface de connexion série et parallèle.
- Contrôle de luminosité avec options de rétro-éclairage.
- Compatibilité avec la bibliothèque Arduino.
- Il dispose d'un grand écran graphique LCD éclairé pour un affichage plus clair des courbes de mesure et des résultats numériques, ce qui convient à notre application voir Figure II.23.

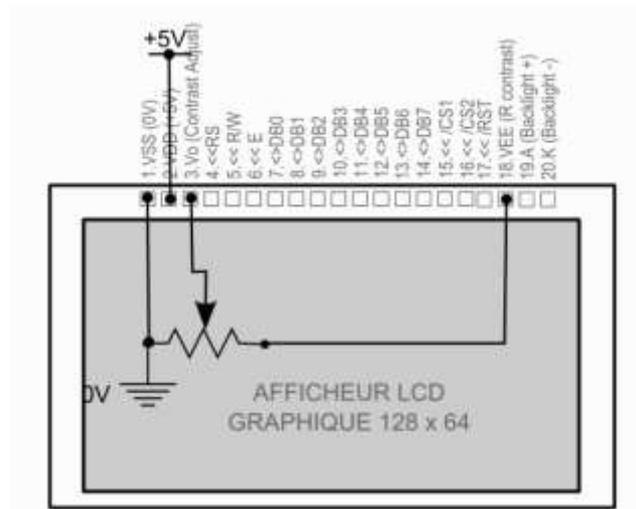


Figure II.23 : Spécifications d'afficheur LCD graphique 128\*64.

### II.2.10. Tracés et analyses fréquentielles des signaux acquis sur l'interface

Dans ce qui suit nous allons présenter des exemples des signaux acquis avec le traitement numérique inclut avec notre application, il est important de noter que lors de l'acquisition temps réel il faut normaliser notre échelle temporelle ainsi que l'échelle d'amplitude, cette normalisation est effectuée initialement par l'élimination de la composante continue introduite par le circuit sommateur décrit auparavant. Ensuite il faut supprimer le gain induit par l'ensemble des étages et finalement l'adaptation de l'axe d'abscisse en fonction du temps au lieu d'échantillons.

Concernant la composante continue on peut l'éliminer par l'utilisation d'un filtre passe haut, ce dernier est de type **Butterworth** d'ordre **4** avec une fréquence de coupure de  $f_c = 0.5 \text{ Hz}$ .

Comme nous l'avons vue précédemment une multiplication successive de gain a été effectuée dans chaque étage, L'ensemble des étages sont montés en cascade ce qui conduit à un gain total donné par :

$$G_{Total} = G_{inst} * G_{fil} * G_{ampl} \quad (II.23)$$

Donc le gain total pour :

- Signal ECG :  $G_{Total} = 93 * 5 * 5 = 2325$ .
- Signal EEG :  $G_{Total} = 228 * 23 = 5227$ .

Pour afficher le tracé en fonction du temps au lieu d'échantillons il faut simplement utiliser la règle trois sachant que la durée entre un échantillon et un autre  $T_e$  est fixé par la condition de Shannon ou  $T_e = 3.9 \text{ mS}$ .

Après application de ces opérations notre signal sera normalisé comme illustre la Figure II.24 en dessous, sachant que nous avons fait les tests sur deux sujets différents.

Le tracé du spectre des signaux ECG est obtenu à l'aide d'utilisation de la Transformé de Fourier Rapide FFT disponible sous **Matlab** afin de voir le contenu fréquentielle, la figure illustre les spectres des signaux. On peut remarquer qu'il contient plusieurs raies situant entre 0 et 40 Hz.

L'étape suivante consiste à appliquer un filtre numérique passe bas et cela afin pour faire une éventuelle détection des différentes ondes et segment constituant le signal tel que le complexe QRS. Ce dernier possède une composante fréquentielle variant autour de 45 Hz. La Figure II.25 nous montre le signal ECG en appliquant un filtre numérique passe bas de type **Butterworth**, d'ordre 4 et avec une fréquence de coupure de 45 Hz. De plus dans la même figure on peut voir les tracés de la transformé du Fourier des signaux ECG pour les deux sujets filtrés par les paramètres décrites au-dessus :

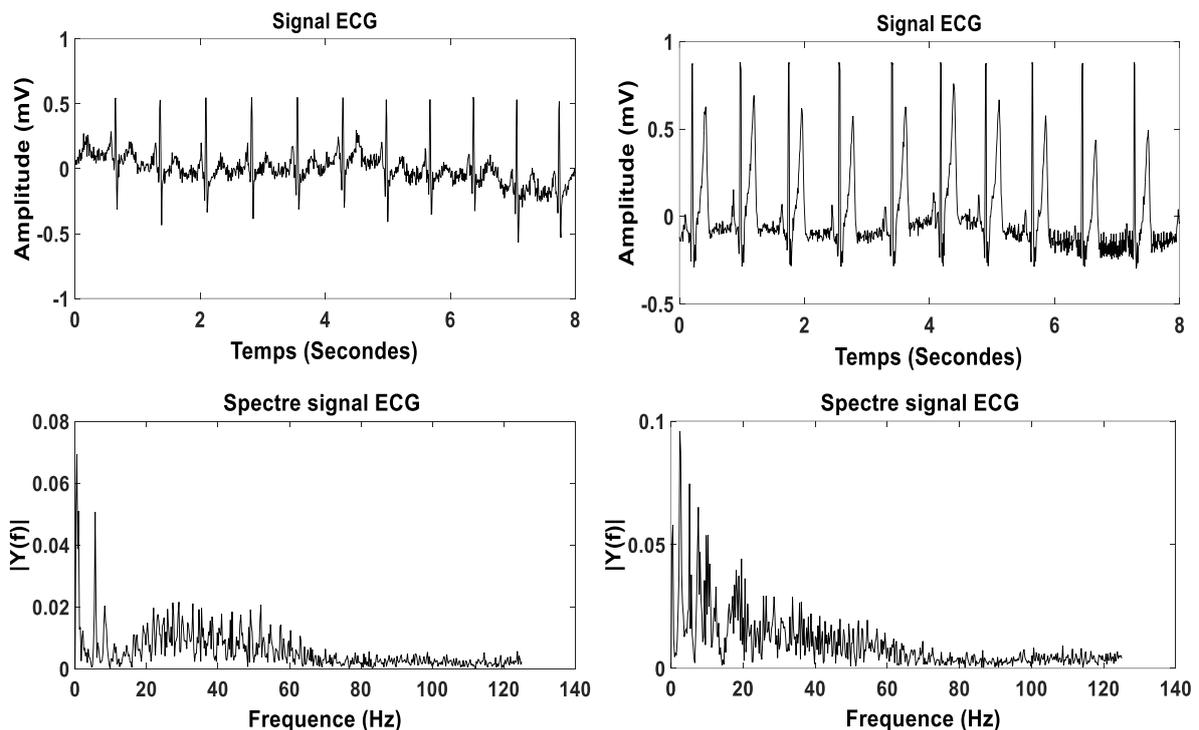


Figure II.24: Tracés des signaux ECG pour le sujet 1 et 2 avec leurs spectres.

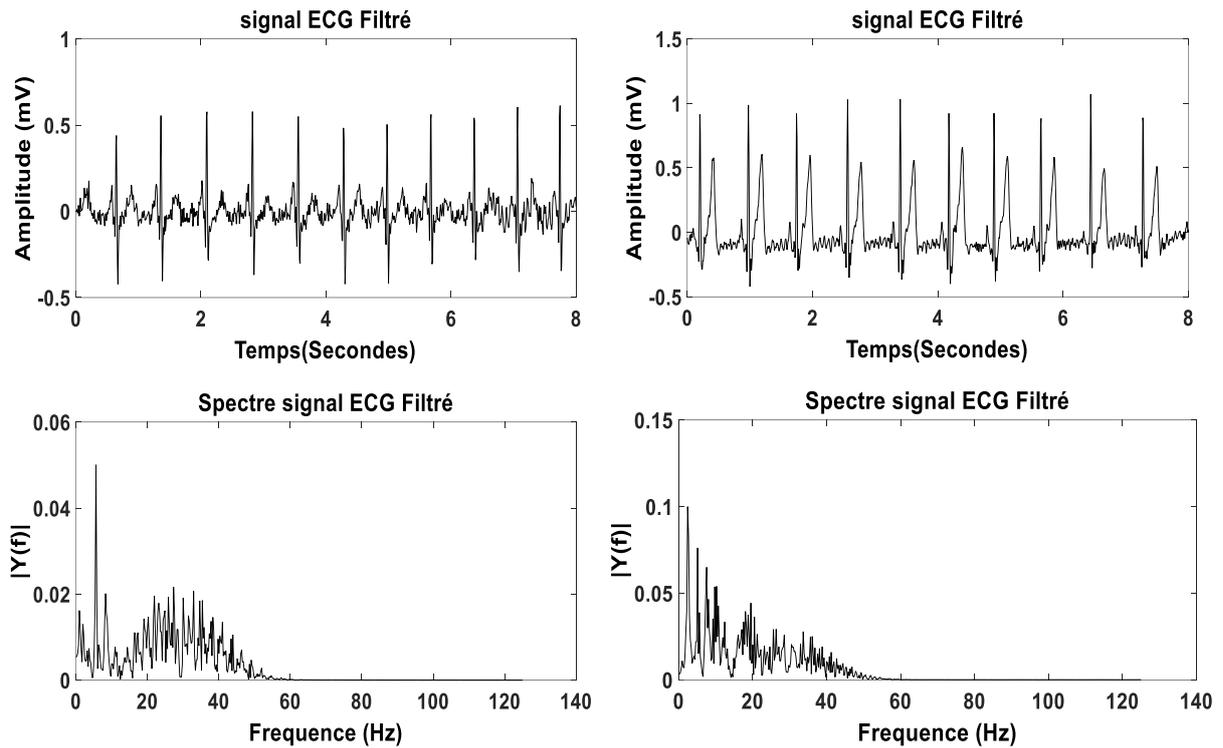


Figure II.25: Tracés des signaux ECG filtrés pour le sujet 1 et 2 avec leurs spectres correspondants.

Dans ce qui suit nous allons présenter les résultats obtenus pour le signal EEG, la Figure II.26 illustre le tracé du signal EEG en fonction du temps pour deux sujets différents, l'enregistrement a une durée de 20 secondes et 40 secondes pour le sujet 1 et 2 respectivement. Rappelons que les deux d'électrodes sont disposées à la partie frontale du crâne. La troisième électrode est placée au-dessous de l'oreille gauche. Sur le tracé on peut remarquer qu'il y a une information supplémentaire associé avec le signal utile ; C'est l'artefact du clin d'œil et qui correspond au signal EOG.

Comme le premier signal, nous avons calculés et tracés la transformée de Fourier Rapide de ce signal. Le spectre est présenté par la Figure II.26 au-dessous. Il est clair que spectre est focalisé vers les basses fréquences environs 0 et 5 Hz. Cette plage qui correspond au domaine fréquentiel du signal EEG.

Le signal EEG parmi les signaux les plus mêlé et contaminé par les sources de bruits et d'interférences. Malgré l'introduction du filtre passe bande analogique dans le circuit ; le problème du bruit persiste toujours où sur le tracé on peut remarquer le bruit qui associes le signal EEG. Pour cela nous envisageons d'appliquer un filtre numérique sous Matlab de type

**Butterworth** d'ordre 4 et de fréquence de coupure de 40 Hz. Les deux signaux filtrés appartiennent au sujet 1 et 2 avec leurs spectres sont représentés par la Figure II.27.

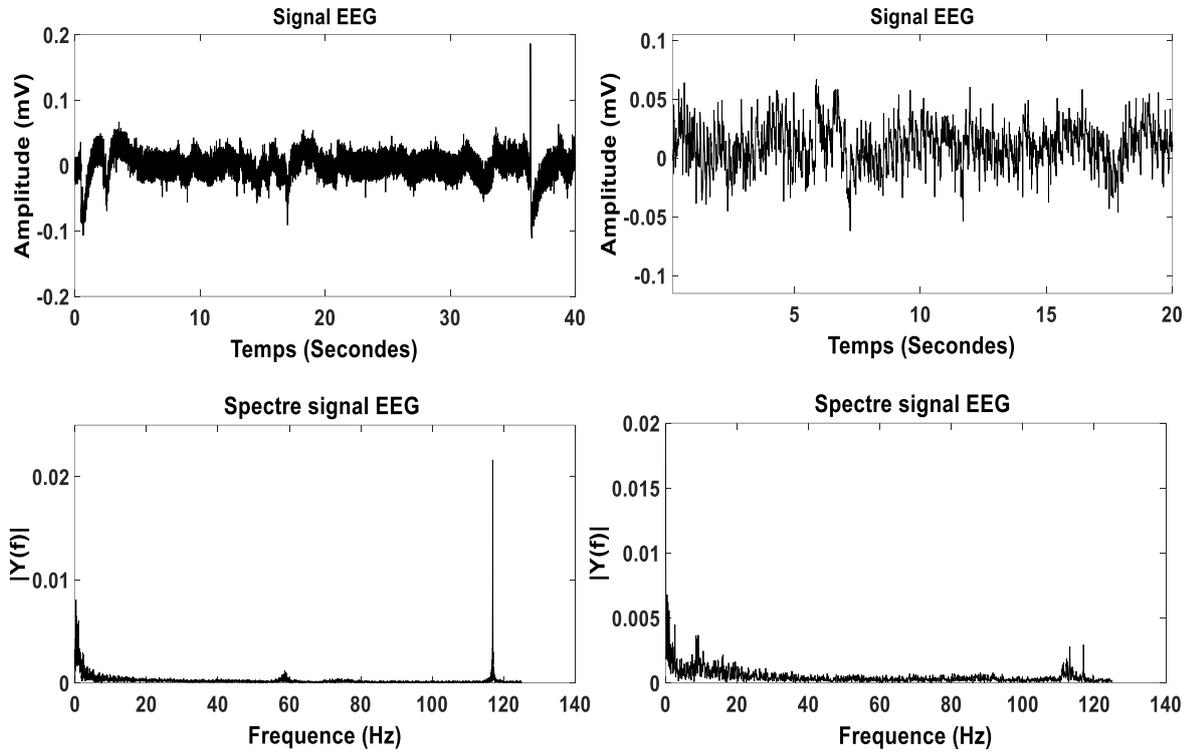


Figure II.26 :Tracés des signaux EEG pour le sujet 1 et 2 avec leurs spectres.

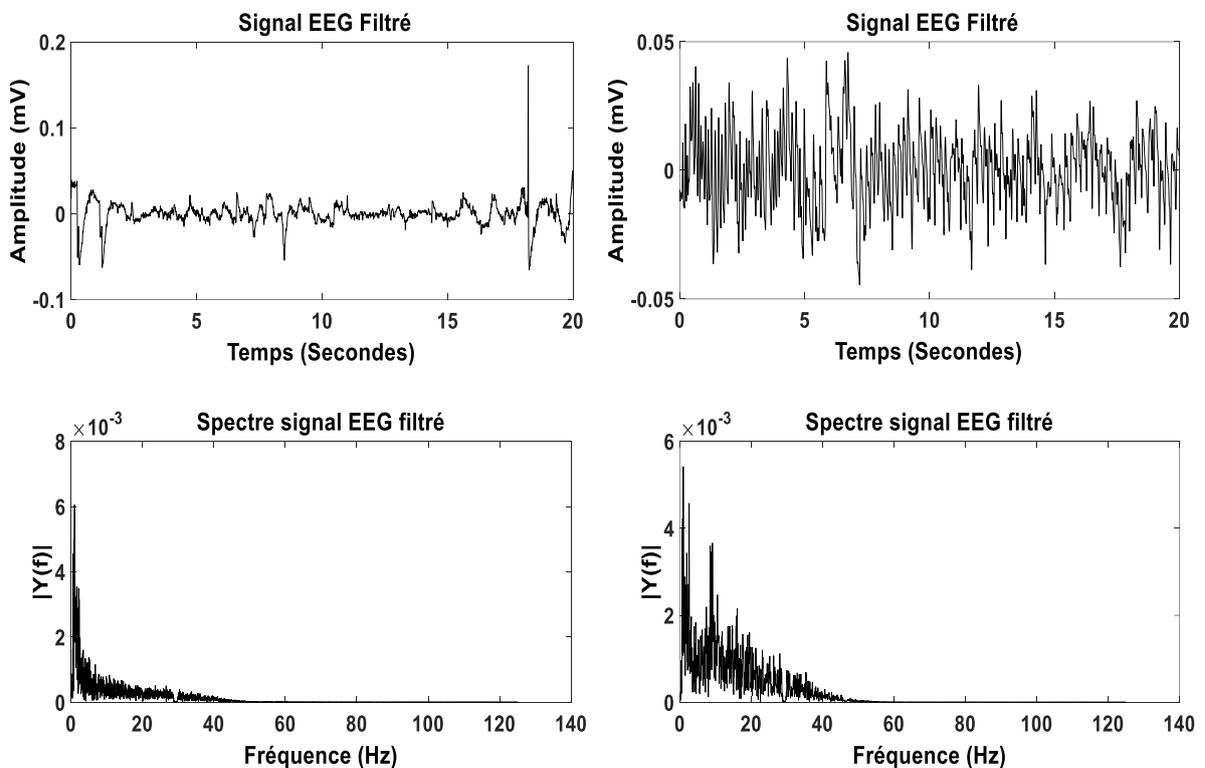


Figure II.27 :Tracés des signaux EEG filtrés pour le sujet 1 et 2 avec leurs spectres correspondants.

Rappelons qu'à côté des informations extraites depuis la variation temporelle des activités électrophysiologiques nous envisageons de faire une analyse fréquentielle des signaux EEG et ECG acquis, cette dernière permettre d'atteindre l'objectif de notre travail. Cette analyse est considérée comme un complément très utile concernant la construction de la base de données désirée. Les informations extraites depuis le domaine fréquentiel nous aident à concevoir un module de détection des crises d'épilepsie fiable et puissant, car lors de l'apparition de la crise il va y avoir bien évidemment un changement dans le contenu fréquentiel des composants formant le signal. Plusieurs outils mathématiques appartiennent au domaine de traitement de signal nous permettent d'avoir des idées sur les composants fréquents, nous citons à titre d'exemple FFT (Fast Fourier Transform déjà calculés), transformée de Fourier à court-terme (TFCT), ...etc.

La transformation de Fourier effectue une transposition de l'espace-temps vers son espace dual des fréquences et perd de ce fait toutes les informations sur le séquençage temporel du signal. Le résultat obtenu par cette transformation est soit une fonction du temps soit une fonction de la fréquence ce qui interdit tout accès à une notion telle que la fréquence instantanée.

### II.2.11. Densité spectrale de puissance

La densité spectrale de puissance est largement utilisée afin de caractériser les processus aléatoires dans les systèmes électroniques, elle permet d'évaluer le rapport signal/bruit du système. De plus Elle représente la répartition de la puissance sur l'axe des fréquences (Roy, M, 2002). C'est la puissance moyenne du signal dans un intervalle  $[0, T]$  exprimée par :

$$\bar{P}(T) = \frac{1}{T} \int_0^T |x(t)|^2 dt \quad (\text{II.24})$$

On peut tirer depuis la figure que la densité spectrale de puissance calculée confirme encore plus ce qui est déduit à partir de la FFT. Présence de plusieurs raies avec forte puissance dans la zone des basses fréquences pratiquement inférieure à 40 Hz pour le signal ECG et cette zone valide qu'il s'agit bien de la plage de variation du signal ECG à partir des notions théoriques trouvées dans la littérature. Concernant le signal EEG ou en parle d'un signal électrophysiologique plus lent, la PSD sélectionne la bande 0-5Hz comme la bande qui contient les fréquences plus puissantes composant le signal EEG.

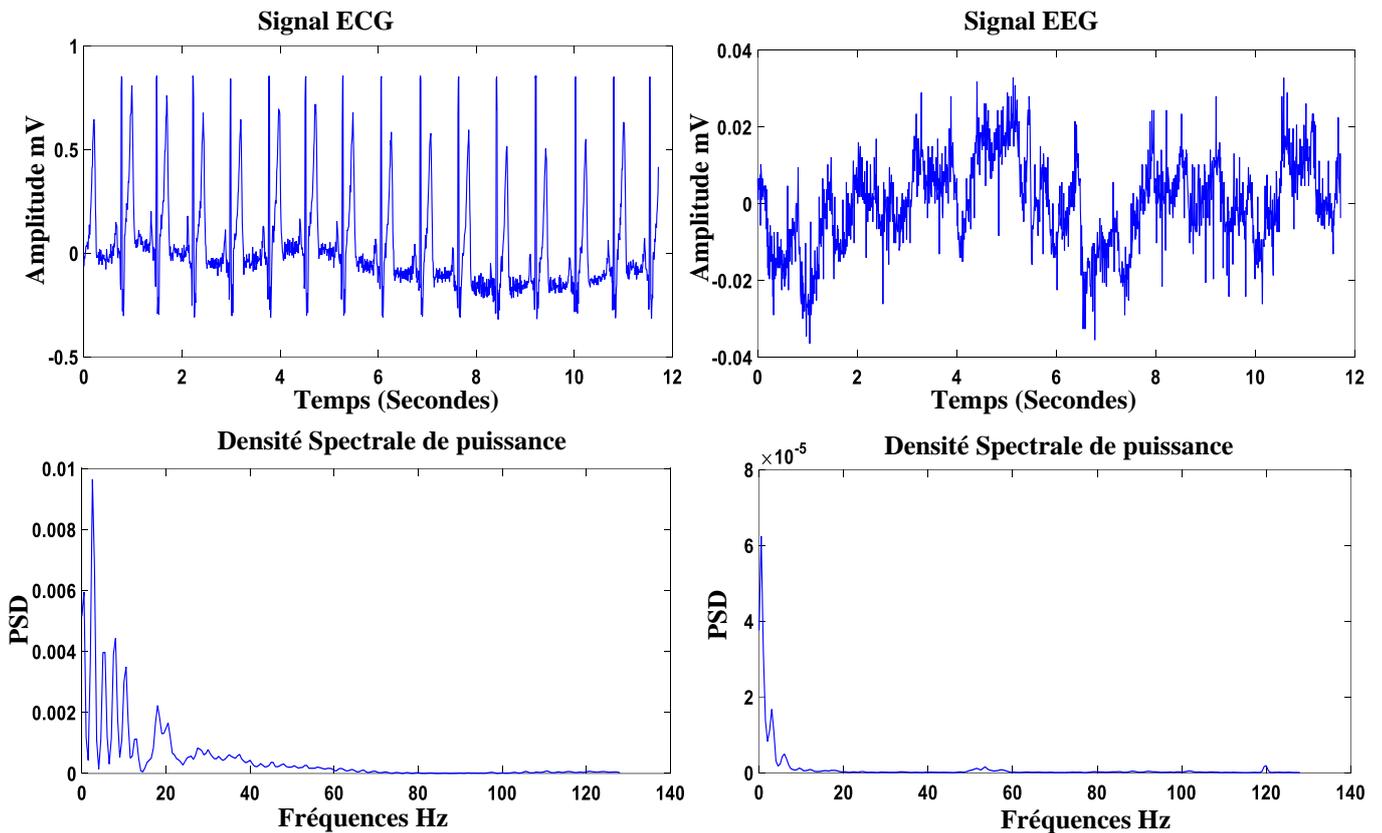


Figure II.28 : Tracés de la densité spectral de puissance pour les signaux EEG et ECG.

## II.2.12. Représentation temps-fréquence et temps-échelle

### II.2.12.a. Transformée de Fourier a court-terme

**Gabor** dans les années 1940 découvre la première forme de représentation temps-fréquence. Sa technique consiste à découper le signal en différentes plages ou fenêtres de longueur fixée. Chaque plage est alors étudiée séparément des autres par l'analyse traditionnelle de Fourier. Une telle méthode est appelée transformée de **Fourier a court-terme** ou "**Short Time Fourier Transform**". à ce niveau nous avons appliqués la transformée de Fourier à court terme pour les signaux EEG et ECG acquis par notre propre système, la figure nous montre le résultat obtenue pour les deux signaux ,sachant que les paramètres permettant le calcul de cette transformée sont les suivants

- Fréquence d'échantillonnage 256Hz.
- Fenêtre de type Hamming avec une taille de 2048 points.
- Un chevauchement de 50% (c à d 1024 points).
- 1024 points avec lesquels on calcul la FFT.

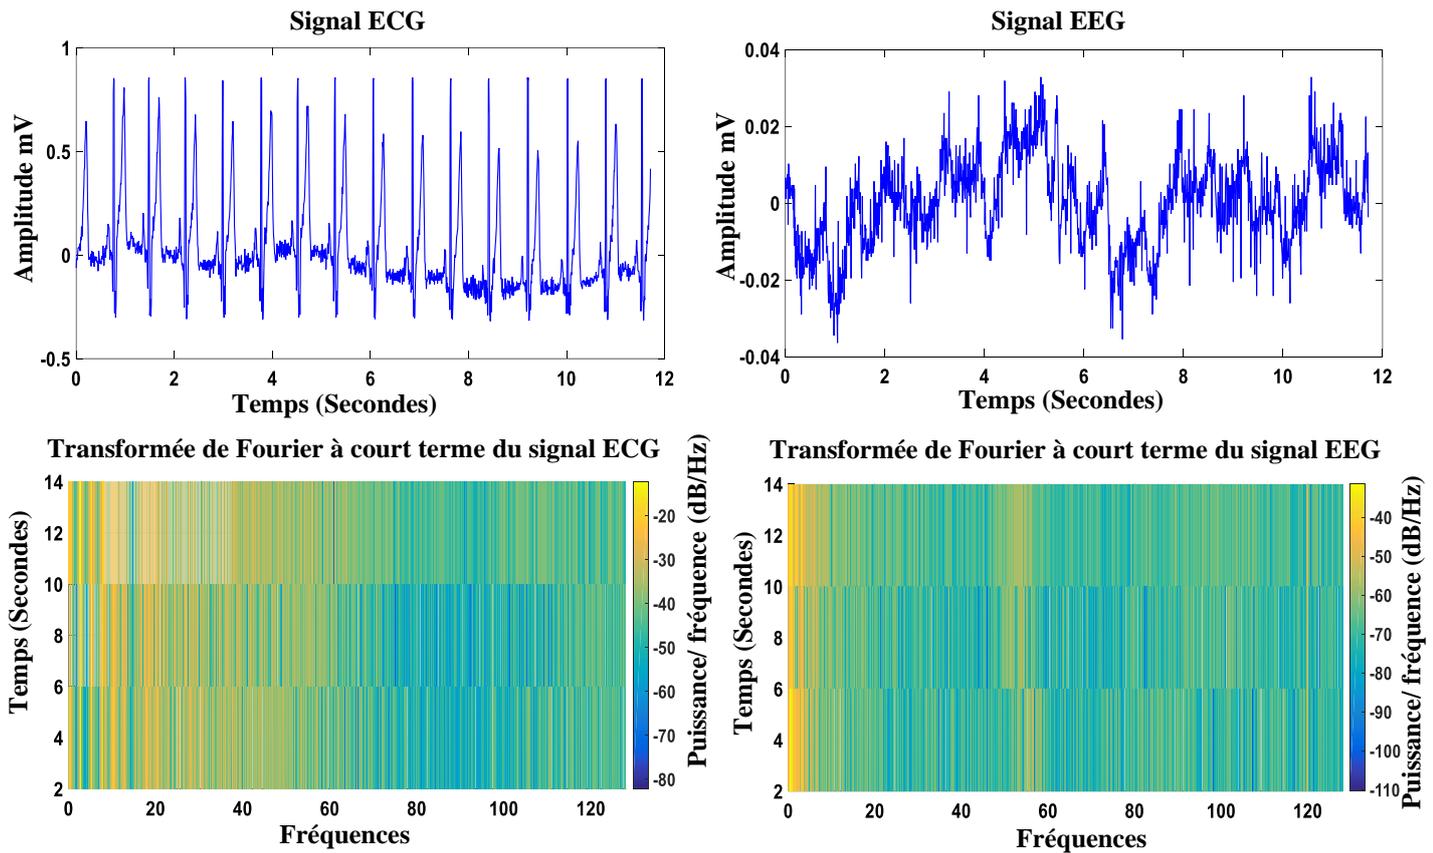


Figure II.29: Tracés des transformées de Fourier à court terme pour les deux signaux.

La figure II.29 confirme ce qu'est déduit à partir des courbes de la densité spectral de puissance calculée (La figure II.29), présence de plusieurs raies dans la plage des basses fréquences, plus précisément inférieur à 60 Hz pour le signal ECG, et inférieur à 20Hz pour le signal EEG, ces raies sont présentées par le jaune et cela durant toute au long des enregistrement. De plus elles expriment la forte puissance dans les signaux. Concernant les autres raies, celle colorées par le bleu traduiteurs faible puissance ou leurs absences dans nos signaux.

### II.2.12.b. Transformée en ondelettes continues

La TFCT définit un outil d'analyse temps fréquence tandis que la WT définit un outil temps échelle. Tous d'abord nous commençons par une petite définition sur cette transformée, La transformation en ondelettes continue consiste à créer à partir d'une ondelette mère notée  $\psi$  (qui ressemble à une petite onde) ou encore appelée ondelette analysante, une famille d'ondelettes.

$$\psi_{ab}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (\text{II.25})$$

Le spectre de l'ondelette de base montre que l'ondelette correspond à un filtre de bande passante autour de  $f_0$ . Le dimensionnement de l'ondelette dans le domaine temporel correspond à une translation dans le domaine des fréquences : Le spectre de l'ondelette dilatée est localisé vers les basses fréquences tandis que celui de l'ondelette contractée vers les hautes fréquences figure(Figure II.30 ).

Le signal est multiplié par l'ondelette de fréquence  $1/a$  décalée de  $b$  par rapport à l'origine des temps.La somme algébrique des aires du produit obtenu donne un coefficient d'ondelette  $S$  pour chaque valeur de  $a$  et de  $b$

$$s(b, a) = |a|^{-1/2} \int_{-\infty}^{+\infty} s(t) * \psi\left(\frac{t-b}{a}\right) dt \quad (II.26)$$

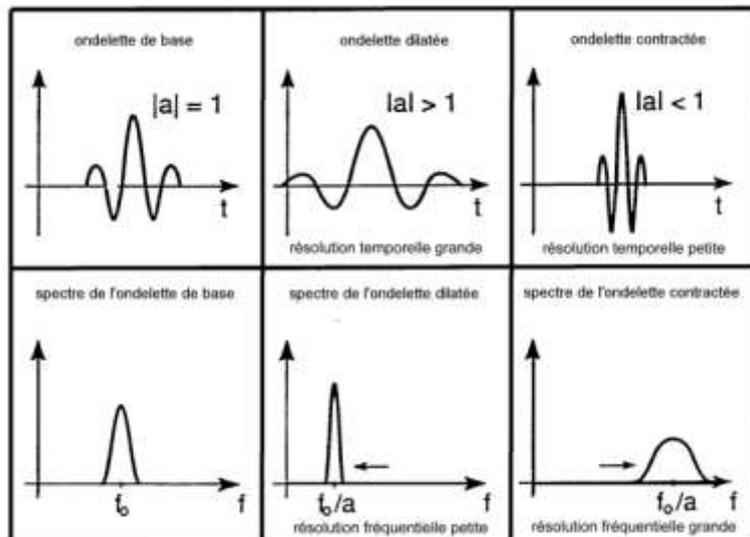


Figure II.30 : Tracés des ondelettes de base avec leurs spectres.

Plus la fenêtre est petite dans le temps, plus l'ondelette va être compressée et osciller rapidement. Le contraire se produira lorsque la fenêtre est dilatée ainsi, les petites et grandes fenêtres enregistreront respectivement les variations rapides et lentes du signal.(Debbal, S, 2004 et Jacky, D. 2001).

Le choix de l'ondelette analysante est important, on peut trouver plusieurs types, nous citons les ondelettes Bio-orthogonal, Morlet, Chapeau Mexicaine, etc.

La figure illustre l'application de la transformée en ondelettes des signaux EEG et ECG acquis précédemment, rappelons que nous avons utilisés l'ondelette de type Bio-orthogonal (noté Bior3.5) avec une échelle de 128. Sur la figure on peut tirer les zones correspond a la forte activité coloré par la couleur jaune, et elle correspond au complexe QRS du signal ECG.

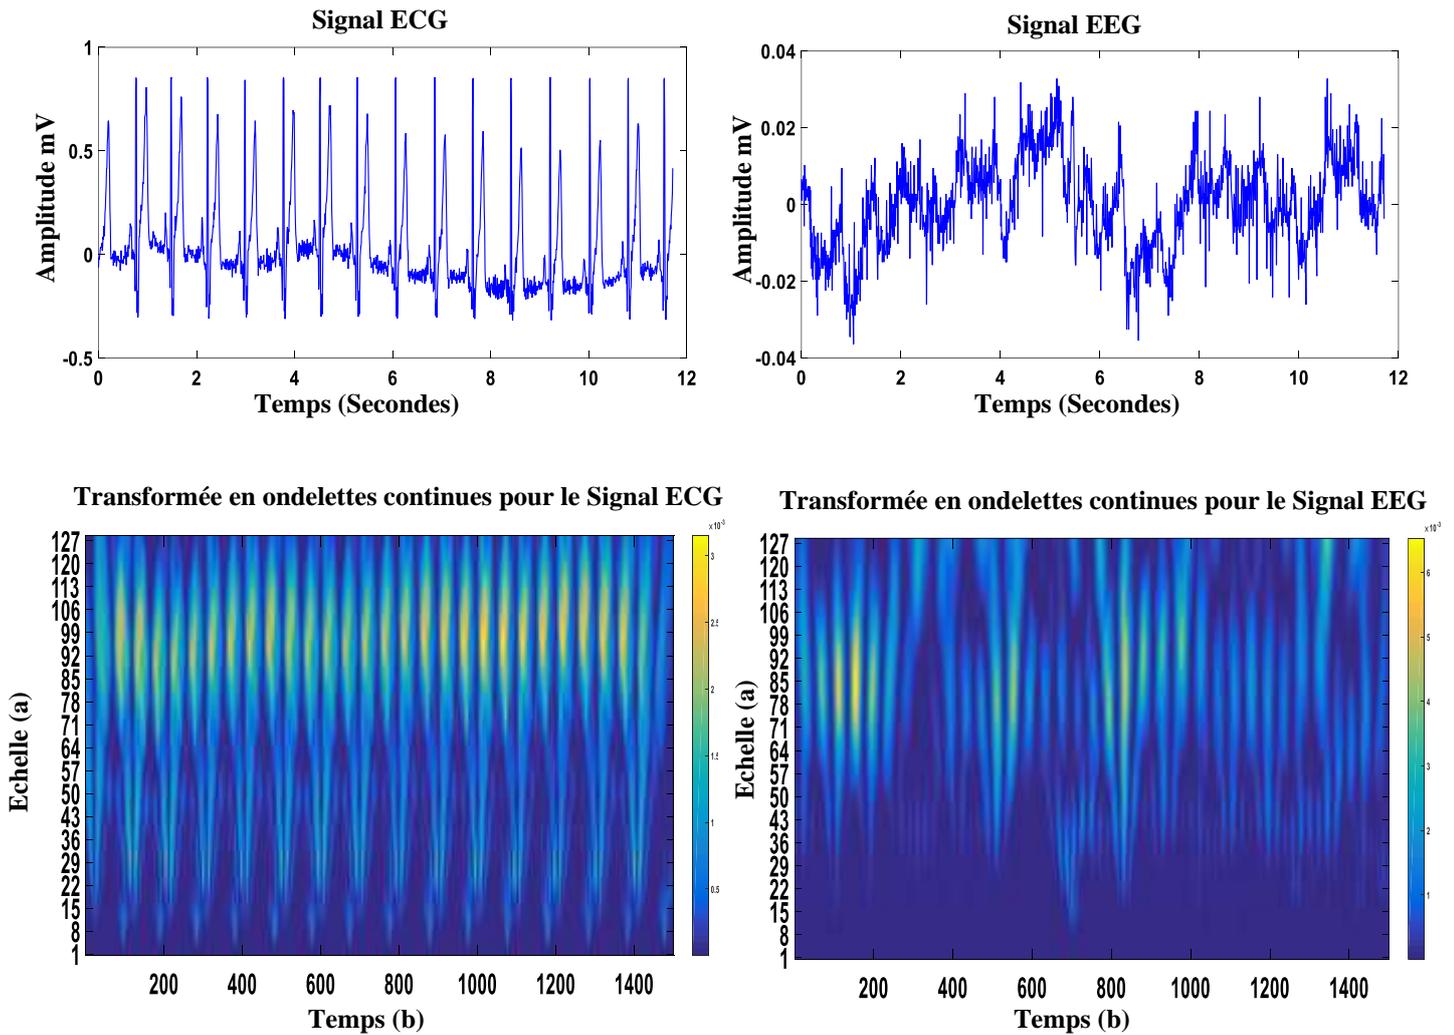


Figure II.31: Tracés des Transformée en ondelettes continues pour les signaux EEG et ECG.

### II.2.13. Tracés et analyses fréquentielles des signaux acquis sur l'Arduino et l'afficheur LCD

Après avoir décrit en détail les résultats des signaux acquis par l'interface graphique, nous présentons ci-après les tracés sur l'afficheur graphique LCD en temps réel des signaux EEG et ECG avec leurs transformer de Fourier rapide (FFT). Notons que sur l'afficheur on peut aussi lire la fréquence dominante du spectre de chaque signal.

Nous Rappelons que l'analyse spectral est effectuée au niveau du microcontrôleur de la carte Arduino sans utiliser le Pc, et cela dans un temps qui ne dépasse pas sept secondes.

La Figure II.32 illustre les tracés des signaux ECG et EEG, on peut constater que chaque signal possède une résolution temporelle médiocre. Tandis que l'analyse spectrale effectué par

Arduino présentée par la même figure possède une bonne résolution, de plus à côté du spectre on peut lire sur l'écran la valeur de la fréquence la plus dominante pour les deux signaux.

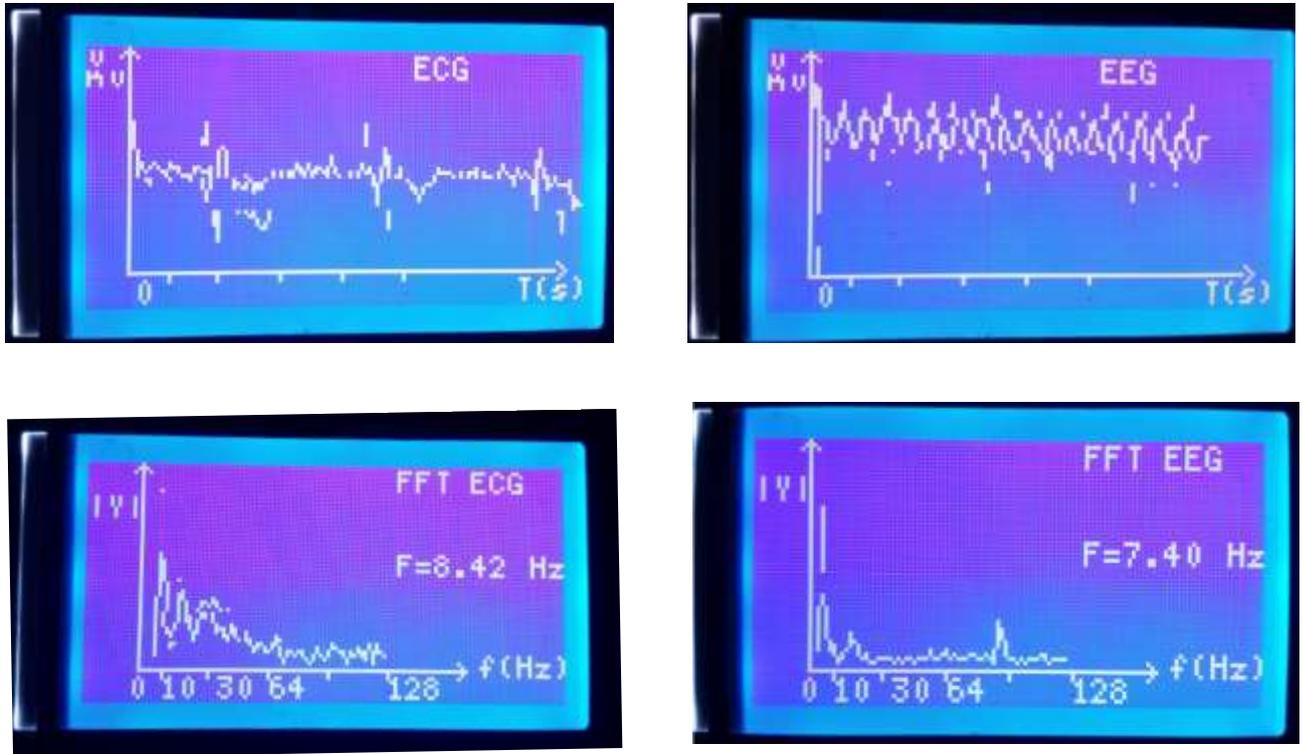


Figure II.32 :Tracés des signaux EEG et ECG sur l'afficheur LCD graphique avec leurs spectres et fréquences dominantes correspondants calculés par la carte Arduino.

Beaucoup d'études ont été développées dans la littérature afin de trouver un algorithme fiable et fonctionnant en temps réel pour la détection et la prédiction des crises épileptiques. La majorité des méthodes reposent sur l'utilisation de l'intelligence artificielle et qu'est basée essentiellement sur l'implémentation du processus de classification (pour plus de détails voir chapitre III). Afin de détecter le mieux possible ces crises, Récemment il existe plusieurs algorithmes qui reposent sur la combinaison de plusieurs signaux physiologique tel que EEG avec ECG et qui représente l'objectif de notre travail.

Il faut noter que chaque étape de classification doit être précédé par une étape de caractérisation, pour cela la détermination des paramètres pertinent est indispensable.

Le but de ce travail est de créer d'une manière organisée et bien structurée une base de données médicales personnelle, cette dernière peut être utilisée pour le suivi médical des patients souffrant de crises épileptiques. D'autre part, la recherche d'un algorithme plus performant qui repose sur la fusion des deux signaux nous a conduit à exploiter comme paramètre pertinent et utile la cohérence entre les signaux EEG et ECG. L'utilisation de cette cohérence peut apporter une grande contribution dans le domaine de la médecine, plus précisément, les patients épileptiques qui souffrent de crises d'épilepsie.

La cohérence  $C_{xy,j}$  mesure la relation entre deux signaux  $X$  et  $Y$  à la même fréquence  $j$ , on note que la cohérence nécessite la transformée de Fourier, elle est donnée par :

$$C_{XY}(f) = \frac{|P_{XY}(f)|^2}{P_{XX}(f)P_{YY}(f)} \quad (\text{II.22})$$

Elle est fonction de la densité spectrale de puissance  $P_{XX}(f)$  et  $P_{YY}(f)$ , de  $X$  et  $Y$ , ainsi que la densité spectrale de puissance transversale  $P_{XY}(f)$  de  $X$  et  $Y$ .

Afin de calculer cette cohérence, nous avons implémenté sous Matlab l'expression mathématique permettant la quantification de la liaison dans le domaine fréquentiel

entre les deux signaux enregistrés auparavant.

Dans le but de valider et évaluer nos résultats, nous envisageons de faire une comparaison avec une source de données médicales, dites universelles, c'est la base de données CHB-MIT. Plusieurs chercheurs dans le monde ont eu recours à cette source de données disponible gratuitement sur Physionet (PhysioBank database, 2016).

La Figure II.43 représente la cohérence obtenue depuis les signaux EEG et ECG de notre module d'acquisition pour une personne dite saine (avec une activité cérébrale et cardiaque normale). D'après le tracé on peut distinguer une forte cohérence (environ 0.8) pour les basses fréquences, plus précisément autour des 20Hz.

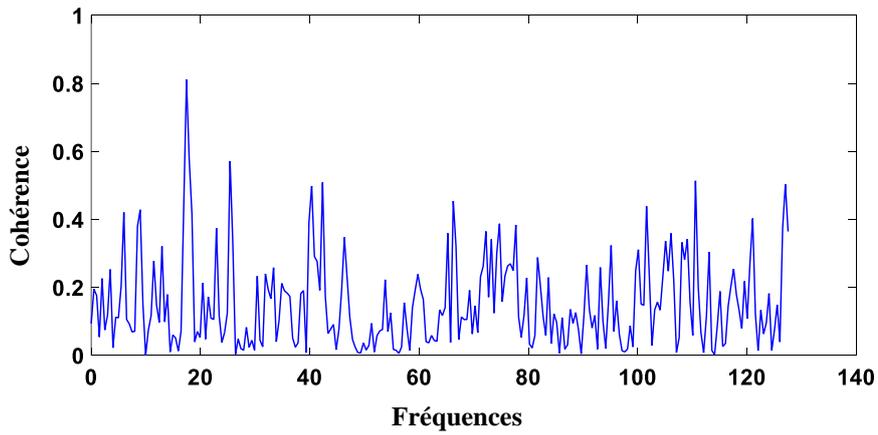


Figure II.33: Cohérence entre les signaux EEG et ECG de notre système.

Nous présentons par la Figure II.34 la cohérence entre deux segments de signaux avec une activité normal (sans symptômes de crise) sélectionnés à partir de la base de données CHB-MIT.

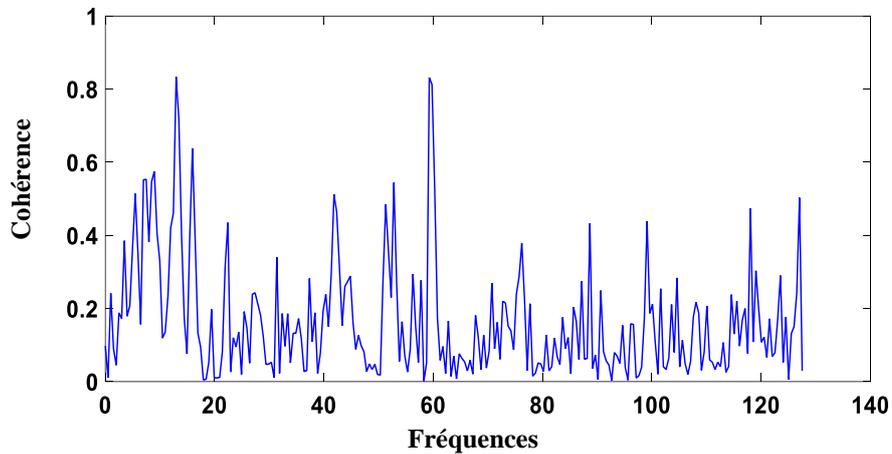


Figure II.34 : Cohérence entre l'EEG et le signal ECG d'un patient sans crise d'épilepsie.

