



الجمهورية الجزائرية الديمقراطية الشعبية

République Algérienne Démocratique et Populaire

Ministère de l'Enseignement Supérieur et de la
Recherche Scientifique

UNIVERSITE IBN KHALDOUN

Faculté des SCIENCES APPLIQUEES

Département Génie Electrique

Mémoire présenté pour l'obtention Du diplôme de Master Académique

Filière : Automatique

Spécialité : Automatique et informatique industrielle

Thème

Classification des signaux ECG en utilisant l'intelligence artificielle

Présenté par :

Mr. KERIA Amir Abdelkader

Mr. KAID Mohamed Riadh

Devant le jury composé de :

Qualité :	Nom et prénom
Président :	Mr. ADDA BENATTIA Abderrahmane
Encadrant :	Mr. ALLAOUI Tayeb
Examineur :	Mr. BENABID Houari
Examineur :	Mr. BEY Mohamed

Soutenu le : 21/06/2023

Année universitaire :2022/2023.

Remerciement

*Au terme de ce travail, nous tenons à remercier notre encadrant **Mr. ALLAOUI Tayeb**, Professeur à l'Université Ibn Khaldoun de Tiaret, d'avoir accepté la direction de ce mémoire, pour son aide, son soutien, sa disponibilité, ses conseils, sa compréhension, ses orientations qui ont été un solide appui pour finaliser ce travail.*

*A, **Mr ADDA BEATTIA Abderrahmane** Maitre de conférences à l'Université Ibn Khaldoun de Tiaret, de nos avoir fait l'honneur d'accepter de présider notre jury, qu'elle trouve ici l'expression de notre profond respect.*

*A **Mr BEY Mohamed** Maitre de conférences à l'université Ibn Khaldoun de Tiaret d'avoir accepté d'examiner notre mémoire.*

*A **Mr BENANID Houari** Maitre-assistant à l'université Ibn Khaldoun de Tiaret d'avoir accepté d'examiner notre mémoire.*

*Un grand merci à **Mr DAOUD Amine** pour leurs précieux conseils ainsi que leurs orientations.*

Toutes nos salutations vont aux enseignants de la faculté des sciences appliquées

Dédicace

Mes parents Aucune dédicace ne saurait exprimer l'amour, l'estime, le dévouement et le respect que j'ai toujours eu pour vous. Rien au monde ne vaut les efforts fournis jour et nuit pour mon éducation et mon bien être. Ce travail est le fruit de vos sacrifices que vous avez consentis pour mon éducation et ma formation.

Vous avez fait plus que des parents puissent faire pour que ses enfants suivent le bon chemin dans leur vie et leurs études.

Je vous dédie ce travail en témoignage de mon profond amour. Je vous souhaite santé, longévité et bonheur.

Merci papa et maman.

À mes frères.

À mes sœurs.

À mon binôme KAID Riadh qui ma comprit et soutenue, ma encouragé de finir quand j'ai senti que je suis au fond, Merci pour tout, ma cher

A tous mes professeurs.

A tous mes amis.

KERIA Amir ABD EL KADER

Dédicace

Je dédie ce travail à :

***Mes parents** Aucune dédicace ne saurait exprimer l'amour, l'estime, le dévouement et le respect que j'ai toujours eu pour vous. Rien au monde ne vaut les efforts fournis jour et nuit pour mon éducation et mon bien être. Ce travail est le fruit de vos sacrifices que vous avez consentis pour mon éducation et ma formation. Vous avez fait plus que des parents puissent faire pour que ses enfants suivent le bon chemin dans leur vie et leurs études.*

Je vous dédie ce travail en témoignage de mon profond amour.

Je vous souhaite santé, longévité et bonheur.

À mes frères qui sont ma force dans la vie.

A mon binôme KERIA Amir ; pour sa compréhension, sa folie et son sérieux au travail avec laquelle j'ai passé d'inoubliable moment.

A tous mes professeurs.

A tous mes amis

Kaïd MOHAMED RIADH

Liste d'abréviation :

IA	I ntelligence A rtificielle
ECG	E lectrocardiogram
CNN	C onvolutional N eural N etwork
ANN	A rtificial N eural N etwork
DL	D eep L earning
NAV	N œud A uriculo- V entricular
NS	N œud S inusal
GBU	U nités de T raitement G raphique
CDN	R éseau de D onnées C ardiaques
BO	O ptimisation b ayésienne

Liste des figures

Figure I.1. Anatomie du cœur.	3
Figure I.2. Circulation Systémique et Pulmonaire.	4
Figure I.3. Dépolarisation de la fibre myocardique	6
Figure I.4. Repolarisation de la fibre myocardique 7	7
Figure I.5. Montage d'Einthoven pour l'enregistrement des dérivations bipolaires des membres [14].	8
Figure I.6. Montage de Goldberger pour l'enregistrement des dérivations unipolaires des membres augmentés.	9
Figure I.7. Position des électrodes précordiales.	10
Figure I.8. Tracé ECG.	11
Figure I.9. Exemples d'ECG : (a) normal et (b): bloc de branche gauche	14
Figure I.10. Tachycardie supra-ventriculaire	15
Figure I.11. Fibrillation auriculaire	15
Figure I.12. Tachycardie ventriculaire 16	16
Figure I.13. Exemple de rythme de bigéminisme	17
Figure I.14. Exemple d'accès de fibrillation ventriculaire 17	17
Figure II.1. Réseau sémantique d'intelligence artificielle 21	21
Figure II.2 Cycle de vie de l'apprentissage automatique 22	22
Figure II.3. Réseaux de neurones 25	25
Figure II.4 : Réseau de neurones non supervisé 26	26
Figure II.5. Réseau neuronal renforcé. 26	26
Figure II.6. Neurone biologique. 27	27
Figure II.7. Modèle de réseau neuronal artificiel (ANN). 28	28
Figure II.8. Différents types d'architectures de réseaux neuronaux profonds pour la segmentation d'image. 28	28
Figure II.9. Architecture de CNN. 29	29

Figure II.10. Feature Map	30
Figure III.1. Les 5 premières lignes de la base de données.	35
Figure III.2. Logo Visual Studio Code.	36
Figure III.3. Logo Spyder.	37
Figure III.5. Logo TensorFlow.	37
Figure III.6. Logo Keras.	37
Figure III.7. Logo numpy.	38
Figure III.8. Logo pandas.	38
Figure III.9. Logo matplotlib.	38
Figure III.10. Logo scikit-learn.	39
Figure III.11. Logo seaborn.	39
Figure III.12. Logo python.	40
Figure III.14. Model Accuracy.	48
Figure III.16. Matrice de confusion. avec normalisation.	50

Sommaire

Introduction générale :	1
CHAPITRE I : SYNTHESE BIBLIOGRAPHIQUE	1
Introduction:.....	Error! Bookmark not defined.
I.1. Anatomies de cœur.....	2
I.2. Types de circulation sanguine : une circulation pulmonaire et systématique : 3	
I.2.1. La circulation pulmonaire	3
I.2.2. La circulation systémique.....	3
I.3. Activité mécanique cardiaque	4
I.3.1. La systole auriculaire	4
I.3.2. La contraction ventriculaire isovolumique.....	4
I.3.3. La systole ventriculaire	4
I.3.4. La diastole	4
I.3.5. La relaxation ventriculaire	5
I.3.6. La phase de repos	5
C'est celle pendant laquelle le sang des veines caves et pulmonaires s'écoule librement dans les ventricules via les oreillettes [8].	5
I.4. La conduction électrique du cœur	5
I.4.1. Le nœud sinusal (NS).....	5
I.4.2. Le nœud auriculo-ventriculaire (NAV).....	5
I.4.3. Le faisceau de His	5
I.4.4. Les fibres de Purkinje.....	6
I.5. La dépolarisation	6
I.6. La repolarisation.....	7
I.7. L'Électrocardiogramme (ECG).....	7
I.7.1. Dérivations bipolaires des membres	8
I.7.2. Dérivations unipolaires des membres	9

I.8. Ondes et Intervalles de L'ECG.....	10
I.8.1. L'onde P.....	11
I.8.2. Le complexe QRS	11
I.8.3. L'onde T	11
I.8.4. L'intervalle RR	12
I.8.5. Le segment ST.....	12
I.8.6. L'intervalle PQ	12
I.8.7. L'intervalle QT.....	12
I.9. Troubles du rythme et de la conduction cardiaque	12
I.9.1. Rythme sinusal	13
I.9.2. Blocs cardiaques.....	13
I.9.3. Bloc Sino-Auriculaire (Bloc SA).....	13
I.9.4. Bloc auriculo-ventriculaire.....	13
I.9.5. Blocs de branche	14
I.10. Les arythmies cardiaques	14
I.10.1. Arythmies supra ventriculaires.....	14
Arythmies ventriculaires	16

CHAPITRE II : Réseaux de neurones 19

II.1. 1.Intelligence artificielle.....	20
II.1.1. 1.1Application de l'intelligence artificielle	20
II.2. Apprentissage automatique	22
II.2.1. Apprentissage automatique automatisé.....	22
II.3. Les types d'apprentissage des réseaux de neurones.....	23
II.3.1. APPRENTISSAGE SUPERVISE.....	23
II.3.2. L'apprentissage non supervisé	23
II.4. Apprentissage automatique dans les applications médicales :.....	24
II.5. Les réseaux de neurones.....	24
II.5.1. Réseau de neurones supervisé.....	25
II.5.2. Réseau de neurones non supervisé.....	25
II.5.3. Réseau de neurones renforcé.....	26
II.6. Réseau neuronal biologique	27

II.7. Structures de réseaux neuronaux profonds	28
II.8. CNN.....	29
II.8.1. La couche de convolution	30
II.8.2. Stride	30
II.8.3. Domaines d’application CNN :.....	31
II.8.4. L’entraînement d’un nouveau CNN :.....	31
CHAPITRE III : Simulation et Résultat	33
Introduction	34
III.1. La base de données utilisée	34
III.2. Prétraitement de données.....	35
III.2.1. Classification binaire	35
III.2.2. Classification multi classe.....	35
III.2.3. Aperçu sur la base de données:	35
III.3. Présentation des outils utilisés :	36
III.3.1. Outils logiciels.....	36
III.4. Organigramme:.....	40
III.4.1. Charger les bibliothèques nécessaires :.....	42
III.4.2. Importe dataset:	43
III.4.3. Valeur de chaque classe :	43
III.4.4. peek on classes	44
III.5. Result	44
III.5.1. Plotting Classes ECG	46
III.5.2. CNN Training.....	46
III.5.3. Accuracy &loss	47
III.5.4. Save model	50
III.5.5. Test le model	50
CONCLUSION ET PERSPECTIVES.....	53
Conclusion et perspectives.....	54
REFERENCES BIBLIOGRAPHIQUES.....	56

Introduction générale :

L'intelligence artificielle (IA) joue un rôle essentiel dans l'analyse des électrocardiogrammes (ECG) en raison de son potentiel à améliorer la précision, l'efficacité et la rapidité des diagnostics cardiaques. Grâce à des algorithmes d'apprentissage automatique sophistiqués, l'IA peut détecter et interpréter avec précision les anomalies du rythme cardiaque, les troubles de la conduction et d'autres affections cardiaques à partir des signaux ECG. En fournissant une assistance aux professionnels de la santé, elle permet une détection précoce des problèmes cardiaques, des interventions rapides et des soins personnalisés. De plus, l'IA contribue à réduire la charge de travail des médecins en automatisant une partie du processus d'analyse de l'ECG, ce qui permet de gagner du temps et d'améliorer l'efficacité des soins. En somme, l'utilisation de l'IA dans l'analyse de l'ECG ouvre de nouvelles perspectives pour des diagnostics précis, des traitements ciblés et une meilleure prise en charge des patients atteints de troubles cardiaques.

Dans ce mémoire, nous aborderons en détail l'utilisation de l'intelligence artificielle pour la classification des signaux ECG. Le premier chapitre sera consacré à une étude approfondie du cœur et de l'ECG, en mettant l'accent sur les principes fondamentaux de l'activité cardiaque et la manière dont les informations électriques sont enregistrées par l'ECG. Nous examinerons également les différentes ondes et segments de l'ECG qui fournissent des indices précieux sur la fonctionnalité cardiaque.

Le deuxième chapitre sera dédié à l'intelligence artificielle, en mettant particulièrement l'accent sur les réseaux de neurones artificiels (RNA). Nous explorerons les concepts de base des RNA, leur structure, leur fonctionnement et leur capacité à apprendre à partir des données. Nous aborderons également d'autres techniques d'apprentissage automatique utilisées en conjonction avec les RNA, telles que les réseaux de neurones convolutifs (RNC), qui ont démontré leur efficacité dans la classification des signaux ECG.

Dans le dernier chapitre, nous présenterons les résultats de notre modèle de classification ECG basé sur l'intelligence artificielle. Nous avons utilisé la base de données MIT-BIH, une référence dans le domaine de l'analyse des signaux ECG. Nous discuterons des performances de notre modèle, notamment sa précision, sa sensibilité et sa spécificité dans la détection des différentes anomalies cardiaques. Nous soulignerons également les avantages et les limites de l'IA dans la classification des signaux ECG, tout en abordant les considérations éthiques liées à l'utilisation de ces modèles pour la prise de décision médicale

CHAPITRE I

Exploration de

l'électrocardiogramme

(ECG)

Introduction :

L'activité cardiaque est essentielle à la survie de l'organisme. Le cœur, en tant que pompe centrale du système circulatoire, maintient la circulation sanguine en propulsant le sang à travers le corps. Cette activité est soutenue par des signaux électriques qui coordonnent les contractions du muscle cardiaque, assurant un fonctionnement harmonieux [1].

L'électrocardiogramme, couramment appelé ECG, est un outil médical puissant permettant de mesurer et d'enregistrer ces signaux électriques produits par le cœur. Il s'agit d'une méthode non invasive et couramment utilisée pour évaluer l'activité électrique du cœur. L'ECG fournit des informations précieuses sur le rythme cardiaque, la conduction électrique et la fonctionnalité globale du cœur [2].

L'ECG a révolutionné la pratique de la cardiologie en fournissant un moyen fiable de diagnostiquer et de surveiller les maladies cardiovasculaires. Les troubles du rythme cardiaque, les maladies coronariennes, les infarctus du myocarde et d'autres affections cardiaques peuvent être identifiés et évalués à l'aide de l'ECG. De plus, l'ECG est également utilisé pour évaluer l'efficacité des traitements cardiaques, suivre l'évolution des patients et détecter les complications potentielles. Ce chapitre est consacré à la définition de l'ECG nous terminons le chapitre par une brève présentation de quelques maladies qui peuvent affecter le cœur [3].

I.1. Anatomies de cœur

Le cœur est un organe creux contractile assurant la circulation sanguine. C'est un muscle strié creux se divisant en deux moitiés indépendantes (droite et gauche). Sa partie droite contient du sang pauvre en oxygène et assure la circulation pulmonaire ; sa partie gauche renferme du sang riche en oxygène et le propulse dans tous les tissus. Chacune des moitiés comporte une oreillette et un ventricule qui communiquent par des valves d'admission qui à l'état normal, laissent passer le sang uniquement de l'oreillette vers le ventricule. Il existe aussi des valves d'échappement qui assurent la communication entre le ventricule droit et l'artère pulmonaire (valve pulmonaire), ainsi qu'entre le ventricule gauche et l'artère aorte (valve aortique). Ces deux valves se trouvent à l'entrée de l'aorte et de l'artère pulmonaire respectivement. Les parois du cœur sont constituées par le muscle cardiaque, appelé myocarde composé d'un ensemble de cellules musculaires cardiaques ou cardiomyocytes [4,5].




Figure I.1. Anatomie du cœur.

I.2. Types de circulation sanguine : une circulation pulmonaire et systématique :

I.2.1. La circulation pulmonaire

La circulation pulmonaire ou la petite circulation, comprend l'oreillette et le ventricule droit (dite le cœur droit) elle a pour fonction de transporter le sang vers les poumons où il se débarrasse du CO₂ et absorbe de l'oxygène. Il est ensuite redirigé vers le cœur, dans l'oreillette gauche, par les veines pulmonaires [6].

I.2.2. La circulation systémique

Circulation systémique ou la grande circulation comprend la partie gauche du cœur (dite le cœur gauche) contenant l'oreillette et le ventricule gauche [6]. Elle assure la distribution générale du sang aux tissus de l'ensemble du corps et les organes vitaux : cerveau, reins, foie, etc.

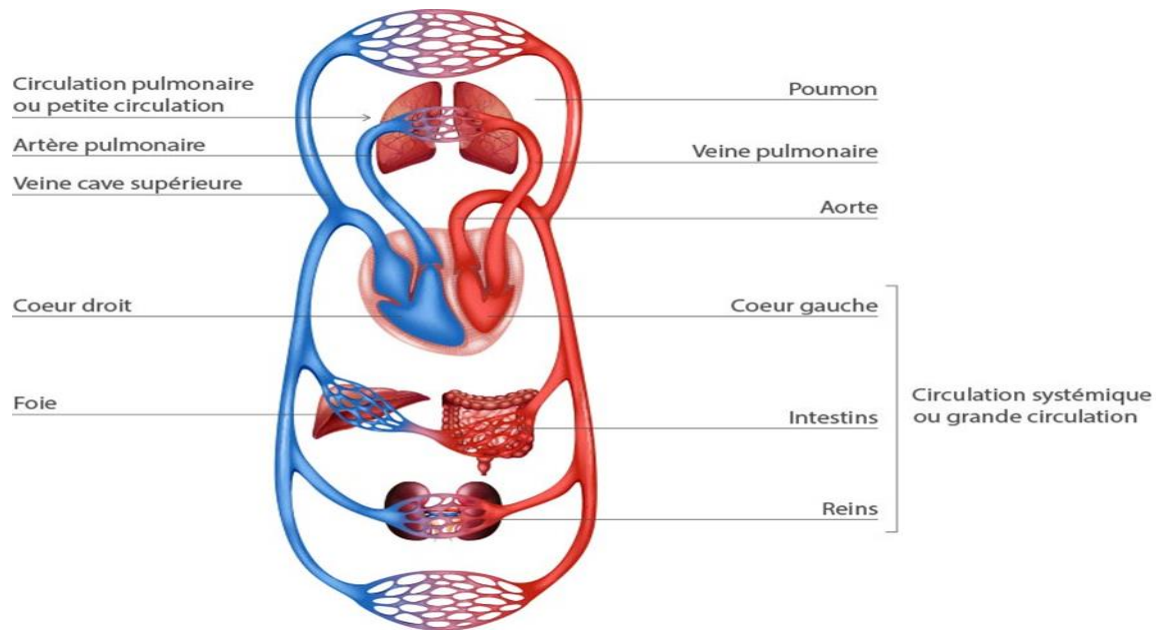


Figure I.2. Circulation Systémique et Pulmonaire [7].

I.3. Activité mécanique cardiaque

Le cycle de la circulation sanguine se répète infiniment et se divise en deux périodes : la systole et la diastole. La systole est la période correspondant à l'envoi du sang dans la grande et petite circulation. Elle se décompose en trois phases : la systole auriculaire, la contraction ventriculaire isovolumique et la systole ventriculaire [8].

I.3.1. La systole auriculaire

C'est la contraction des oreillettes quand elles sont remplies de sang.

I.3.2. La contraction ventriculaire isovolumique

Commence lorsque les cellules musculaires du myocarde ventriculaire se contractent.

I.3.3. La systole ventriculaire

Commence lorsque les pressions dans les ventricules dépassent les pressions dans l'artère pulmonaire et l'aorte.

I.3.4. La diastole

C'est la phase de relaxation du cœur pendant laquelle il se remplit de sang. Cette période est composée de deux phases : la relaxation ventriculaire isométrique et la phase de repos.

I.3.5. La relaxation ventriculaire

Fait suite à la systole. Les ventricules se relâchent, la pression chute jusqu'à être inférieure à celle exercée dans l'aorte et l'artère pulmonaire [8].

I.3.6. La phase de repos

C'est celle pendant laquelle le sang des veines caves et pulmonaires s'écoule librement dans les ventricules via les oreillettes [8].

I.4. La conduction électrique du cœur

La contraction du muscle cardiaque (ou myocarde) a pour origine la propagation d'une onde électrique qui excite les cellules musculaires dans un ordre bien établi afin que la contraction soit la plus efficace possible. Le système spécialisé d'excitation/conduction électrique comprend : le nœud sinusal les voies spécialisées intermodales le nœud auriculo-ventriculaire (NAV), le faisceau de His, appelé nœud pacemaker dominant du cœur les branches droite et gauche et les fibres de Purkinje. L'activité électrique normale du cœur suit la séquence d'activation suivante [8].

I.4.1. Le nœud sinusal (NS)

L'activité électrique est générée spontanément dans le nœud sinusal qui est situé dans la partie haute de la paroi intérieure de l'oreillette droite au niveau où débouche la veine cave supérieure. L'impulsion cardiaque initiée dans le nœud sinusal est transmise aux deux oreillettes. Cette activation est facilitée au moyen des voies spécialisées intermodales qui relient le nœud sinusal au nœud auriculo-ventriculaire [8].

I.4.2. Le nœud auriculo-ventriculaire (NAV)

Il est situé en bas de l'oreillette droite et est constitué de cellules qui présentent une conduction électrique lente. L'activation électrique qui arrive au NAV est physiologiquement ralentie avant d'arriver au faisceau de His. Cette propriété physiologique du NAV permet de protéger les ventricules d'un nombre excessif d'activations du NAV et d'activations auriculaires et concède aux oreillettes un temps de vidange plus grand, ce qui optimise la contraction ventriculaire.

I.4.3. Le faisceau de His

Il est situé dans la partie haute du septum inter ventriculaire et ses fibres traversent le tissu connectif (non excitable) qui sépare électriquement les oreillettes des ventricules. Dans les cas normaux, le NAV et le faisceau de His constituent la seule voie de propagation de l'activité

électrique cardiaque entre les oreillettes et les ventricules. L'ensemble de ces deux structures est souvent appelé la jonction auriculo-ventriculaire. Le faisceau de His comprend un tronc initial qui se divise en deux branches, droite pour le ventricule droit et gauche pour le ventricule gauche.

I.4.4. Les fibres de Purkinje

Les branches du faisceau de His finissent dans un réseau de fibres qui arrivent dans les parois ventriculaires. Les fibres de Purkinje terminent en anastomoses avec les fibres myocardiques musculaires, facilitant leur excitation [9].