Les deux derniers segments sont choisis de tel sort qu'ils contiennent des effets épileptiques. Le résultat est illustré dans la Figure II.45 en dessous :

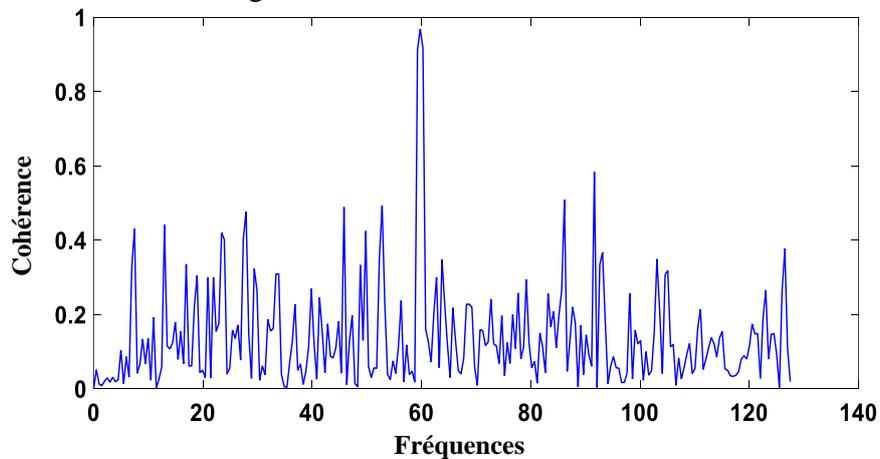


Figure II.45 : Cohérence entre l'EEG et le signal ECG d'un patient avec crise d'épilepsie.

Suivant les trois figures on peut constater que lors la présence de la crise il y a une faible cohérence entre les deux signaux, tandis que lors l'absence de la crise, la cohérence est très forte autour des basses fréquences.

Il faut noter qu'au niveau des deux dernières figures, on peut tirer l'existence d'une très forte cohérence, plus précisément à la fréquence de 60Hz. Cette cohérence correspond à la présence de l'artéfact de l'interférence électromagnétique du secteur d'alimentation dans les deux signaux électrophysiologiques, par conséquent cette valeur ne doit pas être prise en considération.

Afin d'évaluer d'une manière précise, fiable et profonde, nous avons calculés des paramètres statistiques permettant d'effectuer une comparaison statistique entre ces trois cas. Le Table II.2 résume les résultats obtenus, le tableauII.2 nous confirme que la cohérence avec et sans crise sont significativement différents en termes d'énergie moyenne, d'écart-type et d'entropie.

	Signal obtenu à partir de notre système (sans crise)	Signal à partir CHB-MIT source de données	
		Sans crises	Avec crise
<i>Moyenne ± std</i>	0.15065±0.13055	0.17455±0.1567	0.13615±0.1161
Valeur Maximum	0.71355	0.83195	0.614
Energie	10.19835	14.0464	8.1212
Entropie	0.7466	0.8473	0.663

Table II.2 : Une évaluation statistique comparative de la cohérence entre les signaux ECG et EEG avec et sans crise d'épilepsie et obtenue à partir de notre base de données et de la base de données CHB-MIT.

## II.5. Conclusion

Dans cette section nous avons présentés un système d'acquisition temps réel sans fil, nous avons détaillé circuits électroniques qui permettent de mesurer l'activité cardiaque (une seule dérivation) et l'activité neuronale (un canal EEG)tous on basant sur l'analyse des circuits électroniques qui permettre la détection. Pour acquérir ces signaux sur un microordinateur ; nous avons utilisés un module **Arduino**, ce dernier permet la digitalisation, la communication série avec le pc et d'effectuer une analyse spectrale en temps réel, un module Bluetooth de HC05 permet la liaison sans fil avec un smartphone, deux modules radio fréquences XBee permettent d'augmenter encore plus la distance de transmission sans fil, une interface sous Matlab permet la visualisation et le traitement de l'ensemble des signaux acquis et finalement un afficheur LCD graphique.

Nous avons également effectué une analyse fréquentielle à travers quelques outils mathématiques de la théorie de signal, plus exactement ; la transformée de Fourier rapide, l'analyse temps fréquence par l'utilisation de la transformée de Fourier a courte terme connue sous le nom de la transformée a fenêtre glissante, et finalement l'analyse temps échelle via la décomposition en ondelettes continue. Les résultats obtenus sont satisfaisants, il nous reste d'appliquer ces outils sur des signaux épileptiques afin de voir quel changement peut aboutir lors de crise. Ce qui nous conduit une bonne caractérisation des signaux épileptiques et non épileptiques, cette caractérisation nous ramène à concevoir un système de détection des crise fiable, puissant et sensible, ou on peut même faire la prédiction des crises qui sera l'objectif majeur de cette étude.

A la fin de cette section nous avons présenté une comparaison entre notre base de données et la source de données CHB-MIT en termes de la cohérence calculée entre les deux activités électrophysiologiques ; cérébral (EEG) et cardiaque (ECG). Cette cohérence peut être utilisé comme paramètre pertinent lors de l'application ultérieure d'un système de détection des crises à base de processus de classification.

## **Chapitre III :**

# **Etude de l'influence des crises d'épilepsie sur les signaux Electroencéphalogramme (EEG) et Electrocardiogramme (ECG)**

### **III.1. Introduction**

Le cerveau est l'un des organes les plus complexes du corps humain. Il contrôle toutes les fonctions du corps (mouvements musculaires, sécrétions des glandes, etc.). Il gère aussi la conscience, l'intelligence, l'émotion et la mémoire. Le cerveau humain contient des milliards de cellules nerveuses appelées neurones qui communiquent entre eux en s'envoyant ou en recevant des messages.

Comme nous avons vu au premier chapitre, l'électroencéphalogramme (EEG) est une mesure unique et précieuse de la fonction électrique du cerveau, et cela à travers des électrodes placées sur le crâne. Le signal EEG représente la différence de potentiel électrique entre deux sites différents sur la tête recouvrant le cortex cérébral.

De nombreuses maladies neurologiques affectent le cerveau. La plus connue de ces maladies est l'épilepsie. Les crises d'épilepsie ont été étudiées par de nombreux chercheurs. Tous visent à stopper la progression des crises d'épilepsie.

Dans ce chapitre, nous présentons une technique de détection des crises d'épilepsie fondée au départ sur l'intelligence artificiel. Le but de cette technique d'une part est de valider l'idée de fusionner les informations fournis par les deux systèmes ; cardiaque et cérébrale pour une détection plus performante, et à ce niveau on sera capable à confirmer la présence de l'influence des crises sur l'activité cardiaque. D'autre part cette technique permet la conception d'un module automatique de détection basé sur des différents modèles de classification binaire existant dans la littérature.

L'intelligence artificielle ou couramment connu par « machine learning » en anglais, englobe des procédures informatiques automatiques basées sur des opérations logiques ou binaires, qui

apprennent une tâche à partir d'une série d'exemples. Ici, nous nous occuperons que de la classification.

La tâche de la classification se produit dans une large gamme d'activités humaines. L'étude des modèles développés dans ce contexte permet ainsi de mieux comprendre le fonctionnement général des algorithmes de classification. Nous allons exposer de façon détaillée deux modèles de classification bi-classes conventionnels en montrant leurs efficacités face à notre objectif.

Les deux types de classifieurs choisis dans cette étude sont ; le réseau de neurones artificielle (RMA) et K le plus proche voisin de (KNN). Les deux classifieurs permettent la conception d'algorithmes de classification binaires dont le but est d'assigner des étiquettes de classes suivant deux catégories prédéfinies (classe épileptique ou non épileptique).

Il faut noter que l'utilisation de l'approche de la classification nécessite une caractérisation des données médicale, cette caractérisation est effectuée par l'extraction des paramètres depuis les signaux électrophysiologiques (EEG et ECG). Dans ce contexte et à cause de l'influence de la crise d'épilepsie sur la morphologie des signaux électrophysiologiques, plusieurs composantes temporelle et fréquentielle formant le signal vont être changer d'une façon significative durant la crise. Afin d'achever l'objectif de cette étude, nous nous sommes basés sur l'exploitation des paramètres pertinents déduites à partir du domaine temporel seulement, il 's'agit ici d'un ensemble de caractéristiques et facteurs statistiques.

### **III.2. Travaux réalisés sur la détection des crises d'épilepsie**

Récemment, un plus grand nombre de méthodes automatisées de détection et de classification des crises ont été trouvées. Tels que le travail accompli par Arnab et al. (2017), où ils utilisent l'analyse multi-fractale des fluctuations détendues (MFDFA) pour observer les différents changements dans les différents lobes du cerveau. Un autre algorithme est proposé par Garima Chandel et al. (2017), cette méthode est basée sur l'écart absolu moyen (MAD) utilisant la dimension vectorielle inférieure avec un classifieur linéaire pour la détection automatique des crises à l'aide de signaux EEG.

Boukari (2016a), propose un algorithme qui utilise une combinaison adaptative de paramètres autorégressifs pour la classification des signaux EEG épileptiques. Boukari (2016b) utilise également des coefficients autorégressifs à paires impaires (Yule-Walker et Burg) pour l'extraction de caractéristiques des signaux électroencéphalogramme (EEG). Il y a eu d'autres différentes approches de l'analyse des signaux EEG pour la détection des crises convulsives présentées par Suguna et al. (2015).

Comme nous l'avons mentionné plus haut, le cerveau contrôle toutes les fonctions du corps, ce qui signifie que tout dysfonctionnement du cerveau peut affecter d'autres organes. Parmi ces organes, on peut citer le cœur. En effet, et lors des crises épileptiques, les modifications de la fonction cardiaque impliquent une activation du réseau central autonome. L'étude des signaux électrocardiographiques (ECG) peut également fournir des informations précieuses concernant les décharges électriques en cas de crises. Valderrama et al., (2010) et Nasehi et al (2012) ont montré que les crises sont souvent associées à des altérations cardiovasculaires et respiratoires. Plus précisément, les mesures liées à la fréquence cardiaque (la fréquence cardiaque moyenne, la variabilité de la fréquence cardiaque et l'accélération). En plus, des caractéristiques basées sur le rythme cardiaque, des changements importants dans les caractéristiques et la morphologie du signal ECG peuvent être liées directement à une éventuelle crise.

Il existe des études permettant la détection de ces crises et qui repose essentiellement sur la combinaison des signaux EEG et ECG afin de rendre le diagnostic des crises d'épilepsie plus performant. A titre d'exemple nous citons Iosif, M, et al (2015), où ils ont pu détecter des crises d'épilepsie à l'aide des signaux EEG et ECG pour la surveillance, l'analyse et la prise en charge informatisées des patients épileptiques avec un taux impressionnant.

### **III.3. Description de la base de données**

Afin de pouvoir valider et tester l'influence des crises d'épilepsie sur l'activité cardiaque et cérébrale, un ensemble de données contenant les enregistrements des deux activités doit être disponible. De plus ces activités doivent être annoté et divisé en deux catégories ; celles incluent les effets épileptiques, en parle alors à des cas pathologiques, et celles qui représentent une activité normale sans aucune anomalie, il s'agit ici de cas sains. A cet effet, nous avons réalisé un système de détection des signaux EEG et ECG en temps réel, l'étude et l'analyse de ce système est présentée au chapitre deux. Malheureusement l'enregistrement pour un cas épileptiques n'est pas évident, car un tel cas nécessite tous d'abord un patient qui souffre des crises avec un temps de monitoring trop long et qui peut atteindre des heures et même des jours. Pour cette raison l'application de cette étude sur nos propres signaux deviennent difficile ou encore impossible. Enfin de compte, on s'oriente vers l'utilisation d'une base de données acquise par des experts médicale dans le milieu professionnel hospitalier.

Il existe dans la littérature un grand nombre de travaux sur la détection des crises d'épilepsie basés uniquement sur les signaux EEG. Récemment on peut trouver des bases de données

enrichis par de nouveaux signaux physiologiques enregistrés simultanément, et c'est le cas pour notre étude. Nous avons utilisé une base de données contenant les enregistrements des signaux EEG et ECG permettant d'exploiter de manière plus quantitative les informations concernant les crises. Cette étude a été réalisée sur la base de données CHB-MIT Scalp EEG, disponible gratuitement sur Physionet. (PhysioBank database, 2016; Goldberger et al., 2000). Cette base de données, recueillie à l'hôpital des enfants au niveau de la ville de Boston. Elle est constituée d'enregistrements des signaux EEG et ECG provenant de sujets pédiatriques souffrant de crises d'épilepsie. Les sujets ont fait l'objet d'un suivi pendant plusieurs jours après l'arrêt du traitement antiépileptique afin de caractériser leurs crises et d'évaluer leur candidature à une intervention chirurgicale. Tous les enregistrements ont été recueillis auprès de 22 sujets. L'enregistrement simultané des EEG et ECG a été effectué pour un seul sujet parmi eux nommé Chb04. Quatre enregistrements sont utilisés dans le test. Elle provient d'un homme adulte âgé de 22 ans. Chaque enregistrement contient environ 3 heures de signaux EEG numérisés enregistrés simultanément avec le signal ECG (1 canal pour le signal ECG et 23 canaux pour le signal EEG). Ces enregistrements contiennent 3 crises d'épilepsie, le début et la fin de chaque crise a été annotée dans le fichier « **Seizure** ». De plus, les fichiers nommés chbnn-summary.txt contiennent des informations sur le montage utilisé pour chaque enregistrement, et le temps écoulé en secondes entre le début et la fin de chaque crise. Tous les signaux ont été échantillonnés avec une fréquence d'échantillonnage de 256 Hz (256 échantillons par seconde) avec une résolution de 16 bits. Le système international 10-20 concerne la disposition et la nomenclature des électrodes a été utilisé pour ces enregistrements. Le tableau III.1 nous indique l'emplacement des différentes électrodes désignées par des lettres majuscules : Fp (frontopolaire), F (frontal), T (temporel), O (occipital), C (central) et P (pariétal), les nombres pairs et impairs correspondent respectivement aux sites gauche et droit de la tête.

Canal N°	Désignation	Canal N°	Désignation	Canal N°	Désignation
Canal 1	<b>FP1-F7</b>	Canal 9	<b>P3-O1</b>	Canal 17	<b>FZ-CZ</b>
Canal 2	<b>F7-T7</b>	Canal 10	<b>FP2-F4</b>	Canal 18	<b>CZ-PZ</b>
Canal 3	<b>T7-P7</b>	Canal 11	<b>C4-P4</b>	Canal 19	<b>P7-T7</b>
Canal 4	<b>P7-O1</b>	Canal 12	<b>P4-O2</b>	Canal 20	<b>T7-FT9</b>
Canal 5	<b>FP1-F3</b>	Canal 13	<b>FP2-F8</b>	Canal 21	<b>FT9-FT10</b>

Canal 6	<b>F3-C3</b>	Canal 14	<b>F8-T8</b>	Canal 22	<b>FT10-T8</b>
Canal 7	<b>C3-P3</b>	Canal 15	<b>T8-P8</b>	Canal 23	<b>T8-P8</b>
Canal 8	P3-O1	Canal 16	P8-O2	Canal 24	ECG

Tableau III.1 : Nomenclature des électrodes utilisées.

Sur la figure III.1 nous présentons 17 secondes du tracé simultané des signaux EEG et ECG associés à une crise d'épilepsie. Nous avons présenté les 23 canaux pour le signal EEG (en bleu) et avec un seul canal pour le signal ECG (en rouge). On peut observer à partir de la figure le début de changement de la monotonie des signaux EEG dans l'instant 1679 secondes suivi par un changement brusque en termes de fréquence et amplitude à l'instant 1685 secondes depuis le début de l'enregistrement.

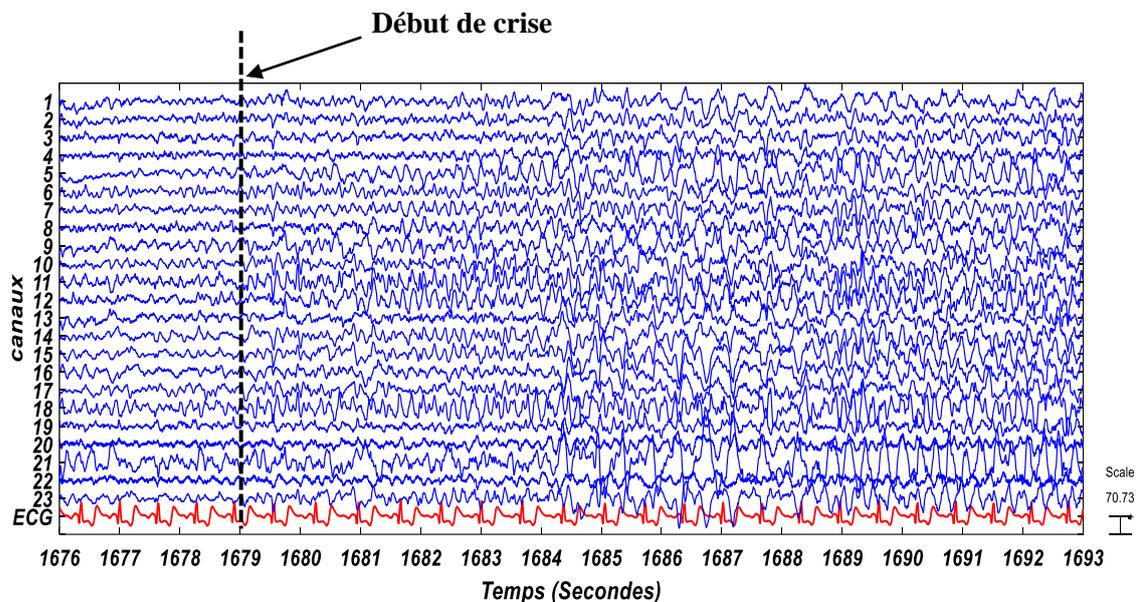


Figure III.1 : Enregistrement simultané du signal ECG et EEG.

### III.4. Réseaux de neurones artificiels (RNA)

Les méthodes de classification ont pour but d'identifier les classes auxquelles appartiennent des objets à partir de certains paramètres descriptifs. Parmi les méthodes utilisées pour la classification, nous citons le réseau de neurones artificiel.

Selon le dictionnaire Webster's, un réseau neuronal est défini comme "une architecture d'ordinateur" dans laquelle un certain nombre de processeurs sont interconnectés par les

connexions entre neurones dans un cerveau humain et qui est capable d'apprendre par un processus d'essais et d'erreurs ». (Li, 2018).

Le développement de réseaux neuronaux artificiels en tant que modèles mathématiques de calcul d'inspiration psychologique trouve son origine dans l'étude du connexionnisme. Une approche générale qui vise à saisir le style architectural et de traitement du système nerveux humain. Le cerveau est un système complexe et non linéaire. Dans cette optique, la discussion se poursuit par un bref aperçu des neurones biologiques et artificiels en tant qu'éléments atomiques des réseaux de neurones naturels et artificiels.

Aujourd'hui les réseaux de neurones artificiels deviennent des outils puissants capables d'être utilisés dans près tous les domaines technologiques tel que le traitement de signal, aide à la décision, robotique, identification des bactéries et reconnaissance des formes,

Un réseau neuronal est un ensemble interconnecté d'éléments, d'unités ou de nœuds de traitement simples, dont la fonctionnalité est vaguement basée sur le neurone animal. La capacité de traitement du réseau est stockée dans les forces de connexion inter-unités, ou poids, obtenues par un processus d'adaptation ou d'apprentissage dans un ensemble de modèles de formation.

Pour plus de détails, nous allons d'abord jeter un coup d'œil rapide à la neurobiologie de base. Le cerveau humain se compose d'environ 100 milliards cellules nerveuses ou neurones. Un exemple très simple d'un neurone est illustré par la Figure III.2

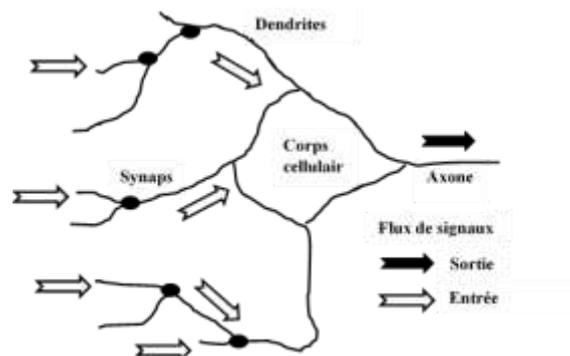


Figure III.2 : Composants essentiels d'un neurone représentés sous forme simplifiée.

### III.4.1. Historique

L'histoire la plus simple de la théorie du cerveau et des réseaux de neurones se limiterait à trois éléments : les études de McCulloch et Pitts (1943), Hebb (1949) et Rosenblatt (1958). Ces travaux ont présenté le premier modèle de réseaux neurones.

En 1943, Mc Culloch et Pitts deux bio-physiciens de l'université de Chicago ont démontré qu'un réseau de neurones discret peut représenter n'importe quelle fonction booléenne, principe de base d'un ordinateur. Le modèle est constitué d'une somme pondérée de ses entrées, suivie d'une fonction non linéaire appelée fonction d'activation (à l'origine une fonction seuil).

$$y_k = \begin{cases} 1 & \text{si } \sum_j w_{kj}x_j - \mu_k \geq 0 \\ 0 & \text{ailleurs} \end{cases} \quad (\text{III.1})$$

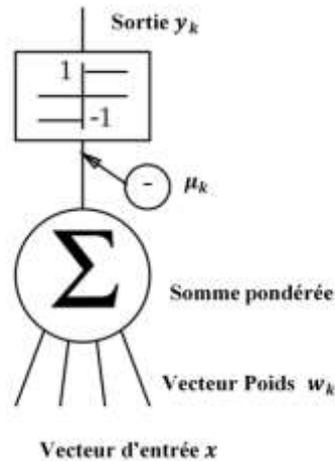


Figure III.3 : Modèle de Mc Culloch et Pitts.

Mathématiquement, un neurone artificiel est une unité de traitement simple qui modélise le style architectural et de traitement élémentaire de son homologue naturel. L'association entre les représentations artificielles et biologiques est résumée dans le tableau III.2.

Biologique	Artificiel
Dendrites	Vecteur d'entrée $(x_1, x_2, \dots, x_n)$
Synapse	Vecteur de pondération $(w_1, w_2, \dots, w_n)$
Agrégation	Activation $\sum_i w_i x_i$
Soma	Fonction d'activation de sortie $f(\sum_i w_i x_i)$
Axone	Sortie y

Tableau III.2 : Comparaison entre les éléments de base du neurone biologique et du neurone artificiel.

En 1949 D. Hebb, physiologiste américain explique le conditionnement chez l'animal par le modèle de base de l'auto-organisation des réseaux. Il introduit le terme connexionnisme avec la proposition de nombreuses règles de mise à jour des poids (Michael,2003).

- En 1958 Rosenblatt a étudié les capacités de groupes de neurones dans une seule couche, tous en agissant sur les mêmes vecteurs d'entrée ; cette structure a été appelée le Perceptron. Cette dernière possède deux couches : Une couche de perception.
- Et une couche liée à la prise de décision.

A ce niveau Rosenblatt a proposé la règle d'apprentissage du Perceptron par l'apprentissage de poids adaptés aux problèmes de classification. Ce réseau est capable d'apprendre par expérience à différencier des formes simples et à calculer certaines fonctions logiques. (Michie,1994).

En 1969, Minsky et Papert soulignent toutefois que de nombreux problèmes du monde réel ne s'inscrivent pas dans ce cadre simple, ils démontrent les limitation et l'incapacité du perceptron à résoudre les problèmes non linéairement séparables citant comme exemple le problème célèbre de la fonction logique *XOR*. Ils ont montré que la solution n'était pas possible avec un réseau perceptron, mais peut être fait avec une structure perceptron à deux couches. Il s'agit du Perceptron multicouche (connu en anglais sous le nom Multi Layer Perceptron "MLP") qui est largement utilisé aujourd'hui.

En 1985 une règle d'apprentissage a été proposée par Hinton qui permet au perceptron multicouche d'apprendre. Cette règle définit la notion de rétropropagation des erreurs à travers le réseau de neurones, et permet de former une grande classe de modèles avec différentes structures de connexion ou d'architectures. Ces travaux ont été à l'origine de l'intérêt récent des chercheurs qui impliquant le succès de cette méthode et son application dans divers domaines.

La figure III.4 montre la structure d'un réseau de neurone multicouches. Cette structure est formée par les couches : entrée, sortie et intermédiaire. Cette dernière est appelée la couche cachée, et contrairement aux couches d'entrée et de sortie, sa taille n'est pas fixe. Elle est généralement utilisée pour créer un goulot forçant le réseau à créer un modèle simple du système générant les données (Stefan, 2015).

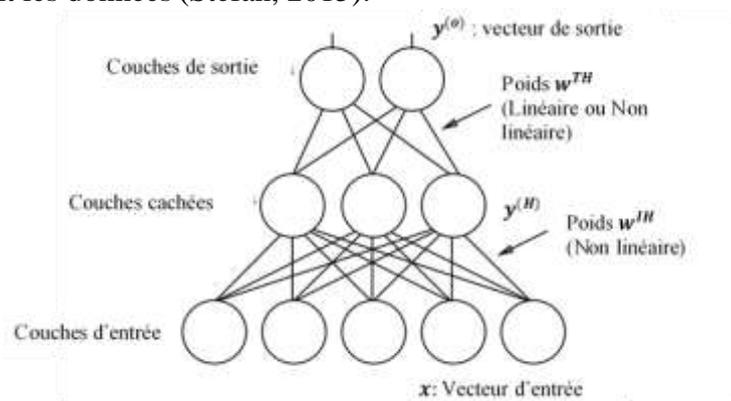


Figure III.4 : structure multicouche (MLP).

Le fonctionnement de ce réseau est défini par :

$$y_i^{(H)} = f^{(H)}(\sum_j w_{ij}^{(HI)} x_j) \quad (III.2)$$

$$y_i = f^{(T)}(\sum_j w_{ij}^{(TH)} y_j^{(H)}) \quad (III.3)$$

Ceci spécifie comment le vecteur d'entrée  $x$  est transformé en vecteur de sortie  $y^{(o)}$  via le vecteur caché  $y^{(H)}$  d'une manière paramétrée par les deux couches de poids  $w^{IH}$  et  $w^{TH}$

La fonction d'activation est présentée généralement par une non linéarité appelée aussi fonction de seuil. Elle permet de définir l'état interne du neurone en fonction de son entrée totale. A titre d'exemple parmi les fonctions les plus utilisées nous citons la fonction sigmoïde qui varie en douceur de 0 à 1 en  $-\infty$  à  $+\infty$  comme une fonction de seuil :

$$f(x) = \frac{1}{1+e^{-x}} \quad (III.4)$$

Il existe d'autres fonctions d'activation souvent plus utilisées, ces fonctions sont illustrées dans la figure III.5.

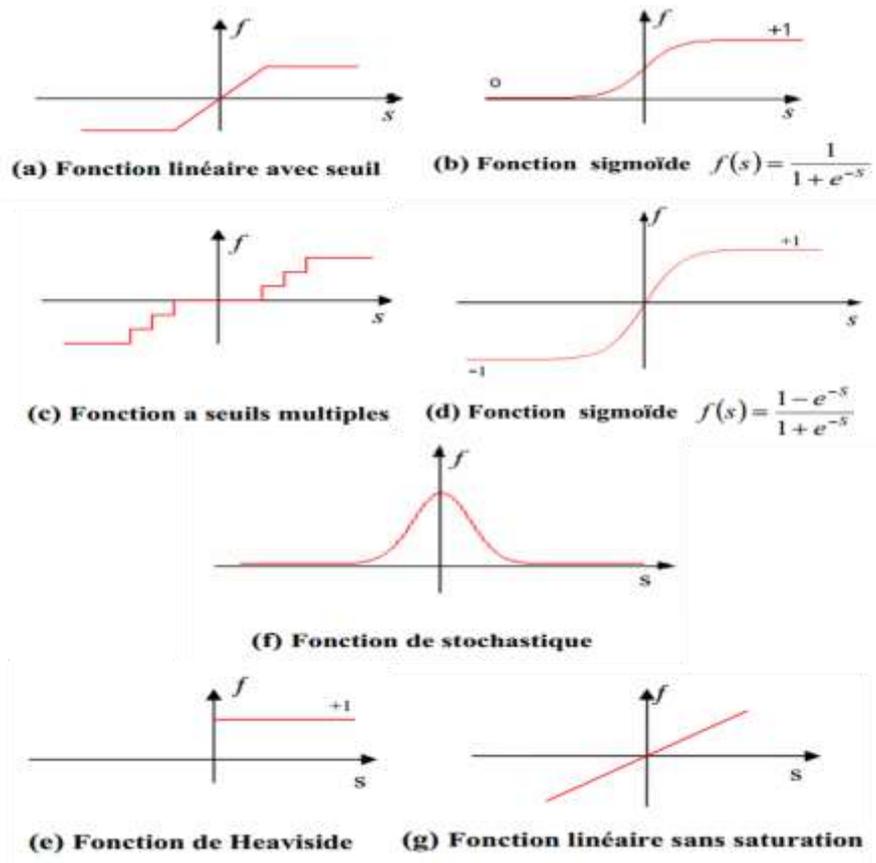


Figure III.5 : Différentes formes de la fonction d'activation.

### III.4.2. Propriétés des réseaux de neurones

Il existe plusieurs propriétés qui portent plus d'intérêts aux réseaux de neurones et qui permettent le dépassement des limitations de l'informatique traditionnel, parmi elles voici quelques-uns :

- **Le parallélisme** : c'est l'architecture qui permet le traitement des données d'une façon simultanée avec la possibilité d'aboutir à des nouvelles techniques de formalisation des problèmes.
- **La capacité d'adaptation** : celle-ci concerne la capacité d'apprentissage et d'auto organisation du réseau afin d'assurer la stabilité des systèmes dynamique.
- **La mémoire distribuée** : cette mémoire correspond à une carte d'activation des neurones.
- **Capacité de généralisation** : Cette capacité est importante surtout dans le cas où la constitution de recueils d'expertise pour un système expert devient difficile (reconnaissance intuitive ou implicite).

### III.4.3. Apprentissage du réseau de neurones

L'étape d'apprentissage consiste à enseigner le réseau de neurones de telle sorte qu'il change son comportement jusqu'à l'obtention du comportement désiré. Techniquement cette phase est élaborée par l'adaptation des différents paramètres tel que les poids à travers un algorithme itératif basé sur des règles d'apprentissage (règle de Hebb, règle de Widrow-Hoff, etc.).

L'apprentissage d'un réseau de neurones peut être classé en deux catégories : les réseaux à apprentissage supervisés et les réseaux à apprentissage non supervisés.

Concernant l'apprentissage supervisé, il repose sur le fait qu'un expert fournit au réseau de neurones un couple de donnée pour chaque exemple, chaque couple de donnée contient des entrées réelles et des sorties désirées. L'adaptation des paramètres du réseau et donc en fonction de la différence entre les entrées et les sorties de chaque exemple, comme le montre la figure III-6.

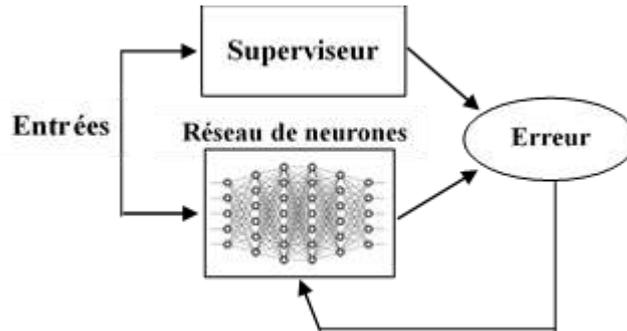


Figure III.6 : Apprentissage supervisé.

En revanche l'apprentissage non supervisé qui est le contraire de l'apprentissage supervisé, est considéré comme un type autonome. Il n'a pas besoin d'expert pour adapter ses paramètres. Il s'agit d'un apprentissage dit par corrélation, ce qui permet la construction automatique des classes sans l'intervention d'opérateur. La figure III.7 montre l'apprentissage non supervisé.

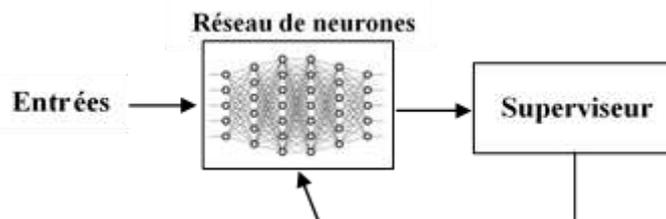


Figure III.7 : Apprentissage non supervisé.

Dans notre étude nous avons utilisé un réseau de neurones à apprentissage supervisé. Ce type de réseau repose essentiellement sur le calcul d'erreur des sorties pour les neurones cachés. L'algorithme le plus utilisé pour résoudre le problème des erreurs est l'algorithme de rétropropagation. Les applications de cet algorithme ont connu un succès spectaculaire et ses performances étaient quelques fois surprenantes. La méthode d'entraînement par rétropropagation utilise la technique suivante :

Elle fournit un modèle d'entrée au réseau, sa sortie est comparée à la sortie désirée, et une distance ou une erreur entre eux est calculée. Ensuite, tous les poids pertinents sont ajustés de telle sorte que la prochaine fois la même instance est traitée, la sortie réelle est plus proche de la sortie désirée, ce qui signifie une diminution d'erreur. Ce processus se poursuit jusqu'à ce qu'une erreur minimale soit atteinte ou jusqu'à ce qu'un nombre donné d'itérations soit complété.

Du point de vue de l'optimisation, apprendre dans un réseau neuronal équivaut à minimiser une fonction d'erreur globale. Il s'agit d'une fonction multivariable qui dépend des poids dans le réseau. De nombreux algorithmes d'apprentissage sont basés sur l'algorithme de descente du gradient. La minimisation est un processus itératif local dans lequel une approximation de la fonction dans un voisinage du point courant dans l'espace de poids est minimisée.

Il existe un certain nombre d'algorithmes d'apprentissage qui peuvent être utilisés pour entraîner un réseau de neurones, les plus connues sont :

- **Descente de gradient** : Ce sont ses algorithmes d'apprentissage les plus populaires qui mettent à jour les poids et les biais dans la direction du gradient négatif. Le principe de base des méthodes de descente est très simple : Comme sur une carte topographique, on utilise les lignes de niveau pour se diriger vers le fond d'une vallée. Pour chaque itération on calcule :

$$x_{k+1} = x_k - \alpha_k \nabla f(x_k) \quad (\text{III.5})$$

Où :  $f(x)$  : est une fonction différentiable qu'on veut minimiser.

$\nabla f(x)$  : est le gradient de  $f$  en point  $x$ .

$\alpha_k$  : le pas de descente.

L'algorithme arrête lorsque la condition suivante est vérifiée :

$$\|\nabla f(x_k)\| \leq \varepsilon \quad (\text{III.6})$$

Il faut noter que lors de l'utilisation de la descente du gradient, et vue que nous cherchons un minimum d'une fonction d'erreur, comme illustré sur la figure III.8 il est possible de tomber dans des minimums locaux, ce qui induit une erreur sur le résultat de notre réseau. Afin d'éviter ce problème il faut :

- Relancer chaque fois l'apprentissage.
- Réduire les poids du réseau par des petites valeurs.
- Et changer le pas d'apprentissage.

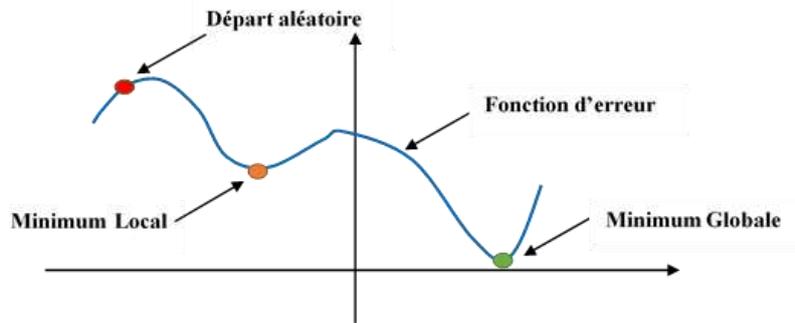


Figure III.8 : Fonction d'erreur avec minimum local et absolu.

- **Gradient conjugué :** c'est une méthode itérative qui converge très vite vers le minimum en un nombre fini d'itérations. De plus si on utilise la descente de gradient, on arrive à un point minimum  $x_k$  selon une première direction  $u_k$ . Cependant quelle est la meilleure direction suivant  $u_{k+1}$  ?

Pour répondre à cette question notre algorithme doit être sous la forme :

$$x_{k+1} = x_k - \alpha_k u_k \quad (\text{III.7})$$

$u_k$  : n'est pas le gradient dans le cas du gradient conjugué, elle varie à chaque étape et on doit avoir :

$$\vec{u}_k \perp \vec{u}_{k+1} \quad (\text{III.8})$$

L'algorithme du gradient conjugué indique l'approximation quadratique de l'erreur E dans un voisinage d'un point w par :

$$E_{qw}(y) = E(w) + E'(w)^T y + \frac{1}{2} y^T E''(w) y \quad (\text{III.9})$$

### III.5. K le plus proche voisin (KNN)

La règle de classification K le plus proche voisin noté (KNN) est l'une des méthodes de classification non paramétrique les plus connues et les plus utilisées. Cette règle est largement utilisée dans un grand nombre de problème de classification. Cette approche consiste à classer une caractéristique inconnue dans une autre caractéristique connue enregistrée dans la base de données appelée données d'entraînement. L'algorithme KNN est un exemple typique d'un

apprenant paresseux parce qu'il mémorise les données d'apprentissage au lieu d'apprendre une fonction discriminante. En utilisant la distance euclidienne, cette approche permet de trouver les K échantillons les plus proches et les plus similaires dans l'ensemble des données de formation aux échantillons que l'on veut classifier, la classe pour le nouvel échantillon est obtenue par vote majoritaire parmi ses k plus proches voisins (figure III.9). (Sebastian, 2015).

Dans cet algorithme, le plus proche est défini en termes d'une mesure de distance telle que la distance euclidienne. La distance euclidienne entre deux enregistrements (ou deux points dans un espace n-dimensionnel) est définie par :

Si  $x_1 = (x_{11}, x_{12}, \dots, x_{1n})$  et  $x_2 = (x_{21}, x_{22}, \dots, x_{2n})$  donc :

$$dist(x_1, x_2) = \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2} \quad (III.10)$$

Où  $x_1$  et  $x_2$  sont deux enregistrements avec n attributs. Cette formule mesure la distance entre deux échantillons  $x_1$  et  $x_2$ . (Mohammed,2012).

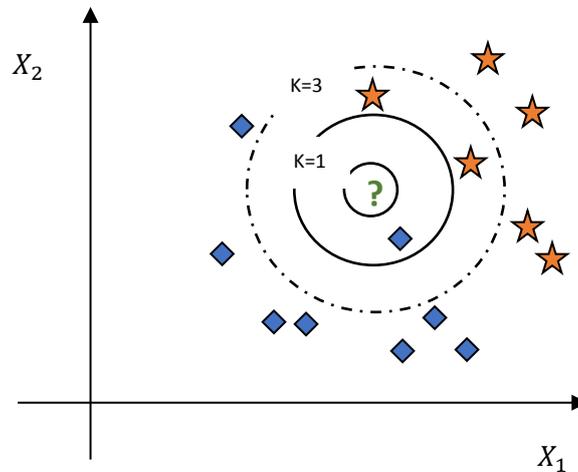


Figure III.9 : Un objet est classé par un vote majoritaire de ses voisins.

### III.6. Description de la méthode Proposée

La figure III.10 présente un schéma bloc de notre détecteur de crises à l'aide d'un algorithme de classification supervisé. L'algorithme consiste à sélectionner des périodes de 10 secondes choisie au hasard dans chacun des 23 canaux bipolaires du signal EEG. Quatre paramètres appartiennent au domaine temporel ont été extraites de chaque segment et concaténées dans un seul grand vecteur. Finalement, le vecteur des paramètres est ensuite assigné comme un

segment normal (absence de crise d'épilepsie) ou segment pathologique (présence de crise d'épilepsie) en utilisant deux type de classifieur ; réseaux de neurones artificielle (RNA) et K le plus proche voisin (KNN). De plus pour une meilleure classification nous envisageons de changer chaque fois les paramètres formant l'architecture de chaque classifieur, d'une part les fonctions d'activation, les fonctions d'optimisations et le nombre de couches cachées pour le réseau de neurones, et d'autre part le nombre des voisins les plus proche pour le classifieur KNN.

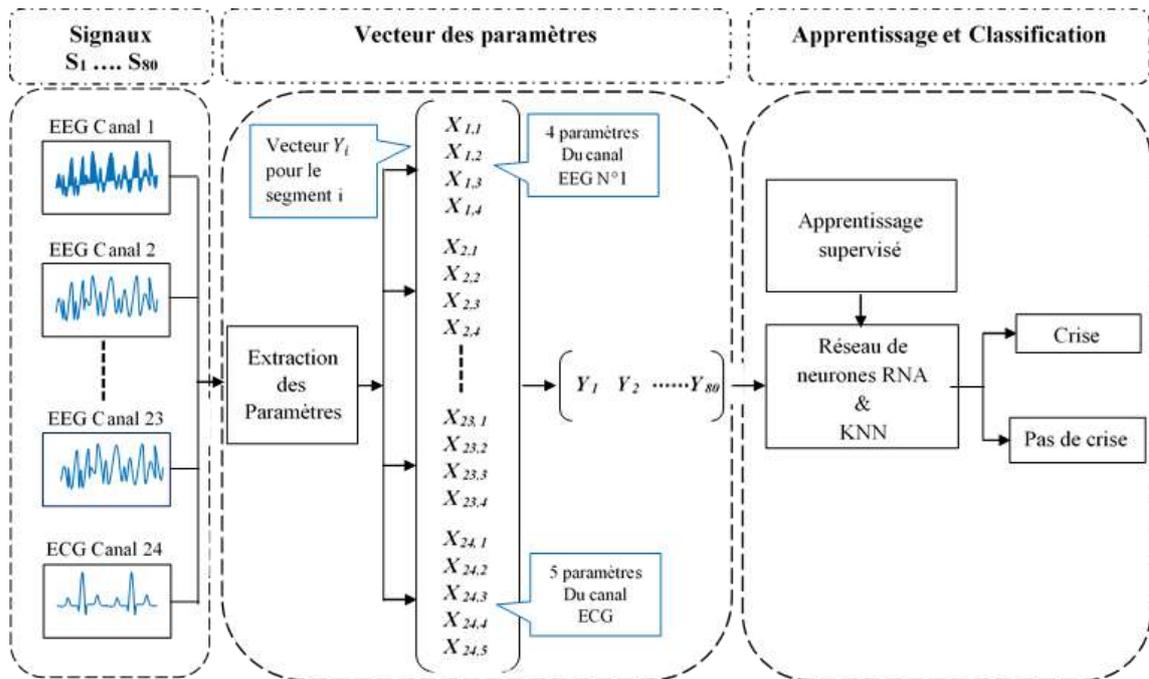


Figure III.10 : Schéma bloc du processus de détection des crises.

Afin d'améliorer encore plus la performance de la détection des crises d'épilepsie, nous avons proposé d'inclure le signal ECG comme information complémentaire au processus de détection.

En plus des quatre paramètres extraits du signal ECG comme le signal EEG, l'activité rythmique (rythme cardiaque) est calculée pour chaque segment et elle est considérée comme un autre paramètre ajouté à notre vecteur. Donc nous avons pour chaque segment  $((4*23) + 5)$  qui équivaut à 97 paramètres.

Comme nous avons mentionnés auparavant, nous avons utilisé une base de données étiquetée par des experts, donc tous les enregistrements contiennent des annotations ; deux enregistrements entre eux contiennent des crises d'épilepsie. Notre test a été évalué sur 80 segments sélectionnés, chaque segment contenant 10 secondes. 30 segments entre eux

contiennent l'événement des crises, les 50 autres segments sont considérés comme une activité normale sans crise ni anomalie.

### III.6.1. Extraction des Paramètres

Dans notre étude le vecteur des paramètres est utilisé pour le processus de classification. Les neuf caractéristiques que nous avons utilisées dans le processus de classification sont présentées dans le tableau III.3. Rappelons que ces paramètres concernent un seul canal pour le signal EEG et un seul canal pour le signal ECG. Il reste à tirer les mêmes paramètres pour les 22 canaux restant pour le signal EEG.

Désignations	Description	Vecteur affecté
$i, EEG_{max_{10}}$	Valeur maximale sur une période de 10 secondes pour le canal $N^{\circ}i$ du signal EEG	$X_1$
$i, EEG_{min_{10}}$	Valeur minimale sur une période de 10 secondes le canal $N^{\circ}i$ du signal EEG	$X_2$
$i, E_{EEG_{10}}$	Energie pour le canal $N^{\circ}i$ du signal EEG (durée de 10 secondes)	$X_3$
$i, \sigma_{EEG_{10}}$	L'écart-type le canal $N^{\circ}i$ du signal EEG (durée de 10 secondes pour le signal EEG)	$X_4$
$ECG_{max_{10}}$	Valeur maximale sur une période de 10 secondes pour le signal ECG	$X_5$
$ECG_{min_{10}}$	Valeur minimale sur une période de 10 secondes pour le signal ECG	$X_6$
$E_{ECG_{10}}$	Energie du signal ECG (durée de 10 secondes)	$X_7$
$\sigma_{ECG_{10}}$	L'écart-type (durée de 10 secondes pour le signal ECG)	$X_8$
$RR$	Rythme cardiaque	$X_9$

Tableau III.3 : Paramètres extraits à partir des signaux ECG et EEG avec leurs vecteurs assignés.

Les énergies mesurées pour chaque segment (respectivement notées  $E_{ECG_{10}}$  et  $E_{EEG_{10}}$ ) sont données par :

$$E_{ECG_{10}}(n) = \sum_{k=1}^L |ECG(k)|^2 \quad (III. 11)$$

$$E_{EEG_{10}}(i, n) = \sum_{k=1}^L |EEG(i, k)|^2 \quad (III. 12)$$

Où :  $n = 1 \dots 80$

L est la longueur de l'enregistrement ( $10 \times 256 = 2560$  échantillons).

$i = 1 \dots M$  avec  $M=23$  est le nombre de canaux du signal EEG.

$\sigma_{ECG_{10}}$  et  $\sigma_{EEG_{10}}$  sont respectivement l'écart-type du signal ECG et du signal EEG qui sont calculés comme suit :

$$\sigma_{ECG_{10}}(n) = \sqrt{\frac{1}{L} \sum_{K=1}^L (ECG(K) - \overline{ECG}(n))^2} \quad (III. 13)$$

$$\sigma_{EEG_{10}}(i, n) = \sqrt{\frac{1}{L} \sum_{K=1}^L (EEG(i, K) - \overline{EEG}(i))^2} \quad (III. 14)$$

$\overline{ECG}$  et  $\overline{EEG}$  Représentent les valeurs moyennes.

La concaténation des vecteurs  $X_1$  à  $X_4$ , nous donne un vecteur  $X_i$ ,

$$[X_i] = [X_1 X_2 X_3 X_4] \quad (III. 15)$$

Donc pour les 23 canaux correspond au signal EEG nous avons un vecteur  $Z$  de taille égale à  $23 * 4 = 92$  ,ou

$$[Z] = [X_1 X_2 \dots \dots X_{23}] \quad (III. 16)$$

Il nous reste alors d'ajouter les paramètres associer au signal ECG afin de réaliser le vecteur de paramètres globale pour chaque segment et enfin nous pouvons utilisés comme entrée de notre classificateur :

$$[Y] = [Z X_5 X_6 X_7 X_8 X_9] \quad (III. 17)$$

### III.6.2. Apprentissage et classification

Dans cette section nous intéressons à la phase d'apprentissage pour les deux classifieurs, où pour chaque classifieur un ensemble de paramètres constituant le classifieur permet d'obtenir plusieurs structures.

Dans le but d'affecter chaque segment a sa propre classe (avec crise ou sans crise), deux types d'algorithmes sont utilisés et comparés : le réseau de Neurones Artificielle (RNA) et le K le plus proche voisin (KNN).

#### III.6.2.1. Phase d'apprentissage du Réseau de neurones

De nombreuses topologies de réseaux de neurones sont testées pour l'architecture RNA et différentes fonctions d'activations sont utilisées pour adapter les réseaux de neurones aux

différents nombres de neurones dans la couche cachée. Dans les structures notées **MLP**, les paramètres sont extraits à partir du signal EEG, tandis que la structure dite **MLPE**, les paramètres sont déduits à partir des deux signaux EEG & ECG. Dans un premier temps nous avons exploité une seule structure pour les fonctions d'activation ; la fonction tangente hyperbolique pour les couches cachées et la fonction exponentielle normalisée pour la couche de sortie. En faisant varier le nombre de couche cachées et les fonctions d'optimisation du réseau, trois types de fonction d'optimisation ont été sélectionnés avec 3 différentes valeurs pour le nombre de couches cachées. 18 topologies sont alors obtenues et utilisées dans la phase de l'essai comme le montre le tableau III.4.

Désignation	Fonction d'optimisation d'un réseau de neurones	Couches Cachées
SC-MLP3	Rétropropagation à gradient conjugué	3
SC-MLPE3		
SC-MLP5		5
SC-MLPE5		
SC-MLP10		10
SC-MLPE10		
CG-MLP3	Gradient conjugué avec réactivation de Powell/Beale	3
CG-MLPE3		
CG-MLP5		5
CG-MLPE5		
CG-MLP10		10
CG-MLPE10		
GD-MLP3	Descente de gradient avec une dynamique et une rétropropagation adaptative à la vitesse d'apprentissage	3
GD-MLPE3		
GD-MLP5		5
GD-MLPE5		
GD-MLP10		10
GD-MLPE10		

Tableau III.4 : Topologies de réseaux de neurones utilisées obtenus à partir différents nombres de couche cachées et fonction d'apprentissage.

Dans un deuxième temps, le nombre de couches cachées du réseau de neurone avec sa fonction d'optimisation sont maintenant fixés. En faisant modifier les fonctions d'activations pour les couches cachés ainsi que les couches de sortie, nous avons choisi trois types de fonction d'activation ; la fonction tangente hyperbolique, la fonction sigmoïde ou logistique et la fonction exponentielle normalisée. Huit différentes structures sont appliquées pour notre étude, dont les structures sont présentées dans le tableau III.5.

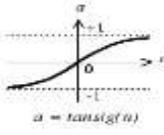
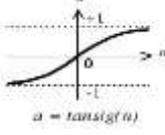
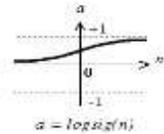
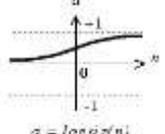
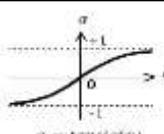
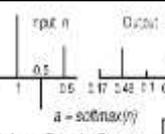
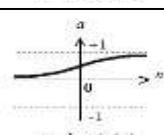
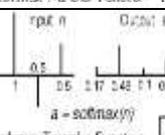
Structure	Couches cachées	Fonction d'activation	Couche De sortie	Fonction d'activation
MLPE3-TT	3		1	
MLP3-TT				
MLPE3-LL				
MLP3-LL				
MLPE3-TS				
MLP3-TS				
MLPE3-LS				
MLP3-LS				

Tableau III.5 : Topologies de réseaux de neurones utilisées obtenus à partir différentes fonctions d'activations.

### III.6.2.2. Phase d'apprentissage du KNN

K le plus proche voisin (KNN) est la deuxième méthode utilisée pour la classification. Le vecteur des paramètres utilisé dans l'algorithme KNN est le même utilisé dans l'algorithme précédent (réseau de neurones) présenté dans le tableau III.3. La capacité de l'algorithme KNN à discriminer entre les classes (crises ou non crises) est influencée par le nombre de voisins les plus proches et la distance entre les échantillons.

Trois structures sont présentées en changeant le nombre de voisins les plus proches (3, 5 et 7).

Trois autres structures sont obtenues en modifiant le type de distance calculé. Il existe plusieurs types de distance, nous citons trois distances pour cette étude ; Euclidienne, cityblock et cosinus. Le tableau III.5 nous montre la définition avec la formule de chaque distance.

<b>Classifieur KNN</b>		
<b>Type de Distance</b>	<b>Définition</b>	<b>Formule</b>
<b>Euclidienne</b>	Distance entre deux vecteurs du plan	$dis(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (III. 18)$
<b>CityBlok</b>	Distance connue aussi sous le nom de distance de Manhattan, c'est la Somme des différences absolues	$d_{ij} = \sum_{k=1}^n  x_{ik} - y_{jk}  \quad (III. 19)$
<b>Cosinus</b>	Distance cosinus considère l'angle entre les vecteurs	$dis(x, y) = 1 - \frac{\sum_{i=1}^n x_i y_i}{\sqrt{\sum_{i=1}^n x_i^2} \sqrt{\sum_{i=1}^n y_i^2}} \quad (III. 20)$

Tableau III.6 : Paramètres des différentes distances utilisées pour le classifieur KNN.

Dans la structure nommée KNN, les paramètres sont extraits seulement depuis le signal EEG, tandis que dans la structure E-KNN, les paramètres sont extraits à partir des deux signaux ECG et EEG.

### III.6.3. Phase de test

Une fois le réseau de neurones est entraîné, il est nécessaire de le tester sur une base de données différente de celle utilisée lors de l'apprentissage.

Comme il a été mentionné plus haut, 800 secondes de données ECG et EEG sont divisées en segments de 10 secondes, ce qui donne un nombre total de 80segments. 24 sont utilisés pour la phase d'apprentissage (1/3 de l'ensemble des enregistrements) et 56 sont utilisés pour la phase de test et de classification (2/3 de l'ensemble des enregistrements).

Les deux algorithmes ont été testés sur 24 signaux, dont 23 signaux EEG et 1 signal ECG, et où neuf signaux contiennent des symptômes de crise d'épilepsie, et les 14 autres signaux correspondent à une activité normale.

L'objectif de notre recherche est d'obtenir le pourcentage le plus élevé de classification qui nous aidera à distinguer avec une grande précision entre les classes crise et non-crise. Nous discuterons également de la façon dont l'information extraite à partir du signal ECG et incorporée dans les classifieurs pour faire une meilleure reconnaissance et distinction entre les deux classes.

Trois indicateurs statistiques sont utilisés pour évaluer la performance des différents systèmes de classification, le taux de classification correcte (CC), la sensibilité (Se) et la spécificité (Sp).

La sensibilité (Se) et la spécificité (Sp) sont calculées normalement par :

$$SE = \frac{VP}{VP + FN} \quad (III. 21)$$

$$SP = \frac{VN}{VN + FP} \quad (III. 22)$$

Et le taux de classification correcte est défini comme suit :

$$CC = \frac{VN + VP}{VP + VN + FN + FP} \quad (III. 23)$$

Où ;

*VP* : vraie positive est le nombre de crises d'épilepsie vraiment positives reconnues,

*VN* : vraie négative est le nombre de crises d'épilepsie vraiment négatives reconnues,

*FP* : fausse positive est le nombre de crises reconnues comme fausses positives,

*FN* : est le nombre de crises d'épilepsie détectées comme étant fausse négatives.

La matrice de classification ou la matrice de confusion est un outil standard très important pour l'évaluation du classifieur. Elle détermine si la valeur prédite correspond à la valeur réelle. Ensuite chaque catégorie sont comptés et les totaux sont affichés. Après consultation des montant de cette matrice, nous pouvons rapidement tirer d'une manière facile les trois indicateurs statistiques décrite (taux de classification, sensibilité et spécificité).

	Prédite	
Réelle	Négative	Positive
Test Négative	<b>VN</b>	<b>FN</b>
Test Positive	<b>FP</b>	<b>VP</b>

Tableau III.7 : Matrice de confusion.

### III.7. Résultats et interprétation

#### III.7.1. Résultats avec réseau de neurones artificiel

La performance des structures multicouche proposé (MLP) dans cette étude concerne la classification par l'utilisation des signaux EEG seul est présenté dans les tableaux III.8

	MLP				
	Taux de Classification	Sensibilité	Spécificité	Meilleure validation	Itérations
SC-MLP3	85.7(%)	61.9(%)	100(%)	8.5868 e-08	53
<b>CG-MLP3</b>	<b>87.5(%)</b>	<b>66.7(%)</b>	<b>97.10(%)</b>	<b>5.0095 e-11</b>	<b>30</b>
GD-MLP3	85.7(%)	61.9(%)	100(%)	1.4158 e-05	245
SC-MLP5	85.7(%)	66.7(%)	100(%)	1.1644 e-06	41
CG-MLP5	85.7(%)	61.9(%)	100(%)	4.7078 e-10	24
GD-MLP5	75.0(%)	33.3(%)	100(%)	0.031527	61
SC-MLP10	85.7	61.9	100	5.9179 e-08	49
CG-MLP10	85.7	66.9	97.1	1.3157 e-11	23
GD-MLP10	73.2	28.6	88.6	0.50149	1

Tableau III.8 : Performance des classificateurs avec structure MLP.

La tableau III.9 illustre la performance des classificateurs avec structure MLPE spécifique pour la classification basée sur la fusion des paramètres tirés à partir des deux activités électrophysiologiques.

	MLPE				
	Taux de Classification	Sensibilité	Spécificité	Meilleure validation	Itérations
SC-MLPE3	91.1(%)	76.2(%)	100(%)	2.1412e-07	45
<b>CG-MLPE3</b>	<b>98.2(%)</b>	<b>95.2(%)</b>	<b>100(%)</b>	<b>1.7096e-11</b>	<b>20</b>
GD-MLPE3	83.9(%)	81.0(%)	94.3(%)	0.1	6

SC-MLPE5	89.3(%)	71.4(%)	100(%)	9.8809e-06	38
CG-MLPE5	89.3(%)	71.4(%)	100(%)	1.2926e-11	26
GD-MLPE5	71.4(%)	23.8(%)	100(%)	1.4133e-02	35
SC-MLPE10	87.5(%)	76.7(%)	100(%)	1.1666e-03	20
CG-MLPE10	87.5(%)	71.4(%)	100(%)	4.427e-14	12
GD-MLPE10	76.8(%)	38.1(%)	97.1(%)	6.206e-02	64

Tableau III.9 : Performance des classificateurs avec structure MLPE.

Les résultats obtenus ont montré que lorsque nous avons utilisé les paramètres de l'EEG comme vecteur paramétrique, le classifieur de type CG-MLP3(3 couches cachées, gradient conjugué) produit de meilleure performance avec un taux de détection de crise de 87,5 % et avec une sensibilité et spécificité de 66.7% et 100 % respectivement. Tandis que lorsque le vecteur paramétrique combiné et assemblé à partir des deux signaux EEG et ECG, le classifieur nommé CG-MLPE3 (3 couches cachées, gradient conjugué) produit la meilleure performance de détection avec un taux de classification de 98,2% et avec une sensibilité et spécificité de 95.2% et 100% respectivement.

D'une manière générale et pour les deux structures MLP et MLPE on peut conclure que les structures avec 3 couches cachées fournissent toujours la meilleure performance par rapport aux autres nombres (5 et 10) figure (histogramme). En termes d'algorithmes d'apprentissages toujours les structures avec le gradient conjugué produit le taux de classification le plus élevé, suivit en deuxième par les structures avec la rétropropagation du gradient, et la descente de gradient en troisième place. Maintenant concernant le taux d'erreur et le nombre d'itérations, chaque fois le gradient conjugué offre une erreur très petite (d'ordre de  $10^{-11}$ ) qui ne dépasse pas les 30 itération par rapport aux autres. N'oublions pas de citer que le nombre d'itérations pour toutes les structures **MLPE** sont toujours inférieur à celles des structure **MLP**. Cela pourra se traduire en disant que le signal ECG a contribué bien évidemment à la détection de la crise en utilisant les réseaux de neurones artificiels (RNA).

Dans le tableau III.10 nous illustrons un exemple de la matrice de confusion spécifique pour les structures CG-MLPE3. A travers cette matrice on peut déduire directement les valeurs correspondants au taux de classification, la sensibilité et la spécificité qui sont de 98.2%, 95.2% et 100% respectivement.

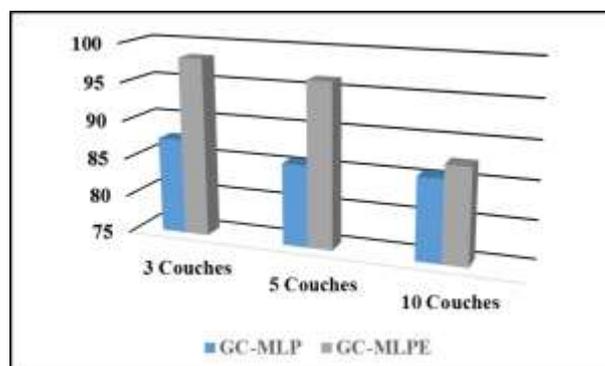
	Prédite	
Réelle	Négative	Positive
Test Négative	<b>20</b> <b>35.7%</b>	<b>0</b> <b>0%</b>
Test Positive	<b>1</b> <b>1.8%</b>	<b>35</b> <b>62.5</b>

Table III.10 : Matrice de confusion de la structure CG-MLPE3.

Le tableau III.11 nous montre la matrice de confusion attribué a la structure nommée CG-MLP3. Le même raisonnement s'applique pour cette structure. Après consultation du tableau on peut tirer directement les valeurs significatives de la classification qui sont le taux de classification (87.5%), la sensibilité (66.7%) et la spécificité (97.1%)

	Prédite	
Réelle	Négative	Positive
Test Négative	<b>14</b> <b>25.0%</b>	<b>1</b> <b>1.8%</b>
Test Positive	<b>7</b> <b>12.5%</b>	<b>34</b> <b>60.7%</b>

Table III.11 : Matrice de confusion de la structure CG-MLP3.



Figures III.11 : Histogramme de la classification pour le réseau de neurones artificiels (ANN).

Les paramètres de performance des réseaux de neurones MLP3 et MLPE3 pendant les phases d'apprentissages et de tests sont montrés sur la figure III.12. Pendant la phase d'apprentissage on peut voir qu'il y a toujours convergence rapide des structure MLPE par rapport aux autres structures nommées MLP en termes de nombre d'itérations. D'autre part la structure à gradient conjugué avec 3 couches cachées converge d'une manière aiguë au bout de 20 itérations vers le minimum plus petit ( $10^{-11}$ ) parmi tous les autres minimums.

Maintenant, en fixant le nombre de couches cachées à trois couches et en gardant le gradient conjugué comme algorithmme de minimisation d'erreur, il nous reste de modifier les fonctions d'activation pour les couches cachées ainsi que pour la couche de sortie. Nous obtiendrons ainsi plusieurs structures. Dans ce qui suit une comparaison a été fait entre 4 topologies pour chacune des structures du MLP et du MLPE.

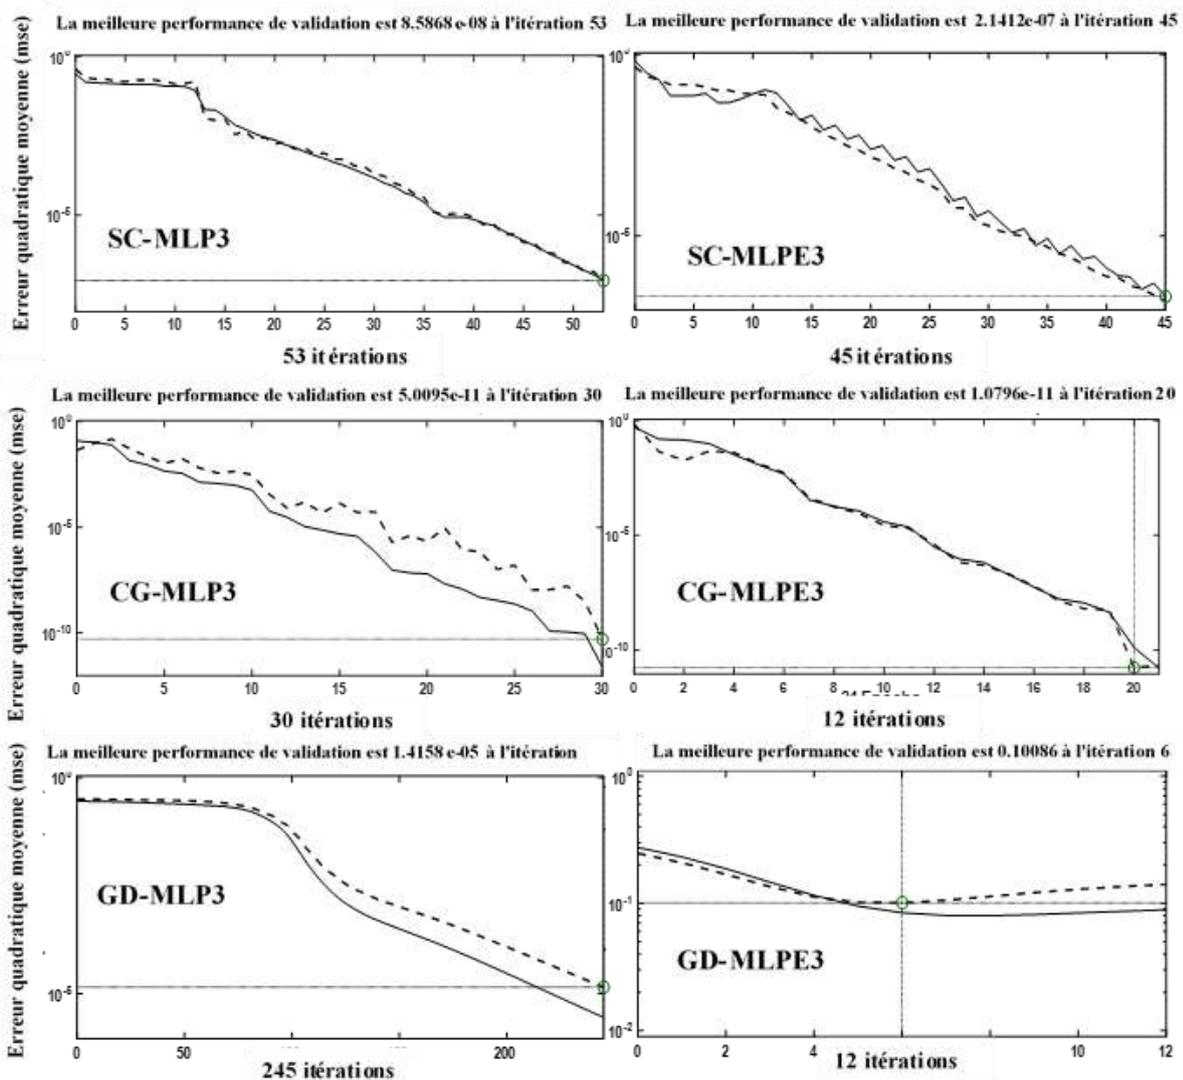


Figure III.12 : Performance des différentes topologies MLP3 et LMPE3 durant la phase d'apprentissage

Les tableaux III.12 et III.13 nous affichent les résultats de classification pour toutes les topologies sélectionnées. Suivant les résultats obtenus, le vecteurs paramétriques contenant les caractéristiques extraites depuis les deux signaux donne une meilleure performance de la classification par rapport à celle extraits uniquement depuis le signal EEG.

D'autre part la structure avec la fonction d'activation pour les couches cachées de type tangente hyperbolique, et la fonction exponentielle normalisé pour la couche de sortie fournit les meilleures performances de classification (89.37%, 98.2%) pour les deux structures MLP et MLPE respectivement. De plus le changement de ces fonctions d'activations a permis d'augmenter le taux de classification, la sensibilité et la spécificité.

	MLP				
	Taux de Classification	Sensibilité	Spécificité	Meilleure Validation	Itérations
<b>MLP3-TT</b>	82.10%	61.9%	94.3%	0.31496	19
<b>MLP3-LL</b>	83.90%	57.1%	100%	0.00935	16
<b>MLP3-TS</b>	<b>89.37%</b>	<b>71.4%</b>	<b>100%</b>	<b>6.1844e-11</b>	<b>21</b>
<b>MLP3-LS</b>	85.70%	66.7%	97.1%	3.2831e-12	31

Table III.12: Performances de classification des structure MLP avec différentes fonctions d'activation.

	MLPE				
	Taux de Classification	Sensibilité	Spécificité	Meilleure validation	Itérations
<b>MLPE3-TT</b>	91.10%	76.20%	100%	6.0306e-3	7
<b>MLPE3-LL</b>	94.60%	85.70%	100%	3.8163e-12	25
<b>MLPE3-TS</b>	<b>98.20%</b>	<b>95.20%</b>	<b>100%</b>	<b>1.7480e-11</b>	<b>28</b>
<b>MLPE3-LS</b>	89.30%	71.40%	100%	2.9185e-12	22

Table III.13: Performances de classification des structure MLP avec différentes fonctions d'activation.

La figure III.13 nous montre les performances de classification des topologies nommées MLP3-TS et MLPE3-TS durant les phases d'apprentissage et de validation, en montrant le taux d'erreur et le nombre d'itération approprié de chaque structure.

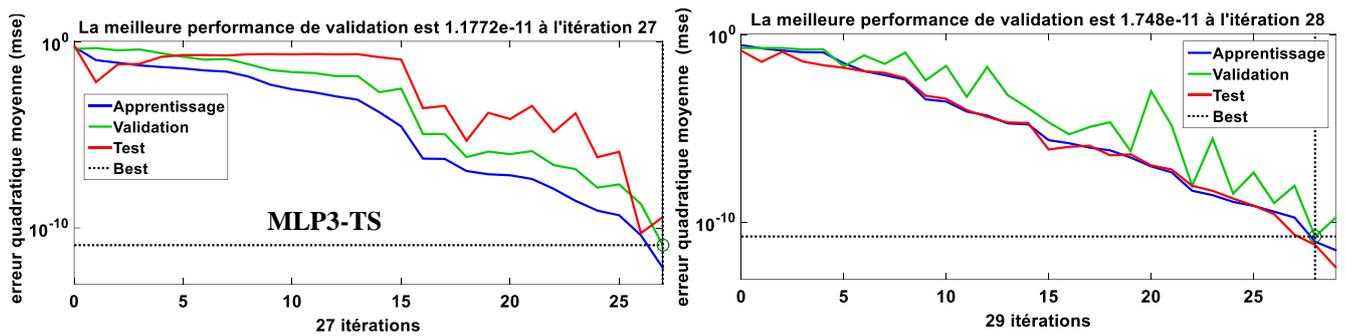


Figure III.13 : Apprentissage et validation des performances des structures MLP3 et MLPE3.

Nous pouvons également conclure que les paramètres extraits depuis le signal ECG combinées à celles extraits depuis le signal EEG peuvent améliorer considérablement la performance de détection des crises. Le nombre de couches cachées, la fonction d'optimisation et la fonction d'activation correspondant au réseau neuronal peuvent affecter les performances du classificateur.

### III.7.2. Résultats avec le classifieur KNN

Dans notre travail, un autre système basé sur l'algorithme K le plus proche voisin (KNN) a été utilisé pour la détection des crises. Il faut rappeler que l'algorithme KNN est appliqué aux mêmes vecteurs paramétriques qui sont décrits précédemment.

Le tableau III.14 décrit les résultats obtenus depuis la structure nommée KNN. Elle concerne les paramètres extraits à partir du signal EEG uniquement. Les résultats de la deuxième structure notée E-KNN sont illustrés par le tableau III.15 et spécifient la combinaison des deux signaux électrophysiologiques EEG et ECG.

Les performances des deux classifieurs KNN et KNN-E sont testés en utilisant différentes valeurs de K (3,6 et 7) d'une part et en utilisant différentes distances entre les échantillons d'autre part (distance euclidienne, cosinus et cityblock).

Pour le premier cas celle de KNN la meilleure performance est obtenue pour K=3 et avec la distance calculée de type cosinus. Elle est effectuée sur des données EEG avec un taux de classification qui vaut 89.28 %, et avec une sensibilité et spécificité de 71.43% et 100% respectivement.

Pour la deuxième structure nommée E-KNN une meilleure classification de 87,50 % est obtenue à travers la combinaison des deux signaux et cela pour un K=3 et une distance de type cosinus.

D'une manière générale on peut conclure que le nombre de voisins les plus proches peut affecter les résultats de classification. A coté de ce paramètre, le type de distance calculée peut aussi contribuer d'une façon considérable sur notre résultat.

On peut remarquer aussi que lors de l'utilisation de ce type de classifieur et contrairement aux réseaux de neurones artificiels, la détection des crises est meilleure lorsque nous nous basons uniquement sur les caractéristiques à partir des signaux EEG au lieu des deux signaux.

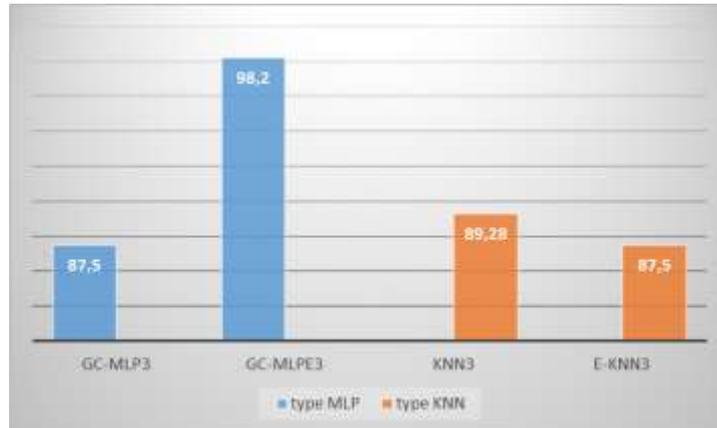
KNN					
Nomination	Le nombre De voisins	Type de Distance	Taux de Classification	Sensibilité	Spécificité
<b>KNN3</b>	<b>K=3</b>	Euclidienne	85.71%	61.90%	100%
		CityBlock	85.71%	61.90%	100%
		<b>Cosinus</b>	<b>89.28%</b>	<b>71.43%</b>	<b>100%</b>
<b>KNN5</b>	<b>K=5</b>	Euclidienne	83.92%	57.14%	100%
		CityBlock	83.92%	57.14%	100%
		Cosinus	85.71%	71.43%	94.29%
<b>KNN7</b>	<b>K=7</b>	Euclidienne	78.57%	42.86%	100%
		CityBlock	76.78%	38.10%	100%
		Cosinus	71.42%	71.43%	71.43%

Tableau III.14: Analyse des performances des classifieurs KNN (sans ECG).

E-KNN					
Nomination	Le nombre De voisins	Type de Distance	Taux de Classification	Sensibilité	Spécificité
<b>E-KNN3</b>	<b>K=3</b>	Euclidienne	82.14%	52.38%	100%
		CityBlock	85.71%	61.9%	100%
		<b>Cosinus</b>	<b>87.50%</b>	<b>71.43%</b>	<b>97.14%</b>
<b>E-KNN5</b>	<b>K=5</b>	Euclidienne	82.14%	52.38%	100%
		CityBlock	85.71%	61.9%	100%
		Cosinus	85.71%	71.43%	94.29%
<b>E-KNN7</b>	<b>K=7</b>	Euclidienne	71.42%	23.81%	100%
		CityBlock	75.00%	33.33%	100%
		Cosinus	82.14%	61.90%	94.29%

Tableau III.15: Analyse des performances des classifieurs E-KNN (avec ECG).

La figure III.14 nous montre une comparaison à base d'histogramme entre les structures à partir du réseau de neurones qui donnent les meilleures performances, et entre les structures depuis le classifieur KNN qui fournissent les meilleurs résultats (EKKN3 et KNN3). Il est clair que les réseaux de neurones produisent le taux de classification le plus haut comparant à celles du classifieur de type KNN.



Figures III.14 : Histogramme de la classification pour les classifieurs KNN et RNA.

### III.8. Conclusion

Dans ce chapitre nous avons présenté une étude comparative entre le classifieur à base de réseau de neurones artificielle nommée RNA et le classifieur K le plus proche voisins noté KNN pour la détection des crises d'épilepsie basée sur les signaux EEG et ECG. Les algorithmes proposés sont testés sur la base de données CHB-MIT Scalp EEG en consultation libre et gratuite chez Physionet. L'approche d'extraction des paramètres consiste en deux étapes : Extraction à partir du signal ECG seul et extraction depuis les deux signaux ECG et EEG. Les résultats obtenus montrent que la fonction d'optimisation du réseau de neurones de type ; rétropropagation à gradient conjugué avec trois couches cachées, et les fonctions d'activations de type tangente hyperbolique et exponentielle normalisée ont produit les meilleurs résultats de reconnaissance de crise en termes de performances décrites à la fois par la sensibilité (Se), la spécificité (Sp) et le taux de classification corrects (CC). Nous pouvons également constater que la combinaison des signaux ECG et EEG améliore considérablement les performances de détection des crises d'épilepsie. Enfin il est important que les paramètres extraits des signaux ECG et EEG doivent

également être bien choisis pour obtenir une meilleure classification. Pour cela nous envisageons de faire une autre étude approfondie qui sera présenté dans le chapitre suivant, et qui permettra enfin de compte d'améliorer encore plus la performance de notre process de reconnaissance de crise.

## **Chapitre IV : Etude d'un module de détection des crises d'épilepsie Basé sur les paramètres des signaux EEG et ECG**

### **IV.1. Introduction**

L'épilepsie est le troisième trouble neurologique chronique le plus courant qui touche des millions de personnes dans le monde. Elle prédispose les individus à avoir des crises récurrentes qui consistent en une perturbation soudaine de l'activité électrique normale du cerveau et qui entraînent des convulsions et des hallucinations. Cette activité correspond au champ électrique généré par les cellules pyramidales, et qui peut être considérée comme un dipôle électrique. La sommation de plusieurs dipôles peut créer un champ électrique important et qui peut être recueilli sur le scalp et donne finalement naissance du signal EEG (électroencéphalogramme), qui peut être immédiatement interprété. À côté des données statiques de la neuroradiologie, il apporte des données dynamiques permettant d'apprécier le fonctionnement cérébral sur des durées allant jusqu'à plusieurs jours. Différentes techniques d'enregistrement peuvent être proposées : l'EEG standard avec ou sans sommeil, l'EEG avec polygraphie, l'EEG vidéo de durée variable, l'Holter EEG. Malgré le développement des techniques d'imagerie neurologiques, l'EEG reste le premier examen le plus utile pour la prise en charge des crises épileptiques chez les patients. De plus le patient doit bénéficier d'un monitoring EEG afin d'assurer l'efficacité du traitement et la disparition des anomalies (Kaminska, et al, 2006).

Récemment, un plus grand nombre de méthodes automatisées de détection et de classification des crises d'épilepsie ont été trouvées. Ces méthodes reposent essentiellement sur l'analyse des signaux EEG. Il a souvent été démontré que les crises sont associées à des altérations qui peuvent apparaître dans d'autres signaux biomédicaux, notamment l'activité cardiaque (ECG) (pour plus de détails voir le chapitre 3).

Nous consacrons ce chapitre pour l'évaluation des effets des crises d'épilepsies sur les deux signaux électrophysiologiques EEG et ECG, bien que nous ayons présentés une étude dans ce contexte à travers le chapitre précédent, mais seulement suivant des paramètres statistiques temporelles, la particularité de cette étude est de perfectionner mieux encore le système de détection des crises automatisé, en faisant appel à des outils mathématiques de traitement de signal qui peut enrichir les connaissances sur ces effets. L'utilisation de ces outils peut être considéré comme un complément synchrone très important avec ce qui a été présenté

auparavant. Nous allons voir qu'à travers cette étude on peut déduire l'influence pertinente des crises sur les discriminateurs fréquentiels.

Pour cela, nous adoptons une approche pour la détection des crises d'épilepsie basée sur les signaux EEG et ECG enregistré simultanément au Children's Hospital de Boston chez un sujet présentant des crises intractables. Notre méthode utilise une décomposition en ondelettes pour construire un vecteur de paramètres. Ces paramètres ont été extraites de chaque niveau de décomposition et sont issues des deux domaines ; domaine temporel et domaine fréquentiel.

Le but du travail est de déterminer si l'enregistrement représente un cas épileptique ou non épileptique en utilisant deux différents classifieurs ; réseau de neurones artificiel (RMA) et la Forêt aléatoire (Random Forest RF).

A la fin de ce chapitre, une comparaison entre les résultats obtenus par notre approche et celle présentée par Iosif, M, et al (2015) sera faite qui montrera des résultats obtenus très prometteurs de notre méthode.

## **IV.2. Transformée en ondelette**

L'objet de cette partie est de présenter la transformation en ondelettes que nous allons utiliser dans la suite de ce travail. Les ondelettes ont été introduites pour combler une lacune entre deux modes extrêmes de représentation du signal ; la représentation d'une fonction par son graphe classique et la représentation dans la base de Fourier. La première représentation concerne toutes les informations dans le domaine temporel, en revanche l'information dans le domaine fréquentiel est absente ou nulle. A l'inverse, la deuxième représentation fournit une information précise en fréquence, mais ne donne aucune information temporelle. Pour cela il existe une autre représentation dans laquelle on puisse lire une information mixte pour les deux domaines à la fois, c'est à dire à l'aide de cette représentation on serait capable de trouver une bonne localisation temporelle et fréquentielle au même instant. On parle alors de la fréquence instantanée. Morlet et Gabor ont cherché à concevoir des fonctions de base qui se situent à mi-chemin entre ces extrêmes. Il s'agit bien de l'analyse par ondelettes, cette analyse est réalisée au moyen d'une fonction d'analyse  $\psi$  appelée ondelette de base.

Durant l'analyse, cette ondelette est positionnée dans le domaine temporel pour sélectionner la partie du signal à traiter. Puis, elle est dilatée ou contractée par l'utilisation d'un facteur d'échelle permettant de concentrer l'analyse sur une gamme donnée d'oscillations. Quand l'ondelette est dilatée, l'analyse regarde les composants du signal qui oscillent lentement ; quand elle est contractée, l'analyse observe les oscillations rapides comme celle contenues dans une

discontinuité du signal. Par ce traitement d'échelle (contraction - dilatation d'une ondelette), la transformée en ondelettes amène à une décomposition temporelle du signal (Dumas,2001).

L'analyse des ondelettes a commencé avec les travaux d' A. Grossmann et J. Morlet au début des années 80. J. Morlet, travaillant pour une compagnie pétrolière française, a mis au point une méthode d'analyse des signaux sismiques transitoires basée sur une analogie avec la transformée de Fourier en fenêtrage (analyse Gabor). Il a remplacé la fonction de la fenêtre par une fonction  $\psi$ , bien localisée dans le temps et la fréquence (par exemple un gaussien), et a remplacé la translation en fréquence par la mise à l'échelle (Arne et al,2001). La transformation est alors définie comme suit

$$CWT(f, a, b) = \int_{-\infty}^{+\infty} f(t) a^{-\frac{1}{2}} \bar{\psi}(a^{-1}(t - b)) dt \quad (IV.1)$$

Dans cette expression,  $a$  est le facteur d'échelle et  $b$  le paramètre de translation. La variable  $a$  joue le rôle de l'inverse de la fréquence, plus  $a$  est petit moins l'ondelette (la fonction analysante) est étendue temporellement, et plus la fréquence centrale de son spectre est élevée (Truchetet,1998). On peut également interpréter cette expression comme une projection du signal sur une famille de fonctions analysantes  $\psi_{a,b}$  construite à partir d'une fonction "mère"  $\psi$  conformément à l'équation suivante :

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (IV.2)$$

On peut calculer la résolution spatio-temporelle en prenant la largeur temporelle de  $\psi$  comme unité. Comme on peut de même calculer l'occupation fréquentielle de l'ondelette en calculant l'écart type pour la transformer de Fourier de  $\psi_{a,0}$ .

On trouve que la résolution fréquentielle est égale à  $\frac{1}{a}$ , de sorte que le pavé élémentaire dans l'espace temps-fréquence est de surface constante tandis que la résolution temporelle est proportionnelle à  $a$ , et que la résolution fréquentielle est inversement proportionnelle à  $a$  comme on le voit sur la figureIV.1.

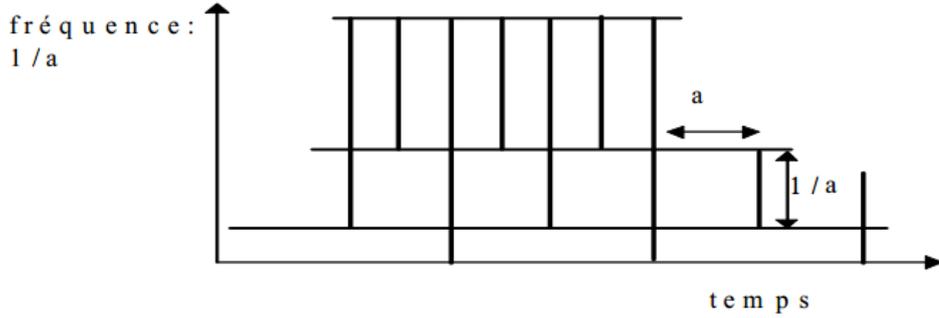


Figure IV.1 Pavage temps-fréquence pour la transformée en ondelette discrète.

### IV.2.1. Transformée en ondelette continue

Les transformées en ondelette continues sont obtenues en prenant le facteur d'échelle  $a$  et le pas de translation  $b$  dans l'ensemble des nombres réels. Ces transformées sont évidemment très redondantes car l'espace-temps-fréquence est parcouru continûment. Ce type de transformation ne peut, dans la pratique, être effectué que de façon approximative et il y a toujours en fait une discrétisation du calcul qui est opérée. La transformée (continue) en ondelettes est ainsi défini par :

$$Wf(t, f, \psi) = \int x(u) \left(\frac{f}{f_0}\right)^{\frac{1}{2}} \psi^* \left(\frac{f}{f_0}(u - t)\right) du \quad (IV.3)$$

### IV.2.2. Transformée en ondelette discrète

La transformée en ondelettes discrète consiste à caractériser une fonction de carré intégrable par ses produits scalaires avec une famille dénombrable de fonctions de carré intégrable : les ondelettes. De plus, les ondelettes sont d'intégrale nulle et se déduisent toutes par dilatation et translation d'une fonction appelée ondelette-mère.

$$\psi^{m,n} : x \mapsto \frac{1}{\sqrt{2^m}} \psi\left(\frac{x-2^m n}{2^m}\right) \quad (IV.4)$$

Il est intéressant de considérer des familles orthogonales d'ondelettes formant une base hilbertienne de  $L^2(\mathbb{R})$  car toute fonction  $f$  de carré intégrable s'écrit :

$$f = \sum f_{m,n} \psi^{m,n} \quad (IV.5)$$

Où

$$f_{m,n} = \langle f, \psi^{m,n} \rangle \quad (IV.6)$$

Avec  $f_{m,n}$  sont appelés coefficients d'ondelettes associés à  $f$ .

### IV.3. Caractérisation de la crise d'épilepsie

Dans cette partie et afin de mieux quantifier l'influence de la crise d'épilepsie sur les deux activités (cérébrale et cardiaque) sur le plan fréquentiel, nous proposons d'approfondir la discrimination de la crise à travers l'utilisation des outils mathématiques du traitement de signal. Ces derniers sont utilisés dans plusieurs domaines, notamment l'analyse des signaux électrophysiologiques. Ils nous permettent de déterminer l'existence de n'importe quelle différence entre les deux phases (crise ou sans crise). Pour cela deux segments pour chaque activité ont été choisis pour évaluer le test, de telle sorte que pour chaque activité, un segment a été obtenu depuis la phase d'activité normale, tandis que le deuxième représente une activité tirée durant la phase épileptique.

#### IV.3.1. Décomposition de l'ondelette continue

Nous avons déjà introduit cette décomposition dans le chapitre deux. Cette décomposition concerne l'analyse temps échelles. La figure IV.2 nous montre le résultat de cette analyse appliqué pour les segments concernant la base Physionet décrits auparavant. Rappelons que nous avons utilisés l'ondelette de type Bio-orthogonal (noté Bior3.5) avec une échelle de 128.

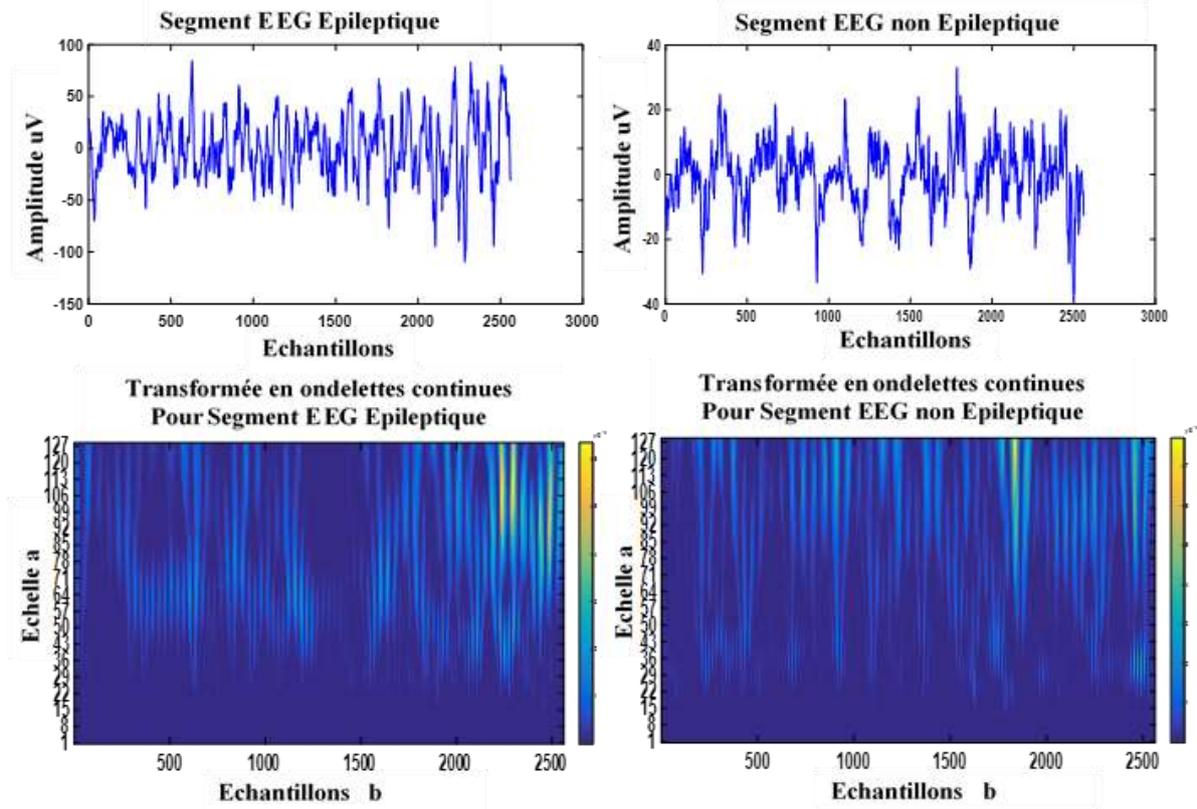


Figure IV.2 : Transformée en ondelettes continues pour deux segments EEG.

Nous pouvons voir sur la figure IV.2 une différence entre les deux phases, elle se traduit par la présence d'une forte activité à l'échelle 120 dans le cas de crise par rapport à celle sans crise.

La figure IV.3 illustre la transformée en ondelette continue pour deux segments ECG en utilisant aussi l'ondelette bio-orthogonal et avec une échelle de 127.

De même pour l'activité cardiaque, nous pouvons également remarquer que le changement brusque entre les deux cas. Pour le cas non épileptique la forte activité réside dans l'échelle 15, cependant, durant la crise cette forte activité c'est déplacée vers l'échelle 92 avec une puissance encore forte.

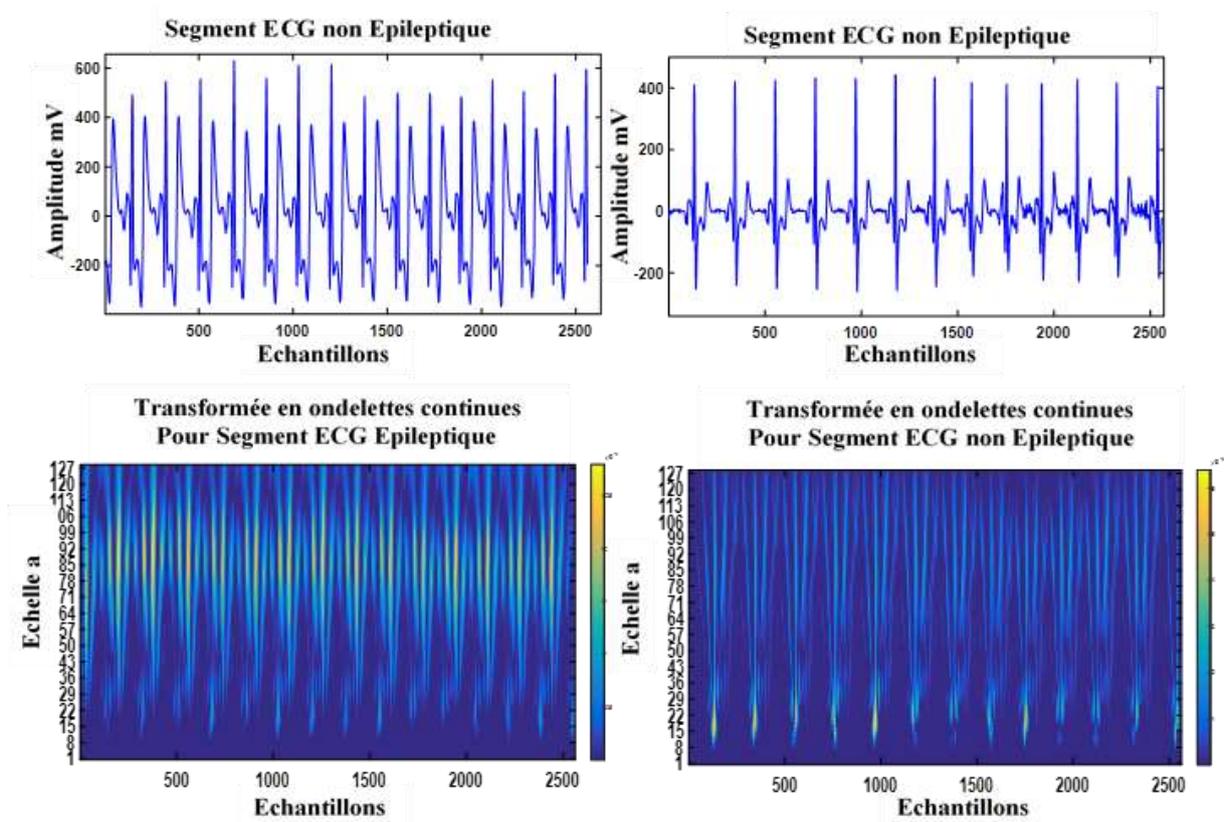


Figure IV.3 : Transformée en ondelettes continues pour deux segments ECG.