I.5. La dépolarisation

Au repos, la fibre cardiaque est polarisée, chargée positivement à l'extérieur et négativement à l'intérieur de la fibre (Figure 3. A). La stimulation induit des changements de la perméabilité de la membrane cellulaire avec inversion des charges électriques, qui deviennent positives à l'intérieur de la fibre et négatives à l'extérieur. Ensuite, cette dépolarisation se propage le long de la fibre (Figure. B) jusqu'à la dépolarisation complète (Figure. C). La transmission aux fibres adjacentes utilise le même mécanisme. Un vecteur représente la propagation de la dépolarisation le long de la fibre avec une direction allant du négatif au positif [10].

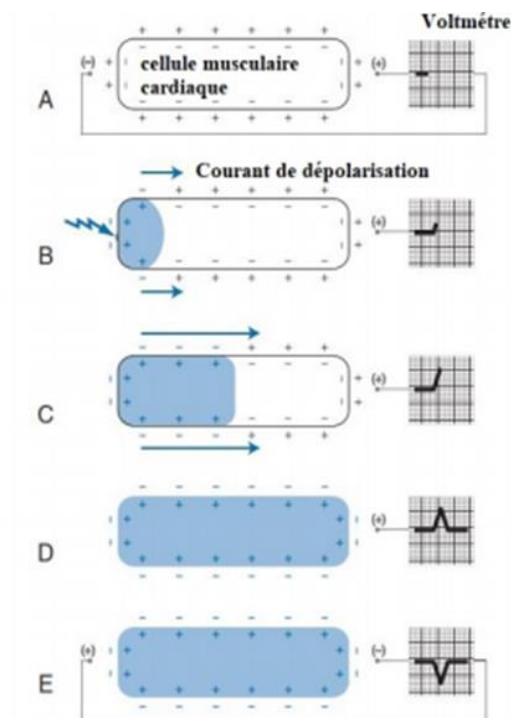


Figure I.3. Dépolarisation de la fibre myocardique [10].

I.6. La repolarisation

Le front d'onde de repolarisation des fibres suit le front d'onde de dépolarisation tout en ramenant les charges électriques à l'état de repos (Figure 4.A). Comme le front d'onde de dépolarisation, le front d'onde de repolarisation progresse le long de la fibre dans la direction opposée (Figure 4.B) ou dans la même direction (Figure 4.C), avec le même résultat final présentant une fibre chargée positivement à l'extérieur et négativement à l'intérieur (Figure 4.D). La flèche qui peut également représenter le front d'onde de repolarisation aura une direction opposée du positif au négatif. Les fronts d'onde de dépolarisation ou de repolarisation sont représentés par un vecteur ou une flèche. La flèche représentant la dépolarisation est positive à l'extrémité et négative à l'arrière. L'inverse est vrai pour le front d'onde de repolarisation : négatif à la pointe et positif à l'arrière. En résumé, la flèche montre la direction de propagation du front d'onde électrique : le front d'onde de dépolarisation est négatif à son origine alors que le vecteur de front d'onde de repolarisation est positif [10].

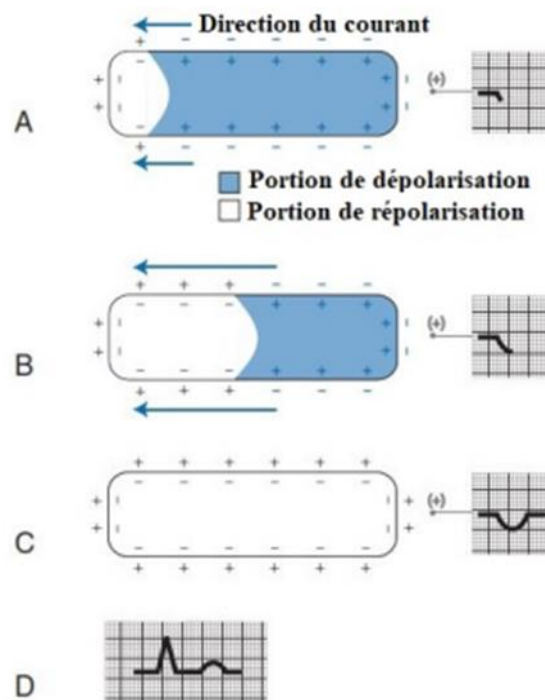


Figure I.4. Repolarisation de la fibre myocardique [10].

I.7. L'Électrocardiogramme (ECG)

L'électrocardiogramme (ECG) est un examen diagnostique non invasif peu coûteux et pos dont de nombreuses indications y compris en médecine d'urgence (MU) [11]. Les conditions de réalisation doivent être strictes afin de ne pas compromettre l'interprétation. En effet une

mauvaise position du patient lors de l'enregistrement peut modifier sensiblement le tracé et donc l'interprétation [12]. Dans les structures de médecine d'urgence (SMU) la réalisation est majoritairement faite par un infirmier diplômé d'état et la première interprétation est fréquemment réalisée par un interne. Dans la littérature seules l'expérience et les formations spécifiques (quel que soit le type de formation ou la méthode d'apprentissage) sont liées significativement à une meilleure qualité d'interprétation [13].

I.7.1. Dérivations bipolaires des membres

Les dérivations bipolaires des membres permettent d'étudier l'activité électrique du cœur sur le plan frontal. Elles ont été déterminées par Einthoven [Einthoven, 1906] au début du vingtième siècle et restent encore utilisées aujourd'hui. Ces trois dérivations sont déduites des trois électrodes posées sur les membres. Soit VL le potentiel sur le bras gauche, VR le potentiel sur le bras droit et VF le potentiel sur la jambe gauche, les trois dérivations sont :

- DI (dérivation I) dont la différence de potentiel respecte l'équation $DI = VL - VR$,
- DII (dérivation II) avec $DII = VF - VR$,
- DIII (dérivation III) avec $DIII = VF - VL$.

Ces trois dérivations constituent le triangle d'Einthoven et chaque dérivation est une arête du triangle (voir Figure 5).




Figure I.5. Montage d'Einthoven pour l'enregistrement des dérivations bipolaires des membres [14].

Le triangle d'Einthoven est formé par les trois électrodes posées sur le bras droit le bras gauche et la jambe gauche. Sur la jambe droite est posée une électrode qui sert de référence (la masse).

Le cœur se trouve au centre du triangle et les trois dériviations bipolaires permettent l'enregistrement sous trois angles différents [14].

I.7.2. Dérivations unipolaires des membres

Les dériviations unipolaires des extrémités enregistrent la différence de potentiel entre un point théorique au centre du Triangle de Einthoven, ayant une valeur de 0 et l'électrode de chaque extrémité, permettant ainsi de connaître le potentiel absolu dans ladite électrode. Dans un premier temps, on a nommé ces dériviations VR, VL et VF. Le V signifiant vecteur et R, L, F : droite, gauche et pied (en anglais). Plus tard, on a ajouté le 'a' minuscule qui signifie amplifiée (les dériviations unipolaires actuelles sont amplifiées par rapport aux premières) [14]

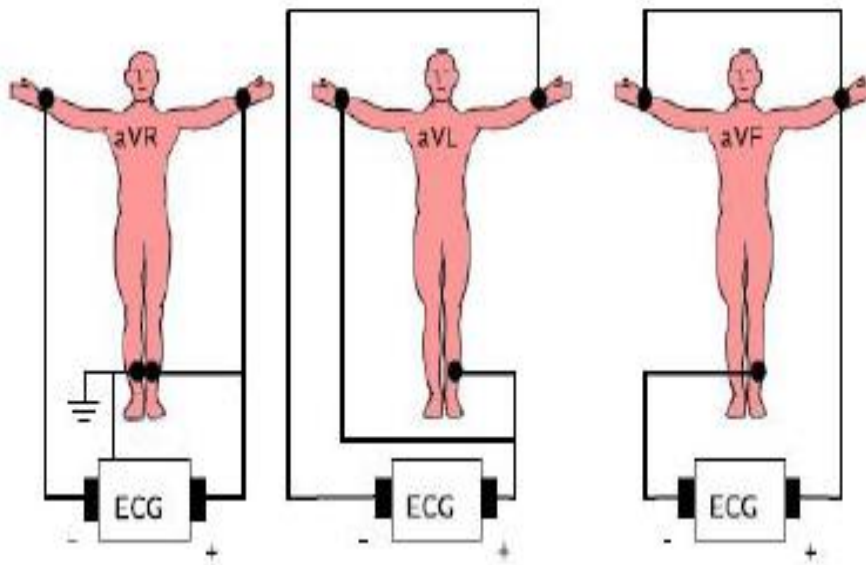


Figure I.6. Montage de Goldberger pour l'enregistrement des dériviations unipolaires des membres augmentés.

Les droites dériviations sont :

- aVL (a comme augmente) dont la différence de potentiel respecte l'équation
- $aVL = VL - VR - VF/2 = 1,5VL$ car selon la loi de Kirchhoff $VL + VR + VF = 0$;
- aVR avec $aVR = 1, WR$;
- aVF avec $aVF = 1,5VF$.

Ces trois dérivations constituent trois vecteurs passant au centre du triangle d'Einthoven (voir Figure 6).

I.7.2.1. Dérivations précordiales

Il y a six pistes précordiales. Ils sont désignés par un V majuscule et un nombre compris entre 1 et 6. Ce sont des dérivations unipolaires, ils enregistrent le potentiel absolu du point où est placée l'électrode de même nom. Ce sont les dérivations les mieux adaptées pour dépister les anomalies du ventricule gauche, en particulier celles des parois antérieure et postérieure. Sur un électrocardiogramme normal, les QRS sont principalement négatifs dans les dérivations V1 et V2 et majoritairement positifs dans V4 à V6 (profil Rs) [14].




Figure I.7. Position des électrodes précordiales.

Ces dérivations sont positionnées comme suit :

- V1 : 4ème espace intercostal, bord droit du sternum (ligne parasternale).
- V2 : 4ème espace intercostal, bord gauche du sternum (ligne parasternale).
- V3 : à mi-distance entre V2 et V4.
- V4 : 5ème espace intercostal, ligne médio-claviculaire gauche.
- V5 : à mi-distance entre V4 et V6, sur la ligne axillaire antérieure.
- V6 : même niveau horizontal que V4 et V5, ligne axillaire moyenne

I.8. Ondes et Intervalles de L'ECG

Le processus de dépolarisation et de repolarisation des structures myocardiques se présente dans l'ECG comme une séquence de déflexions ou ondes superposées à une ligne de potentiel

zéro, appelée ligne isoélectrique ou ligne de base. Ces déflexions sont dites positives si elles sont situées au-dessus de la ligne isoélectrique sinon elles sont dites négatives. Pour chaque battement cardiaque l'ECG enregistre principalement trois ondes successives comme montré sur la figure 8 [15].




Figure I.8. Tracé ECG.

I.8.1. L'onde P

Elle représente la dépolarisation auriculaire. Cette onde peut être positive ou négative avec une durée de l'ordre de 90 ms. Généralement son observation est difficile, spécialement dans des conditions bruitées. Il faut noter que la repolarisation auriculaire n'est pas visible sur l'ECG car elle coïncide avec le complexe QRS d'amplitude plus importante.

I.8.2. Le complexe QRS

Il correspond à la dépolarisation ventriculaire précédant l'effet mécanique de contraction et il possède la plus grande amplitude de l'ECG. Il est constitué de trois ondes consécutives :

L'onde Q qui est négative, l'onde R qui est positive dans un ECG normal et l'onde S qui est négative. Sa durée normale est comprise entre 85 et 95 ms.