### IV.3.2. Densité spectrale de puissance

Dans ce paragraphe nous allons nous intéresser au calcul de la densité spectral de puissance (DSP) pour les mêmes enregistrements. Commençons par le signal EEG, la DSP obtenu pour chaque portion est illustrée sur la figure IV.4. Nous constatons l'apparition de plusieurs raies avec une forte puissance du segment épileptique par rapport au segment non épileptique.

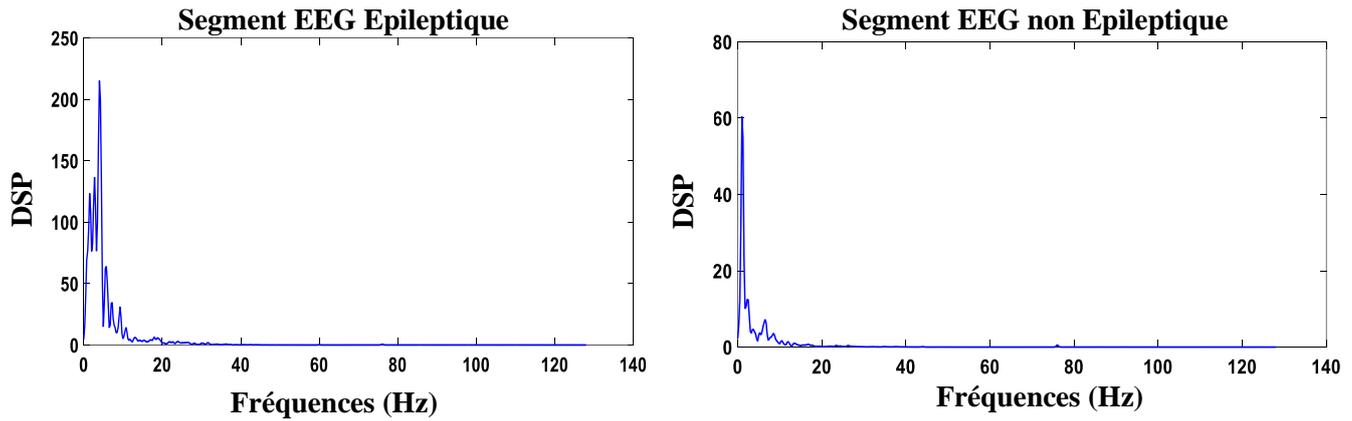


Figure IV.4 : Densité spectrale de puissance pour les deux segment EEG.

La figure IV.5 concerne la densité spectrale de puissance (DSP) calculé pour le signal ECG. D'après les tracés obtenus, il est clair et facile de différencier entre les deux phases, l'allure de la DSP pour le signal ECG épileptique possède une morphologie différente avec une puissance très élevée par rapport au segment non épileptique.

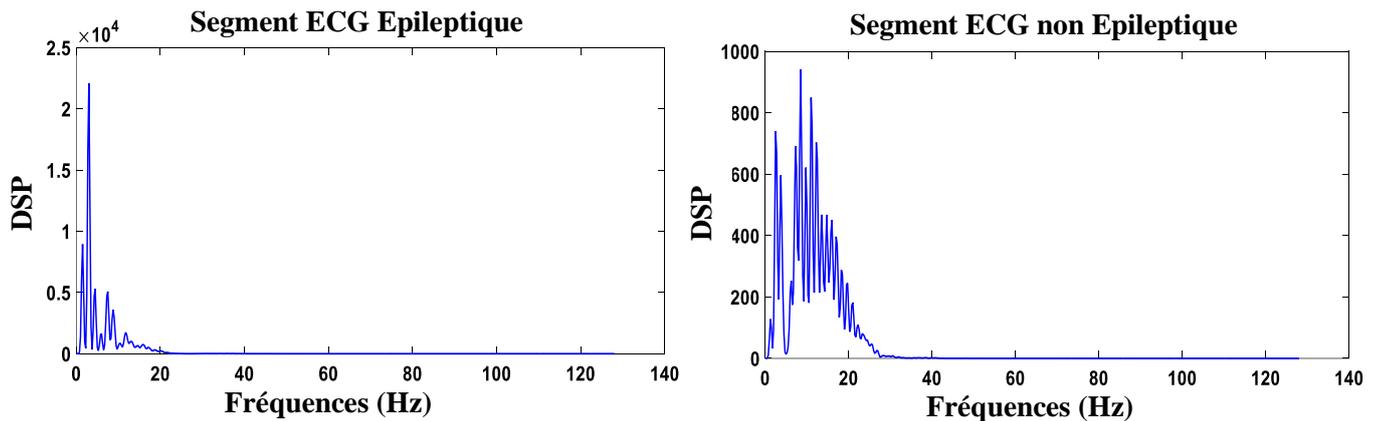


Figure IV.4 : Densité spectrale de puissance pour les deux segment ECG.

### IV.3.3. Transformé de Fourier à court terme

Cette partie concerne l'analyse temps-fréquence par la transformé de Fourier à court terme (TFCT), notons qu'avant de calculé cette transformé, un ensemble de paramètres devrait être pris en considération afin de tracer une courbe représentative avec une bonne résolution, nous citons la taille de la fenêtre, le type de la fenêtre, le nombre de points d'échantillonnage pour calculer la transformée de Fourier discrète, le nombre d'échantillons de chevauchement entre des sections adjacentes et enfin la fréquence d'échantillonnage. Pour cette étude ces paramètres sont fixés comme suit :

- Fenêtre de type Hamming.
- Taille de 2048 points.
- Nombre de point pour le chevauchement égal à 1024.
- Nombre de points pour la transformé de Fourier discrète égal à 1024.
- Fréquence d'échantillonnage de 256 Hz.

La figure IV.5 représente le tracer de la TFCT du signal EEG. Sur la figure la notion de la fréquence instantanée est évidente, ou on peut savoir la présence ou l'absence d'une raie bien déterminer par un gradient de couleur qui varie du jaune pour les raies fortement présentent au bleu clair pour les raies qui n'existe pas ou sont faiblement présent dans le signal. La même remarque peut être tirer depuis la figure présence d'une forte activité de la portion épileptique par rapport a l'autre portion.

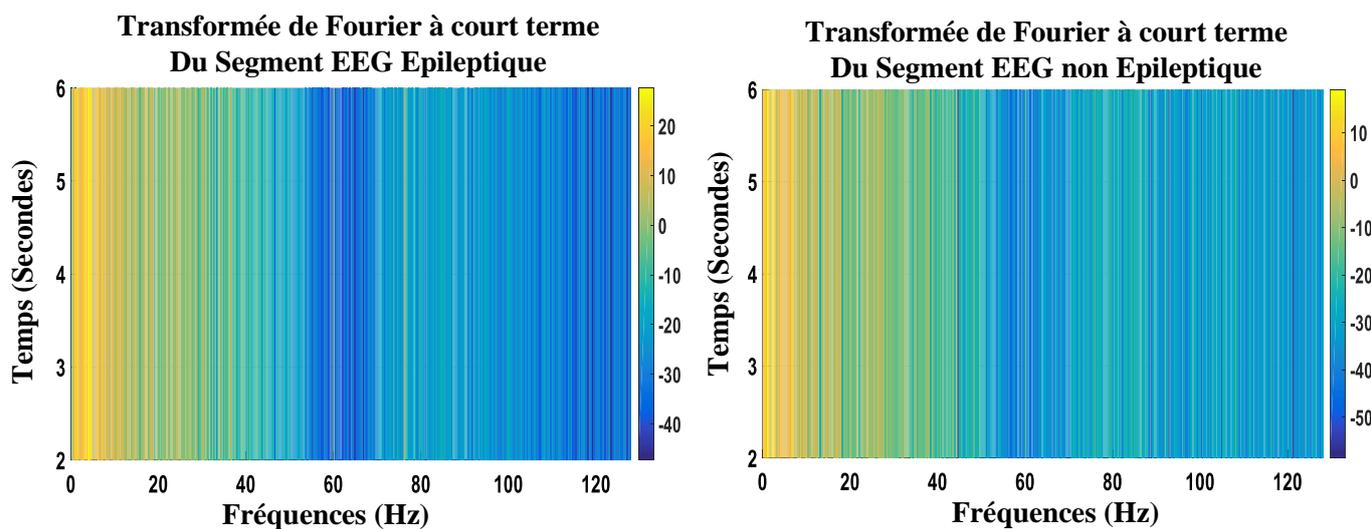


Figure IV.5 : transformées de Fourier à court terme pour les deux Segments EEG non épileptiques.

Le même raisonnement s'applique pour le signal ECG, sur la figure IV.6. La différence entre les deux est remarquable, seulement un ensemble de raies avec une forte puissance durant la phase normale sont disparue lors la présence de la crise.

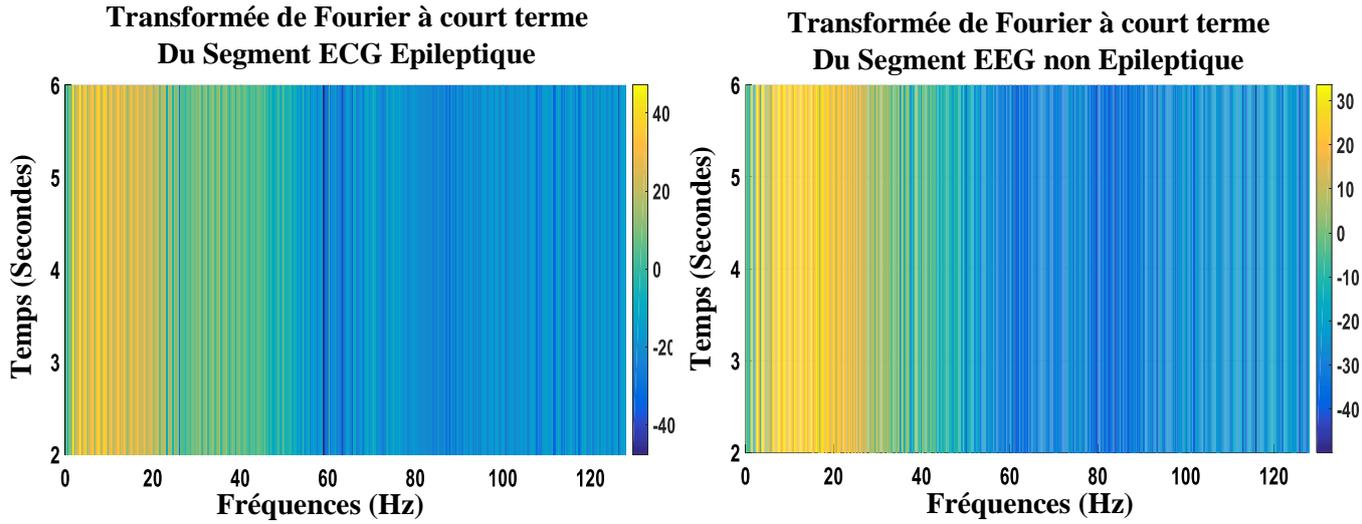


Figure IV.6 : transformées de Fourier à court terme pour les deux Segments ECG non épileptique.

#### IV.3.4. Entropie

L'entropie est une mesure du taux de génération de l'information, où une valeur élevée correspond à une irrégularité élevée tandis qu'une valeur faible traduit une régularité élevée. De nombreux types d'entropie existe dans la littérature, comme l'entropie de l'échantillon, l'entropie de Tssalis et l'entropie de Shannon. Dans cette étude, l'entropie de l'échantillon a été calculée, et correspond à la mesure de la corrélation temporelle d'une série temporelle. L'entropie de l'échantillon est le logarithme naturel négatif d'une estimation de la probabilité conditionnelle que les sous-séries (époques) de longueur  $m$  correspondent en des points dans une tolérance  $r$  qui correspondent également au point suivant (Mathew,2006).

On pourrait l'écrire comme suit :

$$\text{Entrop} = -(N - m)^{-1} \ln \left[ \sum_{i=1}^{N-m} \frac{A_i^m(r)}{B_i^m(r)} \right] \quad (\text{IV. 7})$$

Avec :

$A_i^m(r)$ : Nombre de fois  $x_{m+1}(i)$  dans un rayon de  $r$  de  $x_{m+1}(j) \times (N - m)^{-1}$

$B_i^m(r)$  : Nombre de fois  $x_m(i)$  dans un rayon  $r$  de  $x_m(j) \times x_{m+1}(j) \times (N - m + 1)^{-1}$

$r$ : La tolérance.

$N$ : La longueur de la série d'entrée

Maintenant les deux portions précédentes ont subits un calcul de l'entropie, sachant que chaque portion contient 24 canaux, ce qui nous produit un vecteur de 24 valeurs correspond à l'entropie de chaque canal. La figure IV.7 nous montre le tracer des valeurs d'entropie obtenus pour les mêmes portions. Trois remarques importantes peuvent être tiré depuis le tracer ;

- L'entropie ou la quantité d'information fournit par le segment durant la crise est supérieur par rapport au cas d'activité normale.
- Le signal ECG toujours produit une entropie supérieure par rapport au signal EEG, ce qui signifie que l'ECG peut apporter une information précieuse pour la détection de la crise.
- Dans le cas de crise la monotonie de variation de cette entropie, il suit toujours la variation de l'autre cas et cela pratiquement sur tous les canaux.

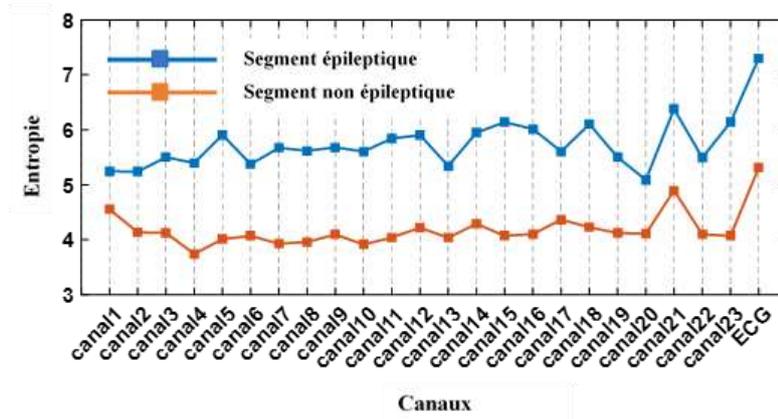


Figure IV.7 : entropie calculée pour les deux segments à travers tous les canaux.

#### IV.3.4. Cohérence quadratique

Cette notion de cohérence a été déjà introduite dans le chapitre 2, rappelons qu'elle traduit le taux de similarité de deux signaux à une fréquence donnée, elle s'exprime par une forte cohérence lorsque le taux est égal à 1. Cependant l'absence de relation entre les deux signaux est explicite et est égal à zéro. Comme nous avons montré dans le chapitre 2, le calcul de la cohérence permet de tracer une courbe montrant le taux de la cohérence partant de la fréquence de 1Hz jusqu'à  $f_s/2$ . Afin de mieux distinguer la différence entre les deux phases, nous prévoyons de faciliter la représentation en utilisant la moyenne de la cohérence obtenue entre chaque canal EEG et le canal du signal ECG. Nous obtenons alors 23 valeurs pour chaque segment, dont l'ensemble des résultats est donné sur la figure IV.8. Cependant, deux canaux ; le canal 7 et 17 possèdent une moyenne supérieure durant le cas d'une épilepsie par rapport à

l'autre cas. Concernant les autres canaux, la cohérence est toujours significative lorsqu'il s'agit d'une activité normale.

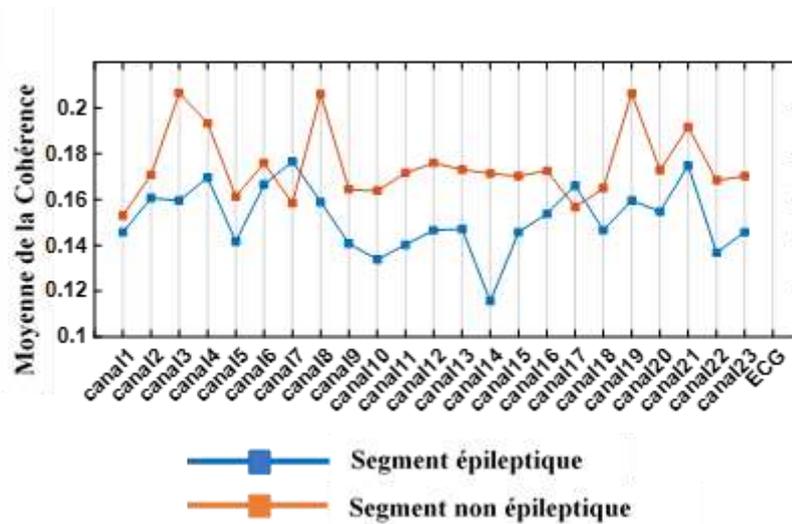


Figure IV.8 : Moyenne de la cohérence quadratique calculée pour les deux segments à travers tous les canaux.

#### IV.4. Description de la méthode proposée

Le schéma bloc de la Figure IV.9 illustre l'architecture de notre module de détection des crises.

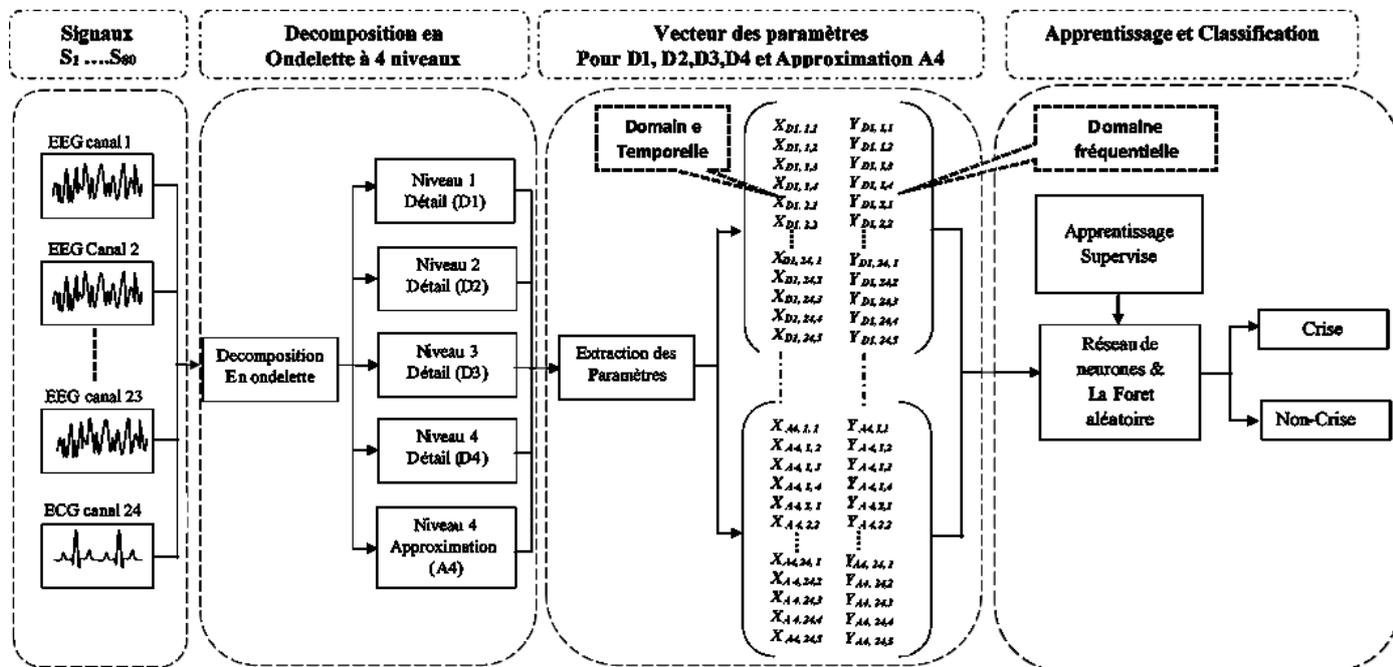


Figure IV.9 : Schéma bloc du processus de détection des crises.

L'algorithme automatisé adopté dans cette étude a été implémenté sous Matlab. Il se compose de 4 étapes essentielles :

Dans la première étape, les enregistrements simultanés de l'EEG et de l'ECG capturés à partir de 24 canaux sont segmentés à des périodes de 10 secondes (où 23 sont les signaux EEG et un signal est le signal ECG). La deuxième étape est accomplie en utilisant une transformée en ondelettes discrètes à quatre niveaux. La troisième étape consiste à l'extraction des paramètres de chaque canal. Nous avons noté que ces paramètres sont dérivées à la fois à partir du domaine temporel et fréquentiel. Ce processus forme une séquence de cinq vecteurs de caractéristiques différents, chaque vecteur caractérise un niveau de la transformation en ondelettes (détail 1, 2, 3, 4 et l'approximation), enfin chaque vecteur assemblé est passé au classifieur. Les vecteurs sont utilisés comme données d'entrée dans un modèle de classification binaire avec deux classes nommées ; crise ou non crise. Ensuite, nous examinons la capacité discriminatoire de notre approche proposée pour détecter les événements des crises en fonction de la capacité de la classification binaire. De plus, nous pouvons également déduire quel est le coefficient (détails et approximation) le plus affecté par les effets de la crise d'épilepsie parmi les coefficients obtenus par la décomposition en ondelettes.

Notons que nous avons adopté dans cette étude deux classifieurs différents ; le premier est le réseau neurones artificiel (RNA) et le second est la forêt aléatoire (RF). Chaque classifieur a été entraîné sur un ensemble de données indépendantes. Ces derniers représentent des exemples d'événements qui concerne les signaux EEG et ECG avec une classe connue (annotés manuellement par des experts médicaux), avec ou sans crise.

Le test a été évalué sur 80 segments sélectionnés, chaque segment contenant 10 secondes. 30 segments parmi eux contiennent l'événement convulsif et les 50 autres segments sont considérés comme une activité normale.

Dans ce qui suit, nous allons examiner en détail toutes les étapes qui permettent d'effectuer le processus de détection automatisée des crises avec une grande précision.

#### **IV.4.1. Décomposition en ondelette discrète**

Notre méthode utilise une décomposition en ondelettes discrète pour construire un vecteur caractéristique qui capture la morphologie du signal EEG et ECG, et qui fournit une analyse temps-fréquence commune des données. La décomposition est faite en se basant sur le type et l'ordre des ondelettes utilisées dans le calcul de nos coefficients, les segments sont décomposés

en 4 niveaux en utilisant l'ondelette Biorthogonal (nommée Bior3.5 sur Matlab). Pour obtenir 4 détails et une approximation pour chacun des 24 canaux.

Rappelons que la décomposition en ondelettes discrètes extrait les signaux de sous-bande contenant une activité à différentes échelles de temps en faisant passer le signal EEG et ECG à travers une structure de filtrages itératifs comme celui illustré sur la Figure IV.10

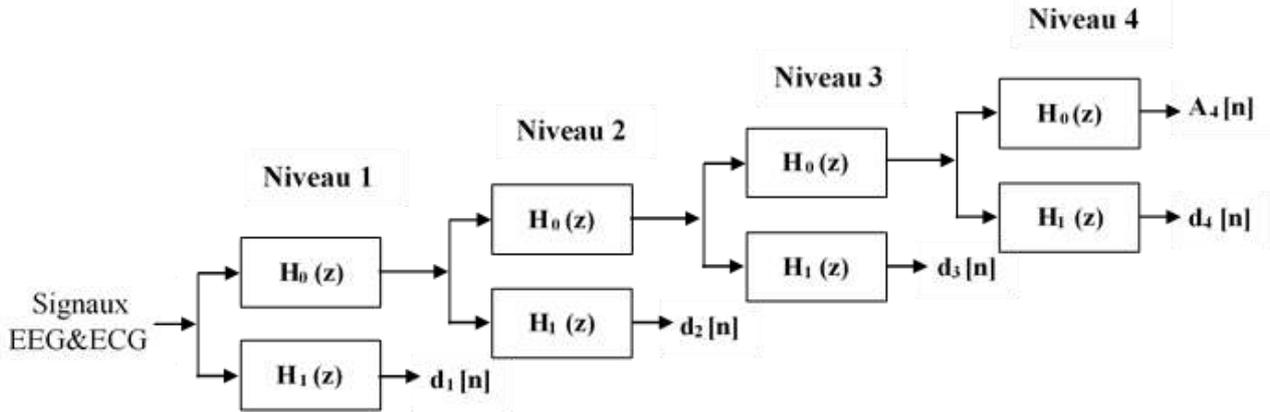


Figure IV.10 : Décomposition en ondelettes discrète à 4 niveaux.

La décomposition en ondelettes utilise une paire de filtres  $H_0$  et  $H_1$  pour décomposer de façon itérative la série temporelle originale. Après chaque itération il en résulte une hiérarchie de la nouvelles séries temporelles.

Le filtre noté  $H_0$  présente un filtre passe-bas, qui produit les signaux des sous-bandes par des itérations inférieures qui capturent l'activité à un échelle de temps plus courts, tandis que le filtre nommé  $H_1$  est le filtre passe-haut, qui produit les signaux des sous-bandes par les itérations supérieures qui capturent l'activité à longue échelle. Ce processus donne un ensemble sous-échantillonné de coefficients d'approximation et de détails, illustrés par les équations suivantes :

$$y_{Bas}[n] = \sum_{k=-\infty}^{+\infty} x[k]H_0[2n - k] \quad (IV.8)$$

$$y_{Haut}[n] = \sum_{k=-\infty}^{+\infty} x[k]H_1[2n + 1 - k] \quad (IV.9)$$

Où  $x[k]$ : est le signal original.

$y_{Bas}[n]$  et  $y_{Haut}$  sont respectivement l'approximation des signaux résultants et les coefficients de détail.

Sur la figure IV.11, nous illustrons un exemple de coefficients des détails et d'approximation obtenus par le processus de décomposition en ondelettes discrète à quatre niveaux appliqués à deux segments EEG, le premier segment est extrait depuis la phase de crise, tandis que le second considéré un segment d'EEG relative à une activité normale sans aucun évènement de crise. On

note que nous avons sélectionné à titre d'exemple le canal 17 pour effectuer cette étape, il s'agit des électrodes positionnées à l'emplacement nommé **FZ – CZ**.

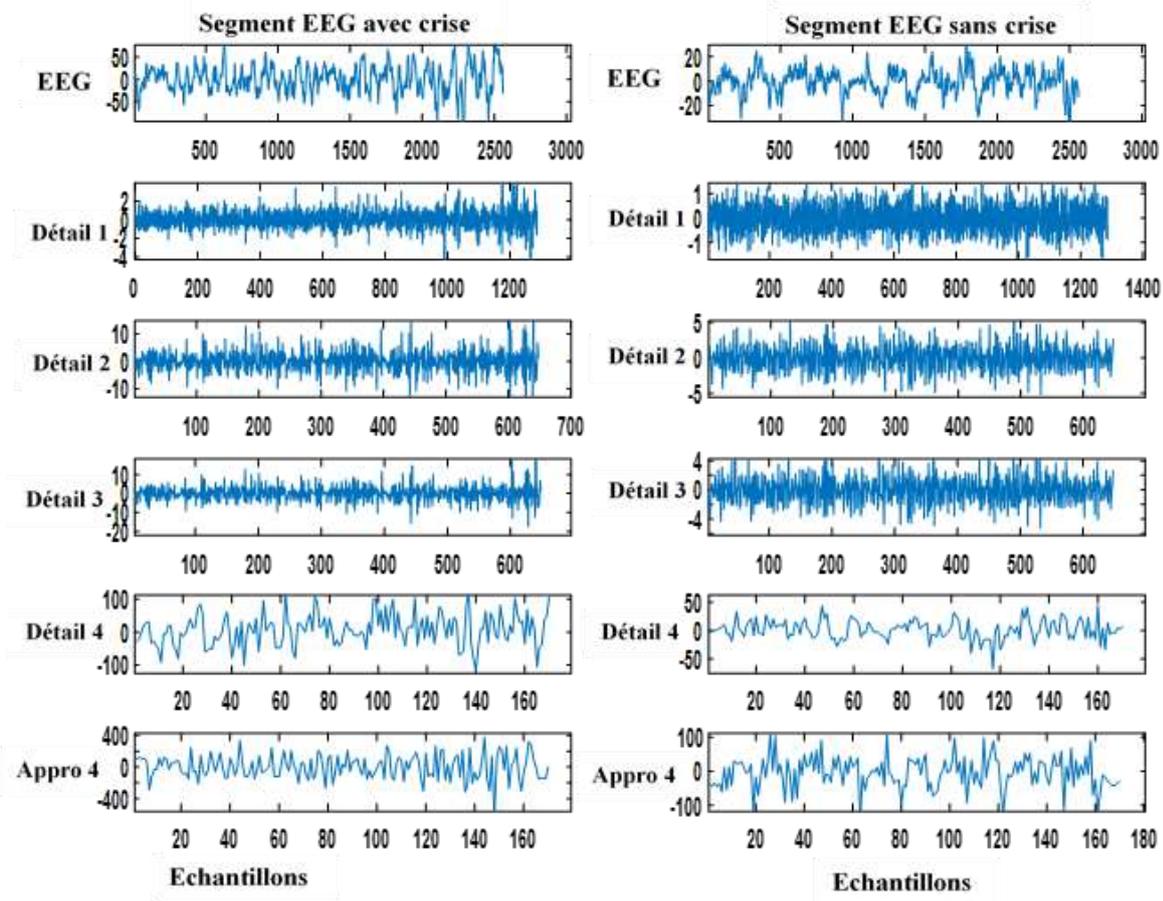


Figure IV.11 : Exemple de décomposition en ondelette discrète à 4 niveaux.

Dans cette figure on peut analyser le résultat de la décomposition de la manière suivante :

- **Sur le plan temporel** : un changement significatif de la morphologie du signal EEG entre les deux phases (sans et avec crise). Ce changement est accompagné d'une augmentation de l'amplitude lors de l'apparition de la crise, et cela concerne toutes les coefficients de la décomposition sans exception.
- **Sur le plan fréquentiel** : L'apparition d'une activité rythmique rapide lors de la présence de la crise par rapport aux portions du signal sans événement de crise d'épilepsie, ce qui traduit une augmentation de la fréquence pour les composantes constituant le signal.

Maintenant nous appliquons la décomposition en ondelettes discrète pour le signal ECG, de même et comme le premier signal deux segment du signal ECG ont subis à la décomposition sans et avec crise, le résultat de la décomposition est affiché sur la figure IV.12.

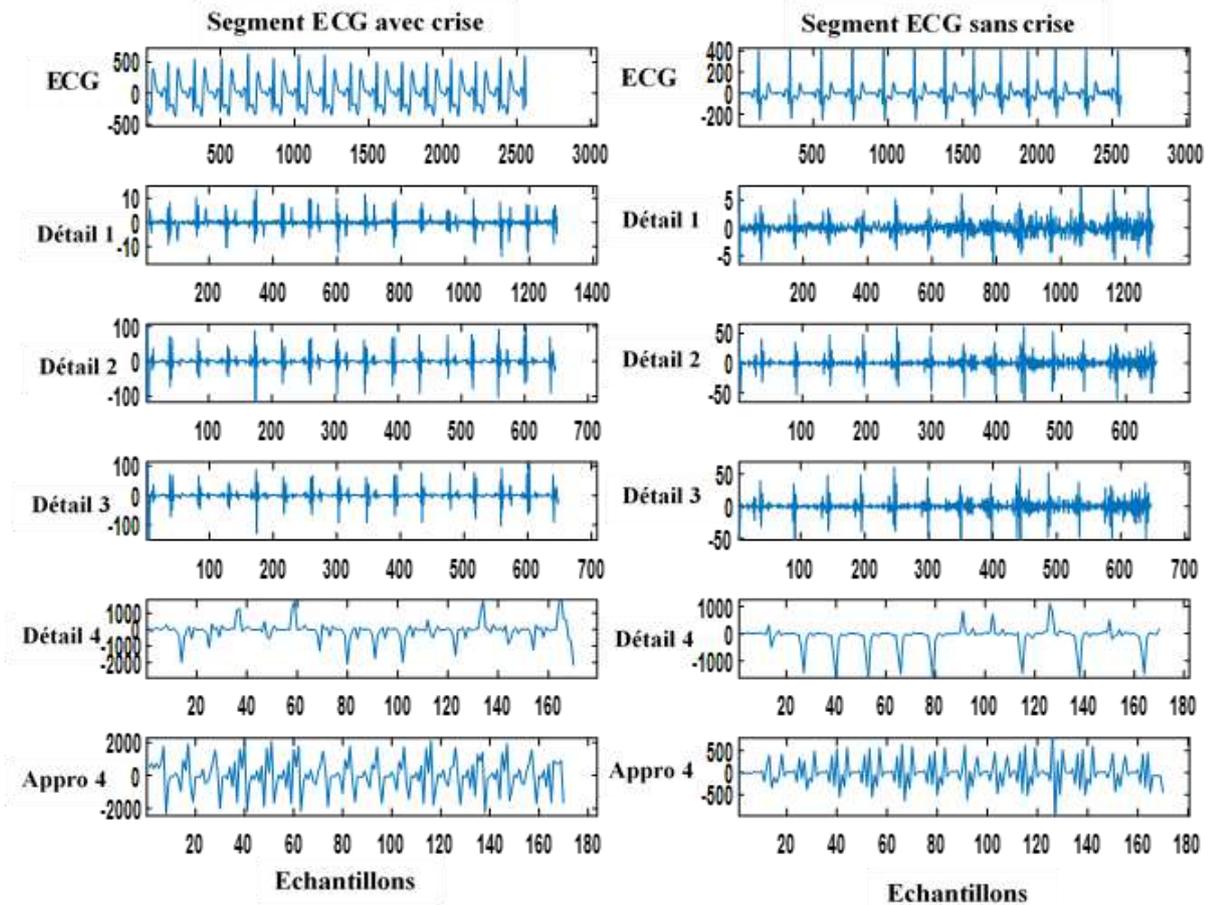


Figure IV.12 : Exemple de décomposition en ondelette discrète à 4 niveaux.

A partir de la figure IV.12, nous pouvons également constater une différence de morphologie entre les deux segments pour les deux domaines (temporelle et fréquentielle). Nous pouvons ainsi conclure que le rythme cardiaque est affecté aussi par la crise, où nous avons un rythme d'environ 78 battements par minute relative à une activité normale (sans crise), face à un rythme de 90 battements par minute pour un segment avec crise.

#### IV.4.2. Extraction des paramètres

Comme nous avons vu dans le chapitre précédent, chaque processus de classification doit être précédé par une étape de caractérisation. Cette dernière consiste à l'extraction de l'ensemble des caractéristiques pertinentes permettant la discrimination entre deux classes distinctes. Pour cela nous proposons dans ce chapitre d'élargir le vecteur caractéristique utilisé auparavant dans le chapitre précédent en introduisant d'autres paramètres y compris celle extraient depuis le

domaine fréquentiel, sachant que l'étude précédente a été effectuée pratiquement sur le plan temporel uniquement.

Chaque segment a été paramétré à l'aide de la procédure suivante :

- **Domaine temporel** : valeur minimale, valeur maximale, énergie, écart-type, entropie et rythme cardiaque.
- **Domaine fréquentiel** : la cohérence et la densité spectrale de puissance.

Cette séquence produit le vecteur caractéristique utilisé pour la classification. Ce vecteur contient 14 paramètres qui sont présentés dans le tableau IV.1 ci-dessous.

Désignation	Description	Vecteur assigné
$EEG_{max_{10}, i}$	Valeur maximale sur une période de 10 secondes du signal EEG pour le canal $i$	$X_1$
$EEG_{min_{10}, i}$	Valeur minimale sur une période de 10 secondes du signal EEG pour le canal $i$	$X_2$
$E_{EEG_{10}, i}$	Energie du signal EEG (canal $i$ avec une durée de 10 Secondes)	$X_3$
$\sigma_{EEG_{10}, i}$	Ecart type du signal EEG (canal $i$ avec une durée de 10 Secondes)	$X_4$
$MSC_{EEG_{10}}$	Moyenne de la cohérence quadratique (pour une durée de 10 Secondes)	$X_5$
$Entrop_{EEG_{10}}$	Entropie du signal EEG (canal $i$ avec une durée de 10 Secondes)	$X_6$
$PSD_{EEG_{10}}$	Moyenne de la densité spectrale de puissance du signal EEG (canal $i$ avec une durée de 10 Secondes)	$X_7$
$ECG_{max_{10}}$	Valeur maximale sur une période de 10 secondes du signal ECG	$X_8$
$ECG_{min_{10}}$	Valeur minimale sur une période de 10 secondes du signal ECG	$X_9$
$E_{ECG_{10}}$	Energie du signal ECG (pour une durée de 10 Secondes)	$X_{10}$
$\sigma_{ECG_{10}}$	Ecart type du signal EEG (pour une durée de 10 Secondes)	$X_{11}$
$Entrop_{ECG_{10}}$	Entropie du signal ECG (pour une durée de 10 Secondes)	$X_{12}$
$PSD_{ECG_{10}}$	Moyenne de la densité spectrale de puissance du signal EEG (pour une durée de 10 Secondes)	$X_{13}$
$RR$	Rythme cardiaque	$X_{14}$

Table IV.1 : Caractéristiques extraites depuis les signaux ECG et EEG avec leurs vecteurs assignés.

Dans ce qui suit une explication de chaque paramètre sera faite.

Les énergies mesurées (respectivement notées  $E_{ECG_{10}}$  et  $E_{EEG_{10}, i}$ ) sont données par :

$$E_{ECG_{10}}(n) = \sum_{k=1}^L |ECG(k)|^2 \quad \text{IV.10}$$

$$E_{EEG_{10}}(i, n) = \sum_{k=1}^L |EEG(i, k)|^2 \quad \text{IV.11}$$

Où  $n = 1 \dots 80$ , car nous avons 80 segments

$L$  est la taille de l'enregistrement (chaque segment contient  $256 \cdot 10 = 2560$  échantillons).

$i = 1 \dots M$ , et  $M = 23$  correspond au nombre de canaux pour le signal EEG.

A titre d'exemple nous avons pris les deux segments utilisés ci-dessus et nous les avons affichés sur la figure IV.13, par rapport aux énergies correspondantes pour chaque canal. Sur cette figure on voit une variation significative entre les deux phases de tel sorte qu'il y a une augmentation importante lors de la présence de la crise d'épilepsie.

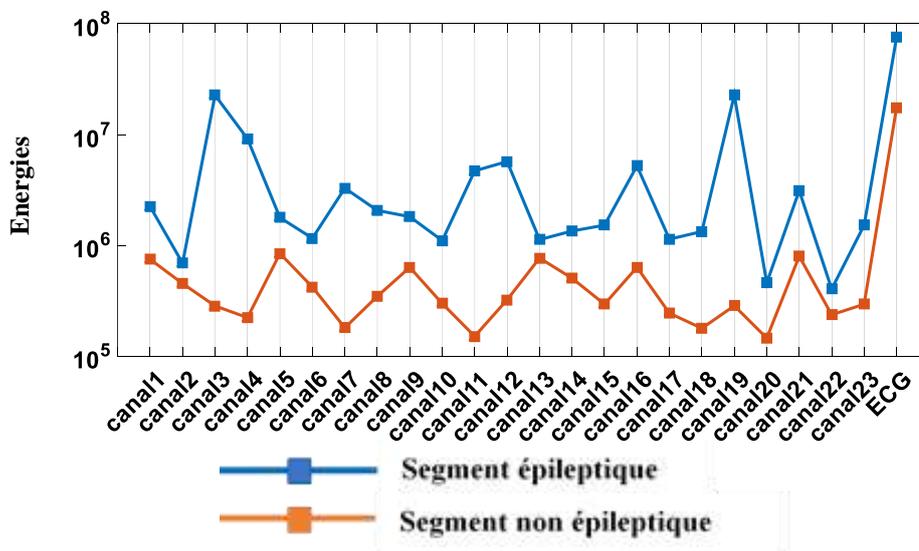


Figure IV.13 : Exemple de Energie calculée pour deux segments

$\sigma_{ECG_{10}}$  et  $\sigma_{EEG_{10}, i}$  sont respectivement les écarts types des vecteurs  $E_{ECG}$  et  $E_{EEG}$ , qui sont calculés comme suit :

$$\sigma_{ECG_{10}}(n) = \sqrt{\frac{1}{L} \sum_{K=1}^L (ECG(K) - \overline{ECG}(n))^2} \quad (IV.12)$$

$$\sigma_{EEG_{10}}(i, n) = \sqrt{\frac{1}{L} \sum_{K=1}^L (EEG(i, K) - \overline{EEG}(i))^2} \quad (IV.13)$$

$\overline{ECG}$  et  $\overline{EEG}$  Représentent les valeurs moyennes de l'ensemble des segments.

De même pour ce paramètre nous l'avons présenté sur la figure IV.14 en prenant en compte cette fois-ci les écarts types calculés pour les mêmes segments choisis auparavant. En suivant le même raisonnement nous obtenons la même remarque, un changement quand la crise à lieu par rapport un segment avec une activité normale.

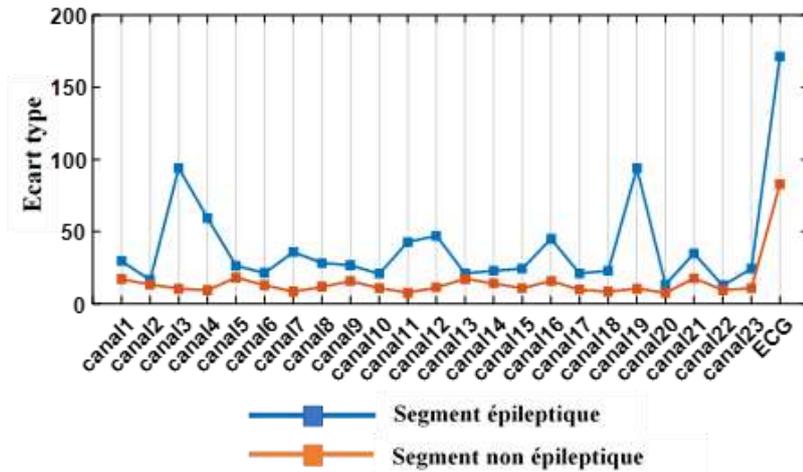


Figure IV.14 : Exemple de l'écart type calculée pour deux segments

Maintenant nous allons faire l'illustration de la cohérence calculée de chaque coefficient du signal EEG avec le coefficient du signal ECG correspondant obtenu par la décomposition en ondelette. Le résultat obtenu est affiché sur la figure IV.15.

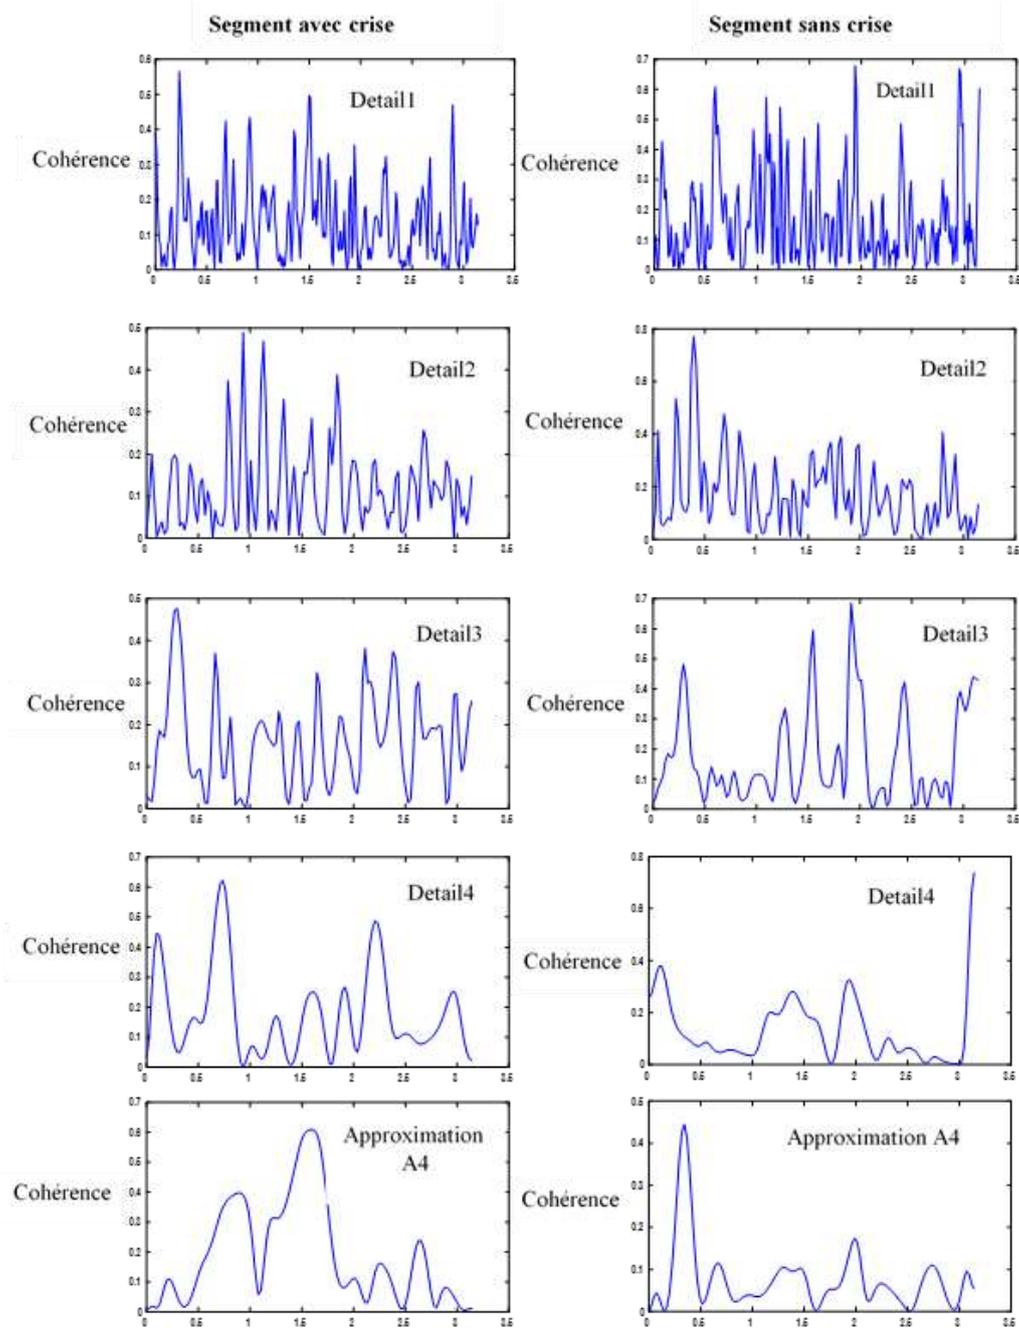


Figure IV.15 : Cohérence calculée entre les coefficients des signaux EEG et ECG.

### IV.4.3. Algorithme de classification

Comme nous avons vu au chapitre 3 le but de cet algorithme est l'identification des classes auxquelles appartiennent les éléments, et cela à partir de certains paramètres descriptifs extraites depuis des exemples connus, il s'agit en effet de la prise de décision correcte et automatisé avec une forte performance de prédiction pour des nouveaux exemples.