I.8.3. L'onde T

Elle correspond à la repolarisation des ventricules, qui peut être négative, positive ou bi-phasique et qui a normalement une amplitude plus faible que le complexe QRS. Bien que la dépolarisation et la repolarisation des ventricules soient des événements opposés, l'onde T est normalement du même signe que l'onde R, ce qui indique que la dépolarisation et la

repolarisation ne sont pas symétriques. L'ECG est aussi caractérisé par plusieurs intervalles comme on peut voir sur la figure 8.

I.8.4. L'intervalle RR

Il est délimité par les sommets de deux ondes R consécutives et d'où est évaluée la fréquence cardiaque instantanée. Cet intervalle est utilisé pour la détection des arythmies ainsi que pour l'étude de la variabilité de la fréquence cardiaque.

I.8.5. Le segment ST

Il représente l'intervalle durant lequel les ventricules restent dans un état de dépolarisation actif. Il est aussi défini comme la durée entre la fin de l'onde S et le début de l'onde T.

I.8.6. L'intervalle PQ

Il représente l'intervalle de temps entre le début de la dépolarisation des oreillettes et le début de la dépolarisation ventriculaire. Il représente le temps nécessaire à l'impulsion électrique pour se propager du nœud sinusal jusqu'aux ventricules et il est mesuré entre le début de l'onde P et le début du complexe QRS.

I.8.7. L'intervalle QT

Il représente la durée entre le début du complexe QRS et la fin de l'onde T. Cet intervalle reflète la durée de la dépolarisation et repolarisation ventriculaire. En effet sa dynamique peut être associée à des risques d'arythmie ventriculaire et de mort cardiaque soudaine [15].

I.9. Troubles du rythme et de la conduction cardiaque

Sous cette dénomination on regroupe les arythmies cardiaques et les blocs cardiaques.

Le meilleur outil pour diagnostiquer une arythmie est l'électrocardiogramme. Dans l'analyse de l'ECG, les pathologies ou anomalies sont détectées et classées en fonction de leur déviation par rapport au rythme idéal qu'est le rythme sinusal. Chaque déviation visible sur l'ECG peut être attribuée à une anomalie physiologique. Ainsi, les blocs cardiaques sont dus à un défaut de conduction de l'onde de dépolarisation à travers le myocarde différencié et les arythmies sont générées par un foyer ectopique prenant le relais ou supplantant le nœud sinusal. Ces pathologies ne sont pas exclusives, un patient peut être atteint d'arythmies et de blocs cardiaques.

Les sections suivantes détaillent le rythme sinusal, les blocs cardiaques et certaines arythmies cardiaques [16].

I.9.1. Rythme sinusal

Le rythme sinusal est le rythme normal cardiaque. Il correspond à une activation physiologique des oreillettes, puis des ventricules, à partir du nœud sinusal. Son rythme est compris entre 60 à 80 battements par minute avec un intervalle régulier entre des battements normaux. Le cœur s'accélère normalement lors de l'activité physique, dans les circonstances physiologiques qui exigent un surcroît de demande métabolique ou sous l'effet des émotions ou d'excitants tels que café, tabac et alcool.

I.9.2. Blocs cardiaques

Les blocs cardiaques sont dus à une rupture de conduction du myocarde qui altère la dépolarisation. Ces ruptures peuvent être plus ou moins sévères : freinées (allongement du temps de parcours), intermittentes (le blocage de la conduction se fait aléatoirement), ou complètes (aucune conduction) [16].

I.9.3. Bloc Sino-Auriculaire (Bloc SA)

Le nœud sinusal peut ne pas transmettre de stimulus aux cellules des oreillettes. La conséquence est qu'au moins un cycle complet n'est pas effectué. Après la pause, due au bloc, le cycle reprend normalement si aucun autre foyer ectopique n'a déclenché la contraction.

I.9.4. Bloc auriculo-ventriculaire

Le bloc auriculo-ventriculaire (AV) peut être défini comme un retard ou une interruption de la transmission d'une impulsion des oreillettes aux ventricules provoquée par une altération anatomique ou fonctionnelle du système de conduction [17, 18]. Les anomalies de la conduction nodale AV peuvent être classées en trois types : premier, deuxième et troisième degré [17, 18]. Le bloc AV du premier degré prolonge simplement l'intervalle P-R au-dessus de 200 millisecondes (ms). Dans le bloc AV du deuxième degré, certaines impulsions auriculaires ne parviennent pas à atteindre les ventricules. On distingue deux types de blocs AV [17, 18].

- Type 1 : (phénomène de Wenckebach) qui se produit au niveau du nœud AV, entraînant un allongement progressif de l'intervalle PR jusqu'à ce qu'un complexe QRS ou une dépolarisation ventriculaire ne se produise pas.
- Type 2 : qui se produit au niveau du faisceau de His et est défini comme la perte intermittente de la conduction AV sans allongement préalable de l'intervalle. Cette forme de bloc AV du second degré est moins courante et suggère une forme plus grave de trouble de la conduction AV dans lequel la progression vers un bloc

cardiaque complet avec compromis hémodynamique est plus probable. Dans le bloc cardiaque du troisième degré (complet), toutes les impulsions auriculaires ne parviennent pas aux ventricules dont le débit est inférieur à 40 bpm [17, 18].

I.9.5. Blocs de branche

Le bloc de branche est dû au blocage de la dépolarisation dans une des branches du faisceau de His. Un bloc dans l'une ou l'autre branche provoque un retard dans la dépolarisation du ventricule auquel elle appartient. La dépolarisation des ventricules est désynchronisée et le complexe QRS est élargi par rapport à l'ECG normal comme montré sur la figure 9 [16].




Figure I.9. Exemples d'ECG : (a) normal et (b): bloc de branche gauche [21].

I.10. Les arythmies cardiaques

Arythmie est une anomalie qui affecte la fréquence cardiaque normale. Plusieurs types d'arythmies ne présentent aucun problème de santé ; cependant, elles peuvent causer divers symptômes gênants, comme des étourdissements ou une douleur dans la poitrine. D'autres formes d'arythmies, plus dangereuses, ont des répercussions sur l'apport sanguin et nécessitent de ce fait une prise en charge médicale. Si une arythmie accélère le rythme cardiaque, on parlera de tachycardie (tachy = rapide) ; si elle le ralentit, on parlera alors de bradycardie (Brady = lent) [19].

I.10.1. Arythmies supra ventriculaires

I.10.1.1. La tachycardie supra-ventriculaire

Lors de tachycardie paroxystique, le cœur s'emballé soudainement et bat très rapidement, jusqu'à 150 à 220 fois par minute comme montré sur la figure 10. Ces épisodes peuvent durer quelques secondes ou se prolonger pendant plusieurs heures. Ils s'arrêtent aussi soudainement qu'ils sont apparus. Les tachycardies supraventriculaires peuvent apparaître dès le très jeune âge et persister toute la vie. Après ces crises, le sujet se sent fatigué, mais ce type d'arythmie

est rarement dangereux. Elles nécessitent néanmoins l'attention du médecin, car elles peuvent être gênantes et diminuer la qualité de vie [20].




Figure I.10. Tachycardie supra-ventriculaire [21].

I.10.1.2. La fibrillation auriculaire

Une fibrillation auriculaire est définie comme la contraction anarchique des oreillettes, qui entraîne une contraction rapide et irrégulière des ventricules comme montré sur la figure 11. Il s'agit d'un trouble du rythme du cœur très fréquent, en particulier chez les sujets de plus de 60 ans. Le diagnostic est difficile car les symptômes de fibrillation auriculaire ne sont absolument pas ressentis.




Figure I.11. Fibrillation auriculaire [21].

I.10.2. Arythmies ventriculaires

I.10.2.1. L'arythmie extrasystolique

L'arythmie extrasystolique est la plus fréquente. Les extrasystoles sont des battements ectopiques, uniques ou répétés, provenant d'un seul ou de plusieurs foyers qui peuvent entraîner des sensations désagréables de ratés, de coups dans la poitrine, d'arrêts de cœur ou de palpitations. Les extrasystoles sont des phases systoliques en trop qui seront apparentes sur l'ECG par un complexe QRS large. Les extrasystoles ne constituent habituellement pas en elles-mêmes un facteur de gravité, leur pronostic dépend de l'état cardiaque qui peut être absolument normal (extrasystoles dites bénignes) ou pathologique. Lorsqu'il existe un double foyer ventriculaire, on parle de doublet ventriculaire.

I.10.2.2. La tachycardie ventriculaire

La tachycardie ventriculaire est en général la manifestation d'un dysfonctionnement du muscle cardiaque. Elle peut apparaître à tout âge, mais elle est fréquemment la conséquence d'un infarctus du myocarde. Elle se manifeste par la désynchronisation des battements ventriculaires qui conduit à une diminution du pompage du sang voire figure 12.




Figure I.12. Tachycardie ventriculaire [21]

I.10.2.3. Les bigéminismes et trigéminismes

Sont des rythmes à deux commandes. La commande de base (généralement sinusale) est interrompue par des battements d'origine ectopique. Lorsque l'on se trouve en présence d'un bigéminisme les QRS qui appartiennent au rythme de base sont suivis d'un QRS d'origine ectopique avec une succession de 1/1. On parle de trigéminisme lorsqu'on est en présence d'une

succession 2/1. La figure 1.20 présente un exemple de rythme de bigéminisme dans le cas d'un rythme sinusal avec un foyer ectopique ventriculaire.




Figure I.13. Exemple de rythme de bigéminisme [21].

I.10.2.4. Fibrillation ventriculaire

La fibrillation ventriculaire (FV) est parfois inaugurale (mort subite), précoce (fibrillation ventriculaire primaire de bon pronostic), parfois tardive (fibrillation ventriculaire secondaire) accompagnant alors un anévrisme du ventricule gauche suite à un mauvais diagnostic. La fibrillation ne peut pas se produire dans un milieu homogène. En fait, la période réfractaire, l'excitabilité, ainsi que la vitesse de conduction n'ont pas des propriétés constantes partout dans le tissu ventriculaire comme montré sur la figure 14 [20].




Figure I.14. Exemple d'accès de fibrillation ventriculaire [21].

Conclusion

Dans ce chapitre, nous avons brièvement passé en revue l'élément de base de l'électrophysiologie du cœur. Après une introduction sur l'anatomie du cœur humain nous avons décrit l'activité mécanique du cœur ainsi que le système de conduction électrique du cœur.

Ainsi ce chapitre nous a permis de définir le tracé utilisé dans ce mémoire qui est l'ECG et nous avons fini par présenter quelques arythmies comme les extrasystoles ventriculaires et comment apparaissent-elles sur le tracé de l'électrocardiogramme pour permettre d'arriver à poser un diagnostic.

CHAPITRE II

Réseaux de neurones

Introduction

Les soins de santé ont récemment commencé à tirer profit des récentes avancées en Intelligence artificielle (IA). Parmi ceux-ci sont les méthodes dites d'apprentissage profond (DL), qui sont des modules non linéaires qui peuvent apprendre automatiquement de multiples niveaux de représentations à partir de données de haute dimension sans avoir besoin de l'ingénierie de fonctionnalités explicites par les humains [22,23]. Les réseaux de neurones convolutionnels (CNN) en particulier, qui ont d'abord gagné en notoriété en 2012 lorsqu'ils ont affiché des performances de pointe sur l'Image Net Large-Scale Visual Recognition Challenge (ILSVRC) [24], ont depuis pris les devants dans la méthode de résolution des problèmes de vision par ordinateur. L'apprentissage profond a également montré des performances de pointe sur une variété de tâches impliquant la classification [25,26], la segmentation [27,28,29], et d'autres aspects de l'imagerie médicale [30].