Les classifieurs satisfaisant pour atteindre ce but sont nombreux. Dans ce chapitre, nous suggérons deux différents types de classifieur ; qui sont les réseaux de neurones artificielle (RNA) et l'arbre de décision CART ( classification and regression tree)

#### **IV.4.3.1. Réseaux de neurones artificiels**

Les réseaux de neurones artificiels (RNA) sont la représentation la plus populaire pour l'apprentissage artificielle. Ces réseaux sont inspirés par les neurones observés dans le cerveau. Ils ont été construits à partir d'hypothèses et des modèles sur la façon dont le cerveau humain fonctionne pour résoudre des problèmes complexes. Ils contiennent de nombreux neurones appelés unités, qui sont beaucoup plus simples que les neurones du cerveau. Les unités sont disposées en une série de couches (couche d'entrée cachée et couche de sortie). Chaque neurone effectue une sommation pondérée des entrées des couches précédentes auxquelles il est connecté. Pour plus de détails voir le chapitre 3.

#### **IV.4.3.2. Arbre de décision**

L'arbre de décision ou forêts d'arbres de décision (**decision tree forests en anglais**) sont une collection d'arbres décisionnels qui peuvent traiter des ensembles de données extrêmement volumineux. En raison de leurs bonnes performances de classification en termes de capacité d'évolution et de facilité d'utilisation, les arbres de décision ont gagné en popularité dans les applications de l'apprentissage artificielle au cours de la dernière décennie. Ils utilisent la majorité des votes de tous les arbres de décision pour classer les données ou utilise un résultat moyen pour la régression. Ils sont formés sur des sous-ensembles choisis au hasard des instances de formation et des variables explicatives.

La Forêts d'arbres de décision utilisent une structure arborescente pour modéliser les relations entre les caractéristiques, dans laquelle chaque nœud interne (unité de décision qui permet de déterminer le nœud suivant) est identifié avec une caractéristique d'entrée. Cette dernière canalise les exemples pour une valeur de classe prédite finale. Chaque feuille de l'arbre est étiquetée avec une classe ou une distribution de probabilité sur les classes figure IV.16.

Ses utilisations potentielles peuvent inclure le diagnostic de conditions médicales basé sur des mesures en laboratoire, symptômes, ou le taux de progression de la maladie.

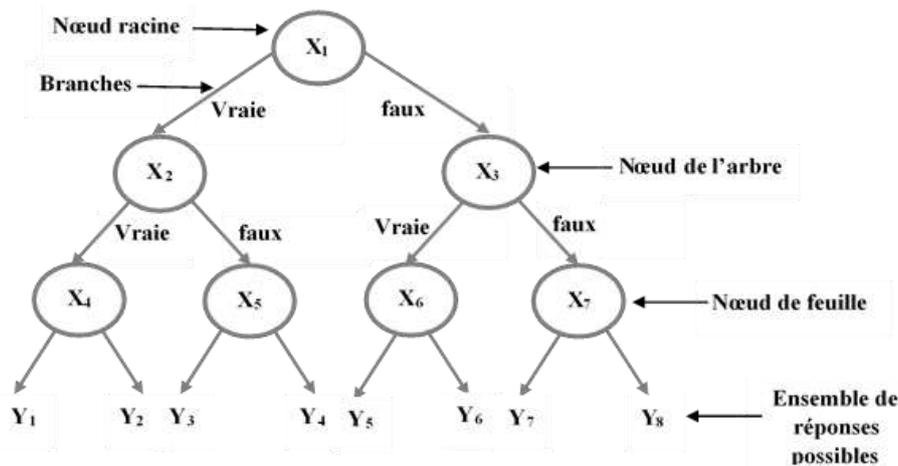


Figure IV.16 : représentation de l'arbre de décision

#### IV.4.4. Apprentissage supervisé et classification

Dans cette étude, nous avons mis en œuvre l'algorithme pour effectuer une classification binaire (crise ou non crise). Cette classification est effectuée sur les mêmes segments des signaux électrophysiologiques sélectionnés dans le chapitre précédent. L'implémentation software du classifieur est indispensable. Pour cela et avant de commencer à entraîner nos classifieurs, un ensemble de caractéristiques doivent être fixer pour chaque classifieur afin d'aboutir aux performances de classification les plus efficaces.

Rappelons que l'étude effectuée dans le chapitre précédent nous a permis d'avoir plusieurs structures et topologies en changeons les paramètres constituant le classifieur. Ce qui nous conduit à avoir des performances de classification opérantes d'une structure à une autre.

Pour la topologie du réseau de neurones artificielle utilisé dans cette étude, nous envisageons une structure avec les caractéristiques suivantes ;

- 167 neurones d'entrée.
- 10 couches cachées.
- Gradient conjugué comme fonction d'optimisation lors de la phase d'apprentissage pour apprendre les coefficients de poids du modèle.
- La fonction d'activation pour les couches cachées de type tangente hyperbolique, et la fonction exponentielle normalisé pour la couche de sortie.
- Une couche de sortie.

La base donnée à laquelle la phase d'apprentissage est accompli pour les deux classifieur correspond à la même base que nous avons exploité au chapitre précédent. Il s'agit de 24 segments contenant l'enregistrement simultané des signaux EEG et ECG (environ 1/3 de la

base globale), auquel 9 segments représentent des cas épileptiques, tandis que les 15 autres segments restants correspondent à des cas normaux.

Suite à la décomposition en ondelette discrète effectué auparavant, nous aurons 5 réseaux de neurones, nommés RNA – D 1, RNA – D 2, RNA – D 3, RNA – D 4 et RNA – A4 correspondant respectivement au détail1, détail2, détail3, détail4 et approximation.

#### IV.5. Résultats et interprétation

A ce niveau la phase d'apprentissage est achevée, il nous reste de tester la performance de discrimination entre les deux classes en introduisant dans ces réseaux neuronaux des nouveaux segments. Pour cela un ensemble de cas égale à 56 cas où 21 cas ressemblent à des cas épileptiques, bien que les 35 restants devraient être classer dans la classe non épileptique.

Toutes fois trois indicateurs statistique sont utilisés afin d'évaluer l'efficacité de chaque modèle, il s'agit ;

- Du taux de classification correcte (CC) ;
- De la sensibilité (Se) ;
- Et de la spécificité (Sp).

##### IV.5.1. Résultats avec réseau de neurones artificiel

Le tableau IV.2 donne un aperçu sur la performance de classification des structures proposé dans cette étude.

	RNA				
	Taux de Classification (%)	Sensibilité (%)	Spécificité (%)	Meilleure validation	Itérations
<b>RNA – D 1</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>1.8398e-07</b>	<b>22</b>
<b>RNA – D2</b>	96.4	90.5	100	7.97e-10	10
<b>RNA – D3</b>	89.3	100	71.4	6.39e-12	13
<b>RNA – D 4</b>	94.6	100	85.7	2.32e-10	13
<b>RNA – A4</b>	98.2	100	95.2	9.58e-08	09

Tableau IV.2 : Performance de classification par réseau de neurones.

Les résultats obtenus ont montré que les cinq réseaux ont une bonne discrimination des crises, ce qui signifie que lors de l'apparition de la crise toutes la bande fréquentielle formant les signaux est affecté. Mais suivant le tableau, le réseau noté *RNA – D1* produit la meilleure performance avec un taux de classification de 100%. L'estimation de la sensibilité et de la spécificité est de 100% pour les deux ce qui produit une efficacité parfaite. Rappelons que les coefficients du détails 1 sont obtenus après passage des signaux électrophysiologiques dans le filtre  $H_0$ . Ce dernier correspond à un filtre passe haut, ce qui indique l'apparition des effets de crises d'épilepsie dans la bande des hautes fréquences. De plus nous observons un taux d'erreur très petit pour tous les réseaux avec un nombre d'itérations finis et inférieur à 25 itérations.

Le tableau IV.3 présente la matrice de confusion le la structure nommé *RNA – D1*. Nous pouvons constater sur le tableau que la prédiction est idéale avec faux positif et faux négatif nulle.

Réelle	Prédite	
	Négative	Positive
Test Négative	<b>21</b> <b>35.7%</b>	<b>0</b> <b>0%</b>
Test Positive	<b>0</b> <b>0%</b>	<b>35</b> <b>62.5</b>

Tableau IV.3 : Matrice de confusion de réseaux de neurone *RNA – D1*

La figure IV.17 confirme ce qui a été constaté, on peut voir la convergence adéquate de notre réseau durant les phases d'apprentissage, validation et test vers une erreur quadratique très petite (de l'ordre de  $1.83 \times 10^{-7}$ ) au bout de 22 itérations.

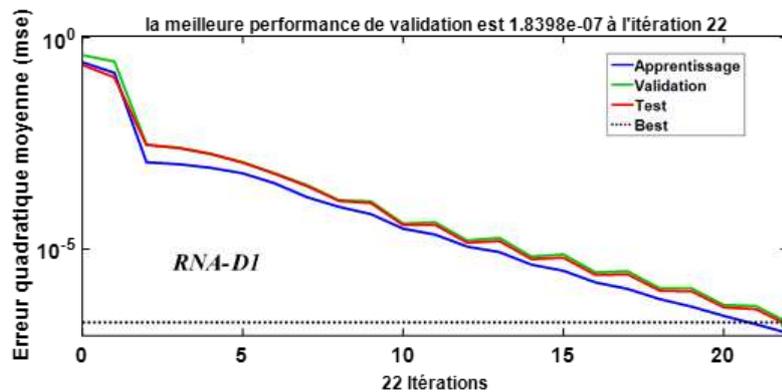


Figure IV.17 : apprentissage et validation des performances du réseau *RNA – D1*.

### IV.5.2. Résultats obtenus en utilisant l'arbre de décision

Comme nous l'avons mentionné auparavant, un autre apprentissage supervisé noté **AD** basé sur l'arbre de décision est utilisé pour la détection des crises d'épilepsie.

Après le test effectué par l'arbre de décision sur les cinq vecteurs caractéristiques de l'ensemble des détails et approximation obtenus, le taux de classification estimé ainsi que les autres indicateurs correspondants de chaque vecteur sont donnés par le tableau IV.4.

	Arbre de décision				
	Taux de Classification (%)	Sensibilité (%)	Spécificité (%)	Erreur	Nombre d'arbres Produits
<b>AD – D 1</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>4.16e-02</b>	<b>41</b>
<b>AD – D 2</b>	95.24	100	100	4.16e-02	52
<b>AD – D 3</b>	83.92	57.14	100	4.16e-02	56
<b>AD – D 4</b>	92.85	80.95	100	8.33e-02	87
<b>AD – A 4</b>	91.07	76.19	100	3.1 e-02	10

Tableau IV.4 : Performance de classification par l'arbre de décision.

D'après les résultats cités dans le tableau, l'algorithme de l'arbre de décision confirme ce qui a été obtenu par les réseaux de neurones, où les indicateurs du processus de classification suivent la même évolution avec la même monotonie. Le plus grand taux de classification a été obtenu pour **AD – D 1** correspond au vecteur caractéristique du premier coefficient de détail de décomposition en ondelettes. De plus, l'erreur était presque la même pour tous les coefficients d'environ  $4,16 \times 10^{-02}$  avec une moyenne de 50 arbres produits. Cela pourra se traduire en disant que les coefficients du détail 1 sont les coefficients les plus influencés par les effets de la crise.

Notons que lorsque l'utilisation de l'arbre de décision nous pouvons obtenir une représentation graphique de l'erreur de classification. Cette erreur concerne la probabilité d'erreur de classification sur le nombre d'arbre obtenus. Prenons le cas des coefficients de détail 1, cette erreur a été calculée et tracé sur la figure IV.18.

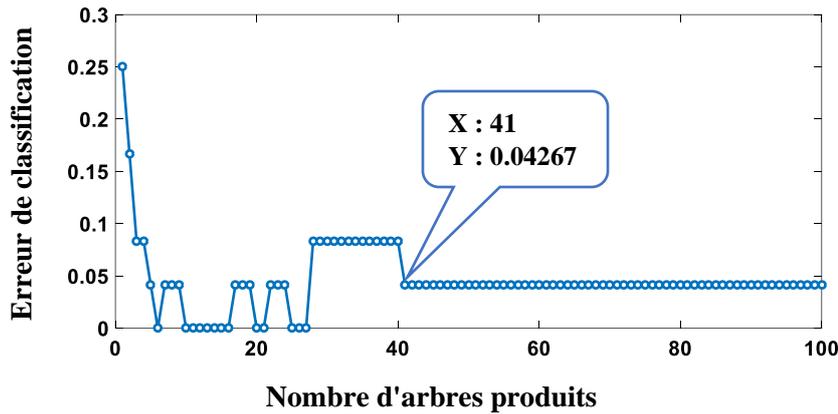


Figure IV.18 : Erreur de classification par l'arbre de décision.

Dans ce type de classifieur, nous pouvons également identifier et classer par ordre d'importance les paramètres les plus significatives parmi les attributs utilisés dans la classification. L'importance des caractéristiques d'entrée est l'un des facteurs les plus importants caractérisant l'algorithme de l'arbre de décision. Il permet de trouver les caractéristiques les plus importantes parmi toutes les caractéristiques utilisées dans le processus de classification. Elle est obtenue par le calcul de l'erreur quadratique moyenne de tous les arbres divisés par l'écart type pris en compte pour tous les arbres.

Dans cette étude, nous voulons savoir si toutes les caractéristiques sont importantes pour la précision de notre classifieur. Les résultats obtenus sont présentés sur la figure IV.19

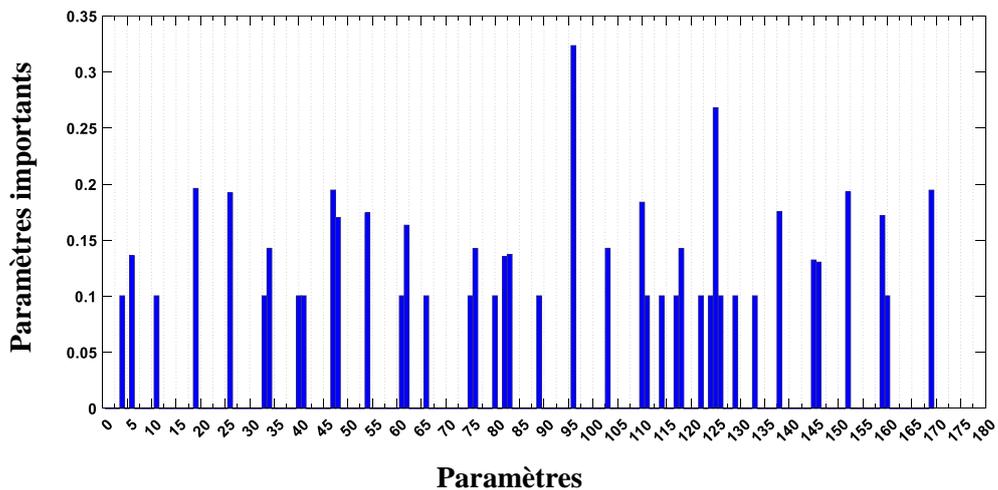


Figure IV.19 : Histogramme des paramètres les plus importants.

Rappelons que la phase d'extraction des paramètres concerne tous les canaux, c'est à dire que les 24 canaux ont subi une extraction des mêmes paramètres, pour cela nous avons proposé de

faire la moyenne de l'importance de chaque paramètre sur les 24 canaux. La nouvelle courbe d'importance est donc présentée par le diagramme de la figure IV.20.

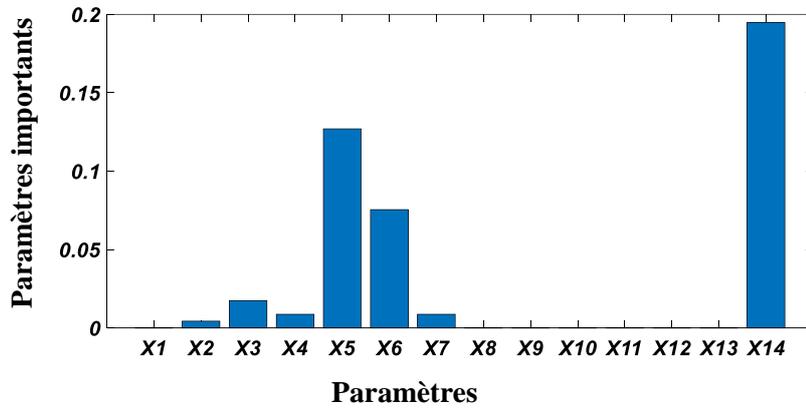


Figure IV.20 : Moyenne de l'importance de chaque paramètre sur les 24 canaux.

Comme nous pouvons le voir, les paramètres  $x_5$ ,  $x_6$ , et  $x_{14}$  correspondent respectivement à  $MSC_{EEG_{10}}$ ,  $Entrop_{EEG_{10}}$  et  $RR$  qui sont les trois caractéristiques les plus puissantes et importantes parmi les 14 caractéristiques utilisées dans cette étude. C'est à dire nous devons baser sur leurs contributions qui permettent en fin de compte d'améliorer la performance du processus de détection des crises.

Alors que les paramètres  $x_3$ ,  $x_4$  et  $x_7$  représentent respectivement  $E_{EEG_{10}}$ ,  $\sigma_{EEG_{10}}$  et  $PSD_{EEG_{10}}$  sont relativement moins importantes, contrairement aux paramètres  $x_1$ ,  $x_2$ ,  $x_8$ ,  $x_9$ ,  $x_{10}$ ,  $x_{11}$ ,  $x_{12}$ , et  $x_{13}$  qui ne sont pas très importantes. Si nous essayons de les supprimer, la puissance de l'algorithme pourrait ne pas diminuer de manière significative. En effet, à travers cet algorithme on pourra optimiser nos vecteurs caractéristique, en faisant éventuellement diminuer leur tailles et par la suite réduire le temps et la complexité des données de classification sans une diminution de performance de notre classifieur.

La figure IV.21 illustre un exemple de l'arbre de classification utilisé dans cette étude, pour détecter la classe de crise ou de non-crise, la décision doit être suivie dans l'arbre du nœud racine au nœud feuille.

A cause de la taille énorme de l'arbre, nous proposons dans cette figure de voir l'évolution de l'arbre de décision uniquement pour les deux paramètres  $x_6$  et  $x_7$ .

Nous pouvons résumer le processus de décision pour ces deux caractéristiques comme suit :

- 1- Si  $x_7 < 7.80538$  donc nœud 2 sinon Si  $x_7 \geq 7.80538$  donc nœud 3 sinon **non-crise**

- 2- Si  $x_7 < 0.0628675$  donc nœud 4 sinon Si  $x_7 \geq 0.0628675$  donc nœud 5 sinon **non-crise**.
- 3- classe = crise.
- 4 -Si  $x_6 < 2.75715$  donc nœud 6 sinon Si  $x_6 \geq 2.75715$  donc nœud 7 sinon crise.
- 5-Si  $x_6 < 4.94997$  donc nœud 8 sinon Si  $x_6 \geq 4.94997$  donc nœud 9 sinon **non-crise**.
- 6- class = non-crise.
- 7- Si  $x_6 < 3.53305$  donc nœud 10 sinon  $x_6 \geq 3.53305$  donc nœud 11 Si **non-crise**
- 8- classe = non-crise.
- 9- classe = crise.
- 10- classe = crise
- 11- classe = non-crise

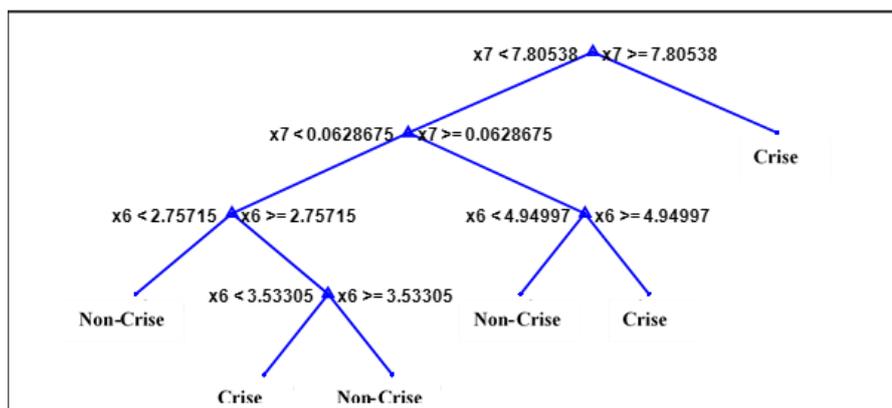


Figure IV.21: Arbre de décision pour les paramètres  $x_6$  et  $x_7$ .

Maintenant nous faisons une comparaison entre les deux classifieurs comme le montre la figure IV.22. Nous trouvons que leurs résultats se coïncide, de tel sorte qu'ils produisent le même taux de classification pour le détail(d'environ 100%). Nous concluons que les événements de crise peuvent apparaître pour tous les coefficients de détails et d'approximation mais que le taux de reconnaissance dans le détail1 est meilleur que les autres détails.

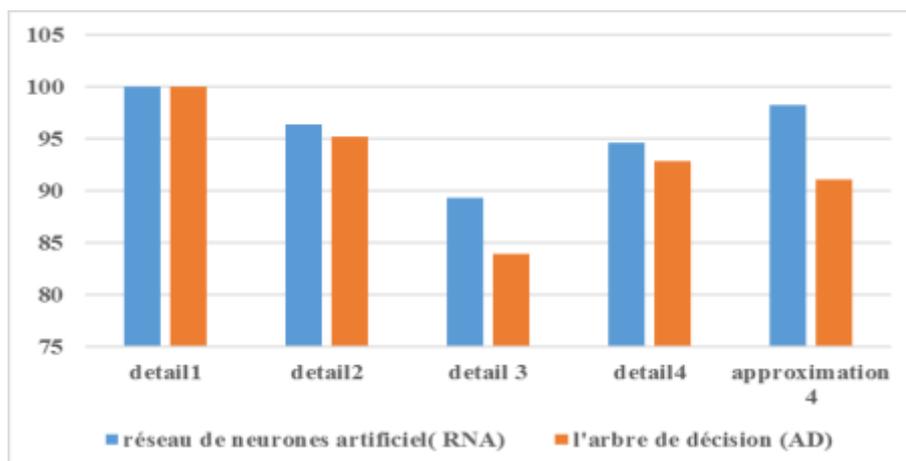


Figure IV.22: Histogramme du taux de classification pour chaque détail et approximation utilisés par le classifieur RNA et AD.

Nous avons cité plusieurs approches qui s'intéressent à la détection et l'analyse des crises d'épilepsie, pour cela nous proposons dans ce qui suit une comparaison entre notre approche et deux autres approches, la première proposée par "Iosif" (Iosif et al., 2015), la deuxième concerne la méthode présentée par "Varun's" (Varun et al., 2012).

Le tableau IV.5 résume les performances de détection des crises par les trois approches. En conséquence, sur la base des résultats obtenus, notre technique proposée offre des performances supérieures par rapport aux deux autres méthodes

Méthode	Architecture du Système	Taux de Classification (%)	Sensibilité (%)	Spécificité (%)
Notre Méthode	<ul style="list-style-type: none"> <li>• 23 canaux pour l'EEG.</li> <li>• Un seul canal ECG</li> <li>• Réseaux de neurone artificielle RNA</li> <li>• Base de données collectée au niveau de l'hôpital pédiatriques de Boston.</li> <li>• Fréquence d'échantillonnage égal à 256Hz</li> </ul>	<b>100</b>	<b>100</b>	<b>100</b>
(Iosif, M et al)	<ul style="list-style-type: none"> <li>• 21 canaux pour l'EEG.</li> </ul>	96.1	92.31	99.90

	<ul style="list-style-type: none"> <li>• Un seul canal ECG</li> <li>• Support vector machine SVM</li> <li>• Base de données collectée au niveau de the Epilepsy Clinic in the Department of Clinical Neurophysiology of St Thomas Hospital.</li> <li>• Fréquence d'échantillonnage égal à 500Hz</li> </ul>			
(Varun, B et al)	<ul style="list-style-type: none"> <li>• 100 canaux pour l'EEG.</li> <li>• Utilisation de la décomposition en mode empirique.</li> <li>• Utilise de la décomposition en mode empirique.</li> <li>• Fréquence d'échantillonnage égal à 173.61 Hz</li> <li>• Pas de signal ECG.</li> </ul>	100	100	99.38

Tableau v.5 : Résultats de l'évaluation de notre algorithme de détection des crises par rapport à la méthode "Iosif " et la méthode de "Varum".

#### IV.6. Conclusion

Dans ce chapitre nous avons présenté une étude sur l'influence de la crise d'épilepsie sur les signaux EEG et ECG dans le domaine fréquentiel à travers plusieurs outils de traitement de signal. Cela nous a permis d'enrichir encore plus notre vecteur caractéristique par rapport au vecteur utilisé dans le chapitre précédent, pour pouvoir améliorer la performance du module de détection de crises basé sur les signaux EEG et ECG proposé.

Les algorithmes proposés sont testés sur la base de données EEG CHB-MIT Scalp EEG en libre accès chez Physionet. Comme nous l'avons vu précédemment, le schéma proposé utilise différentes étapes, dont l'étape de décomposition des ondelettes discrète, l'extraction des caractéristiques, l'apprentissage et enfin la classification.

Pour achever l'étape de classification deux type de classifieurs sont utilisés ; réseaux de neurones artificiel (RNA) et l'arbre de décision (AR). Les paramètres ont été extraites à la fois du domaine temporel et fréquentiel.

Une étude comparative a été faite entre les deux classifieurs choisis et nous avons montré que le classificateur ANN produit les meilleurs résultats de classification en termes de performances décrit à la fois par le taux de classification, la sensibilité ( $S_e$ ) et la spécificité ( $S_p$ ).

Les résultats montrent que la crise peut être détectée sur les quatre niveaux de décomposition des ondelettes utilisés dans ce travail, mais au premier niveau (D1) produit le meilleur taux de classification.

Pour terminer, d'après les résultats obtenus pour l'algorithme de l'arbre de décision, nous concluons que la cohérence (MSC) et la fréquence cardiaque (RR) sont les caractéristiques les plus importantes qui peuvent affecter considérablement le taux de reconnaissance dans ces deux classifieurs.

## **Chapitre V : Approche pour la prédiction des crises d'épilepsie basée sur la corrélation entre les paramètres du signal ECG et du signal EEG**

### **V.1. Introduction**

Plus de cinquante millions de personnes dans le monde, soit environ 1 % de la population mondiale souffrent d'épilepsie. Selon la définition de la Ligue International Contre l'Epilepsie (ILAE ;International League Against Epilepsy), Une crise d'épilepsie est une manifestation importante de signes et/ou de symptômes dus à une activité neuronale excessive ou synchronisée anormale dans le cerveau. L'épilepsie peut avoir une influence directe sur la qualité de vie des patients en raison des effets secondaires liés au traitement des troubles cognitifs et surtout de la mémoire ou des blessures associées aux crises, elle peut avoir une influence directe sur la qualité de vie des patients en raison des effets secondaires liés au traitement, des troubles cognitifs et particulièrement de la mémoire ou des blessures associées aux crises, des troubles de la santé mentale et de l'isolement social, surtout quand la maladie se prolonge dans le temps. De plus, il semble que les membres de la famille ou les soignants des patients éprouvent également de multiples difficultés psychologiques ou sociales sous forme de dépression et de restriction sociale. Outre ces effets négatifs sur les conditions personnelles et sociales de la vie, le budget annuel élevé consacré aux activités de soins de santé liées aux coûts d'investigation, de traitement et d'hospitalisation des patients épileptiques ne peut être négligé. L'impact socio-économique très négatif de l'épilepsie justifie la nécessité de poursuivre la recherche et le développement de systèmes diagnostiques et thérapeutiques soutenus par la technologie. Les progrès de la technologie au cours des dernières décennies ont fourni les moyens de passer d'indices qualitatifs à des indices quantitatifs, liés au processus inconnu qui produit une crise. L'investigation des crises se fait principalement par analyse quantitative de l'électroencéphalogramme (EEG).

La détection des crises d'épilepsie est basée sur la méthode conventionnelle qui aide le médecin à observer les caractéristiques des crises d'épilepsie et le diagnostic avec précision est l'électroencéphalogramme (EEG). Cette méthode repose essentiellement sur l'analyse visuelle du signal EEG multidimensionnel (généralement constitué d'enregistrements synchrones dans le temps capturés à partir d'un système de 10 à 20 électrodes pour scalps) qui est effectué manuellement par des neurologues experts pour la détection des modèles intéressants comme les crêtes et complexes à ondes pointues.

Comme nous l'avons mentionné au chapitre 3, le développement de la technologie des systèmes électronique ont contribué d'une façon précieuse à l'étude et à la conception des modules automatisé pour la détection des crises. Nous avons également cité de nombreuses méthodes qui ont été réalisées concernant le problème de crise d'épilepsie. A côté du signal EEG, l'étude des signaux électrocardiographiques (ECG) peut également fournir des informations précieuses concernant les décharges de crises. Par conséquent de nombreuses études aient déjà été réalisées dans ce domaine. De plus, notre étude présentée dans les chapitres 3 et 4 a affirmé l'implication positive du signal ECG dans le processus de détection des crises.

Récemment de nombreuses recherches scientifiques ont la tendance de perfectionné des appareils d'EEG ambulatoires sans fil pour la surveillance à long terme de l'épilepsie et la détection en temps réel des crises. Pour améliorer la qualité des soins et du diagnostic des patients.

Dans ce chapitre, nous proposons une approche pour la prédiction des crises d'épilepsie basée sur la combinaison et la corrélation entre les paramètres de l'électrocardiogramme (ECG) et de l'électroencéphalogramme (EEG). Une étude statistique sera effectuée pour quantifier la relation linéaire existant entre les signaux EEG et ECG dans les deux domaines ; temporel et fréquentielle. Cette relation est évaluée dans le domaine temporel en utilisant les coefficients de corrélation de Pearson et de Spearman et l'algorithme de l'arbre de décision, et dans le domaine fréquentiel la relation est élaborée par le biais de la cohérence quadratique noté (MSC) et la densité spectrale de puissance (CPSD), qui ont été étudiés et validés dans les chapitres précédents.

## **V.2. Travaux réalisés sur la prédiction des crises d'épilepsie**

Récemment Plusieurs études ont utilisé l'EEG et l'ECG pour automatiser la détection de l'apparition des crises d'épilepsie à l'aide de nombreuses méthodes. Ces deux indicateurs

physiologiques critiques peuvent être utilisés comme indicateurs de l'état du corps et de l'esprit pour un soin de santé clinique. Parmi ces méthodes l'approche proposée par Worawich, S (Worawich, S et al, 2014) qui utilise les deux paramètres de l'EEG et l'ECG comme indicateur de prédiction précoce. La méthode consiste à la technique d'extraction des paramètres basée sur la transformé de Hilbert Huang. Cette dernière est accomplie à travers deux étapes essentielles ; la décomposition Modale Empirique afin de détecter le pic R du signal ECG et l'application de la transformé d'Hilbert pour les signaux EEG pour trouver la fréquence instantanée. L'exploration de la fréquence instantanée moyenne de l'EEG et l'intervalle R-R de l'ECG ont changé d'une manière significative et cela environ 130 secondes avant l'apparition des crises. Une autre approche proposée par Thomas, B (Thomas, B et al, 2009) qui utilise la Fusion d'informations à partir de l'EEG et l'ECG pour la détection des événements épileptiques par le biais de fluctuations cardiaques. La détection fondée sur des données unimodales et une mesure de la complexité de la série chronologique de l'EEG ou une mesure de l'occurrence d'une arythmie cardiaque. Yang-Yen et al ont exploités le classifieur SVM pour une Corrélation et classification des indices avec les signaux EEG/ECG (Yang-Yen et al, 2013), 6 paramètres ont été extraits (5 depuis le signal EEG et 1 à partir du signal ECG) puis introduite dans un classifieur. Ali Houssein propose une classification pour la détection du début de crise basé sur la combinaison des paramètres composées par l'Energie dans des bandes de fréquence des signaux EEG et de la fréquence cardiaque moyenne (Ali H, 2009). Un moniteur ECG sans fil miniaturisé pour la détection en temps réel des crises d'épilepsie est présenté par FABIEN MASSE. Les données ECG sont analysées par des algorithmes intégrés : un algorithme robuste de détection de battement combiné à un détecteur de crise d'épilepsie en temps réel (Fabien M et al, 2013).

### **V.3. Méthode**

#### **V.3.1. Base de données**

Cette étude a été réalisée sur la base de données CHB-MIT Scalp EEG Database, disponible gratuitement sur Physionet (PhysioBank database, 2016 ; Goldberger et al., 2000). Rappelons que cette base a été présentée et utilisée dans l'étude précédente. Pour plus de détails voir le chapitre 3. La figure V.1 nous montre un exemple d'enregistrement de cette base de données avec les annotations qui concerne la crise.

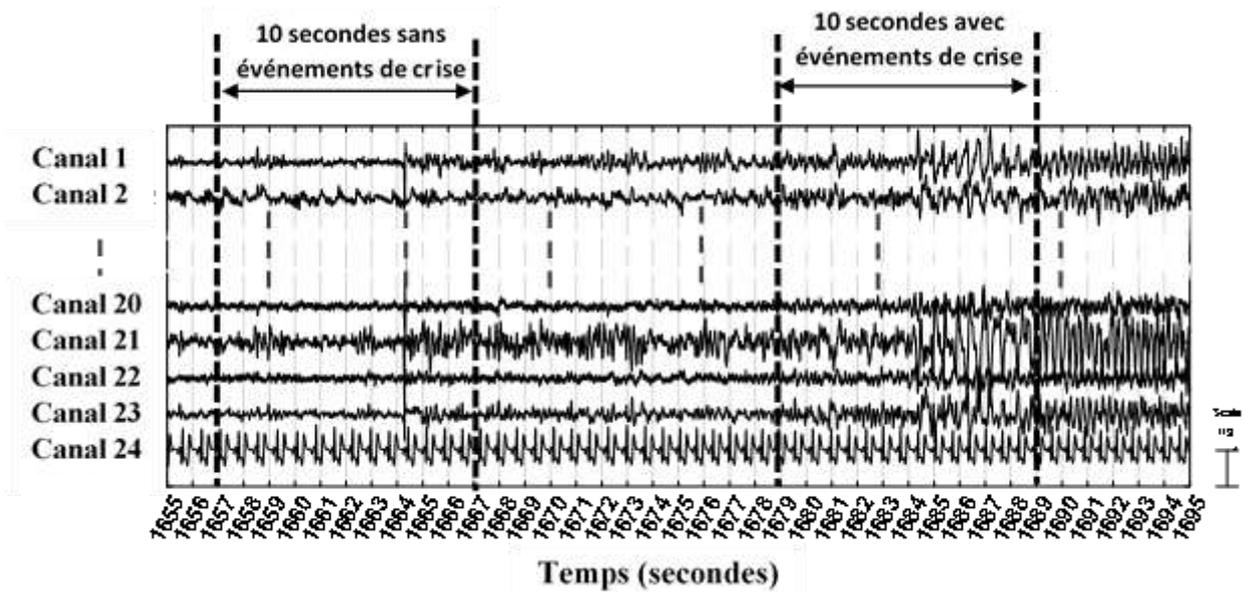
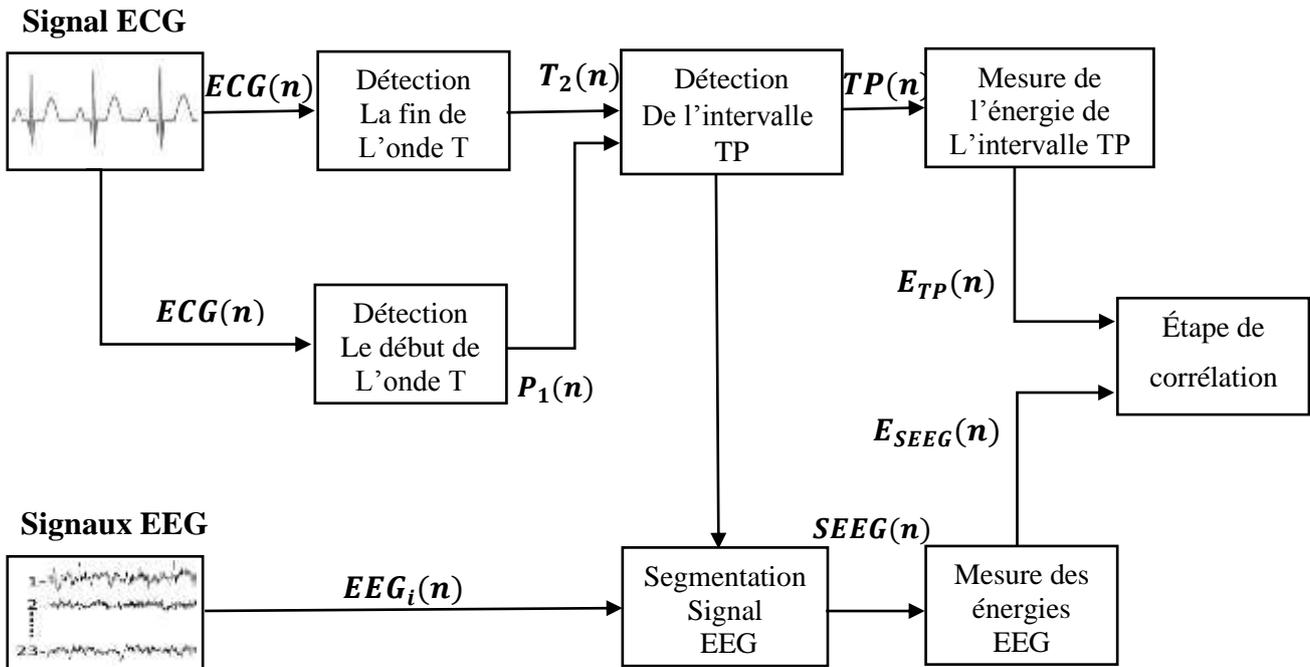


Figure V.1 : Exemple d'enregistrement des signaux EEG et ECG annoté.

### V.3.2. Description de la méthode proposée

La figure V.2 illustre le schéma bloc décrivant les étapes implémentées afin d'achever notre objectif. Le processus est divisé en un certain nombre d'étapes séquentielles présentées comme suit :

- Détection des ondes du signal ECG (fin de l'onde T et début de l'onde P) ;
- Détection de l'intervalle TP ;
- Segmentation du signal EEG ;
- Mesure des énergies de l'intervalle TP et les segments EEG ;
- Corrélation entre les énergies.



FigureV.2 : Schéma bloc de l'algorithme proposé.

### V.3.2.1. Détection des ondes ECG (fin de l'onde T et début l'onde P)

La première étape de notre algorithme est la détection des ondes de l'ECG. Comme illustré sur la figure V.3. La détection de la position de l'onde R est définie à l'aide d'un algorithme précédemment décrit en détail dans (Hadj Slimane et al, 2010). La fin de l'onde T (noté  $T_2(n)$ ) et le début de l'onde P (noté  $P_1(n)$ ) sont détectées en utilisant la méthode décrite par (Laguna et al, 1990 et 1994).

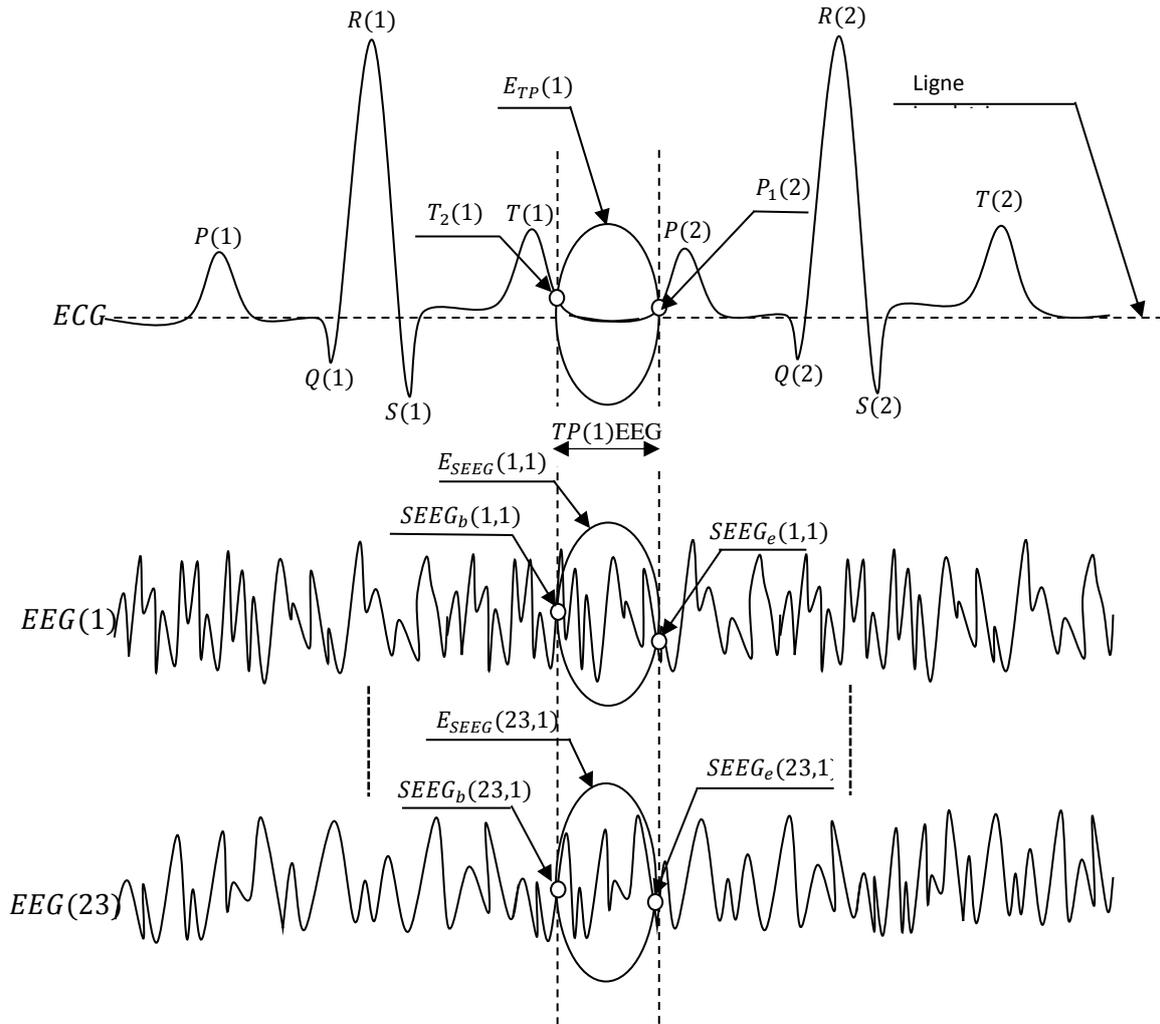


Figure V.3 : Extraction et calcul des énergies à partir des signaux ECG et EEG.

### V.3.2.2. Détection de l'intervalle TP

Une fois la fin de l'onde T (noté  $T_2(n)$ ) et le début de l'onde P (noté  $P_1(n)$ ) sont définis, nous définissons maintenant l'intervalle TP comme suit :

$$TP(n) = P_1(n) - T_2(n - 1) \quad (V.1)$$

Où :  $n = 2 \dots N - 1$

$N$  est le nombre de battement de cœur pour chaque enregistrement.

### V.3.2.3. Segmentation des signaux EEG

Après la définition des ondes à partir du signal ECG, nous définissons ensuite les segments  $SEEG_b$  et  $SEEG_e$  par projection du point  $P_1$  et du point  $T_2$  sur les signaux EEG. Voir figure V.4.

### V.3.2.4. Mesure des Energie de l'intervalle TP et les segments EEG

Les énergies de l'intervalle TP et les segments EEG (notés respectivement  $E_{TP}$  et  $E_{SEEG}$ ) sont données par :

$$E_{TP}(n) = \sum_{k=T_2(n)}^{P_1(n+1)} |ECG(k)|^2 \quad (V. 2)$$

$$E_{SEEG}(i, n) = \sum_{k=SEEG_b(i,n)}^{SEEG_e(i,n)} |EEG(i, k)|^2 \quad (V. 3)$$

Où :  $n = 2 \dots N - 1$

$N$  est le nombre de battement de cœur pour chaque enregistrement.

$i = 1 \dots M$   $M=23$  est le nombre des canaux des signaux EEG.

### V.3.2.5. Corrélation entre les énergies

Les corrélations entre les énergies de l'intervalle TP et les énergies EEG sont mesurées en utilisant le coefficient de corrélation de Pearson et le coefficient de corrélation de Spearman.

Le coefficient de corrélation de Pearson est utilisé pour mesurer la corrélation entre deux variables. Il peut être écrit de la manière suivante (Nian, 2008) (Hauke et al, 2011) :

$$r_p(X, Y) = \frac{Cov(X, Y)}{\sigma_X \sigma_Y} \quad (V. 4)$$

$$Cov(X, Y) = \frac{1}{N} \sum_{i=1}^N (X(i) - \bar{X})(Y(i) - \bar{Y}) \quad (V. 5)$$

Pour notre cas  $X(i) = E_{TP}(i)$  et  $Y(i) = E_{SEEG}(n, i)$ ,  $i = 1 \dots N$

$n = 1 \dots M$ ,  $M=23$  est le nombre de canaux des signaux EEG.

$N$  est le nombre de battement de cœur pour chaque enregistrement.

$\bar{X}$  et  $\bar{Y}$  Sont respectivement les valeurs moyennes de  $E_{TP}$  et  $E_{SEEG}$ . Ils peuvent s'écrire comme suit :

$$\bar{X} = \bar{E}_{TP} = \frac{\sum_{i=1}^N E_{TP}(i)}{N} \quad (V. 6)$$

$$\bar{Y} = \bar{E}_{SEEG} = \frac{\sum_{i=1}^N E_{SEEG}(n, i)}{N} \quad (V. 7)$$

$\sigma_X$  et  $\sigma_Y$  sont respectivement les écarts-types des vecteurs  $E_{TP}$  et  $E_{SEEG}$ .

$$\sigma_X = \sqrt{\frac{1}{N} \sum_{i=1}^N (X(i) - \bar{X})^2} \quad (V.8)$$

$$\sigma_Y = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y(i) - \bar{Y})^2} \quad (V.9)$$

Le coefficient de corrélation de Pearson varie de -1 à 1 et son interprétation est la suivante :

- $r_p(X, Y) = 0$  il y a aucune corrélation linéaire entre X et Y ;
- $-1 < r_p(X, Y) < 0$  indique une corrélation linéaire négative entre X et Y ;
- $0 < r_p(X, Y) < +1$  indique une corrélation linéaire positive entre X et Y ;
- Plus la valeur de  $r_p(X, Y)$  est proche de 1, plus la corrélation linéaire positive est forte ;
- Plus la valeur de  $r_p(X, Y)$  est proche de -1, plus la corrélation linéaire négative est forte.

Les coefficients de corrélation de Spearman dénotés  $r_s$  sont une version basée sur le rang du coefficient de corrélation de Pearson. Il examine s'il existe une relation entre les rangs d'observations pour les caractères X et Y, qui peut détecter l'existence de relations monotones (croissantes ou décroissantes). On peut l'écrire comme suit :

$$r_s = \frac{\frac{1}{N} \sum_{i=1}^N (R(x_i) - \bar{R}_x)(R(y_i) - \bar{R}_y)}{\sqrt{\frac{1}{N} \sum_{i=1}^N (R(x_i) - \bar{R}_x)^2} \sqrt{\frac{1}{N} \sum_{i=1}^N (R(y_i) - \bar{R}_y)^2}} \quad (V.10)$$

Où  $R(x_i)$  et  $R(y_i)$  sont les rangs de l'observation dans l'échantillon.

Le coefficient de corrélation de Spearman varie également de -1 à 1 et son interprétation est la même que celle du coefficient de corrélation de Pearson.

Afin d'étudier plus en détail la relation entre les signaux EEG et ECG dans le domaine fréquentiel, nous calculons la cohérence ( $MSC(f)$ ) comme suit :

$$MSC(f) = \frac{|P_{xy}(f)|^2}{P_{xx}(f)P_{yy}(f)} \quad (V.11)$$

Nous avons également utilisé la densité spectrale de puissance (CPSD). Il représente la distribution de la puissance par unité de fréquence et se définit comme suit :

$$P_{XY}(f) = \sum_{m=-\infty}^{+\infty} R_{XY}(m)e^{-jwm} \quad (V.12)$$

Où  $R_{XY}$  est la corrélation croisée définie comme suit:

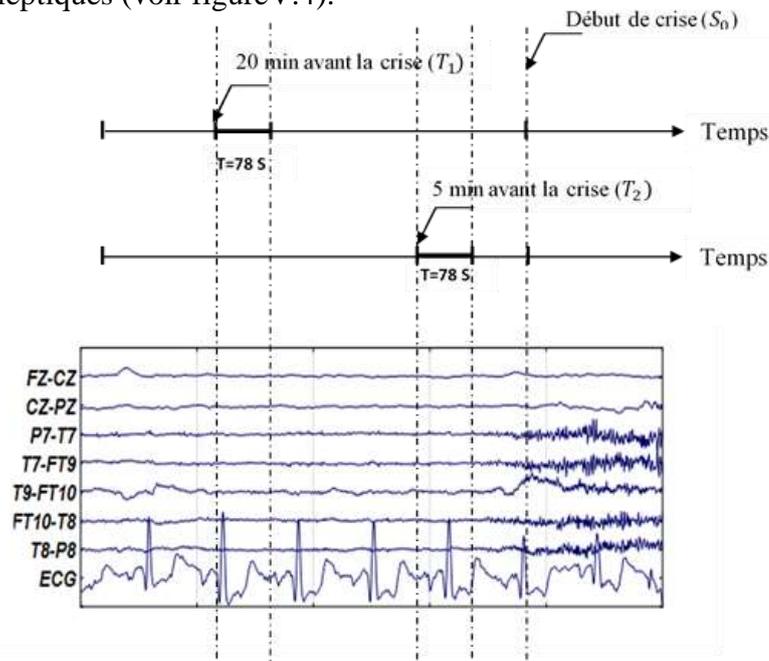
$$R_{XY}(m) = E\{X_{n+m}Y_n^*\} = E\{X_nY_{n-m}^*\} \quad (V.13)$$

E : indique la valeur prévue.

#### V.4.Résultats et discussion

Notre méthode est testée en utilisant 4 enregistrements du même sujet qui représente le cas d'un homme adulte de 22 ans. Chaque enregistrement se compose d'un signal ECG et 23 canaux pour le signal EEG enregistré simultanément. Les cas 1 et 2 ont deux crises annotées. Les cas 3 et 4 correspondent à une activité normale sans crises .

Pour les cas 1 et 2 (enregistrement avec crises épileptiques), la corrélation entre les signaux EEG et ECG est calculée sur une période de 78 secondes prise 20 minutes et 5 minutes avant le début des crises épileptiques (voir figureV.4).



FigureV.4 : Corrélation entre les signaux EEG et ECG calculée sur une période de 78 secondes prise 20 minutes et 5 minutes avant l'apparition des crises d'épilepsie.

Dans la période de temps sélectionnée (78 secondes), la corrélation entre les énergies (énergie de l'intervalle TP et énergie EEG) est mesurée entre le signal ECG et toutes les données des canaux EEG.

Quelques exemples de séries simultanées réelles des énergies calculées (l'intervalles TP et les segments de l'EEG) avec le diagramme de dispersion correspondant sont représentés sur les figures V.5 et V.6. La figure V.7 illustre les résultats de corrélation entre les énergies obtenues à partir des enregistrements 1 à 4 et du signal EEG de tous les canaux (avec et sans crises épileptiques).

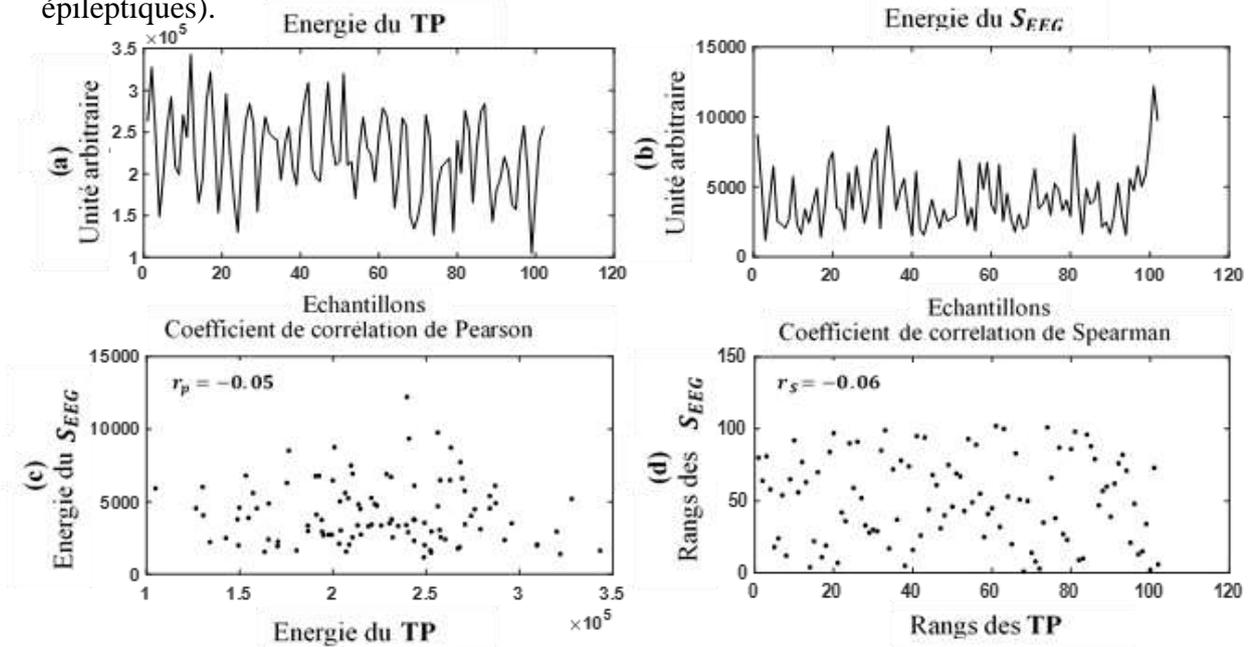


Figure V.5 : Exemple d'une série simultanée réelle des énergies des intervalles TP et segments EEG avec leurs diagrammes de dispersion correspondant.

Les coefficients de Pearson et de Spearman sont calculés pour le canal 19 (P7-T7), 20 minutes avant la crise.

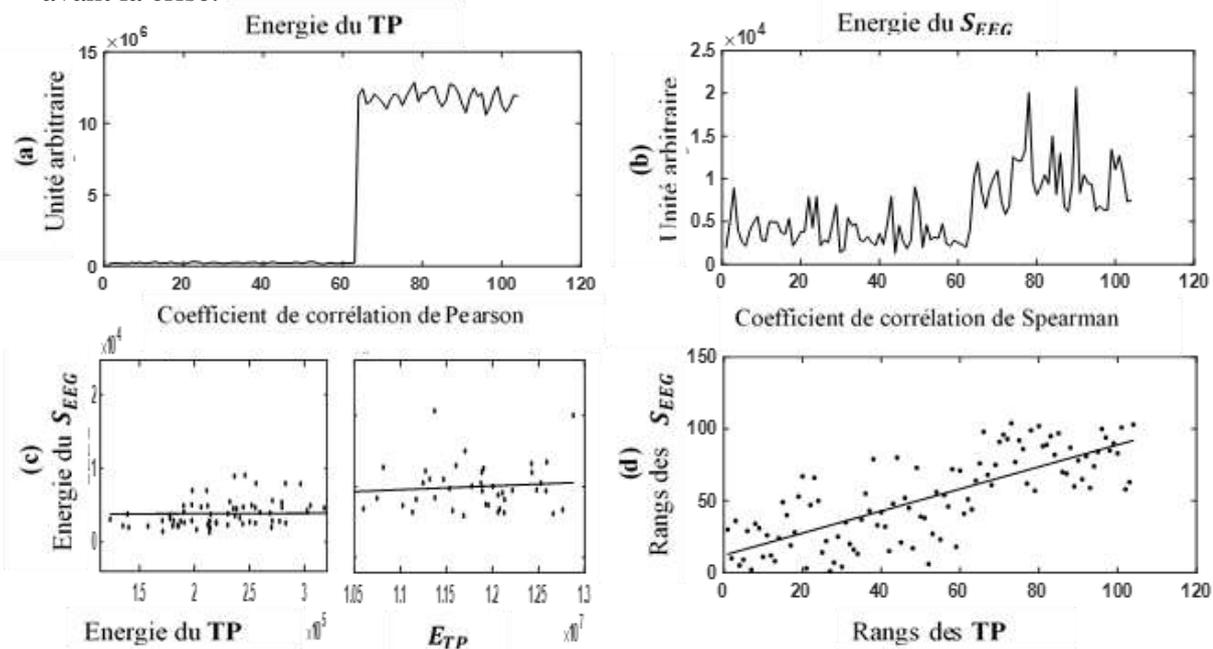


Figure V.6 : Exemple d'une série simultanée réelle des énergies des intervalles TP et segments EEG avec leurs diagrammes de dispersion correspondant.

Les coefficients de Pearson et de Spearman sont calculés pour le canal 19 (P7-T7), 5 minutes avant la crise.

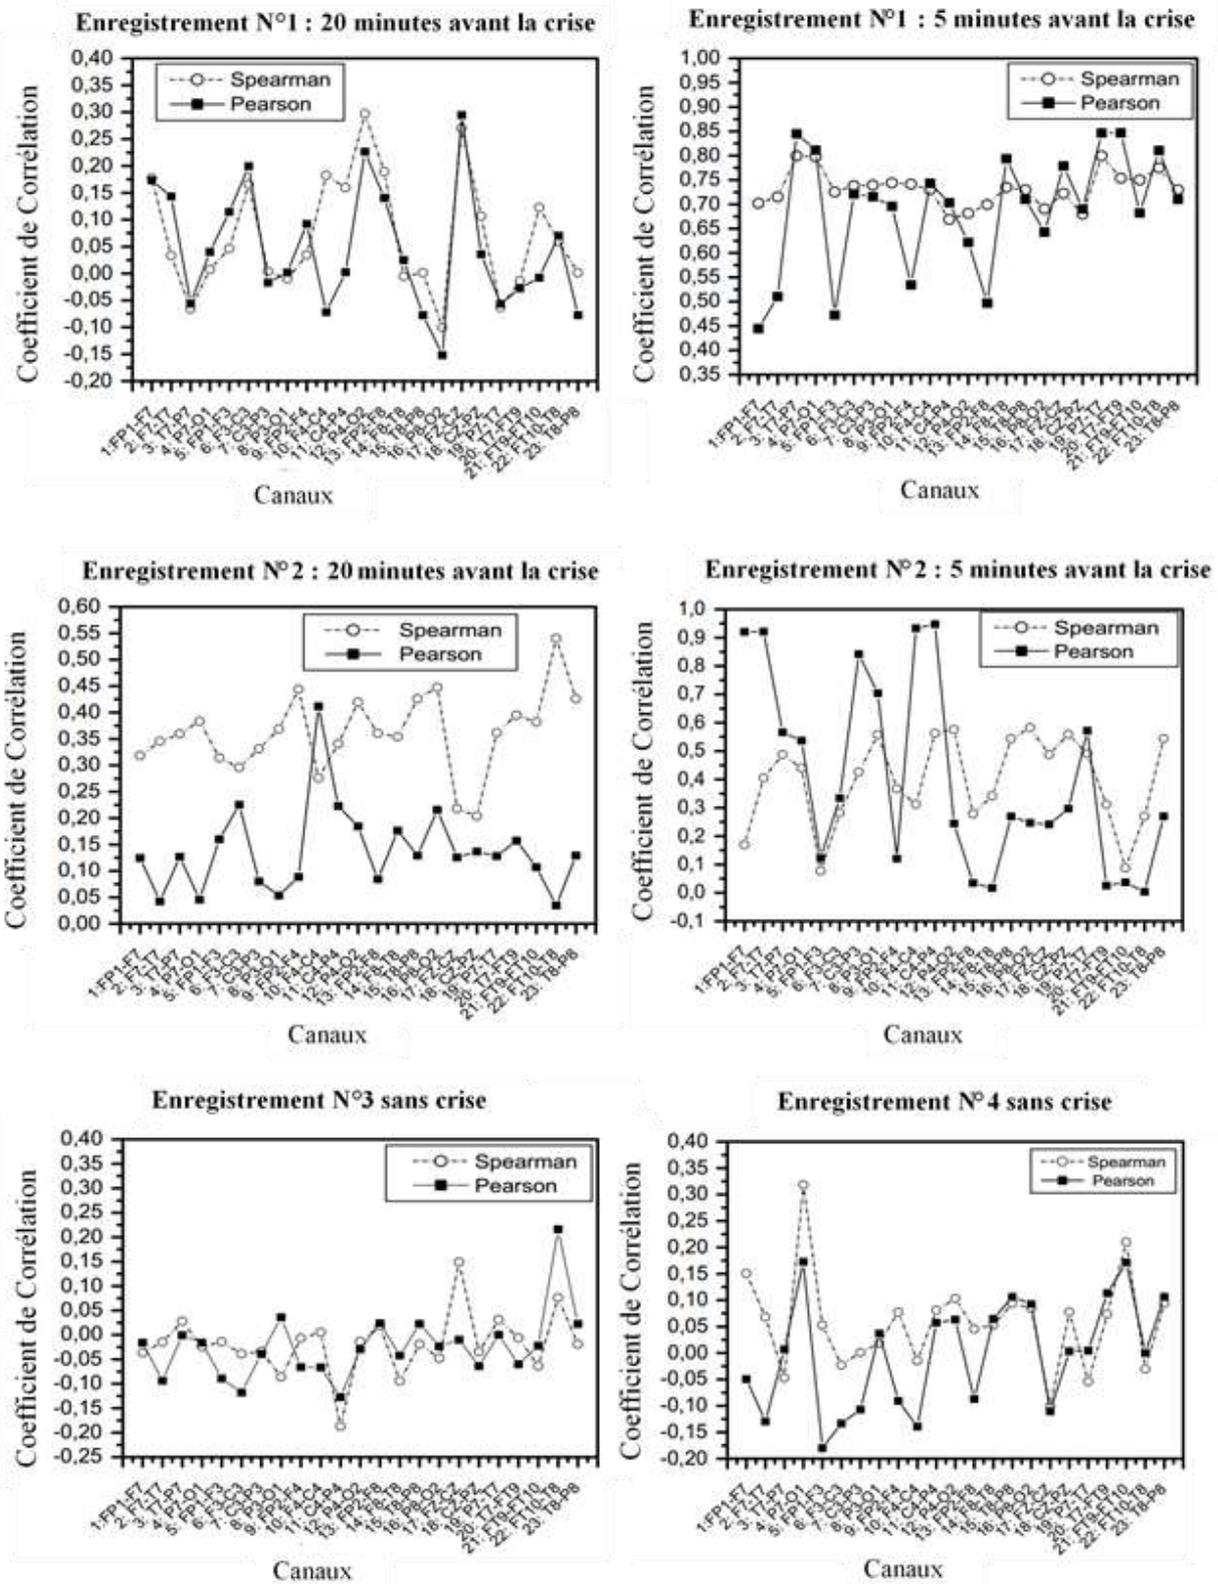


Figure V.7: Résultats de corrélation entre les énergies obtenues à partir des enregistrements 1 à 4 à travers tous les canaux du signal EEG (avec et sans crises épileptiques).

Le tableau V.1 résume tous les calculs des coefficients de corrélation Pearson noté ( $r_p$ ) et Spearman noté ( $r_s$ ) pour chaque enregistrement.

<b>Enregistrement (N°)</b>	<b>Temps</b>	<b>Coefficient de corrélation de Spearman <i>moy ± std</i> (<i>min~max</i>)</b>	<b>Coefficient de corrélation de Pearson <i>moy ± std</i> (<i>min~max</i>)</b>
Enregistrement N° 1	5 min Avant la crise	$0.73 \pm 0.03$ ( 0.66~0.79)	$0.68 \pm 0.12$ (0.44~0.84)
	20 min Avant la crise	$0.07 \pm 0.10$ (-0.10 ~ 0.29)	$0.04 \pm 0.11$ (-0.15 - 0.29)
Enregistrement N° 2	5 min Avant la crise	$0.39 \pm 0.15$ (0.07~0.58)	$0.40 \pm 0.33$ (0.003~0.94)
	20 min Avant la crise	$0.12 \pm 0.15$ (-0.09~0.44)	$0.16 \pm 0.08$ (-0.08~0.54)
Enregistrement N° 3	Sans Crise	$0.05 \pm 0.09$ (-0.10~0.31)	$0.08 \pm 0.10$ (-0.18~0.17)
Enregistrement N° 4	Sans Crise	$0.01 \pm 0.06$ (-0.18~0.14)	$-0.02 \pm 0.06$ (-0.12~0.21)

Tableau V.1 : Résumé de tous les calculs des coefficients de corrélation Spearman et Pearson.

Dans le tableau V.1 on peut voir qu'il existe une corrélation linéaire significative entre l'énergie de l'intervalle TP et l'énergie des segments de l'EEG dans les 5 minutes précédant l'apparition des crises avec un coefficient de corrélation Pearson et Spearman élevé (0,68 et 0,73 respectivement) et cela pour l'enregistrement N°1. Concernant l'enregistrement N°2 nous avons obtenus un coefficient de corrélation Pearson et Spearman moyen (0,40 et 0,39 respectivement). D'autre part, nous pouvons observer qu'il n'y a pas de corrélation significative dans les 20 minutes précédant la crise épileptique.

Les figures V.8 et V9 montrent selon la représentation des diagrammes en boîtes, tous les résultats obtenus en termes de médiane et d'écart-type.

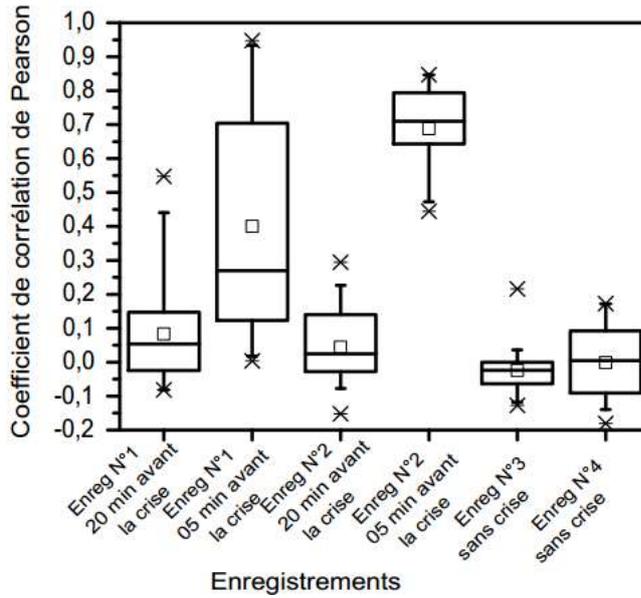


Figure V.8: Coefficient de corrélation de Pearson représenté en termes de médiane et d'écart-type des enregistrements 1 à 4 de tous les canaux du signal EEG (5 et 20 minutes avant la crise)

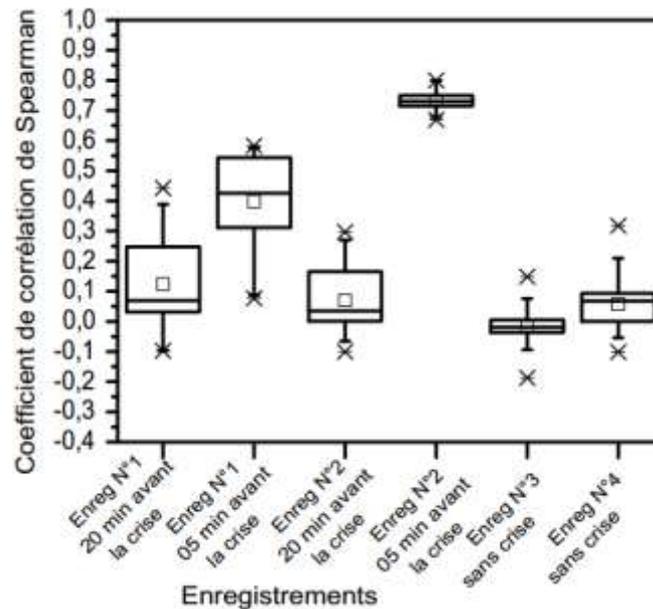


Figure V.9: Coefficient de corrélation de Spearman représenté en termes de médiane et d'écart-type des enregistrements 1 à 4 de tous les canaux du signal EEG (5 et 20 minutes avant la crise).

Nous pouvons également introduire l'algorithme de l'arbre de décision afin de voir le pourcentage de la vraie prédiction de la crise d'épilepsie, car les arbres de décision répondent à notre objectif, ils représentent graphiquement un ensemble de règles et sont aisément interprétables. Les algorithmes d'apprentissage par arbres de décision sont efficaces, disponibles dans la plupart des environnements de fouille de données. Pour cela l'ensemble des

énergies des segments calculées auparavant représentent notre nouveau vecteur paramétrique spécifique pour le processus de classification à base de l'algorithme proposé. Comme d'habitude ce vecteur est divisé en trois, le 1/3 sert à l'apprentissage de notre classifieur et les 2/3 restants correspondent à la population consacrée à la phase de test, ce qui permet d'évaluer la performance de l'algorithme de décision à travers les indicateurs statistiques décrits dans les sections précédentes (taux de classification, sensibilité et spécificité).

Nous envisageons de fixer un nombre d'arbres de 400 comme critère d'arrêt du processus de prédiction. Après le test effectué par cet algorithme, le taux de convergence d'erreur obtenu est illustré sur la figure V.10.

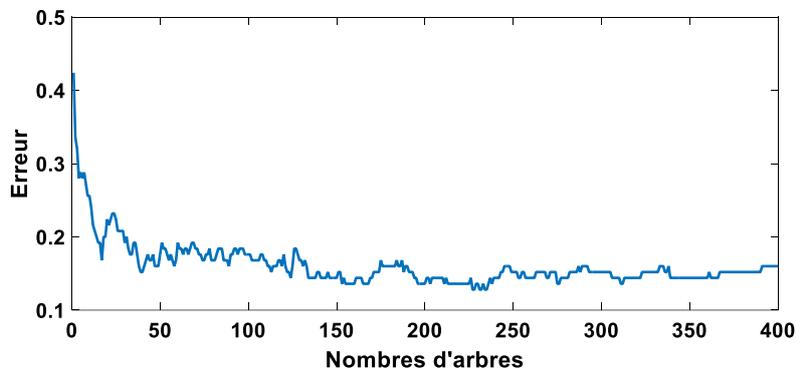


Figure V.10: Erreur de classification par l'algorithme de l'arbre de décision.

Nous remarquons qu'il n'y a pas de stabilité d'erreur, ce qui nous a conduit à faire plusieurs tests avec différents nombres d'arbres. Afin de sélectionner le bon nombre d'arbres qui nous ramène au meilleur taux de prédiction, nous envisageons de faire un balayage allant d'un seul arbre jusqu'à 400. Chaque fois que le taux de prédiction est sauvegardé dans un vecteur, les éléments de ce vecteur sont tracés et présentés sur la figure V.11.

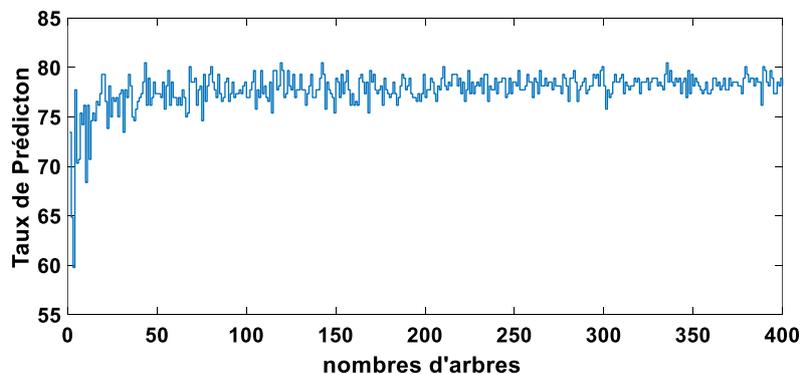


Figure V.11: Taux de prédiction pour chaque Nombre d'arbre.

Nous avons sélectionné les quatre différentes valeurs qui produise les meilleures performances. Les résultats obtenus en détail sont représentés dans le tableau V.2.

Nombre D'arbres	Taux de classification (%)	Sensibilité (%)	Spécificité (%)	Erreur
<b>43</b>	<b>80,47</b>	<b>72.81</b>	<b>86.82</b>	<b>0.176</b>
56	79.68	70.18	87.32	0.176
68	80.07	71.05	87.32	0.1920
89	78.90	72.81	83.80	0.16

Tableau V.2 : Performance de classification des quatre meilleurs nombres d'arbre de décision.

Après le test effectué par cet algorithme de l'arbre de décision, nous avons estimés le meilleur taux de prédiction à **80.47%**, avec une sensibilité et une spécificité de 72.81% et de 86.82% respectivement. Cette structure correspond aux nombres d'arbres de 43 avec une erreur de 0.176.

Les résultats obtenus qui concernent cette architecture sont représentés en détail par la matrice de confusion dans le tableau V.3.

Réelle	Prédite	
	Négative	Positive
Test Négative	<b>123</b> <b>48.05%</b>	<b>31</b> <b>12.11%</b>
Test Positive	<b>19</b> <b>7.42%</b>	<b>83</b> <b>32.42%</b>

Tableau V.3 : Matrice de confusion pour l'algorithme de décision avec 43 arbres.

A partir de cette matrice, nous pouvons également calculés la sensibilité et la spécificité qui sont égaux à :

- **Sensibilité (%) =72.81%.**
- **Spécificité (%) =86.82%**

L'arbre de décision a reconnu correctement 206 segments par les 256 segments, dont 83 cas correspond à la phase qui précède l'apparition de la crise, ce qui signifie que la prédiction de la crise est juste. Nous remarquons aussi notre algorithme de prédiction a raté 50 segments.

Le tracé de l'arbre de décision associé à ces conditions est illustré sur la figure V.12, sachant que chaque  $x_i$  représente l'énergie du segment sélectionné à partir du canal numéro  $i$ .

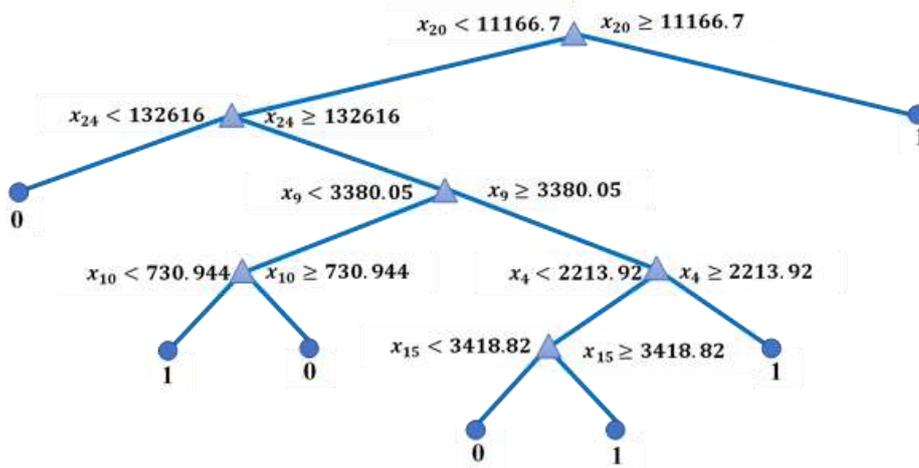


Figure V.12: Structure de l'arbre de décision.

Comme nous avons vu dans le chapitre précédent, l'algorithme de l'arbre de décision permet de tirer l'importance de chaque paramètre de la tribus mis en jeu dans le process de prédiction, dans cette étude, la question sera comme suit ; quel canal parmi les 24 canaux a contribué plus pour identifier l'apparition de la crise d'épilepsie ? La réponse sur cette question se trouve sur la figure V.13, ou on peut voir l'importance de chaque canal par rapport à un autre. Les canaux 5,9,10,13,19,20 pour le signal EEG a coté du canal 24 pour le signal ECG constitue l'ensemble des canaux les plus importants par rapport aux autres. L'autre remarque la plus importante est que le segment tiré depuis le signal ECG représente le canal le plus important, ce qui justifie et confirme l'efficacité de l'incorporation de l'information extraite depuis l'activité cardiaque (signal ECG).

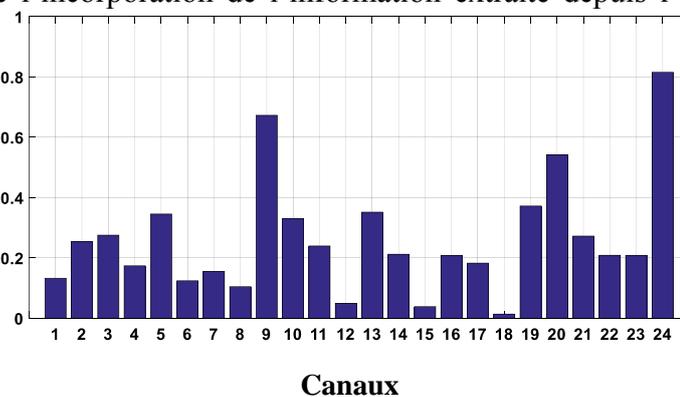


Figure V.13: Histogramme des canaux les plus importants dans le process de prédiction.

Nous pouvons constater à partir des résultats obtenus que l'algorithme de l'arbre de décision peut prédire la crise d'épilepsie. Mais nous noterons que le taux de la correcte prédiction est quasiment bon, ce qui nécessite une restructuration du vecteur paramétrique à travers une recherche approfondie. Cette recherche peut aboutir éventuellement à des discriminateurs encore plus pertinents, et qui permettra en fin de compte une meilleure compréhension et correcte prédiction de la crise d'épilepsie.

Nous identifions également la corrélation dans le domaine fréquentiel entre les signaux ECG et EEG avant et pendant la crise en termes de coefficient de cohérence quadratique (MSC) et de densité spectrale de puissance croisée (CPSD) comme mentionné dans les relations (V. 11) et (V. 12).

L'étude de fréquence a été effectuée sur une fenêtre de temps de 40 secondes avant 4 moments différents (30, 20, 10 et 5 minutes avant l'apparition des crises) et pendant les crises épileptiques (voir figure V.14).

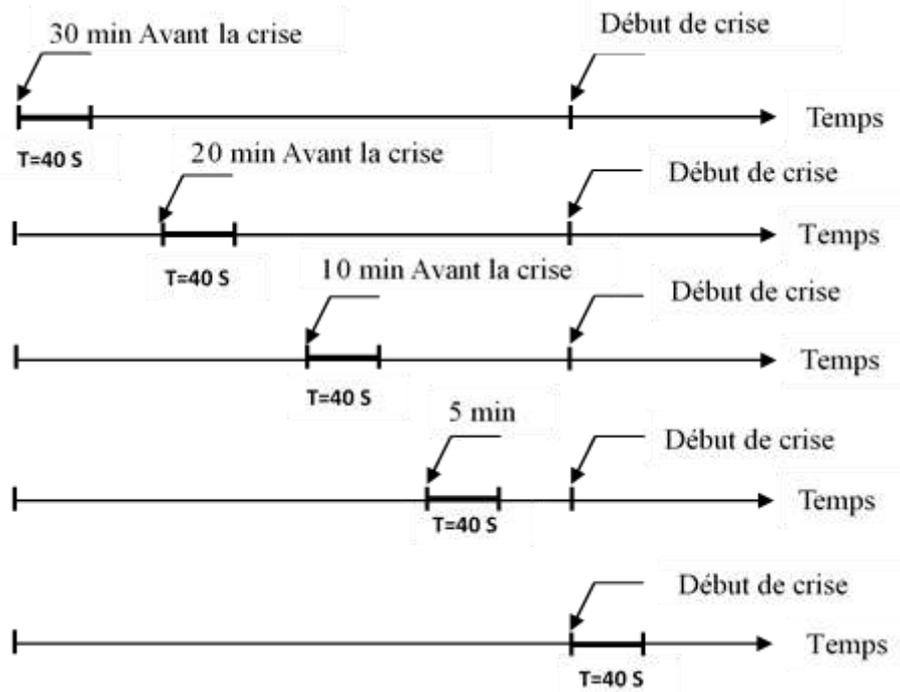


Figure V.14 : Représentation chronologique des étapes utilisées pour identifier la corrélation dans le domaine fréquentiel entre les signaux ECG et EEG avant et pendant la crise.

La figure V.15 représente la cohérence quadratique et la densité spectrale de puissance croisée obtenues à partir du canal EEG (FZ-CZ c'est à dire canal 17). On peut observer que dans la gamme de fréquences de 0 Hz à 25 Hz et pendant 30, 20, 10 minutes avant l'apparition des

crises, il y a un coefficient de cohérence quadratique (MSC) de grande amplitude, surtout autour de la fréquence de 3 Hz. Cependant, pendant 5 minutes avant l'apparition des crises et pendant la crise épileptique, un faible coefficient MSC est observé.

Dans la gamme de fréquences de 80 Hz à 100 Hz, en particulier autour de la fréquence de 100 Hz, nous signalons une augmentation du coefficient de cohérence et cela 5 minutes avant la crise. Nous pouvons également voir qu'il y a une augmentation significative du coefficient MSC dans la gamme de fréquences 80 Hz - 100 Hz pendant 10 et 5 minutes avant l'apparition des crises épileptiques. Dans la même figure, nous pouvons également observer une augmentation significative de la densité spectrale de puissance (CPSD) dans la gamme de fréquences de 0 Hz à 20 Hz avant le début des crises.

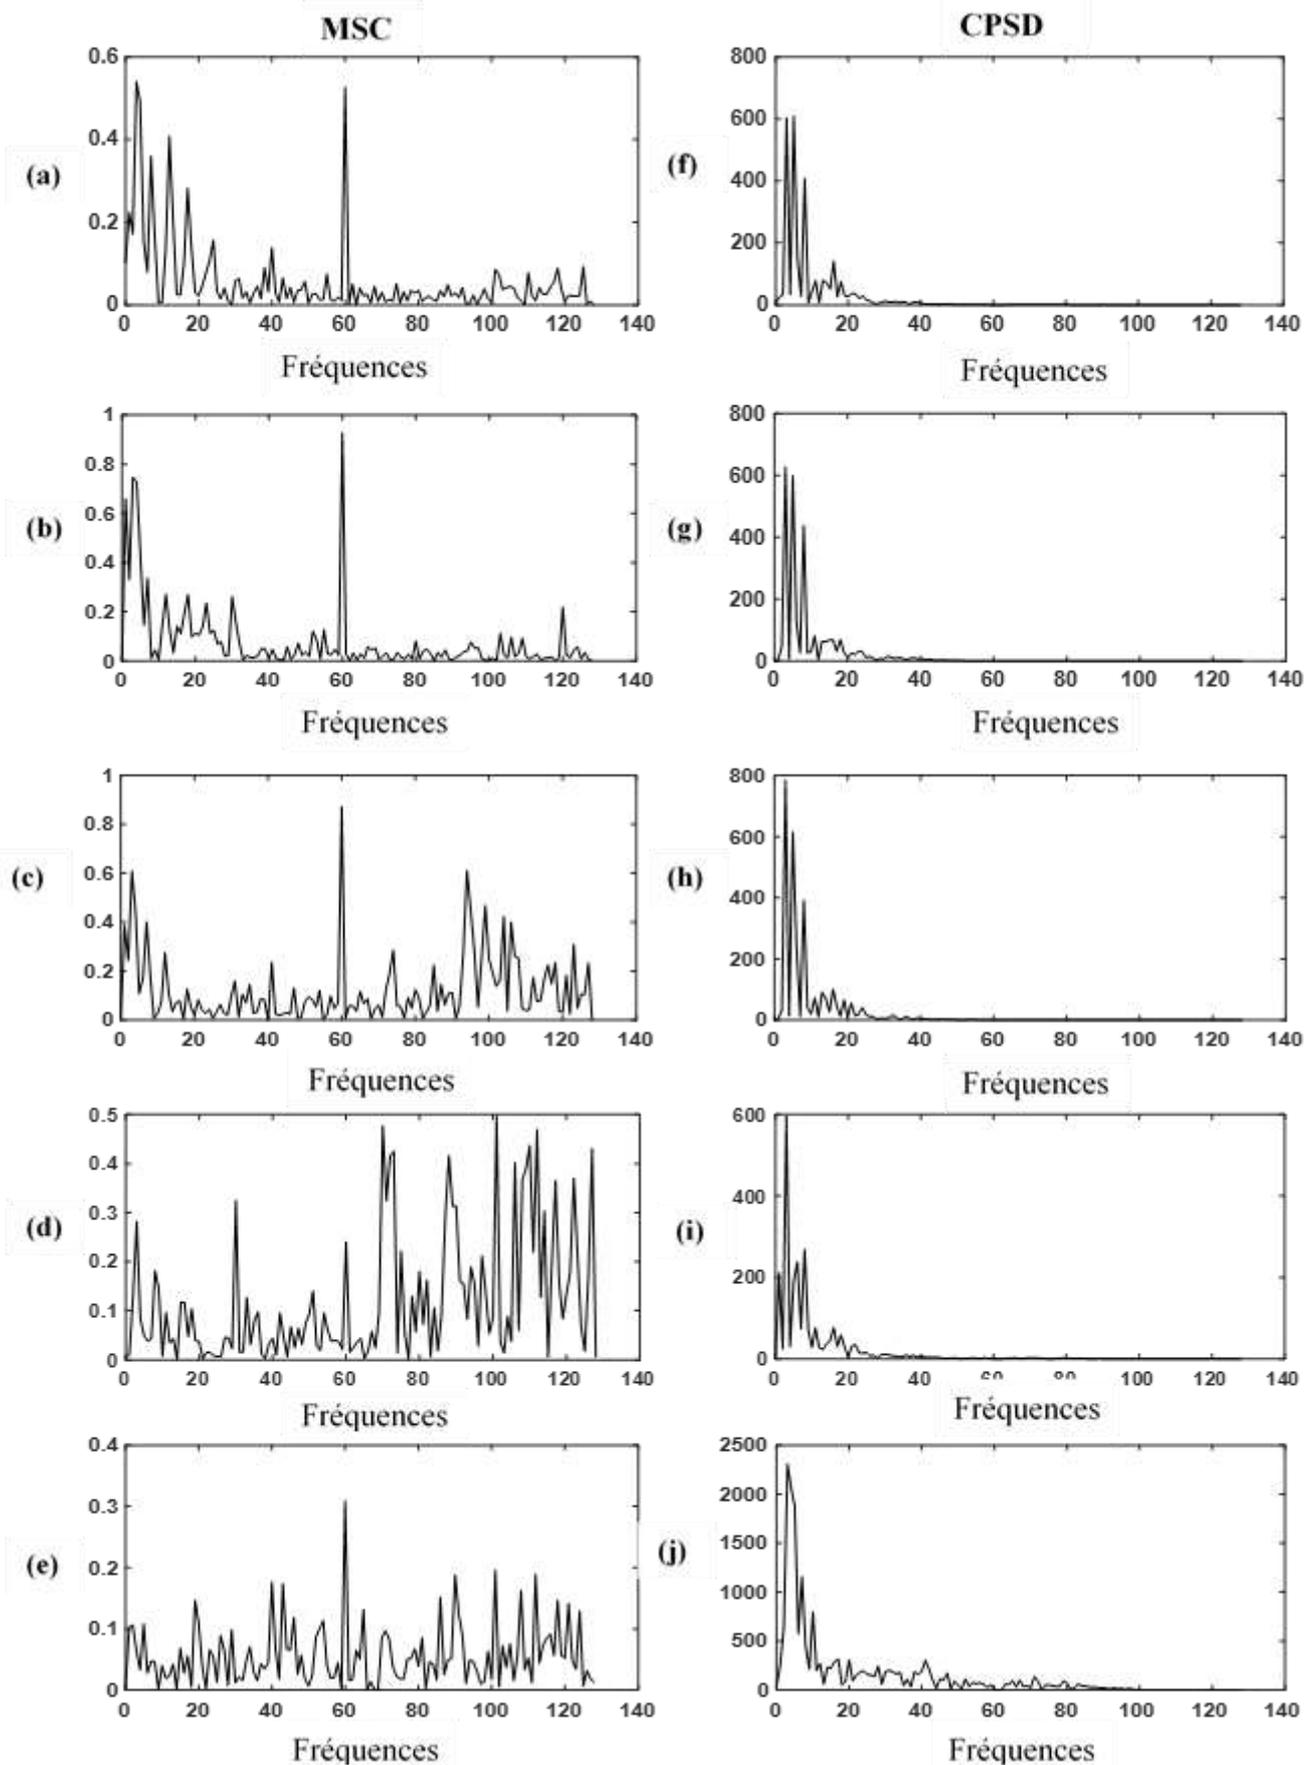


Figure V.15 : Coefficients de la cohérence quadratique (MSC) et de la densité spectrale de puissance (CPSD) obtenues à partir du signal EEG canal FZ-CZ (canal 17).

Comme le montrent les résultats, nous pouvons suggérer que les crises peuvent être prédites jusqu'à quelques minutes avant leur apparition en utilisant une corrélation entre l'énergie de l'intervalle TP de l'ECG et les énergies des segments EEG correspondante en utilisant le coefficient de cohérence (MSC) et la densité spectrale de puissance (CPSD).

## **V.5. Conclusion**

Dans cette partie une approche pour la prédiction des crises d'épilepsie basée sur la corrélation entre les paramètres de l'électrocardiogramme (ECG) et de l'électroencéphalogramme (EEG) a été présentée. La relation existante entre les paramètres de l'EEG et de l'ECG a été étudiée dans le domaine temporelle et fréquentielle. Les résultats obtenus montrent une forte augmentation de la corrélation entre l'énergie de l'intervalle TP et l'énergie EEG quelques minutes avant l'apparition des crises. Des variations du coefficient de cohérence quadratique (MSC) et de la densité spectrale de puissance (PCDS) ont également été observées juste avant les crises d'épilepsie. L'algorithme proposé nous permettra de prédire l'apparition précoce des crises, d'où nous pouvons également utiliser comme indicateur de précaution des crises épileptiques.

## CONCLUSION GENERALE

Nous nous sommes intéressés durant cette thèse à l'étude des relations pouvant exister entre l'activité cérébrale exprimée par le signal électroencéphalogramme (EEG) et l'activité cardiaque traduite par le signal électroencéphalogramme (ECG).

L'étude était divisée en plusieurs étapes, commençons par la première étape, où une chaîne complète d'acquisition à distance des signaux EEG et ECG a été conçue, afin de servir à réaliser une base de données personnelle sans avoir recours à d'autres bases. Les signaux acquis par le circuit électronique proposé ont la possibilité d'être transmis sans fil via des modules de transmission à distance (XBee et Bluetooth) et arrivent finalement au PC sur une interface graphique réalisée sous Matlab permettant l'enregistrement simultané en temps réel de ces signaux. De plus un ensemble d'opérations de traitement de signal numérique a été effectué pour pouvoir tester et caractériser la relation entre l'EEG et l'ECG.

La deuxième étape consistait à concevoir un module d'aide au diagnostic dédié au patient souffrant de crises d'épilepsie basé sur l'intelligence artificielle, une caractérisation à travers des paramètres temporels extraits à partir de la base de données CHB-MIT Scalp EEG, disponible gratuitement sur Physionet. Cette caractérisation permettait de démontrer l'importance de l'incorporation de l'information complémentaire déduite depuis l'ECG pour la reconnaissance des crises d'épilepsie à travers des algorithmes de réseaux de neurones artificiels (RNA), nous avons également testé plusieurs structures des réseaux de neurones artificiels en changeant les paramètres constituant les réseaux de neurones, et qui nous a permis d'atteindre une bonne performance de détection de crise.

La troisième étape était considérée comme une étude complémentaire de l'étape précédente, où la décomposition en ondelettes discrètes était introduite afin de diviser les signaux enregistrés simultanément en quatre sous-bandes, chaque bande représentait une partie de la fréquence constituant la plage fréquentielle complète de nos signaux. La phase de caractérisation avait aussi subi une extension, de telle sorte qu'à côté du domaine temporel un ensemble de paramètres avait été extrait depuis le domaine fréquentiel. Ces paramètres sont exprimés par la cohérence quadratique et la densité spectrale de puissance. La performance de détection est encore améliorée avec un taux de reconnaissance très élevé, cela traduisant l'efficacité de la

méthode proposé pour concevoir un système d'authentification des crises d'épilepsie basé sur les paramètres du signal EEG et ECG.

Pour la dernière étape, nous passons de la phase de détection à la phase de prédiction, on est confronté à la situation de prédiction de la crise avant son apparition. Cette étape consistait à trouver un algorithme performant qui permettait la quantification de la corrélation entre les deux activités électrophysiologiques. Dans ce contexte, les énergies des segments TP avec leur segment EEG correspondantes sont corrélées. Le taux de corrélation avait été exprimé par les coefficients de Spearman et Pearson d'une part, et par l'utilisation de l'algorithme de l'arbre de décision. Nous avons mis en œuvre également un autre algorithme basé sur le calcul de cohérence quadratique ainsi que la densité spectrale de puissance entre les deux signaux, et cela sur plusieurs durées qui précède l'apparition de la crise. L'ensemble des résultats obtenus ainsi que les méthodes développées nous ont été utiles pour concevoir un système d'authentification de l'apparition de la crise épileptiques basé sur les signaux EEG et ECG, et qui pourra être en fin de compte un outil efficace pour l'aide au diagnostic.

Ce travail nous a ouvert plusieurs perspectives, il serait intéressant d'approfondir les recherches sur l'interaction entre le signal ECG et le signal EEG à travers la recherche des nouveaux paramètres agissant d'une manière positive dans le processus de classification. D'autres améliorations peuvent être faites au niveau de la chaîne d'acquisition en augmentant le nombre de canaux acquis pour le signal EEG avec plus de dérivations pour le signal ECG. Un système de stockage externe (carte mémoire externe) peut être éventuellement utilisé pour plus d'autonomie de notre système.

# Bibliographie

Abdelliche, F. (2011) 'Contribution au diagnostic des signaux électrocardiographiques en utilisant les concepts des fractales', *Thèse de Doctorat, département d'électronique, Faculté Des Sciences De L'ingénieur. Université Mentouri De Constantine, Algérie.*

Ali, S. and John, G. (2009) 'Application of Machine Learning to Epileptic Seizure Detection', *Doctor of Philosophy in Electrical and Medical Engineering, Harvard-MIT Divion of Health Sciences and Technology.*

Ali, S, Herman. E, Jack. C, Blaise. B. STed. T, and John. G. (2004) 'Patient-specific seizure onset detection', *Elsevier Epilepsy & Behavior* 5, pp 483–498.