Nous illustrerons et décrirons les architectures de réseau neuronal, SVM et deep learning choisies dans ce chapitre. Nous discuterons également des façons d'apprendre (machine learning).

II.1. 1.Intelligence artificielle

L'intelligence artificielle est définie de diverses façons. Le test de Turing définit l'IA comme la capacité des ordinateurs à communiquer avec les humains (par des dispositifs de sortie électroniques) sans exposer leur nature non humaine, où le critère de jugement clé est binaire. L'un des pionniers de l'IA, Marvin Minsky, a défini l'IA comme la capacité des robots à accomplir des tâches nécessitant l'intelligence humaine. Selon l'école symbolique, l'IA est l'opération des symboles, et les symboles les plus primitifs correspondent aux réalités physiques. Bien qu'il existe de multiples définitions de l'IA, les idées d'étude, les méthodologies, les techniques et les applications pour imiter, étendre et augmenter l'intellect humain sont largement acceptées. Actuellement, la notion d'IA a une influence croissante sur l'existence humaine. L'IA est la pierre angulaire de la technique à l'ère moderne et au-delà, semblable aux rôles des machines à vapeur à l'ère de la vapeur, des générateurs à l'ère de l'électricité et des ordinateurs à l'ère de l'information [31].

II.1.1. Application de l'intelligence artificielle

Le terme "AI" a gagné en popularité dans pratiquement tous les domaines de notre vie. Les résultats de la recherche Web of Science (2021-08-26) ont été utilisés pour construire le graphique de réseau sémantique (Figure 15), qui a ensuite été visualisé à l'aide du programme

VOS Viewer. Il affiche les relations et le niveau d'impact des termes les plus pertinents liés à l'IA. La couleur des liens indique dans quelle mesure l'accent a été mis sur "l'application" de l'IA dans la littérature.

Les principaux domaines de concentration pour les algorithmes sont "réseau neuronal", "classification" et "prédiction", la notion étant fortement liée aux sciences "système". Les systèmes et le génie, la science du cerveau, la psychologie, les sciences cognitives, les mathématiques, l'informatique et bien d'autres sciences font partie des domaines de recherche de l'IA. L'intelligence artificielle (IA) a un large éventail d'applications, notamment la reconnaissance vocale [32,33], le traitement d'images [34,35], le traitement du langage naturel [36,37], les robots intelligents [38,39], les véhicules autonomes [40,41], les systèmes énergétiques [42,43], les soins de santé [44,45], FinTech [46], et plus encore. L'IA a surpassé les humains dans quelques niches.

Un nouveau débat sur la façon dont l'IA pourrait modifier la société humaine a été déclenché par les phénomènes d'IA toujours croissante qui n'est pas humaine. Malgré le fait que de nombreuses applications d'IA sont incroyables, elles ne nous ont pas mis mal à l'aise comme l'ont fait des films de science-fiction comme The Terminator ou The Matrix parce que la capacité est censée être spécifique à une zone et limitée.

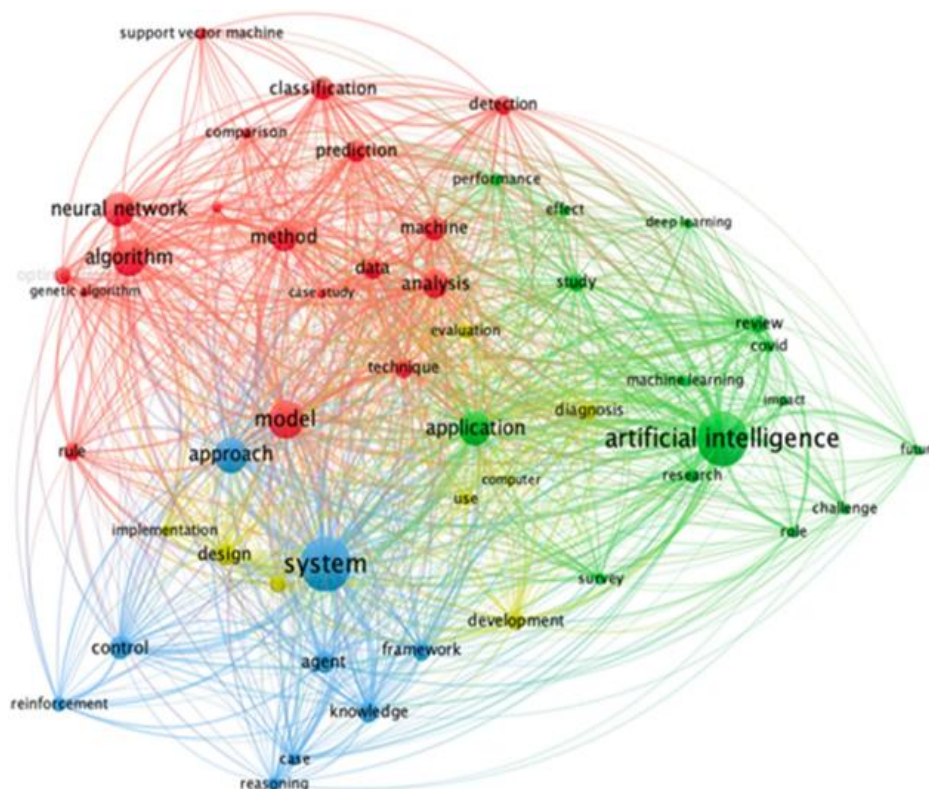


Figure II.1. Réseau sémantique d'intelligence artificielle [31].

II.2. Apprentissage automatique

La science des machines de programmation pour apprendre des données est connue sous le nom de machine Learning, ou ML en anglais. En d'autres termes, l'apprentissage automatique (ML) est le domaine de recherche qui permet aux ordinateurs d'apprendre sans programmation explicite. Aurélien Géron divise les différents systèmes d'apprentissage automatique en trois catégories basées sur une variété de facteurs. Premièrement, s'il a reçu une formation sous supervision humaine, l'apprentissage automatique non supervisé, semi-supervisionné, supervisé et renforcé sont tous possibles. La classification de l'apprentissage en ligne ou par lots suit, en tenant compte de la possibilité d'apprentissage à la volée. Enfin, il y a l'apprentissage par instance ou par modèle s'ils travaillent simplement en comparant de nouveaux points de données à des points de données connus ou s'ils trouvent des modèles dans les données d'apprentissage et créent un modèle de prédiction [47].




Figure II.2 Cycle de vie de l'apprentissage automatique [48].

II.2.1. Apprentissage automatique automatisé

Un cadre Auto ML complet peut gérer un large éventail d'activités, y compris le prétraitement des données, la sélection des fonctionnalités, la sélection des modèles, le réglage des hyperparamètres et l'analyse des résultats. L'apprentissage automatique (Auto ML) est une expression fréquemment utilisée. Il y a plusieurs Framework Auto ML disponibles ; nous allons brièvement en explorer quelques-uns.

Auto-WEKA L'un des premiers Framework Auto ML était Auto-WEKA [49], qui est encore utilisé aujourd'hui [50]. Basé sur le paquet WEKA ML basé sur Java, Auto-WEKA intègre de nombreux modèles ML utilisant BO et diverses techniques d'ensemble.

Auto-sklearn Utilisant des modèles ML du paquet Python scikit-learn, Auto-sklearn [51] a remporté plusieurs concours. Ce qui suit sont quelques éléments cruciaux qui soutiennent leur succès : Trois Auto-sklearn introduit une méthode de budget de temps pour équilibrer l'efficacité et la précision. Un Auto- Sklearn utilisent une technique de sélection de modèle d'ensemble [52] pour l'intégration des modèles. Deux Auto-sklearn utilise une approche de méta-apprentissage [53] pour préparer l'acquisition d'hyperparamètres plus précis.

II.3. Les types d'apprentissage des réseaux de neurones

Dans la phase d'apprentissage de la formation des réseaux neuronaux, les poids des neurones sont déterminés pour rapprocher les sorties des réseaux des sorties des neurones. En outre, il existe deux groupes de base pour les processus d'apprentissage : l'apprentissage supervisé et l'apprentissage non supervisé. Nous examinerons le premier de notre étude de cas afin que vous puissiez obtenir plus de détails [54,55].

II.3.1. APPRENTISSAGE SUPERVISE

Lorsque l'apprentissage est supervisé, on suppose qu'il y a un enseignant présent dont le travail consiste à évaluer la performance du réseau lorsqu'on lui donne un exemple tiré de la base d'apprentissage. Cette surveillance consiste à transmettre des données au réseau afin qu'il puisse adapter ses connexions, et parfois même sa propre architecture, afin de diminuer le taux de défaillance. Une mesure de l'erreur commise peut servir de version explicite de l'information.

Par exemple, ou tous les exemples fondamentaux combinés. Le Perceptron provoque cela. Cependant, elle peut également être plus implicite (apprentissage par renforcement), prendre la forme d'une évaluation directe (bonne ou mauvaise punition ou compensation) sans mesure erronée, ou même être appliquée globalement à toutes les tâches que le réseau doit effectuer. Dans ce dernier scénario, il est clair que l'apprentissage est la tâche la plus difficile parce que le réseau trouve difficile de déterminer les étapes précises du processus qui ont mené au succès ou à l'échec [54,55].

II.3.2. L'apprentissage non supervisé

Un nombre suffisant d'exemples contenant des répétitions (aussi connu sous le nom de redondance) doit être envoyé à un réseau autonome pour l'apprentissage sans supervision afin

que les régularités soient automatiquement libérées. Ces réseaux sont souvent appelés apprentissage compétitif ou auto-organiseurs. S'il n'y a pas de superviseur ou d'expert humain, l'apprentissage sans supervision ne contient pas d'information sur le résultat. L'objectif est de spécifier les paramètres du réseau neuronal conformément à un critère encore à préciser. Dans ce cas, les instances à l'entrée conduisent à l'auto-adaptation d'un réseau pour produire des valeurs de sortie qui sont similaires aux valeurs d'entrée en réponse. Par rapport à l'apprentissage supervisé, ce type d'apprentissage implique souvent moins de calculs compliqués. L'architecture réseau, que son utilisateur a définie, est sans aucun doute un type de supervision [54,55].

II.4. Apprentissage automatique dans les applications médicales :

Les termes outils, méthodes et techniques utilisés dans de nombreux domaines sont appelés apprentissage automatique (ML) (p. ex., médical). Il peut aider à l'identification des maladies dans une variété de domaines médicaux, y compris les capteurs portables, la détection du cancer et l'imagerie médicale. ML est utilisé pour examiner les aspects cliniques importants, comme la récupération des données médicales et la prévision des maladies et des phases de développement. Par conséquent, il facilite la planification et fournit un soutien pour l'état du patient. En outre, il assure un suivi médical efficace en aidant au traitement des données et en donnant des avertissements intelligents si nécessaire. Les informations sur les diagnostics des patients sont considérées comme des dossiers médicaux dans les hôpitaux spécialisés. L'encodage précis des données patientes est nécessaire au fonctionnement de l'algorithme d'apprentissage. L'encodage est un processus simple, mais ML doit prendre un bon départ en analysant automatiquement les données et en les comparant aux problèmes précédemment résolus de nature similaire. En conséquence, il aide le médecin à diagnostiquer précisément, simplement et rapidement de nouveaux cas. Il peut être utilisé pour diagnostiquer les patients par les non-spécialistes et les étudiants ainsi [56,57].

II.5. Les réseaux de neurones

Un réseau neuronal est une collection d'algorithmes qui vise à identifier les liens sous-jacents dans un ensemble de données en utilisant une méthode qui imite le fonctionnement du cerveau humain. Dans ce contexte, les réseaux neuronaux sont des systèmes de neurones d'origine organique ou synthétique. Puisque les réseaux neuronaux sont capables de s'adapter aux changements d'entrée, le réseau peut produire le meilleur résultat sans avoir à modifier le

critère de sortie. L'idée des réseaux neuronaux basée sur l'intelligence artificielle prend rapidement de l'importance dans la conception des systèmes de trading.

Un réseau neuronal synthétique agit de même. Sur trois couches, il fonctionne. La couche d'entrée reçoit des données. L'entrée est traitée par la couche cachée. La couche de sortie envoie alors la sortie du calcul (58).




Figure II.3. Réseaux de neurones [58].

II.5.1. Réseau de neurones supervisé

La sortie de l'entrée dans un réseau neuronal supervisé est déjà connue. La sortie anticipée du réseau neuronal est contrastée avec la sortie réelle. Les paramètres sont modifiés en réponse à l'erreur, et le réseau neuronal est alors alimenté à nouveau. Le réseau neuronal d'alimentation directe utilise des réseaux neuronaux supervisés [58].

II.5.2. Réseau de neurones non supervisé

Le réseau neuronal n'a aucune idée préalable de la sortie de l'entrée. La principale tâche du réseau consiste à classer les données en fonction de certaines similitudes. Le réseau neuronal vérifie la corrélation entre les différentes entrées et les regroupe. [58].




Figure II.4 : Réseau de neurones non supervisé [58].

II.5.3. Réseau de neurones renforcé

L'apprentissage du renforcement décrit les algorithmes orientés vers les buts qui découvrent comment maximiser le long d'un axe spécifique sur un certain nombre d'itérations, pour maximiser le nombre de points marqués pendant un jeu. Ils sont capables de partir de rien, et étant donné les circonstances correctes, ils sont capables de performance surhumaine. Ces algorithmes sont punis quand ils font les jugements incorrects et récompensés quand ils font les bons, tout comme un bambin qui est encouragé par les fessées et les bonbons. Cela a appelé renforcement [58].

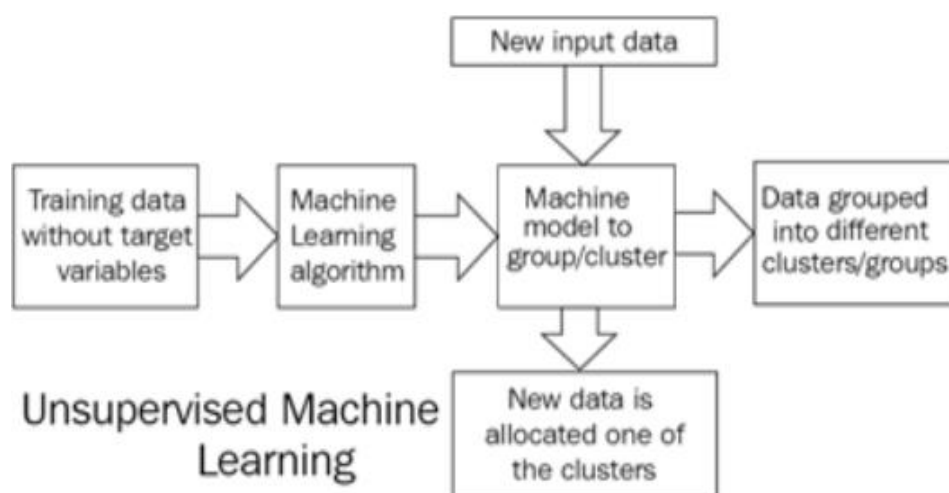


Figure II.5. Réseau neuronal renforcé.

II.6. Réseau neuronal biologique

Environ 100 milliards de neurones biologiques composent le cerveau humain, et ces neurones sont reliés par des structures spécialisées appelées synapses qui détectent les stimulations et transmettent des signaux à d'autres neurones [59]. Un neurone, composé d'un corps cellulaire (soma), d'arbres dendritiques et d'un axone, est l'unité structurelle et fonctionnelle de base du réseau d'information neuronale [60,61]. Les dendrites sont les sections les plus longues de nombreux neurones, et leurs caractéristiques électriquement actives influencent la façon dont l'information provenant des neurones est façonnée [62].

Au fil des ans, les scientifiques ont étudié le mécanisme de la composante neuronale dans le domaine de la biologie [60,63,64]. Une classe de potentiels d'action dendritique à médiation calcique (dCaAPs) a récemment été identifiée par la recherche [64,65]. Ce qui suit est une citation du document de recherche original : "Ces dCaAPs ont permis aux dendrites des neurones pyramidaux néocorticaux humains individuels d'identifier des entrées linéairement non séparables - un calcul traditionnellement supposé exiger des réseaux multicouches." [64].

Les axones servent de fils de liaison entre les neurones. Ces axones transportent des signaux électriques de la sortie d'un neurone à l'entrée d'un autre neurone (synapse). Les signaux entrants sont ajoutés, traités et le courant de sortie est produit par les neurones [65].




Figure II.6. Neurone biologique.

II.7. Structures de réseaux neuronaux profonds

La méthode la plus cruciale pour l'intelligence artificielle est l'apprentissage profond. Une technique d'apprentissage profond construit un réseau neuronal artificiel en utilisant un certain nombre de couches. Une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie constituent un réseau neuronal artificiel (ANN) [66]. La couche d'entrée d'un réseau reçoit des signaux, une couche de sortie décide comment utiliser l'entrée, et entre les couches d'entrée et de sortie sont des couches cachées qui effectuent des calculs (voir la figure 21). Entre les couches d'entrée et de sortie, un réseau neuronal profond a de nombreuses couches cachées.




Figure II.7. Modèle de réseau neuronal artificiel (ANN).

Une revue des différents réseaux neuronaux d'apprentissage profond utilisés pour la segmentation d'image est fournie dans cette section. Comme le montre la figure 22, les différentes topologies de réseaux neuronaux profonds habituellement utilisées pour la segmentation d'image peuvent être catégorisées.

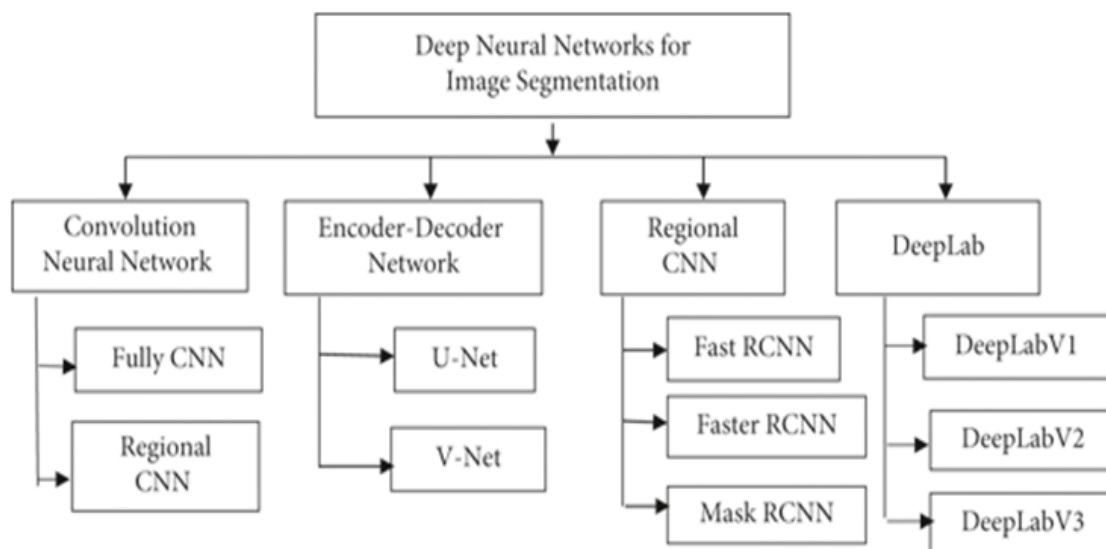


Figure II.8. Différents types d'architectures de réseaux neuronaux profonds pour la segmentation d'image.

II.8. Convolutional Neural Network (CNN)

L'apprentissage profond (DL) est une méthode de traitement d'image de pointe avec beaucoup de potentiel. Il a été utilisé efficacement dans un certain nombre de domaines, y compris la reconnaissance et la classification des images vidéo, entre autres. Cette méthode, souvent appelée CNN ou réseaux de neurones convolutifs, a été mise au point par Fukushima en 1998 [67].

Pour limiter le nombre de paramètres, un CNN utilise un ensemble de filtres et un opérateur de convolution. Des techniques avancées de classification des images ont été activées par cet algorithme. En substance, 1D CNN fonctionne en prenant un filtre de taille noyau (noyau) en commençant par le premier horodatage. L'opérateur de convolution multiplie chaque élément du filtre proportionnellement à la taille initiale du noyau. La cellule initiale de la couche suivante du réseau neural est alors créée en ajoutant ces produits ensemble. Le filtre se répète ensuite tout en avançant par pas de temps. Nous utiliserons la valeur de foulée par défaut de Keras de 1, qui est 1. Afin de classer les images, nous utiliserons le remplissage standard, qui est 0. Afin de simuler un réseau neuronal dense, la sortie de la convolution est ensuite multipliée par un ensemble de poids W , ajoutés à un biais b , puis envoyés par une fonction d'activation non linéaire. En répétant ce processus avec plus de couches CNN, nous utiliserons Dropout, une méthode pour réduire le surajustement en éliminant arbitrairement certains nœuds. Une pile de couches de traitement indépendantes constitue l'architecture CNN.

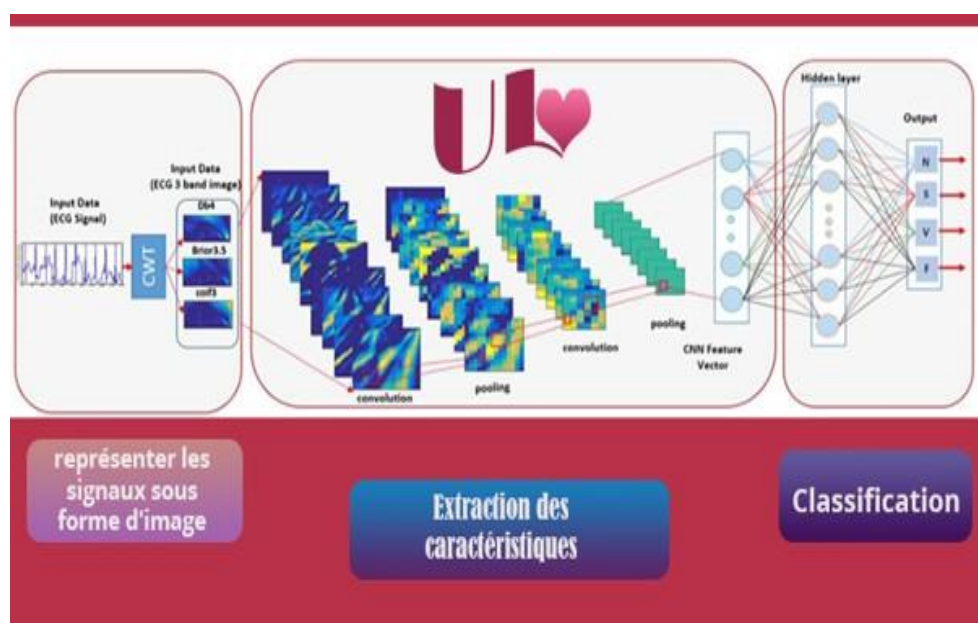


Figure II.9. Architecture de CNN.