Anders, I., Arne W. and Lars H. Z. (1981) 'Computer analysis of EEG signals with parametric models', *Proceedings of the IEEE*, Vol. 69, NO. 4. pp 451-4610.

André, H. (2010) 'EEG signal processing and emotiv's neuro headset'. *Thèse de baccalauréat, Université technique de Darmstadt.*

Arduino home (2016) [online] <https://www.arduino.cc/>

Arnab, R., Anwasha, B., Ankita, M., Poulami, G., Anilesh, D. and Tibarewala, D.N. (2017) 'Fractal analysis of EEG signals of EEG signals for studying the effect of cognitive stress on brain', *Int. J. Biomedical Engineering and Technology*, Vol. 25, No. 2/3/4, pp.336–369.

Arnaud, M. (2010) 'Caractérisation de la relation structure-fonction dans le cerveau humain à partir de données d'IRM fonctionnelle et de diffusion : méthodes et applications cognitive et clinique'. *Neurosciences Université Nice Sophia Antipolis.*

Arne, J. and Anders. L, C. (2001) 'Ripples in Mathematics the Discrete Wavelet Transform', *Springer-Verlag Berlin Heidelberg New York*. ISBN 3-540-41662-5.

Bachir, M S. (2017) 'L'évaluation de l'influence de la respiration sur le rythme cardiaque et les paramètres du signal électrocardiogramme (ECG) ', *Thèse de Doctorat, Département de Génie biomédical, faculté de la Technologie, université de Tlemcen.*

Balasaraswathy, N. and Rajavel, R. (2015) 'Automatic seizure detection system with low complex PSD using TMS320C6713 DSP', *Int. J. Biomedical Engineering and Technology*, Vol. 18, No. 2, pp.139–155.

Belaid, B. (2014) 'Etude et réalisation d'un système d'acquisition temps réel des signaux EEG&EMG', *Master en Electronique Biomédicale, Département Génie Biomédical, Faculté de technologie, université de Tlemcen, Algérie.*

Boukari, N. (2016a) 'Adaptive combination methods of autoregressive parameters for epileptic EEG signals classification', *Int. J. Biomedical Engineering and Technology*, Vol. 22, No. 1, pp.47–57.

Boukari, N. (2016b) 'Combined odd pair autoregressive coefficients for epileptic EEG signals classification by radial basis function neural network', *Int. J. Biomedical Engineering and Technology*, Vol. 22, No. 4, pp.314–324.

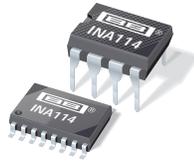
- Bruno, T. (1995) 'Analyse continue par ondelettes' *InterEditions*, 5, ISBN 2 7296 0591 6.
- Carlos, G M. and Armando, M T. (2012) 'EEG signal processing for epilepsy' *University Carlos III of Madrid, Signal Theory and Communications Department Avda, Universidad, 30 28911 Leganes*. pp 49-74.
- Chapelon, A C. (2004), 'Électrocardiogramme normal de l'adulte', *Encyclopédie Médico-Chirurgicale* 11-003-F-30.
- Crouzeix, A. (2001) 'Méthodes de localisation des générateurs de l'activité électrique cérébrale à partir de signaux électro- et magnétoencéphalographies', *Thèse De Doctorat, Génie Biologique Et Médical, L'institut National Des Sciences Appliquées De Lyon*.
- Dabbagh, A., Esmailian, F, and Aranki, S F. (2014) 'Postoperative critical care for cardiac surgical patients', *Springer Heidelberg New York*, ISBN 978-3-642-40417-7.
- Debbal, S,M(2004) 'Aalyse du signal Phonocardiogramme par Application des Transformées d'Ondelettes' thèse de doctorat d'état université Aboubekr Belkaid Tlemcen.
- Dumas, J. (2001) 'L'analyse Temps – Fréquence', *01dB-STELL (Groupe MVI technologies)* pp.1–40.
- Feneck, B. and Duncan, F. (1994) 'How to read the ECG part 1', *Current Anaesthesia and Critical Care*, p.223:230.
- Freeman, W.J. and Quian Q, R. (2013) 'Imaging brain function with EEG: advanced temporal and spatial analysis of electroencephalographic signals', *Springer Science, New York*, pp,1-19.
- Garima Chandel, P.P., Muhammed, S., Omar, F. and Yusuf, U.K. (2017) 'A simplified method for classification of epileptic EEG signals', *Int. J. Biomedical Engineering and Technology*, Vol. 25, No. 1, pp.60–76.
- Geoffray, A. (2005) 'Méthodes de traitement d'image appliquées au problème inverse en magnéto- électro-encéphalographie.', *Thèse de doctorat en informatique, Ecole National des Pont et des Chaussé*.
- Gertsch, M. (2004), 'The normal ECG and its (normal) variants', *Springer-Verlag Berlin Heidelberg*, pp.19:20.
- Goldberger, A., Amral, L., Glass, L., Hausdorff, J., Ivanov, P., Mark, R., Mietus, J., Moody, G., Peng, C., and Stanley, H. (2000) 'Physiobank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals', *Circulation*, Vol. 101, No. 23, pp.215–220
- Hadj slimane, Z. (2006) 'Analyse et synthèse de méthodes de détection du complexe QRS du signal électrocardiogramme', *Thèse de Doctorat, Département D'Electronique Faculté Des Sciences De L'ingénieur, Université De Tlemcen*.
- Hadj Slimane, Z.E. and Nait-Ali, A. (2010) 'QRS complex detection using Empirical Mode Decomposition', *Digital Signal Processing*, Vol. 20, pp.1221–1228.
- Hauke, J. and Kossowski, T. (2011) 'Comparison of Values of Pearson's and Spearman's Correlation Coefficients on the Same Sets of Data. Quaestiones Geographicae', Vol.30, No. 2.
- Iosif, M., Vasiliki, T., Evangelia, I., Michalis, K., Mark, R. and Vasileios, M. (2015) 'Seizure detection using EEG and ECG signals for computer-based monitoring, analysis and management of epileptic patients', *Expert Systems with Applications*, Vol. 42, No.6, pp. 3227-3233.

- Jacky, D. (2001) 'L'analyse temps – fréquence' 01dB-STELL Groupe MVI technologies
- JAMES N. KNIGHT. (2003). 'Signal fraction analysis and artifact removal in EEG'. *Master of science, Colorado State University*.
- Janaka, E., Kithsiri, L., Jianzhong, W., Akihiko, Y. and Nick, J.(2012)' Smart Grid Technology And Applications' *A John Wiley & Sons, Ltd., Publication, ISBN 978-0-470-97409-4*.
- Kamel, A. (2012). 'Caractérisation du cerveau humain : application à la biométrie', *Thèse de doctorat traitement de signal et de l'image, Mathématique et Science et Technologies de l'Information et de la Communication, université Paris Est*.
- Kaat. V, Thomas De. C, Ying. G, Evy, C. Kasper, C. Wim Van. P, Sabine Van H. and Borbála H. (2017) 'Automated Epileptic Seizure Detection Based on Wearable ECG and PPG in a Hospital Environment', *Journal Sensors*, pp 1-12
- Kaminska, A. et Perrine, P. (2006) 'Apport de l'EEG dans le diagnostic et le suivi des épilepsies de l'enfant' *mt pédiatrie paris*, vol. 9, n° 5-6, pp 278-292.
- Kim E, B, and Scott, B. (2010) 'Ganong's review of medical physiology twenty-third edition', *the McGraw-Hill Companies*, ISBN: 978-0-07-160568-7.
- Laguna, P., Thakor, N.V., Caminal, P., Jané, R., Hyung-Ro, Y., Bayés de Luna, A., Marti, V. and Josep, G. (1990) 'New algorithm for QT interval analysis in 24-hour Holter ECG: performance and applications', *Medical & Biological Engineering & Computing*, Vol. 28, pp.63–73.
- Laguna, P., Jané, R. and Caminal, P. (1994) 'Automatic detection of wave boundaries in multilead ECG signals: Validation with the CSE data-base', *Comput. Biomed. Res.*, Vol. 27, No. 1, pp.45–60.
- Li, Z., Zhang, X., Mohua, G. A. and Vassili, K. (2018)'Artificial Neural Networks (ANNs) for Spectral Interference Correction Using a Large-Size Spectrometer and ANN-Based Deep Learning for a Miniature One', *Intech Open Science*, chapter 12 pp. 227-248.
- Masse, F., van Bussel, M., Serteyn, A., Arends, J., and Penders, J. 2013. Miniaturized wireless ECG monitor for real-time detection of epileptic seizures. *ACM Trans. Embedd. Comput. Syst.* 12, 4, Article 102 (June 2013), 21 pages
- Martijn, A. (2011) 'Personalized medecin in ADHD and depression a quest For EEG treatment predictors', *IPSKOMP DRUKKERS' AMSTERDAM*.
- Mathew, B, A. (2006) 'Entropy Of Electroencephalogram (EEG) Signals Changes With Sleep State', *University of Kentucky Master's Teses*. 203.
- Maurice, B. (2012) 'Traitement Numérique du Signal' *8 ieme édition DUNOD, ISBN: 978-2100041862*
- Michael, A. A. (2003)'The Handbook of Brain Theory and Neural Networks Second Edition ', *The Mit Press Cambridge, Massachusetts London, England, ISBN 0–262–01197–2*.
- Michael, M. and Nicholas, W. (2011)'Arduino CookBook' *O'Reilly Media, ISBN: 978-0-596-80247-9*.

- Mohammed, Z., Faiz, Al, and Abbas H. M(2012) ‘Artificial Human Arm Driven by EMG Signal’, *Intech Web of Science* chapter 16 pp.365–392.
- Nasehi S., Pourghassem H. (2012) Seizure Detection Algorithms Based on Analysis of EEG and ECG Signals: a Survey’, *Neurophysiology*. 44(2), 174-186
- Nian, S. C. (2008) ‘Pearson’s versus Spearman’s and Kendall’s correlation coefficients for continuous data’, *B.S. Winona State University*. Available on line at [http://d-scholarship.pitt.edu/8056/1/Chokns\\_etd2010.pdf](http://d-scholarship.pitt.edu/8056/1/Chokns_etd2010.pdf)
- PhysioBank database. (2016) [online] <https://physionet.org/physiobank/database/chbmit/>
- Rahul, U., Swati, J., Prabin, K.P. and Pavan, K.K. (2015) ‘Application of wavelet fractal features for the automated detection of epileptic seizure using electroencephalogram signals’, *Int. J. Biomedical Engineering and Technology*, Vol. 19, No. 4, pp.355–372.
- Raoul, S, and Peter, W. K. (2017) ‘The History of Continuous EEG Monitoring’, *Springer International Publishing Switzerland*, pp.3 – 12.
- Roy, M. H. (2002) ‘Principles of Random Signal Analysis and Low Noise Design The Power Spectral Density and its Applications’ *Curtin University of Technology Perth, Australia, ISBN: 0-471-22617-3*
- Sebastian R. (2015). ‘Python Machine Learning’ Packt Publishing ISBN 978-1-78355-513-0.
- Stefan, A.A.(2015) ‘An Introduction To Deep Learning’, *A Thesis Submitted For The Degree Of Bachelor Of Science The Faculty Of Engineering And Physical Sciences University Of Manchester*.
- Suguna, B. and Santhi, B. (2015) ‘Different approaches of analysing EEG signals for seizure detection’, *Int. J. of Signal and Imaging Systems Engineering*, Vol. 8, No. 1/2, pp.28–38.
- Sende, J. (2003) ‘ Guide pratique ECG’, *Editions ESTEM de BOECK DIFFUSION, Paris, ISBN 2-84271-2106*.
- Stefan, S, et Florian, L. (2000) ‘ Atlas de Poche de Physiopathologie’, *Médecine-Sciences Flammarion, Paris*.
- Tatum, W.O., Husain, A.M., Benbadis, S.R. and Kaplan, P.W. ‘Handbook of EEG **interpretation**’, 2nd Edition, Kindle Edition.
- Thomas, B., David, L. and Anne, L., (2009) ‘EEG/ECG information fusion for epileptic event detection’, *IEEE the 16th international conference on Digital Signal Processing*, pp 824-831.
- Tonya, H. (2016) ‘Anatomy of the brain’, *Mayfield clinic Brain & Spine USA <https://mayfieldclinic.com/PE-AnatBrain.htm>*.
- Tortora, GJ, and Grabowski, S.R. (1993) ‘Principles of anatomy and physiology, seventh edition’, *Biological Sciences Textbooks*, ISBN 2-8041-1024-9 De Boeck.
- Truchetet, F. (1998) ‘ Ondelettes pour le Signal Numérique ’, *Editions Hermes, Paris*,
- Valderrama M., Nikolopoulos S., Adam C., Navarro V., Le Van Quyen M. (2010) ‘Patient-specific seizure prediction using a multi-feature and multi-modal EEG-ECG classification’, *XII Med. Conf. on Medical and Biological Engineering and Computing*. 29, 77-80.

- Valerie C, S, and Tina S. (2007) 'Essentials of anatomy and physiology Fifth Edition ', *F. A. Davis Company Philadelphia*.
- Varun, B. and Ram Bilas, P. (2012) 'Classification of Seizure and Nonseizure EEG Signals Using Empirical Mode Decomposition ', *IEEE transactions on information technology in biomedicine*, VOL. 16, NO. 6, pp.1135–1142.
- William, O., Aatif, M, H., Selim R, B. and **Peter**, W, K. (2008) 'Handbook of EEG **interpretation** ', *edition Demo*.
- Worawich, P. Songol, O, and Yodchanan, W. (2014) 'The Preliminary Study of EEG and ECG for Epileptic Seizure Prediction based on Hilbert Huang Transform', *The 2014 Biomedical Engineering Interational Conference (BMEiCON-2014)*, *IEE 978-1-4799-6801-5/14/*.
- Yusuf, U.K. and Omar, F. (2015) 'Wavelet-based multi-class discrimination of EEG for seizure detection', *Int. J. Biomedical Engineering and Technology*, Vol. 19, No. 3, pp.266–278.
- Zachary, C. (2011). 'Comparison of EEG preprocessing methods to improve the classification of P300 Trials', *thesis Master of Science, Colorado State University*.

# ANNEX



INA114

# Precision INSTRUMENTATION AMPLIFIER

## FEATURES

- **LOW OFFSET VOLTAGE:** 50µV max
- **LOW DRIFT:** 0.25µV/°C max
- **LOW INPUT BIAS CURRENT:** 2nA max
- **HIGH COMMON-MODE REJECTION:** 115dB min
- **INPUT OVER-VOLTAGE PROTECTION:** ±40V
- **WIDE SUPPLY RANGE:** ±2.25 to ±18V
- **LOW QUIESCENT CURRENT:** 3mA max
- **8-PIN PLASTIC AND SOL-16**

## DESCRIPTION

The INA114 is a low cost, general purpose instrumentation amplifier offering excellent accuracy. Its versatile 3-op amp design and small size make it ideal for a wide range of applications.

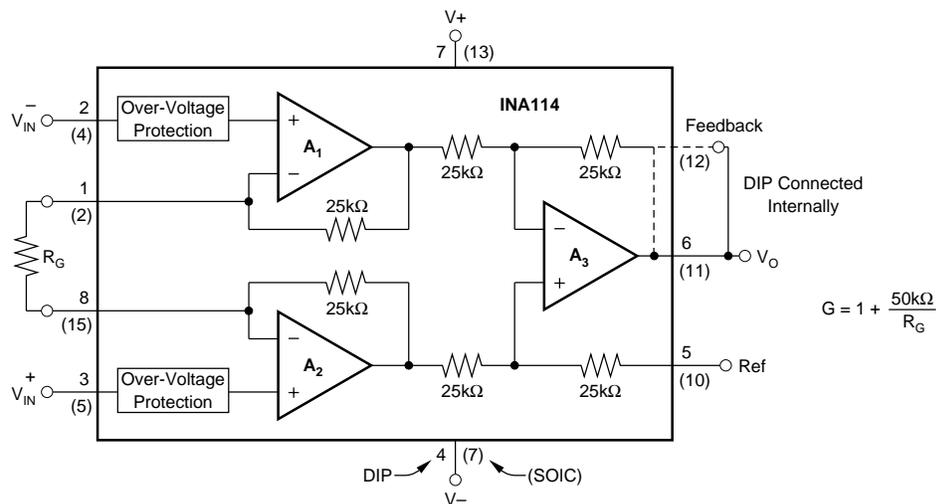
A single external resistor sets any gain from 1 to 10,000. Internal input protection can withstand up to ±40V without damage.

The INA114 is laser trimmed for very low offset voltage (50µV), drift (0.25µV/°C) and high common-mode rejection (115dB at G = 1000). It operates with power supplies as low as ±2.25V, allowing use in battery operated and single 5V supply systems. Quiescent current is 3mA maximum.

The INA114 is available in 8-pin plastic and SOL-16 surface-mount packages. Both are specified for the -40°C to +85°C temperature range.

## APPLICATIONS

- BRIDGE AMPLIFIER
- THERMOCOUPLE AMPLIFIER
- RTD SENSOR AMPLIFIER
- MEDICAL INSTRUMENTATION
- DATA ACQUISITION



International Airport Industrial Park • Mailing Address: PO Box 11400, Tucson, AZ 85734 • Street Address: 6730 S. Tucson Blvd., Tucson, AZ 85706 • Tel: (520) 746-1111 • Twx: 910-952-1111  
Internet: <http://www.burr-brown.com/> • FAXLine: (800) 548-6133 (US/Canada Only) • Cable: BBRCORP • Telex: 066-6491 • FAX: (520) 889-1510 • Immediate Product Info: (800) 548-6132

# SPECIFICATIONS

## ELECTRICAL

At  $T_A = +25^\circ\text{C}$ ,  $V_S = \pm 15\text{V}$ ,  $R_L = 2\text{k}\Omega$ , unless otherwise noted.

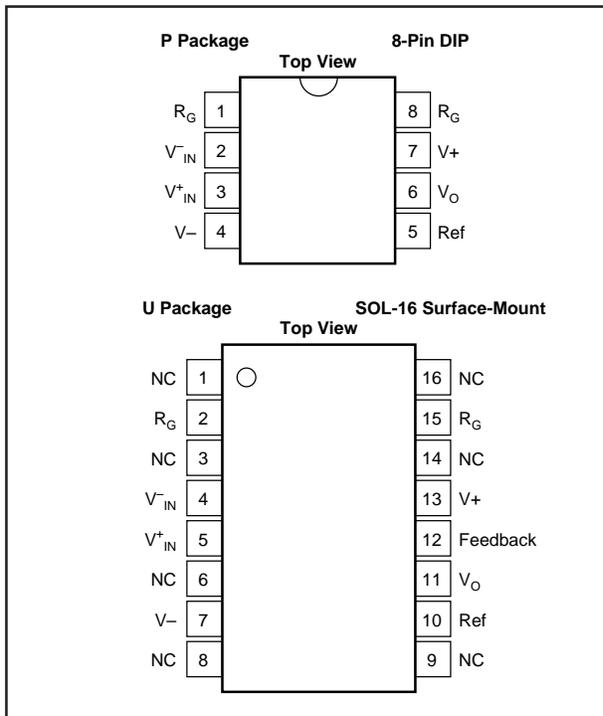
PARAMETER	CONDITIONS	INA114BP, BU			INA114AP, AU			UNITS
		MIN	TYP	MAX	MIN	TYP	MAX	
<b>INPUT</b> Offset Voltage, RTI Initial vs Temperature vs Power Supply Long-Term Stability Impedance, Differential Common-Mode Input Common-Mode Range Safe Input Voltage Common-Mode Rejection	$T_A = +25^\circ\text{C}$ $T_A = T_{\text{MIN}}$ to $T_{\text{MAX}}$ $V_S = \pm 2.25\text{V}$ to $\pm 18\text{V}$  $V_{\text{CM}} = \pm 10\text{V}$ , $\Delta R_S = 1\text{k}\Omega$ $G = 1$ $G = 10$ $G = 100$ $G = 1000$		$\pm 10 + 20/G$ $\pm 0.1 + 0.5/G$ $0.5 + 2/G$ $\pm 0.2 + 0.5/G$ $10^{10} \parallel 6$ $10^{10} \parallel 6$ $\pm 13.5$	$\pm 50 + 100/G$ $\pm 0.25 + 5/G$ $3 + 10/G$		$\pm 25 + 30/G$ $\pm 0.25 + 5/G$ * * * * *	$\pm 125 + 500/G$ $\pm 1 + 10/G$ * * * * *	$\mu\text{V}$ $\mu\text{V}/^\circ\text{C}$ $\mu\text{V}/\text{V}$ $\mu\text{V}/\text{mo}$ $\Omega \parallel \text{pF}$ $\Omega \parallel \text{pF}$ $\text{V}$ $\text{V}$
<b>BIAS CURRENT</b> vs Temperature			$\pm 0.5$ $\pm 8$	$\pm 2$		* *	$\pm 5$	nA $\text{pA}/^\circ\text{C}$
<b>OFFSET CURRENT</b> vs Temperature			$\pm 0.5$ $\pm 8$	$\pm 2$		* *	$\pm 5$	nA $\text{pA}/^\circ\text{C}$
<b>NOISE VOLTAGE, RTI</b> $f = 10\text{Hz}$ $f = 100\text{Hz}$ $f = 1\text{kHz}$ $f_B = 0.1\text{Hz}$ to $10\text{Hz}$ Noise Current $f = 10\text{Hz}$ $f = 1\text{kHz}$ $f_B = 0.1\text{Hz}$ to $10\text{Hz}$	$G = 1000$ , $R_S = 0\Omega$		15 11 11 0.4			* * * *		$\text{nV}/\sqrt{\text{Hz}}$ $\text{nV}/\sqrt{\text{Hz}}$ $\text{nV}/\sqrt{\text{Hz}}$ $\mu\text{Vp-p}$
<b>GAIN</b> Gain Equation Range of Gain Gain Error  Gain vs Temperature 50k $\Omega$ Resistance <sup>(1)</sup> Nonlinearity	$G = 1$ $G = 10$ $G = 100$ $G = 1000$ $G = 1$  $G = 1$ $G = 10$ $G = 100$ $G = 1000$	1	$1 + (50\text{k}\Omega/R_G)$  $\pm 0.01$ $\pm 0.02$ $\pm 0.05$ $\pm 0.5$ $\pm 2$ $\pm 25$ $\pm 0.0001$ $\pm 0.0005$ $\pm 0.0005$ $\pm 0.002$	10000  $\pm 0.05$ $\pm 0.4$ $\pm 0.5$ $\pm 1$ $\pm 10$ $\pm 100$ $\pm 0.001$ $\pm 0.002$ $\pm 0.002$ $\pm 0.01$	*	* * * * * * * * * * * *	* * $\pm 0.5$ $\pm 0.7$ $\pm 2$ $\pm 10$ * $\pm 0.002$ $\pm 0.004$ $\pm 0.004$ $\pm 0.02$	V/V V/V % % % % ppm/ $^\circ\text{C}$ ppm/ $^\circ\text{C}$ % of FSR % of FSR % of FSR % of FSR
<b>OUTPUT</b> Voltage  Load Capacitance Stability Short Circuit Current	$I_O = 5\text{mA}$ , $T_{\text{MIN}}$ to $T_{\text{MAX}}$ $V_S = \pm 11.4\text{V}$ , $R_L = 2\text{k}\Omega$ $V_S = \pm 2.25\text{V}$ , $R_L = 2\text{k}\Omega$	$\pm 13.5$ $\pm 10$ $\pm 1$	$\pm 13.7$ $\pm 10.5$ $\pm 1.5$ 1000 $+20/-15$		* * *	* * * * * *		V V V pF mA
<b>FREQUENCY RESPONSE</b> Bandwidth, -3dB  Slew Rate Settling Time, 0.01%  Overload Recovery	$G = 1$ $G = 10$ $G = 100$ $G = 1000$ $V_O = \pm 10\text{V}$ , $G = 10$ $G = 1$ $G = 10$ $G = 100$ $G = 1000$ 50% Overdrive		1 100 10 1 0.6 18 20 120 1100 20			* * * * * * * * * *		MHz kHz kHz kHz V/ $\mu\text{s}$ $\mu\text{s}$ $\mu\text{s}$ $\mu\text{s}$ $\mu\text{s}$ $\mu\text{s}$
<b>POWER SUPPLY</b> Voltage Range Current	$V_{\text{IN}} = 0\text{V}$	$\pm 2.25$	$\pm 15$ $\pm 2.2$	$\pm 18$ $\pm 3$	* *	* *	* *	V mA
<b>TEMPERATURE RANGE</b> Specification Operating $\theta_{\text{JA}}$		-40 -40	80	85 125	* *		* *	$^\circ\text{C}$ $^\circ\text{C}$ $^\circ\text{C}/\text{W}$

\* Specification same as INA114BP/BU.

NOTE: (1) Temperature coefficient of the "50k $\Omega$ " term in the gain equation.

The information provided herein is believed to be reliable; however, BURR-BROWN assumes no responsibility for inaccuracies or omissions. BURR-BROWN assumes no responsibility for the use of this information, and all use of such information shall be entirely at the user's own risk. Prices and specifications are subject to change without notice. No patent rights or licenses to any of the circuits described herein are implied or granted to any third party. BURR-BROWN does not authorize or warrant any BURR-BROWN product for use in life support devices and/or systems.

## PIN CONFIGURATIONS



## ELECTROSTATIC DISCHARGE SENSITIVITY

This integrated circuit can be damaged by ESD. Burr-Brown recommends that all integrated circuits be handled with appropriate precautions. Failure to observe proper handling and installation procedures can cause damage.

ESD damage can range from subtle performance degradation to complete device failure. Precision integrated circuits may be more susceptible to damage because very small parametric changes could cause the device not to meet its published specifications.

### PACKAGE/ORDERING INFORMATION

PRODUCT	PACKAGE	PACKAGE DRAWING NUMBER <sup>(1)</sup>	TEMPERATURE RANGE
INA114AP	8-Pin Plastic DIP	006	-40°C to +85°C
INA114BP	8-Pin Plastic DIP	006	-40°C to +85°C
INA114AU	SOL-16 Surface-Mount	211	-40°C to +85°C
INA114BU	SOL-16 Surface-Mount	211	-40°C to +85°C

NOTE: (1) For detailed drawing and dimension table, please see end of data sheet, or Appendix C of Burr-Brown IC Data Book.

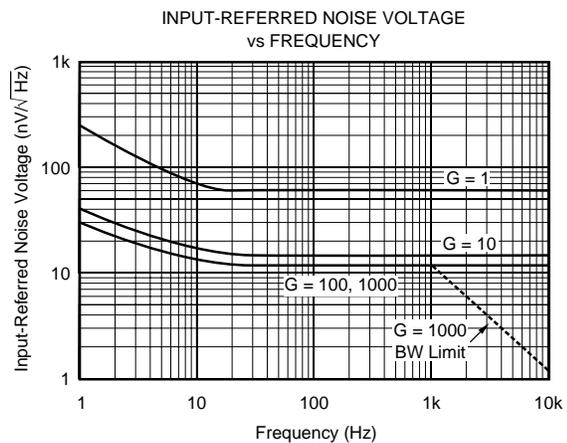
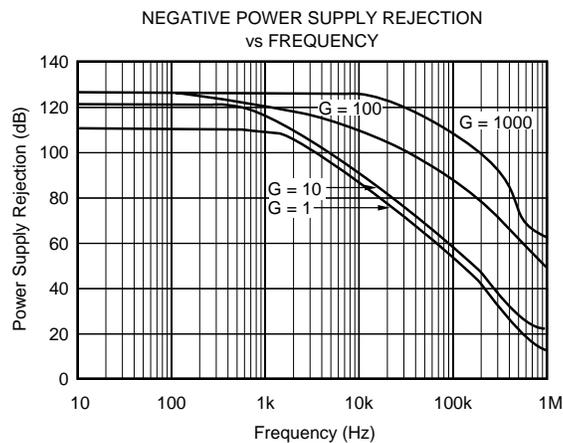
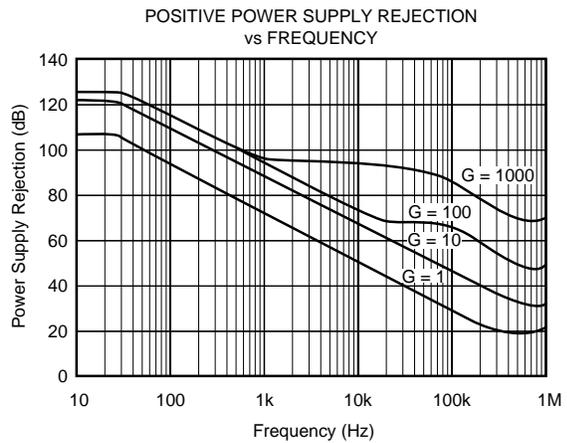
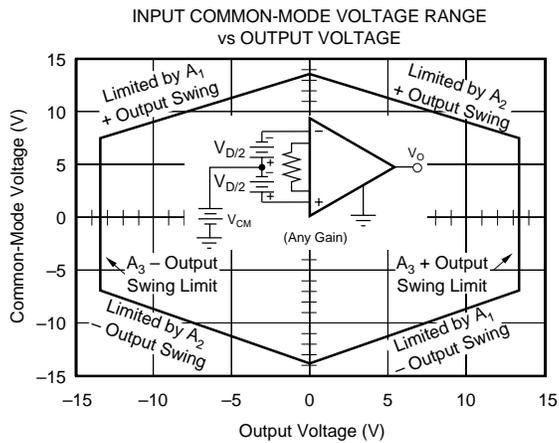
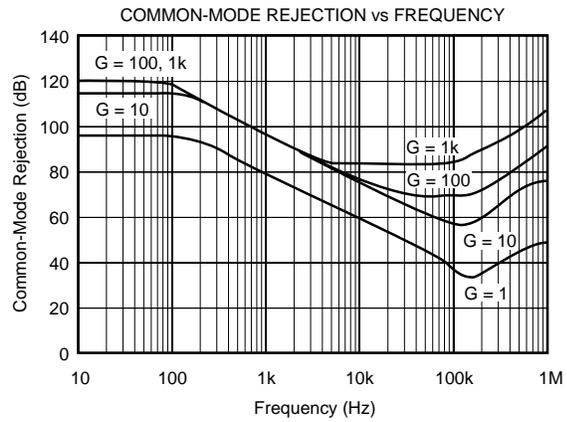
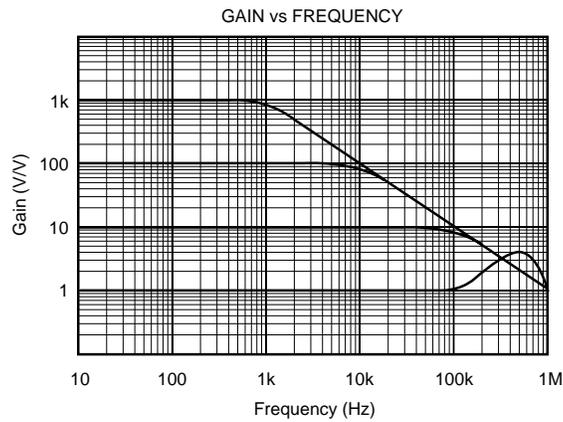
### ABSOLUTE MAXIMUM RATINGS<sup>(1)</sup>

Supply Voltage .....	±18V
Input Voltage Range .....	±40V
Output Short-Circuit (to ground) .....	Continuous
Operating Temperature .....	-40°C to +125°C
Storage Temperature .....	-40°C to +125°C
Junction Temperature .....	+150°C
Lead Temperature (soldering, 10s) .....	+300°C

NOTE: (1) Stresses above these ratings may cause permanent damage.

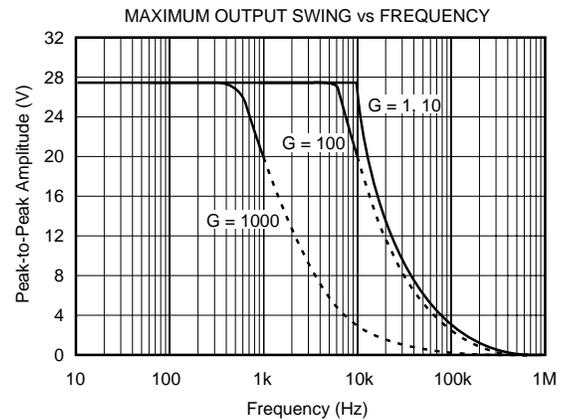
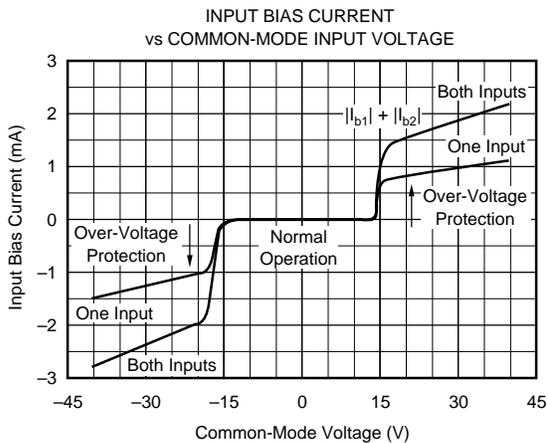
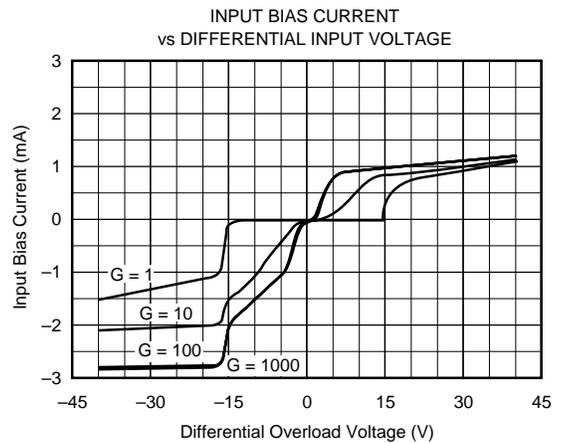
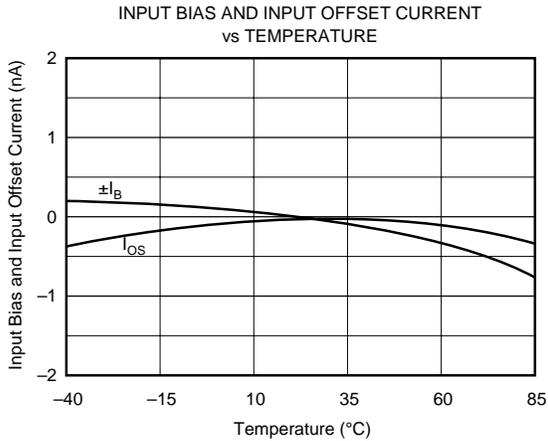
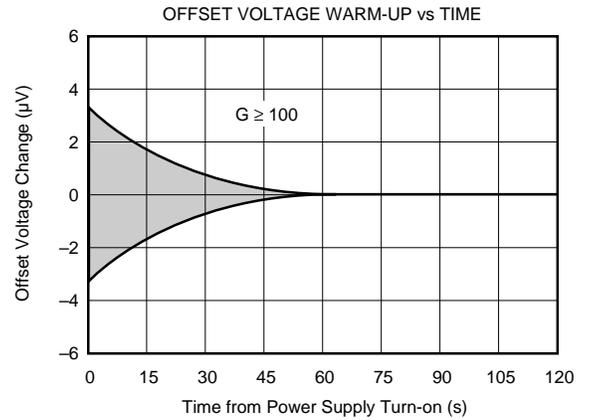
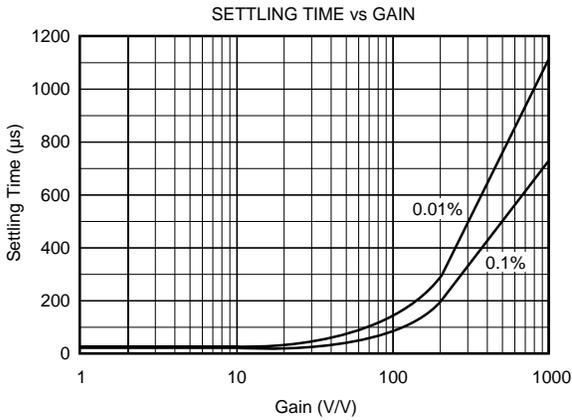
# TYPICAL PERFORMANCE CURVES

At  $T_A = +25^\circ\text{C}$ ,  $V_S = \pm 15\text{V}$ , unless otherwise noted.



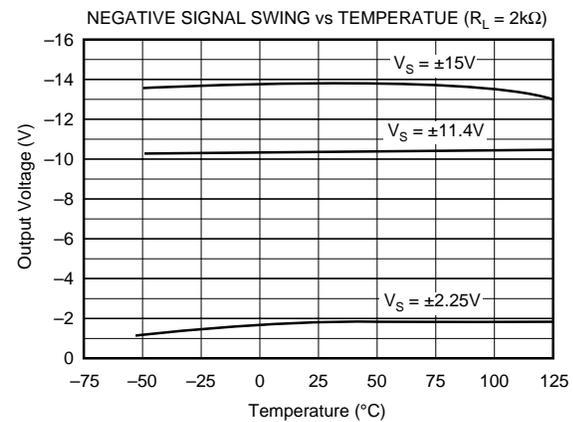
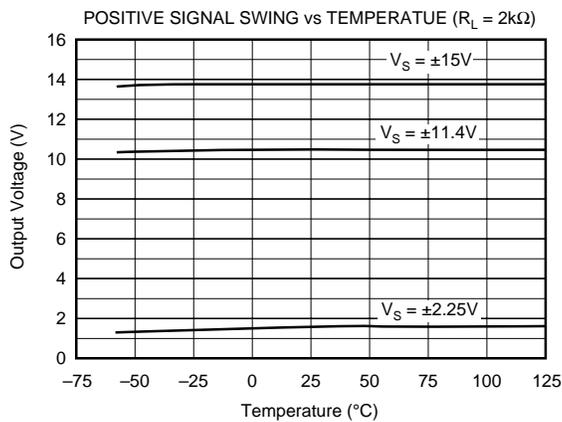
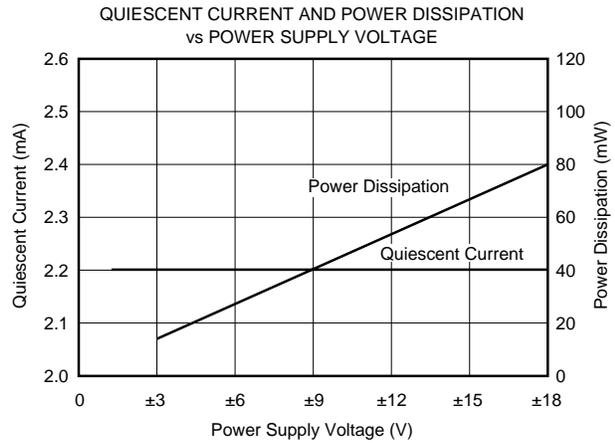
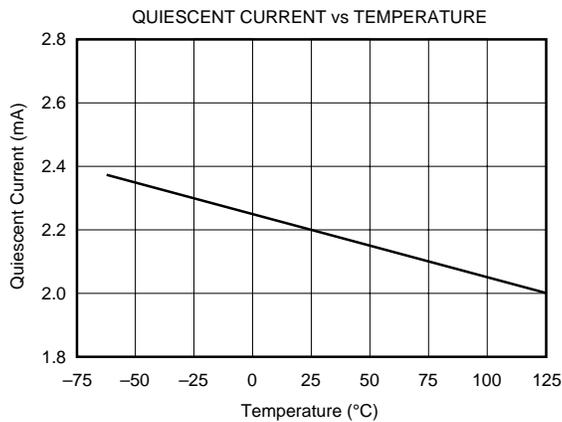
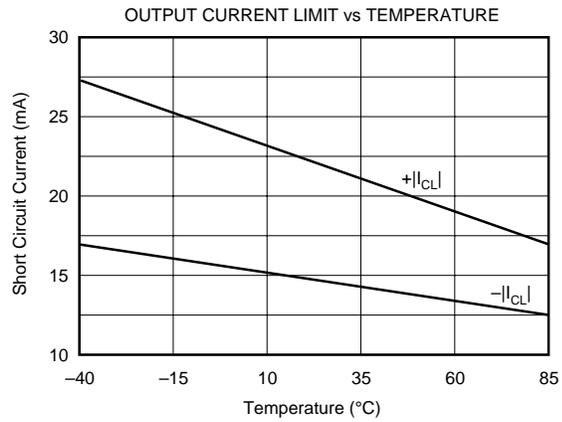
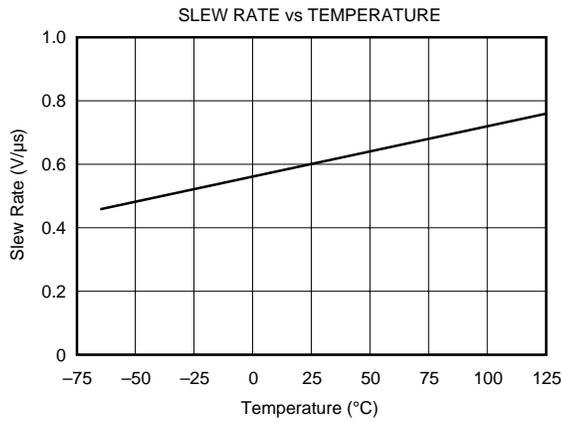
# TYPICAL PERFORMANCE CURVES (CONT)

At  $T_A = +25^\circ\text{C}$ ,  $V_S = \pm 15\text{V}$ , unless otherwise noted.



# TYPICAL PERFORMANCE CURVES (CONT)

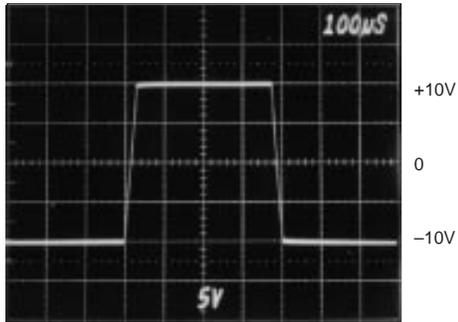
At  $T_A = +25^\circ\text{C}$ ,  $V_S = \pm 15\text{V}$ , unless otherwise noted.



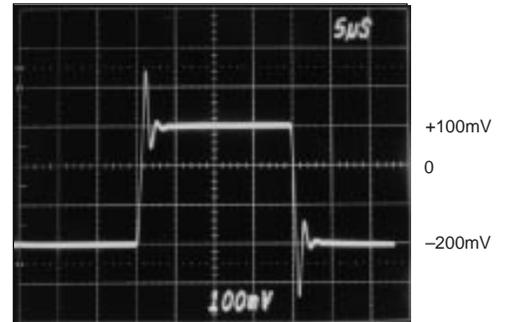
# TYPICAL PERFORMANCE CURVES (CONT)

At  $T_A = +25^\circ\text{C}$ ,  $V_S = \pm 15\text{V}$ , unless otherwise noted.

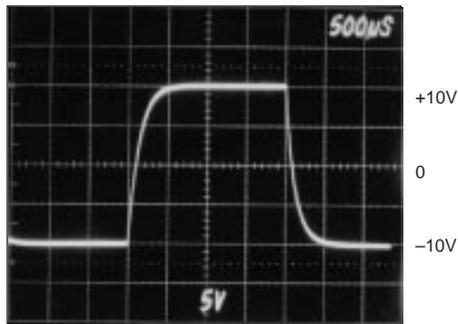
LARGE SIGNAL RESPONSE,  $G = 1$



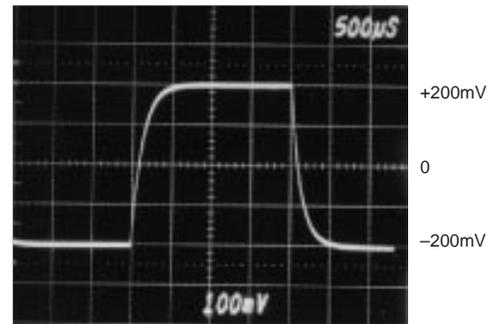
SMALL SIGNAL RESPONSE,  $G = 1$



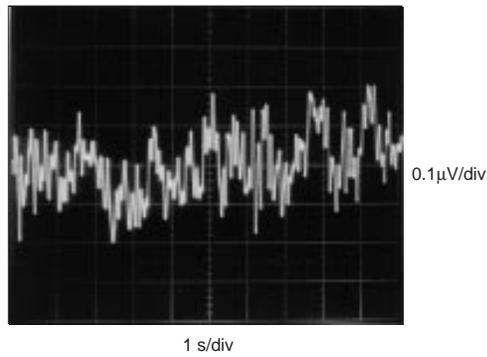
LARGE SIGNAL RESPONSE,  $G = 1000$



SMALL SIGNAL RESPONSE,  $G = 1000$



INPUT-REFERRED NOISE, 0.1 to 10Hz



# APPLICATION INFORMATION

Figure 1 shows the basic connections required for operation of the INA114. Applications with noisy or high impedance power supplies may require decoupling capacitors close to the device pins as shown.

The output is referred to the output reference (Ref) terminal which is normally grounded. This must be a low-impedance connection to assure good common-mode rejection. A resistance of 5Ω in series with the Ref pin will cause a typical device to degrade to approximately 80dB CMR ( $G = 1$ ).

## SETTING THE GAIN

Gain of the INA114 is set by connecting a single external resistor,  $R_G$ :

$$G = 1 + \frac{50 \text{ k}\Omega}{R_G} \quad (1)$$

Commonly used gains and resistor values are shown in Figure 1.

The 50kΩ term in equation (1) comes from the sum of the two internal feedback resistors. These are on-chip metal film resistors which are laser trimmed to accurate absolute val-

ues. The accuracy and temperature coefficient of these resistors are included in the gain accuracy and drift specifications of the INA114.

The stability and temperature drift of the external gain setting resistor,  $R_G$ , also affects gain.  $R_G$ 's contribution to gain accuracy and drift can be directly inferred from the gain equation (1). Low resistor values required for high gain can make wiring resistance important. Sockets add to the wiring resistance which will contribute additional gain error (possibly an unstable gain error) in gains of approximately 100 or greater.

## NOISE PERFORMANCE

The INA114 provides very low noise in most applications. For differential source impedances less than 1kΩ, the INA114 may provide lower noise. For source impedances greater than 50kΩ, the INA111 FET-input instrumentation amplifier may provide lower noise.

Low frequency noise of the INA114 is approximately 0.4μVp-p measured from 0.1 to 10Hz. This is approximately one-tenth the noise of "low noise" chopper-stabilized amplifiers.

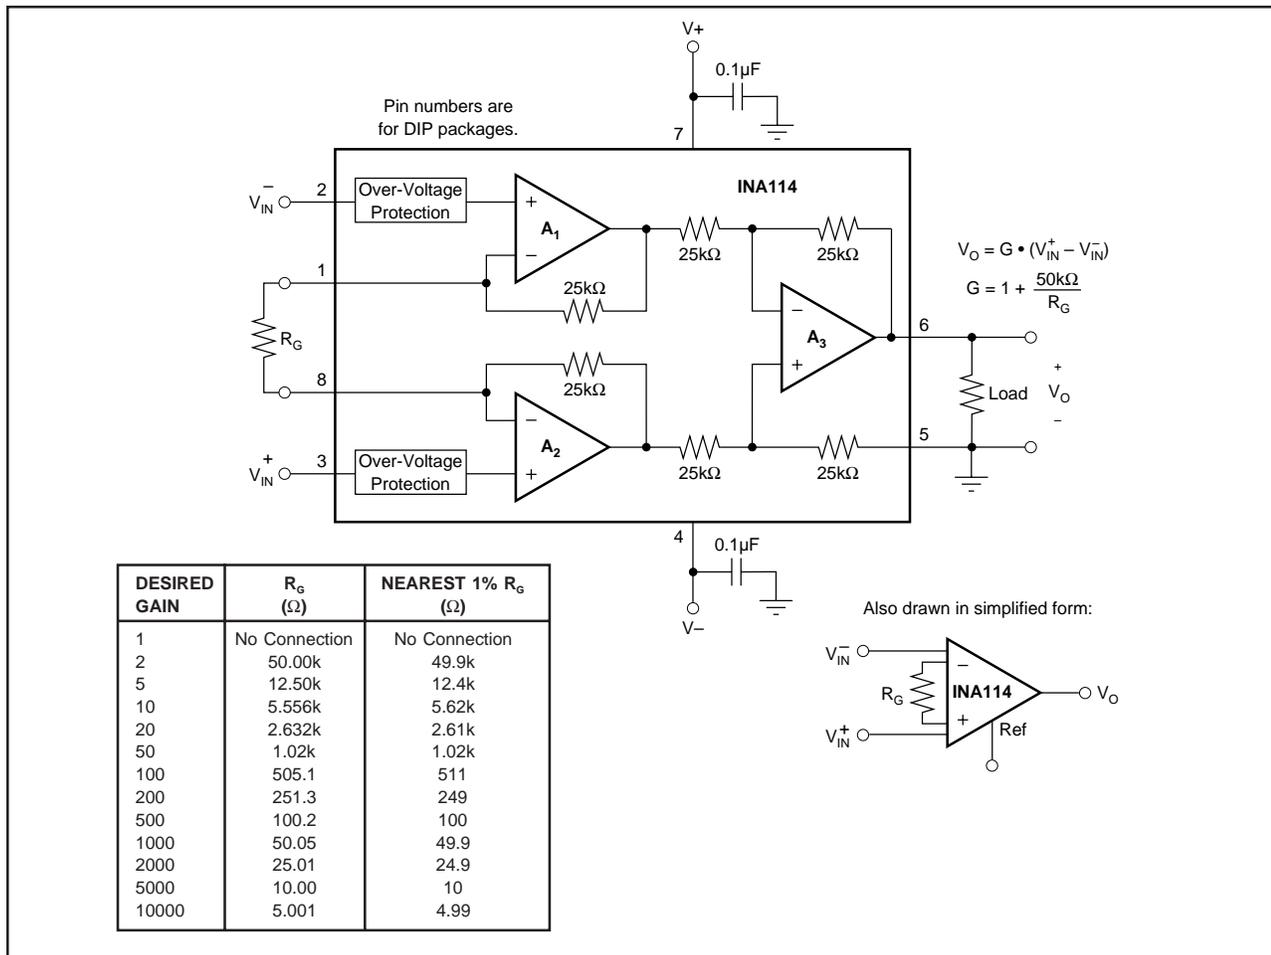


FIGURE 1. Basic Connections.

## OFFSET TRIMMING

The INA114 is laser trimmed for very low offset voltage and drift. Most applications require no external offset adjustment. Figure 2 shows an optional circuit for trimming the output offset voltage. The voltage applied to Ref terminal is summed at the output. Low impedance must be maintained at this node to assure good common-mode rejection. This is achieved by buffering trim voltage with an op amp as shown.

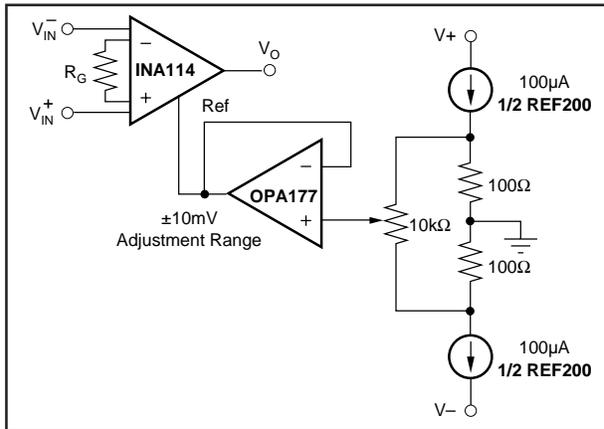


FIGURE 2. Optional Trimming of Output Offset Voltage.

## INPUT BIAS CURRENT RETURN PATH

The input impedance of the INA114 is extremely high—approximately  $10^{10}\Omega$ . However, a path must be provided for the input bias current of both inputs. This input bias current is typically less than  $\pm 1\text{nA}$  (it can be either polarity due to cancellation circuitry). High input impedance means that this input bias current changes very little with varying input voltage.

Input circuitry must provide a path for this input bias current if the INA114 is to operate properly. Figure 3 shows various provisions for an input bias current path. Without a bias current return path, the inputs will float to a potential which exceeds the common-mode range of the INA114 and the input amplifiers will saturate. If the differential source resistance is low, bias current return path can be connected to one input (see thermocouple example in Figure 3). With higher source impedance, using two resistors provides a balanced input with possible advantages of lower input offset voltage due to bias current and better common-mode rejection.

## INPUT COMMON-MODE RANGE

The linear common-mode range of the input op amps of the INA114 is approximately  $\pm 13.75\text{V}$  (or  $1.25\text{V}$  from the power supplies). As the output voltage increases, however, the linear input range will be limited by the output voltage swing of the input amplifiers,  $A_1$  and  $A_2$ . The common-mode range is related to the output voltage of the complete amplifier—see performance curve “Input Common-Mode Range vs Output Voltage.”

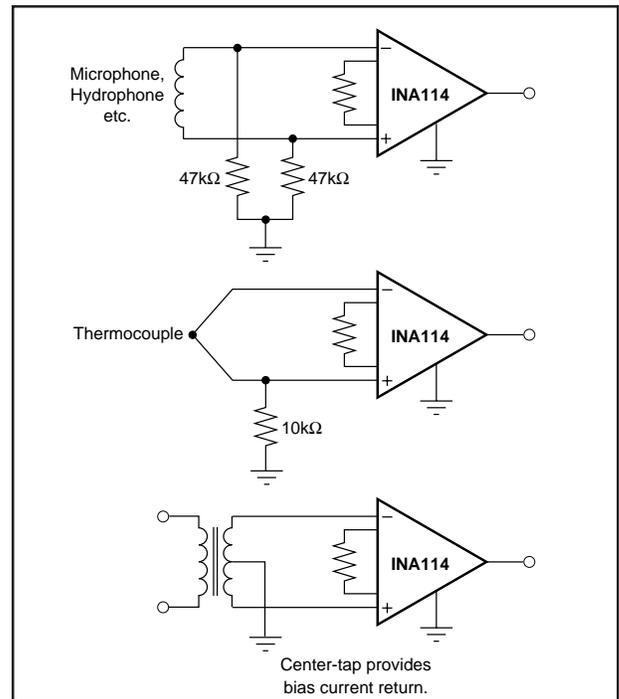


FIGURE 3. Providing an Input Common-Mode Current Path.

A combination of common-mode and differential input signals can cause the output of  $A_1$  or  $A_2$  to saturate. Figure 4 shows the output voltage swing of  $A_1$  and  $A_2$  expressed in terms of a common-mode and differential input voltages. Output swing capability of these internal amplifiers is the same as the output amplifier,  $A_3$ . For applications where input common-mode range must be maximized, limit the output voltage swing by connecting the INA114 in a lower gain (see performance curve “Input Common-Mode Voltage Range vs Output Voltage”). If necessary, add gain after the INA114 to increase the voltage swing.

Input-overload often produces an output voltage that appears normal. For example, an input voltage of  $+20\text{V}$  on one input and  $+40\text{V}$  on the other input will obviously exceed the linear common-mode range of both input amplifiers. Since both input amplifiers are saturated to nearly the same output voltage limit, the difference voltage measured by the output amplifier will be near zero. The output of the INA114 will be near  $0\text{V}$  even though both inputs are overloaded.

## INPUT PROTECTION

The inputs of the INA114 are individually protected for voltages up to  $\pm 40\text{V}$ . For example, a condition of  $-40\text{V}$  on one input and  $+40\text{V}$  on the other input will not cause damage. Internal circuitry on each input provides low series impedance under normal signal conditions. To provide equivalent protection, series input resistors would contribute excessive noise. If the input is overloaded, the protection circuitry limits the input current to a safe value (approximately  $1.5\text{mA}$ ). The typical performance curve “Input Bias Current vs Common-Mode Input Voltage” shows this input

current limit behavior. The inputs are protected even if no power supply voltage is present.

### OUTPUT VOLTAGE SENSE (SOL-16 package only)

The surface-mount version of the INA114 has a separate output sense feedback connection (pin 12). Pin 12 must be connected to the output terminal (pin 11) for proper operation. (This connection is made internally on the DIP version of the INA114.)

The output sense connection can be used to sense the output voltage directly at the load for best accuracy. Figure 5 shows how to drive a load through series interconnection resistance. Remotely located feedback paths may cause instability. This can be generally be eliminated with a high frequency feedback path through  $C_1$ . Heavy loads or long lines can be driven by connecting a buffer inside the feedback path (Figure 6).

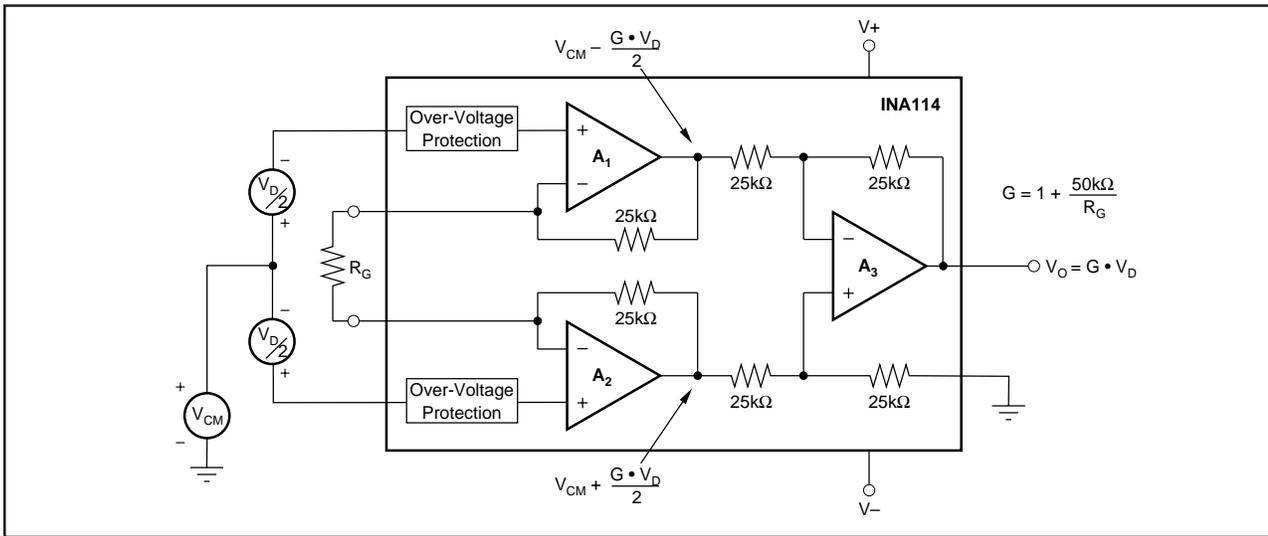


FIGURE 4. Voltage Swing of  $A_1$  and  $A_2$ .

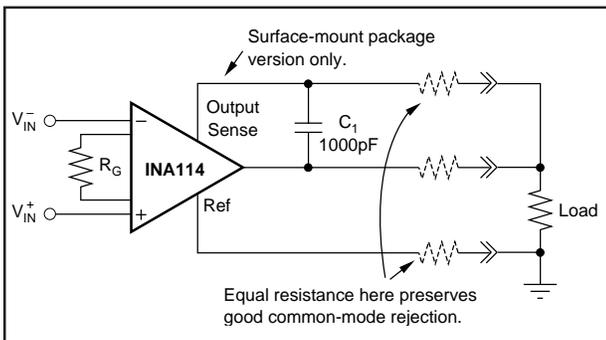


FIGURE 5. Remote Load and Ground Sensing.

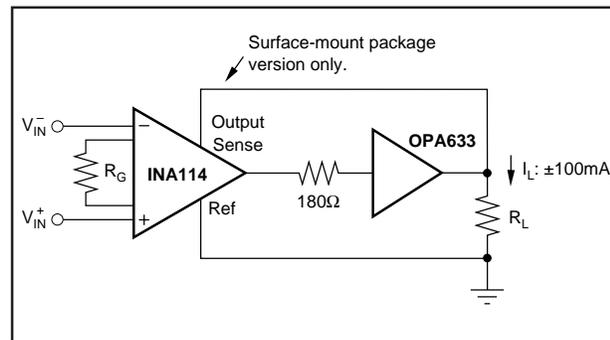


FIGURE 6. Buffered Output for Heavy Loads.

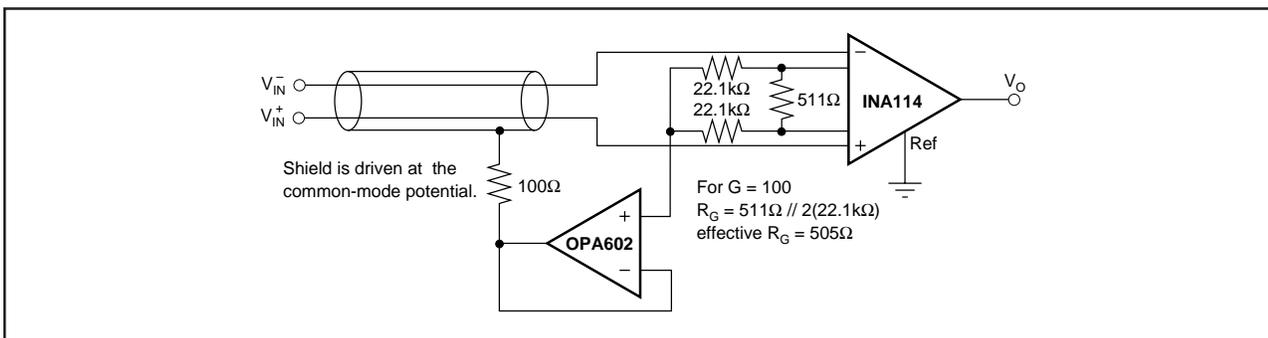


FIGURE 7. Shield Driver Circuit.

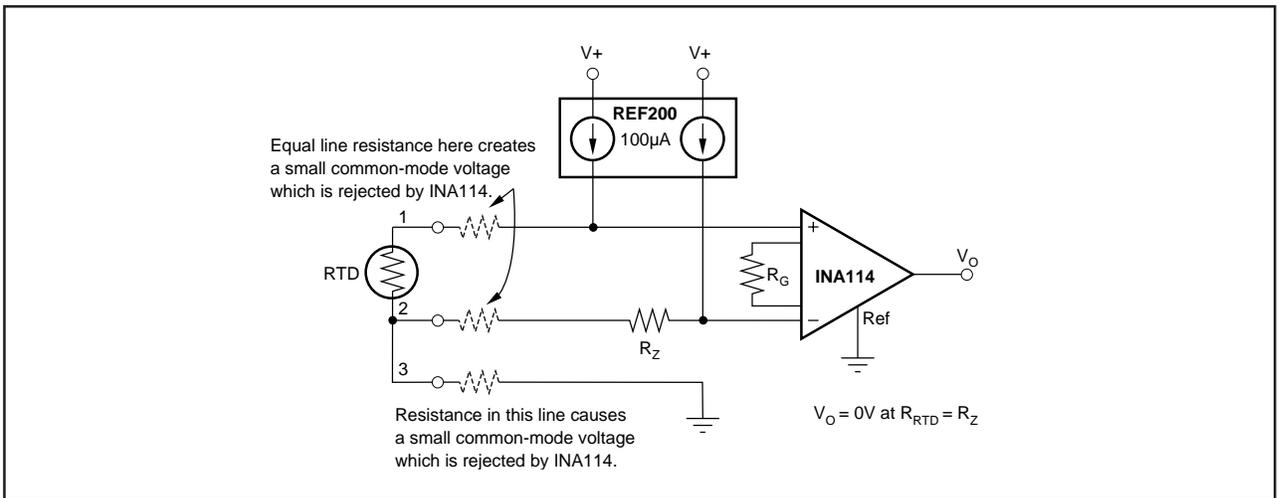


FIGURE 8. RTD Temperature Measurement Circuit.

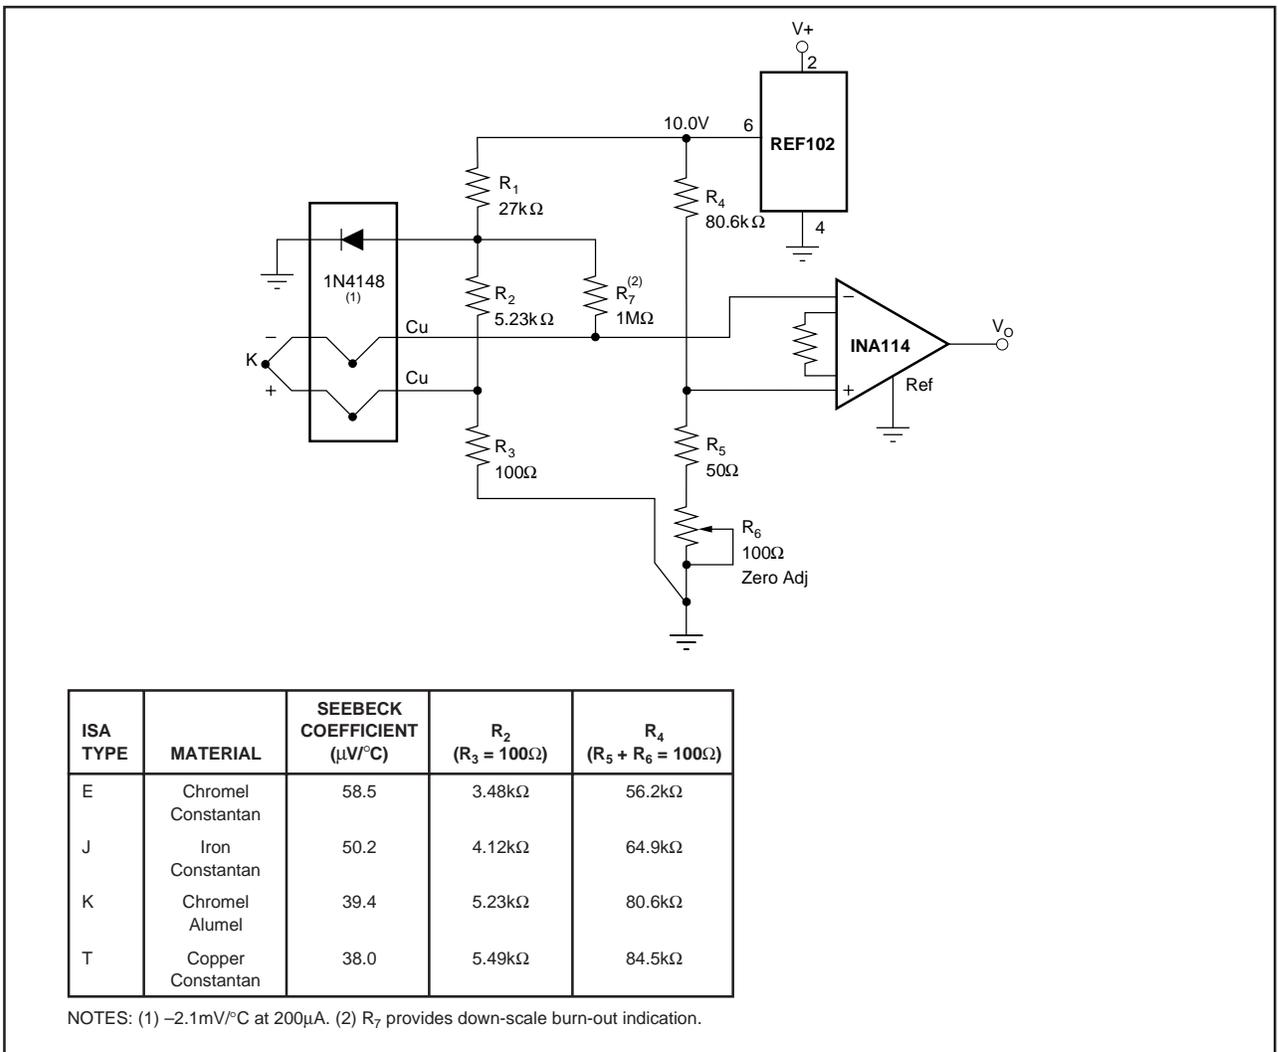


FIGURE 9. Thermocouple Amplifier With Cold Junction Compensation.

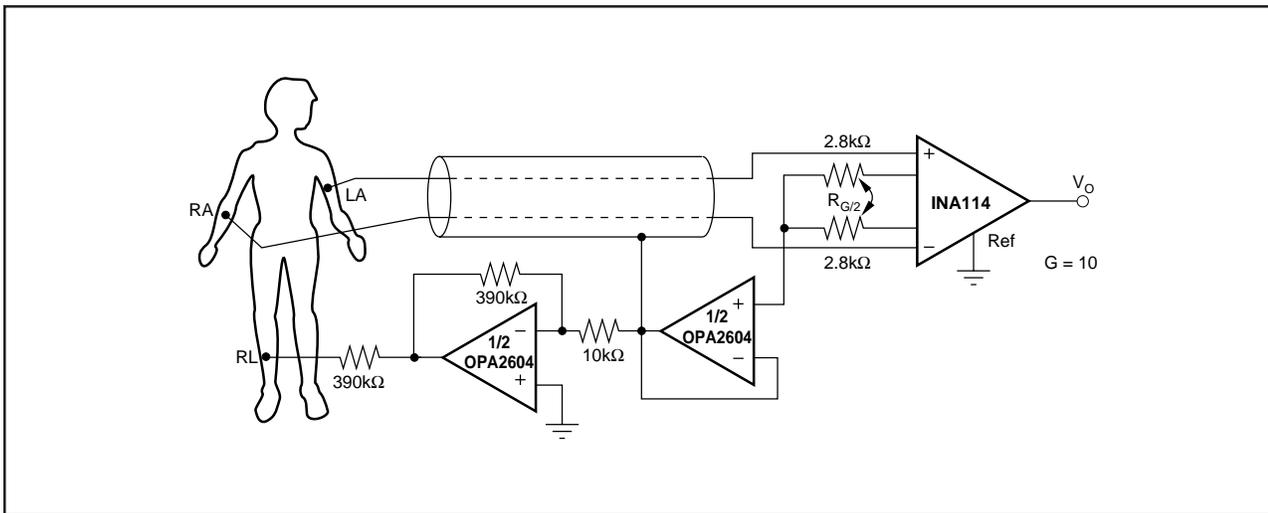


FIGURE 10. ECG Amplifier With Right-Leg Drive.

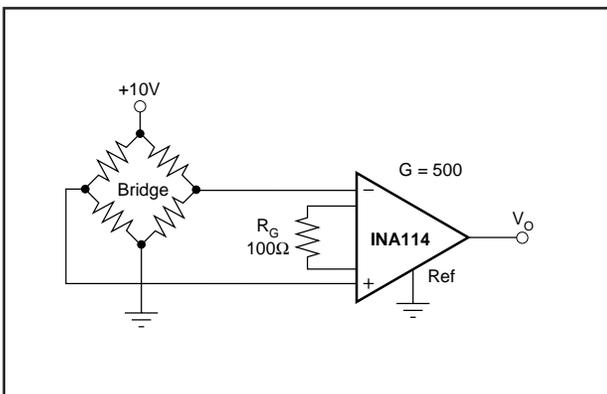


FIGURE 11. Bridge Transducer Amplifier.

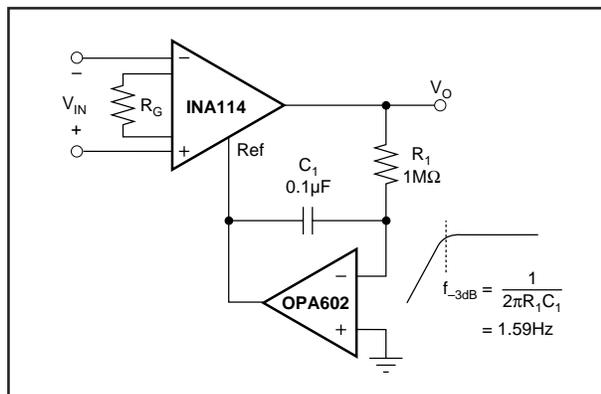


FIGURE 12. AC-Coupled Instrumentation Amplifier.

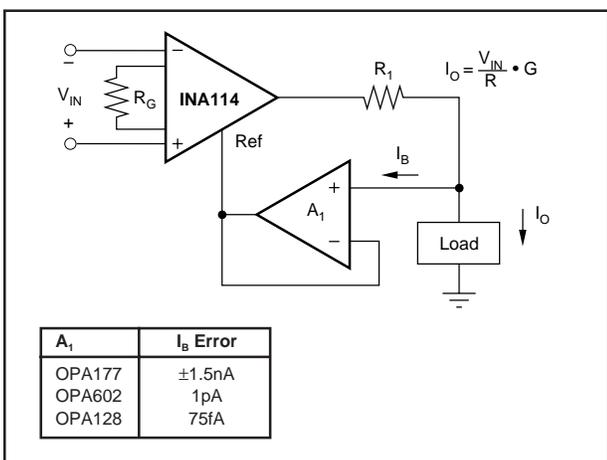


FIGURE 13. Differential Voltage-to-Current Converter.

### FEATURES

- Low  $V_{os}$ : 75  $\mu\text{V}$  maximum
- Low  $V_{os}$  drift: 1.3  $\mu\text{V}/^\circ\text{C}$  maximum
- Ultrastable vs. time: 1.5  $\mu\text{V}$  per month maximum
- Low noise: 0.6  $\mu\text{V}$  p-p maximum
- Wide input voltage range:  $\pm 14\text{ V}$  typical
- Wide supply voltage range:  $\pm 3\text{ V}$  to  $\pm 18\text{ V}$
- 125 $^\circ\text{C}$  temperature-tested dice

### APPLICATIONS

- Wireless base station control circuits
- Optical network control circuits
- Instrumentation
- Sensors and controls
  - Thermocouples
  - Resistor thermal detectors (RTDs)
  - Strain bridges
  - Shunt current measurements
- Precision filters

### GENERAL DESCRIPTION

The OP07 has very low input offset voltage (75  $\mu\text{V}$  maximum for OP07E) that is obtained by trimming at the wafer stage. These low offset voltages generally eliminate any need for external nulling. The OP07 also features low input bias current ( $\pm 4\text{ nA}$  for the OP07E) and high open-loop gain (200 V/mV for the OP07E). The low offset and high open-loop gain make the OP07 particularly useful for high gain instrumentation applications.

### PIN CONFIGURATION

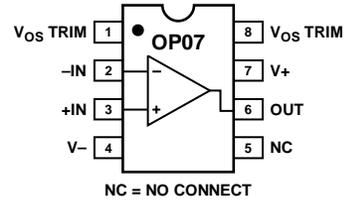
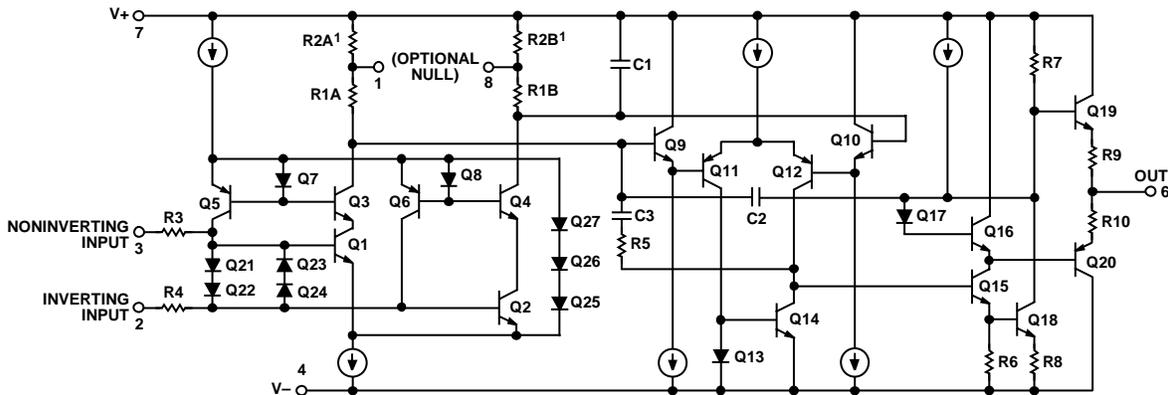


Figure 1.

The wide input voltage range of  $\pm 13\text{ V}$  minimum combined with a high CMRR of 106 dB (OP07E) and high input impedance provide high accuracy in the noninverting circuit configuration. Excellent linearity and gain accuracy can be maintained even at high closed-loop gains. Stability of offsets and gain with time or variations in temperature is excellent. The accuracy and stability of the OP07, even at high gain, combined with the freedom from external nulling have made the OP07 an industry standard for instrumentation applications.

The OP07 is available in two standard performance grades. The OP07E is specified for operation over the  $0^\circ\text{C}$  to  $70^\circ\text{C}$  range, and the OP07C is specified over the  $-40^\circ\text{C}$  to  $+85^\circ\text{C}$  temperature range.

The OP07 is available in epoxy 8-lead PDIP and 8-lead narrow SOIC packages. For CERDIP and TO-99 packages and standard microcircuit drawing (SMD) versions, see the OP77.



<sup>1</sup> R2A AND R2B ARE ELECTRONICALLY ADJUSTED ON CHIP AT FACTORY FOR MINIMUM INPUT OFFSET VOLTAGE.

Figure 2. Simplified Schematic

### Rev. G

Information furnished by Analog Devices is believed to be accurate and reliable. However, no responsibility is assumed by Analog Devices for its use, nor for any infringements of patents or other rights of third parties that may result from its use. Specifications subject to change without notice. No license is granted by implication or otherwise under any patent or patent rights of Analog Devices. Trademarks and registered trademarks are the property of their respective owners.

## CMOS Voltage Converters

The Intersil ICL7660 and ICL7660A are monolithic CMOS power supply circuits which offer unique performance advantages over previously available devices. The ICL7660 performs supply voltage conversions from positive to negative for an input range of +1.5V to +10.0V resulting in complementary output voltages of -1.5V to -10.0V and the ICL7660A does the same conversions with an input range of +1.5V to +12.0V resulting in complementary output voltages of -1.5V to -12.0V. Only 2 noncritical external capacitors are needed for the charge pump and charge reservoir functions. The ICL7660 and ICL7660A can also be connected to function as voltage doublers and will generate output voltages up to +18.6V with a +10V input.

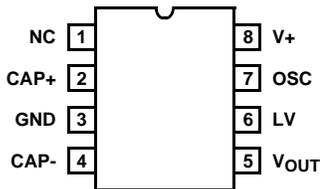
Contained on the chip are a series DC supply regulator, RC oscillator, voltage level translator, and four output power MOS switches. A unique logic element senses the most negative voltage in the device and ensures that the output N-Channel switch source-substrate junctions are not forward biased. This assures latchup free operation.

The oscillator, when unloaded, oscillates at a nominal frequency of 10kHz for an input supply voltage of 5.0V. This frequency can be lowered by the addition of an external capacitor to the "OSC" terminal, or the oscillator may be overdriven by an external clock.

The "LV" terminal may be tied to GROUND to bypass the internal series regulator and improve low voltage (LV) operation. At medium to high voltages (+3.5V to +10.0V for the ICL7660 and +3.5V to +12.0V for the ICL7660A), the LV pin is left floating to prevent device latchup.

## Pinouts

ICL7660, ICL7660A  
(8 LD PDIP, SOIC)  
TOP VIEW



## Features

- Simple Conversion of +5V Logic Supply to ±5V Supplies
- Simple Voltage Multiplication ( $V_{OUT} = (-) nV_{IN}$ )
- Typical Open Circuit Voltage Conversion Efficiency 99.9%
- Typical Power Efficiency 98%
- Wide Operating Voltage Range
  - ICL7660 . . . . . 1.5V to 10.0V
  - ICL7660A . . . . . 1.5V to 12.0V
- ICL7660A 100% Tested at 3V
- Easy to Use - Requires Only 2 External Non-Critical Passive Components
- No External Diode Over Full Temp. and Voltage Range
- Pb-Free Plus Anneal Available (RoHS Compliant)

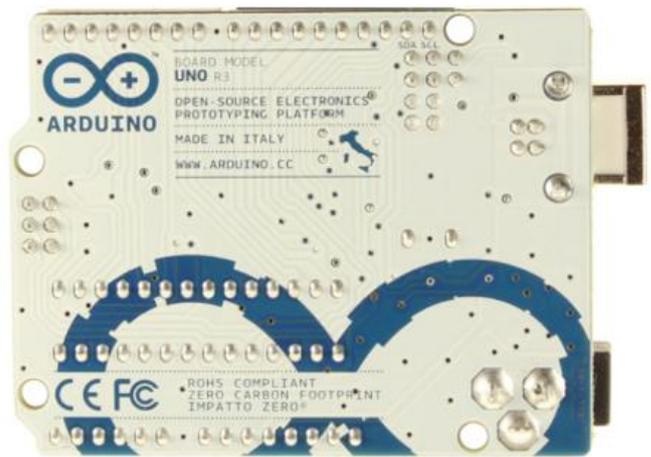
## Applications

- On Board Negative Supply for Dynamic RAMs
- Localized  $\mu$ Processor (8080 Type) Negative Supplies
- Inexpensive Negative Supplies
- Data Acquisition Systems

# Arduino Uno



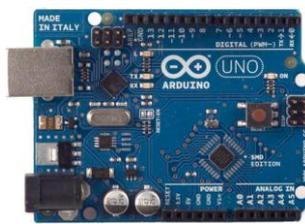
Arduino Uno R3 Front



Arduino Uno R3 Back



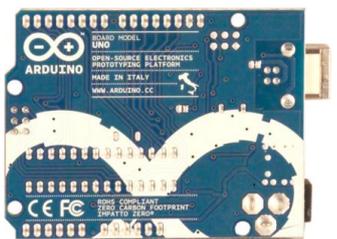
Arduino Uno R2 Front



Arduino Uno SMD



Arduino Uno Front



Arduino Uno Back

## Overview

The Arduino Uno is a microcontroller board based on the ATmega328 ([datasheet](#)). It has 14 digital input/output pins (of which 6 can be used as PWM outputs), 6 analog inputs, a 16 MHz ceramic resonator, a USB connection, a power jack, an ICSP header, and a reset button. It contains everything needed to support the microcontroller; simply connect it to a computer with a USB cable or power it with a AC-to-DC adapter or battery to get started.

The Uno differs from all preceding boards in that it does not use the FTDI USB-to-serial driver chip. Instead, it features the Atmega16U2 (Atmega8U2 up to version R2) programmed as a USB-to-serial converter.

[Revision 2](#) of the Uno board has a resistor pulling the 8U2 HWB line to ground, making it easier to put into [DFU mode](#).

[Revision 3](#) of the board has the following new features:

- 1.0 pinout: added SDA and SCL pins that are near to the AREF pin and two other new pins placed near to the RESET pin, the IOREF that allow the shields to adapt to the voltage provided from the board. In future, shields will be compatible both with the board that use the AVR, which operate with 5V and with the Arduino Due that operate with 3.3V. The second one is a not connected pin, that is reserved for future purposes.
- Stronger RESET circuit.
- Atmega 16U2 replace the 8U2.

"Uno" means one in Italian and is named to mark the upcoming release of Arduino 1.0. The Uno and version 1.0 will be the reference versions of Arduino, moving forward. The Uno is the latest in a series of USB Arduino boards, and the reference model for the Arduino platform; for a comparison with previous versions, see the [index of Arduino boards](#).

## Summary

Microcontroller	ATmega328
Operating Voltage	5V
Input Voltage (recommended)	7-12V

Input Voltage (limits)	6-20V
Digital I/O Pins	14 (of which 6 provide PWM output)
Analog Input Pins	6
DC Current per I/O Pin	40 mA
DC Current for 3.3V Pin	50 mA
Flash Memory	32 KB (ATmega328) of which 0.5 KB used by bootloader
SRAM	2 KB (ATmega328)
EEPROM	1 KB (ATmega328)
Clock Speed	16 MHz

## Schematic & Reference Design

EAGLE files: [arduino-uno-Rev3-reference-design.zip](#) (NOTE: works with Eagle 6.0 and newer)

Schematic: [arduino-uno-Rev3-schematic.pdf](#)

**Note:** The Arduino reference design can use an Atmega8, 168, or 328, Current models use an ATmega328, but an Atmega8 is shown in the schematic for reference. The pin configuration is identical on all three processors.

## Power

The Arduino Uno can be powered via the USB connection or with an external power supply. The power source is selected automatically.

External (non-USB) power can come either from an AC-to-DC adapter (wall-wart) or battery. The adapter can be connected by plugging a 2.1mm center-positive plug into the board's power jack. Leads from a battery can be inserted in the Gnd and Vin pin headers of the POWER connector.

The board can operate on an external supply of 6 to 20 volts. If supplied with less than 7V, however, the 5V pin may supply less than five volts and the board may be unstable. If using more than 12V, the voltage regulator may overheat and damage the board. The recommended range is 7 to 12 volts.

The power pins are as follows:

- **VIN.** The input voltage to the Arduino board when it's using an external power source (as opposed to 5 volts from the USB connection or other regulated power source). You can supply voltage through this pin, or, if supplying voltage via the power jack, access it through this pin.
- **5V.** This pin outputs a regulated 5V from the regulator on the board. The board can be supplied with power either from the DC power jack (7 - 12V), the USB connector (5V), or the VIN pin of the board (7-12V). Supplying voltage via the 5V or 3.3V pins bypasses the regulator, and can damage your board. We don't advise it.
- **3V3.** A 3.3 volt supply generated by the on-board regulator. Maximum current draw is 50 mA.
- **GND.** Ground pins.

## Memory

The ATmega328 has 32 KB (with 0.5 KB used for the bootloader). It also has 2 KB of SRAM and 1 KB of EEPROM (which can be read and written with the [EEPROM library](#)).

## Input and Output

Each of the 14 digital pins on the Uno can be used as an input or output, using [pinMode\(\)](#), [digitalWrite\(\)](#), and [digitalRead\(\)](#) functions. They operate at 5 volts. Each pin can provide or receive a maximum of 40 mA and has an internal pull-up resistor (disconnected by default) of 20-50 kOhms. In addition, some pins have specialized functions:

- **Serial: 0 (RX) and 1 (TX).** Used to receive (RX) and transmit (TX) TTL serial data. These pins are connected to the corresponding pins of the ATmega8U2 USB-to-TTL Serial chip.
- **External Interrupts: 2 and 3.** These pins can be configured to trigger an interrupt on a low value, a rising or falling edge, or a change in value. See the [attachInterrupt\(\)](#) function for details.
- **PWM: 3, 5, 6, 9, 10, and 11.** Provide 8-bit PWM output with the [analogWrite\(\)](#) function.

- **SPI: 10 (SS), 11 (MOSI), 12 (MISO), 13 (SCK).** These pins support SPI communication using the [SPI library](#).
- **LED: 13.** There is a built-in LED connected to digital pin 13. When the pin is HIGH value, the LED is on, when the pin is LOW, it's off.

The Uno has 6 analog inputs, labeled A0 through A5, each of which provide 10 bits of resolution (i.e. 1024 different values). By default they measure from ground to 5 volts, though it is possible to change the upper end of their range using the AREF pin and the [analogReference\(\)](#) function. Additionally, some pins have specialized functionality:

- **TWI: A4 or SDA pin and A5 or SCL pin.** Support TWI communication using the [Wire library](#).

There are a couple of other pins on the board:

- **AREF.** Reference voltage for the analog inputs. Used with [analogReference\(\)](#).
- **Reset.** Bring this line LOW to reset the microcontroller. Typically used to add a reset button to shields which block the one on the board.

See also the [mapping between Arduino pins and ATmega328 ports](#). The mapping for the Atmega8, 168, and 328 is identical.

## Communication

The Arduino Uno has a number of facilities for communicating with a computer, another Arduino, or other microcontrollers. The ATmega328 provides UART TTL (5V) serial communication, which is available on digital pins 0 (RX) and 1 (TX). An ATmega16U2 on the board channels this serial communication over USB and appears as a virtual com port to software on the computer. The '16U2 firmware uses the standard USB COM drivers, and no external driver is needed. However, [on Windows, a .inf file is required](#). The Arduino software includes a serial monitor which allows simple textual data to be sent to and from the Arduino board. The RX and TX LEDs on the board will flash when data is being transmitted via the USB-to-serial chip and USB connection to the computer (but not for serial communication on pins 0 and 1).

A [SoftwareSerial library](#) allows for serial communication on any of the Uno's digital pins.

The ATmega328 also supports I2C (TWI) and SPI communication. The Arduino software includes a Wire library to simplify use of the I2C bus; see the [documentation](#) for details. For SPI communication, use the [SPI library](#).

## Programming

The Arduino Uno can be programmed with the Arduino software ([download](#)). Select "Arduino Uno" from the **Tools > Board** menu (according to the microcontroller on your board). For details, see the [reference](#) and [tutorials](#).

The ATmega328 on the Arduino Uno comes preburned with a [bootloader](#) that allows you to upload new code to it without the use of an external hardware programmer. It communicates using the original STK500 protocol ([reference](#), [C header files](#)).

You can also bypass the bootloader and program the microcontroller through the ICSP (In-Circuit Serial Programming) header; see [these instructions](#) for details.

The ATmega16U2 (or 8U2 in the rev1 and rev2 boards) firmware source code is available. The ATmega16U2/8U2 is loaded with a DFU bootloader, which can be activated by:

- On Rev1 boards: connecting the solder jumper on the back of the board (near the map of Italy) and then resetting the 8U2.
- On Rev2 or later boards: there is a resistor that pulling the 8U2/16U2 HWB line to ground, making it easier to put into DFU mode.

You can then use [Atmel's FLIP software](#) (Windows) or the [DFU programmer](#) (Mac OS X and Linux) to load a new firmware. Or you can use the ISP header with an external programmer (overwriting the DFU bootloader). See [this user-contributed tutorial](#) for more information.

## Automatic (Software) Reset

Rather than requiring a physical press of the reset button before an upload, the Arduino Uno is designed in a way that allows it to be reset by software running on a connected computer. One of the hardware flow control lines (DTR) of the ATmega8U2/16U2 is connected to the reset line of the ATmega328 via a 100 nanofarad capacitor. When this line is asserted (taken low), the reset line drops long enough to reset the chip. The Arduino software uses this capability to allow you to upload code by simply pressing the upload button in the Arduino environment. This means that the bootloader can have a shorter timeout, as the lowering of DTR can be well-coordinated with the start of the upload. This setup has other implications. When the Uno is connected to either a computer running Mac OS X or Linux, it resets each time a connection is made to it from software (via USB). For the following half-second or so, the bootloader is running on the Uno. While it is programmed to ignore malformed data (i.e. anything besides an upload of new code), it will intercept the first few bytes of data sent to the board after a connection is opened. If a sketch running on the board receives one-time configuration or other data when it first starts, make sure that the software with which it communicates waits a second after opening the connection and before sending this data.

The Uno contains a trace that can be cut to disable the auto-reset. The pads on either side of the trace can be soldered together to re-enable it. It's labeled "RESET-EN". You may also be able to disable the auto-reset by connecting a 110 ohm resistor from 5V to the reset line; see [this forum thread](#) for details.

## **USB Overcurrent Protection**

The Arduino Uno has a resettable polyfuse that protects your computer's USB ports from shorts and overcurrent. Although most computers provide their own internal protection, the fuse provides an extra layer of protection. If more than 500 mA is applied to the USB port, the fuse will automatically break the connection until the short or overload is removed.

## **Physical Characteristics**

The maximum length and width of the Uno PCB are 2.7 and 2.1 inches respectively, with the USB connector and power jack extending beyond the former dimension. Four screw holes allow the board to be attached to a surface or case. Note that the distance between digital pins 7 and 8 is 160 mil (0.16"), not an even multiple of the 100 mil spacing of the other pins.

## Résumé

Cette thèse porte sur l'étude des relations pouvant exister entre le signal électroencéphalogramme EEG et le signal électrocardiogramme appliqué pour des patients souffrant de crises d'épilepsie, en vue de créer une base de données personnel, notre approche consiste à la réalisation d'un système de monitoring sans fil pour la mesure et la détection en temps réel des signaux EEG & ECG afin de renforcer considérablement l'amélioration de la qualité de vie des patients. De plus, une étude corrélative entre les deux signaux a été faite, et une exploitation de la classification (réseaux de neurones, l'arbre de décision) ainsi que l'utilisation des techniques statistiques (coefficient de Pearson et Spearman) nous a permis d'atteindre l'objectif de la détection et de la prédiction des crises d'épilepsie avec une performance fiable.

**Mots clés: ECG, EEG, Crise d'épilepsie , Classification, Réseau de neurones, Arbre de décision.**

## Abstract

This thesis focuses on the study of the possible relationships between the electroencephalogram signal (EEG) and the electrocardiogram signal (ECG) applied for patients suffering from epilepsy seizures, in order to create a personal database, our approach consists of the realization of a real-time wireless monitoring system for measurement and detection of EEG & ECG signals that significantly can improve the quality of life of patients. In addition, a correlative study between the two signals was carried out, and an exploitation of the classification process (neural networks, decision tree) as well as the use of statistical techniques (Pearson and Spearman coefficient) allowed us to achieve the objective of detecting and predicting epileptic seizures with reliable performance.

**Keywords: ECG, EEG, epileptic seizure, classification, neural Networks, decision tree**

## ملخص

هذه المذكرة تختص بدراسة حول العلاقة التي تربط الإشارات الكهربائية للدماغ مع الإشارات الكهربائية للقلب وتخص بذلك الأشخاص المصابين بنوبات الصرع. من أجل إنشاء قاعدة بيانات، يعتمد منهجنا على تحقيق نظام مراقبة لاسلكي لقياس واكتشاف إشارات الدماغ والقلب في الوقت الفعلي من أجل تحسين نوعية حياة المرضى بشكل ملحوظ. بالإضافة إلى ذلك، قمنا بإجراء دراسة ارتباطية بين الإشارتين مع استغلال الذكاء الاصطناعي (الشبكات العصبية، شجرة القرار) وكذلك استخدمنا التقنيات الإحصائية (معامل بيرسون وسبيرمان) التي سمحت لنا بالوصول إلى هدف اكتشاف نوبات الصرع والتنبؤ بها من خلال أداء موثوق به.

**الكلمات المفتاحية: إشارات الدماغ، إشارات القلب، نوبات الصرع، الذكاء الاصطناعي، الشبكات العصبية، شجرة القرار**