II.8.1. La couche de convolution

Lorsqu'on lui donne une toute nouvelle image, CNN tente de localiser les caractéristiques tout au long de l'image dans n'importe quel endroit parce qu'il est incertain si oui ou non ils seront là. Nous filtrons les données en déterminant si chaque caractéristique est présente à chaque point de l'image. Les réseaux neuronaux de convolution tirent leur nom du type de mathématiques que nous employons pour mener ce processus, connu sous le nom de convolutions. La couche de convolution, qui constitue toujours au moins la première couche de réseaux neuronaux convolutifs, est un composant essentiel. Son objectif est de trouver la présence d'une collection particulière de fonctionnalités dans les photos d'entrée.

Il fonctionne comme un extracteur d'image caractéristique. La carte d'activation, ou carte de fonctionnalités, nous indique où se trouvent les fonctionnalités dans l'image et plus la valeur est élevée, plus l'emplacement correspondant dans l'image ressemble à la fonctionnalité [67].

Une image est passée à travers une série de filtres, ou noyaux de convolution.

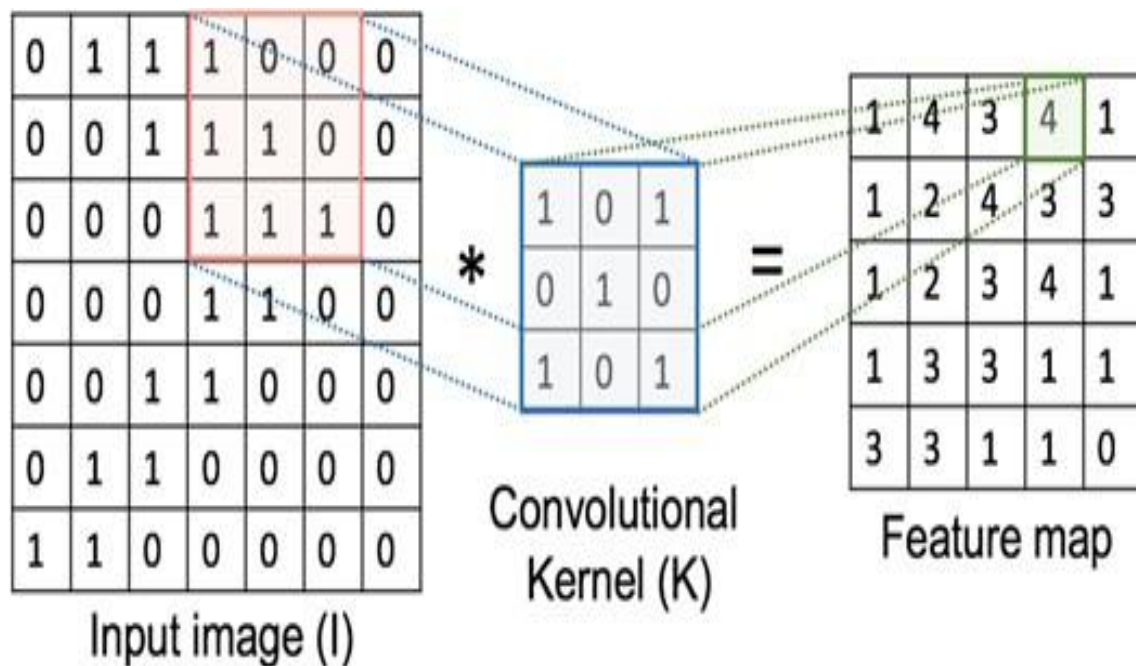


Figure II.10. Feature Map [67].

II.8.2. Stride

C'est la quantité de pixels décalés sur la matrice d'entrée. Nous déplaçons les filtres à 1 pixel à la fois lorsque la foulée est de 1. Nous avançons les filtres à 2 pixels à la fois lorsque la foulée est de 2, et ainsi de suite [68].

II.8.2.1. Padding

Parfois, le filtre ne correspond pas exactement à l'image d'entrée. Nous avons deux possibilités :

Pour corriger, ajoutez des zéros à l'image.

Mettre de côté la zone de l'image où le filtre ne correspond pas. Il s'agit d'un remplissage valide qui ne conserve que la zone légitime de l'image [68].

II.8.3. Domaines d'application CNN :

- CNN sont recommandés pour l'interprétation visuelle des données.
- Inclure la reconnaissance des visages.
- L'évaluation médicale.
- Analyse d'images et découverte de médicaments.

II.8.4. L'entraînement d'un nouveau CNN :

Il est coûteux de construire un nouveau réseau de neurones convolutifs en termes de connaissances, de matériel et de quantité de données annotées nécessaires. L'architecture réseau, ou le nombre de couches, leurs tailles, et les opérations matricielles qui les relie, doit être fixée au départ. Le lecteur suivant consiste à minimiser l'erreur de classification en sortie en optimisant les coefficients réseau. Pour le plus grand CNN, cette formation pourrait prendre plusieurs semaines.

A des nombreux GPU travaillant sur des millions de photos annotées. Des équipes de chercheurs se concentrent sur l'amélioration des CDN. Ils affichent des informations sur les réseaux formés et leurs avancées technologiques dans des bases de données de référence (Boughaba.).

Quelques réseaux convolutifs célèbres

- LeNet développée par Yann LeCun dans les années 1990.
- AlexNet développée par Alex Krizhevsky en 2012.
- Zfnet développée par Matthew Zeiler et Rob Fergus en 2013.
- GoogLeNet développée par Szegedy et al. De Google en 2014.
- ResNet développé par Kaiming He et al en 2015.

Conclusion

De nombreuses applications s'appuient sur des réseaux neuronaux artificiels, qui ont montré leur valeur dans la pratique à travers des traits comme la généralisation et la robustesse contre le bruit.

Ces réseaux ne sont essentiellement qu'un :

Le neurone biologique est inspiré par un groupe de neurones formels, et ils sont reliés par des synapses qui incluent des poids.

Catégorisation, prédiction et approximation d'un problème général à l'aide de diverses techniques d'apprentissage.

Dans ce chapitre, nous nous sommes principalement concentrés sur le perceptron multicouche, un type d'architecture neurale qui est généralement utilisé pour classer les troubles cardiaques.

CHAPITRE III

Simulation et Résultat

Introduction

L'étude des maladies cardiovasculaires est un domaine médical largement exploré à travers le monde, suscitant un vif intérêt. Pour l'ensemble de l'humanité, l'étude de l'arythmie revêt une signification profonde et significative. Le signal ECG, en tant qu'indicateur continu du fonctionnement cardiaque, joue un rôle essentiel, et sa surveillance permet de détecter efficacement toute déviation fonctionnelle. L'utilisation de la machine Learning, en particulier du Deep Learning, offre de multiples solutions aux professionnels de la santé, leur permettant d'analyser et de classer les données ECG.

Dans ce chapitre, nous aborderons l'utilisation de méthodes d'apprentissage en profondeur basées sur les réseaux neuronaux convolutifs (CNN) pour détecter les anomalies du rythme cardiaque. De plus, nous mentionnerons certaines méthodes déjà mises en œuvre dans ce domaine.

III.1. La base de données utilisée

Les bases de données utilisées c'est un fichier CSV qui contient :

- Nombre d'échantillons : 109446.
- La fréquence d'échantillonnage : 125Hz.
- Nombre de catégories : 5.

Source de données : Ensemble de données sur l'arythmie MIT-BIH de Physionet [35], cet ensemble de données a été utilisé pour explorer la classification des pulsations cardiaques à l'aide d'architectures des réseaux neuronaux profonds et pour observer certaines des capacités d'apprentissage par transfert associées. Les signaux correspondent aux battements du cœur sous forme d'électrocardiogramme (ECG) pour le cas normal et aux cas affectés par différentes arythmies et infarctus du myocarde. Ces signaux sont prétraités et segmentés, chaque segment correspondant à un battement du cœur.

III.2. Prétraitement de données

III.2.1. Classification binaires

On sait que les classes 1, 2, 3 et 4 correspondent à des signaux des personnes malades, et pour faire la classification binaire il faut qu'il y ait que deux classes : 0 et 1. Donc on remplace toutes les classes qui ont 2, 3 et 4 par 1, pour avoir qu'une seule classe des signaux des personnes malades. Donc en tout on aura deux classes 0 et 1 et donc on pourra faire une classification binaire.

III.2.2. Classification multi classe

Le but de la classification multi classe est de déterminer le type de la maladie vu qu'on sait si on passe à la classification multi classe, donc la personne est malade. Donc on prend la base de données originale qui avait 5 classes et on supprime toutes les lignes qui contiennent la classe 0 puis on n'aura à la fin que 4 classes qui correspondent aux types des maladies cardiaques.

III.2.3. Aperçu sur la base de données :

- La base de données contient 109446 lignes et 188 colonnes.
- De 0 jusqu'à 186 se sont des attributs (factures).
- La colonne 187 représente la classe cible (label) de la base de données qui peut être soit 0 ou 1 lors de la classification binaire et soit 1, 2, 3 ou 4 lors de la classification multi classe.

```
df.head()
```

	0	1	2	3	4	5	6	7	8	9	...	178	179	180	181	182	183	184	185	186	187
0	0.977941	0.926471	0.681373	0.245098	0.154412	0.191176	0.151961	0.085784	0.058824	0.049020	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
1	0.960114	0.863248	0.461538	0.196581	0.094017	0.125366	0.099715	0.088319	0.074074	0.082621	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
2	1.000000	0.659459	0.186486	0.070270	0.070270	0.059459	0.056757	0.043243	0.054054	0.045946	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
3	0.925414	0.665746	0.541436	0.276243	0.196133	0.077348	0.071823	0.060773	0.066298	0.058011	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
4	0.967136	1.000000	0.830986	0.586854	0.356808	0.248826	0.145540	0.089202	0.117371	0.150235	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0

5 rows × 188 columns

Figure III.1. Les 5 premières lignes de la base de données.

III.3. Présentation des outils utilisés :

III.3.1. Outils logiciels

III.3.1.1. Environnement

Visual Studio Code : est un éditeur de code source gratuit et très populaire, développé par Microsoft. Il offre un large éventail de fonctionnalités pour faciliter la programmation et le développement de logiciels. Visual Studio Code est connu pour sa simplicité, sa légèreté et sa flexibilité, ce qui en fait un choix populaire parmi les développeurs de logiciels de différents domaines.

Cet éditeur de code prend en charge de nombreux langages de programmation, avec des fonctionnalités telles que la coloration syntaxique, l'autocomplétions, la navigation intelligente, la refactorisation du code, le débogage, l'intégration avec les systèmes de contrôle de version, ainsi que l'accès à une vaste gamme d'extensions pour personnaliser et étendre ses fonctionnalités de base.

Visual Studio Code est disponible sur les principales plateformes, y compris Windows, MacOS et Linux, et il est largement utilisé par les développeurs pour des projets de différentes tailles et complexités




Figure III.2. Logo Visual Studio Code.

Spyder : est un environnement de programmation Python. Il comprend un certain nombre de bibliothèques scientifiques, y compris Matplotlib, NumPy, SciPy, et IPython, et est libre et multiplateforme [69].



Figure III.3. Logo Spyder.

Jupyter-notebook : Les utilisateurs peuvent créer des pages de bloc-notes avec du code en direct, des widgets interactifs, des formes d'onde, de la prose narrative, des équations, des photos et des vidéos à l'aide du bloc-notes Jupyter, un environnement informatique interactif [69].

**Figure III.4.** Logo Jupyter.

III.3.1.2. Framework

Tensorflow : Il a été développé par l'équipe Google Brain pour la recherche ML et Deep Learning. Il est considéré comme une adaptation contemporaine de Theano [69].

**Figure III.5.** Logo TensorFlow.

Keras : Le Framework le plus avancé et accessible de la liste. Il donne aux utilisateurs la possibilité d'exécuter les modèles qu'ils créent sur Theano ou TensorFlow. Francis Chollet, un autre membre de l'équipe de Google Brain, est responsable de son écriture et de son entretien [69].

**Figure III.6.** Logo Keras.

III.3.1.3. Bibliothèques utilisées

NumPy : est un paquet Python pour les calculs numériques. Il comprend une gestion simple de la table des nombres, des fonctions complexes (diffusion), et peut également intégrer le code C/C++ et Fortran [70].



Figure III.7. Logo numpy.

Pandas : est une bibliothèque open source pour le langage de programmation Python qui offre des structures de données et des outils de haute performance et conviviaux pour l'analyse de données sous la licence BSD [71].



Figure III.8. Logo pandas.

Matplotlib : Pour le langage de programmation Python et son extension mathématique numérique NumPy, il existe une bibliothèque de suivi appelée Matplotlib. Pour intégrer des graphiques dans des programmes, il propose une API orientée objet [71].



Figure III.9. Logo matplotlib.

Scikit-learn: Une bibliothèque appelée Scikit-learn a été créée dans le langage de programmation de haut niveau Python. Il peut être utilisé comme middleware et est consacré à l'apprentissage statistique (machine learning) et est particulièrement utile pour les applications nécessitant la prédiction [70].



Figure III.10. Logo scikit-learn.

WFDB : La base de données Python waveform (WFDB) est livrée avec un paquet natif. Un ensemble d'applications pour le traitement, l'écriture et la lecture de signaux et d'annotations WFDB. Les éléments principaux de ce paquet sont basés sur les spécifications originales de WFDB [72]. Les fonctionnalités de ce package diffèrent légèrement de celles du package WFDB original. Avec des API conviviales, il s'efforce de mettre en œuvre autant de ses principales fonctionnalités que possible. Au fil du temps, des technologies physiologiques plus pratiques de traitement des signaux sont ajoutées.

Seaborn : c'est un paquet de visualisation de données Python construit sur matplotlib. Il offre une interface utilisateur sophistiquée pour créer des visualisations de données visuellement attrayantes et utiles. Vous pouvez lire les notes d'introduction pour un bref aperçu des concepts sous-jacents à la bibliothèque.



Figure III.11. Logo seaborn.

Warning : sont des soupçons d'erreurs, pas des erreurs. Le programme pourrait continuer, mais il pourrait se terminer un peu plus tard, avec un avertissement qui a été déclenché un peu plus tôt comme cause possible.[73].

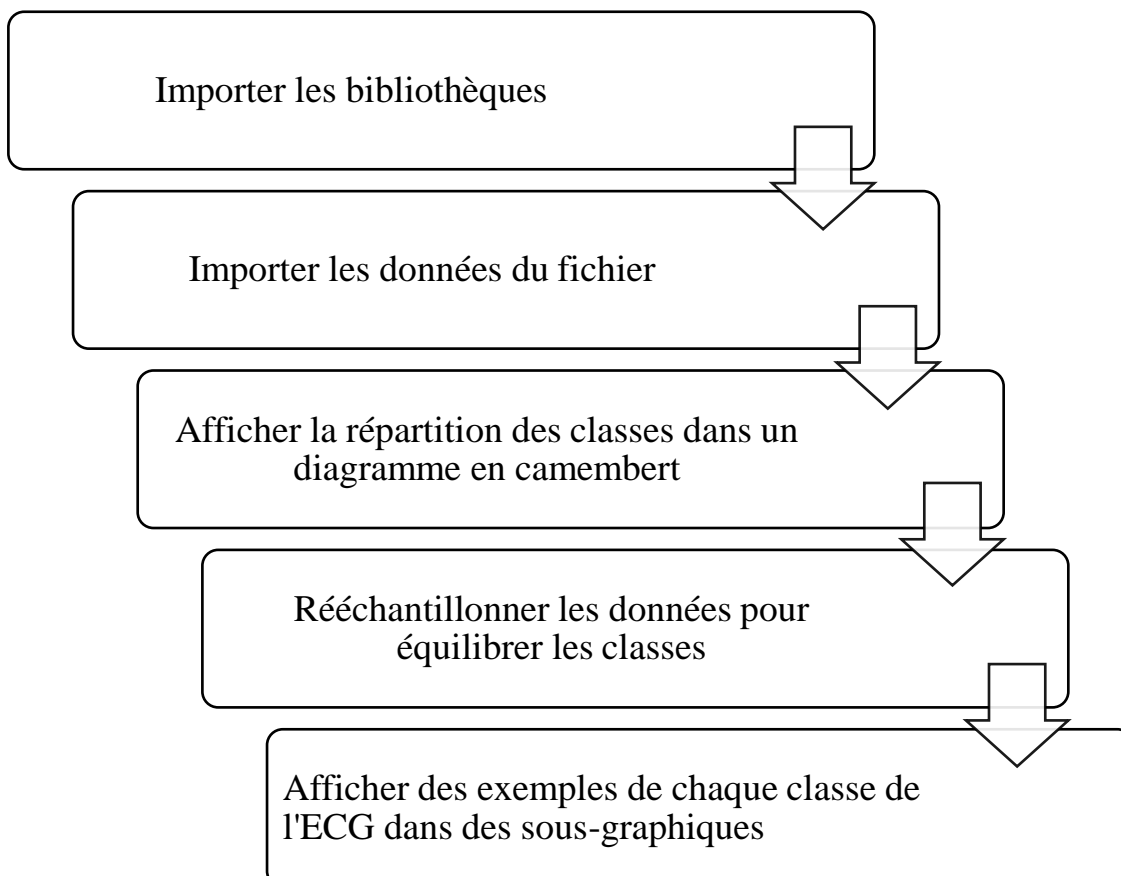
III.3.1.4. Langages de programmation

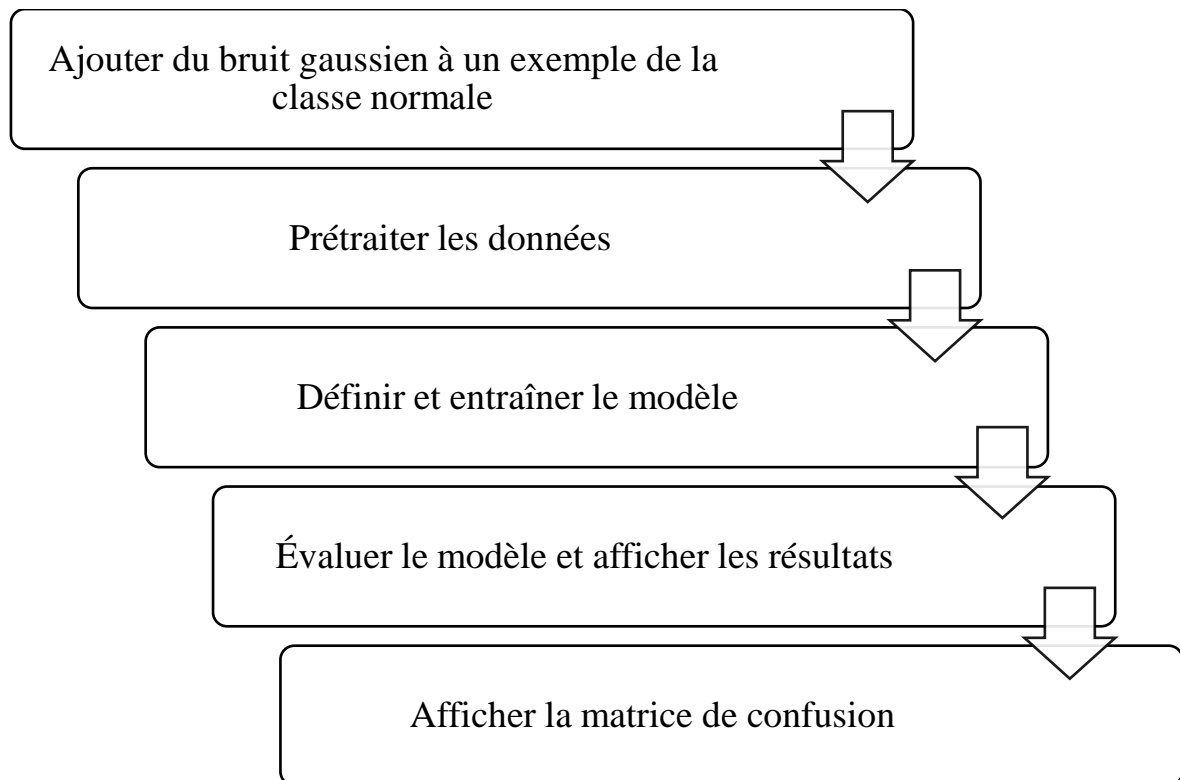
Python : Grâce à sa simplicité et à ses bibliothèques de logiciels, qui incluent les mathématiques, il se propage non seulement dans le domaine de l'éducation du secondaire à l'université, mais permet également à l'industrie de piloter des systèmes sophistiqués. La première partie de ce livre couvre les bases linguistiques, tandis que la deuxième partie fournit des instructions de codage à travers 130 exercices et problèmes [70]. En commençant par les fondements de l'algorithme classique, il aborde des sujets moins enseignés comme les graphiques, l'analyse lexicale et syntaxique, les moteurs physiques, l'intelligence artificielle (neurone, génétique) et la musique électronique.



Figure III.12. Logo python.

III.4. Organigramme :





Cet organigramme représente les principales étapes de la programmation fournie. Voici une description de chaque étape :

- Les bibliothèques nécessaires sont importées.
- Les données du fichier CSV sont importées et stockées dans les Data Frames `train_df` et `test_df`.
- La répartition des classes dans les données d'entraînement est affichée sous forme d'un diagramme en camembert.
- Les données d'entraînement sont rééchantillonnées pour équilibrer les classes.
- Des exemples de chaque classe de l'ECG sont affichés dans des sous-graphiques.
- Du bruit gaussien est ajouté à un exemple de la classe normale.
- Les données sont prétraitées, notamment en convertissant les étiquettes en catégories et en remodelant les données d'entraînement et de test.
- Le modèle de réseau neuronal est défini et entraîné sur les données d'entraînement.
- Le modèle est évalué sur les données de test et les résultats sont affichés, y compris les courbes d'exactitude et de perte au fil des époques.
- La matrice de confusion est calculée et affichée pour évaluer les performances du modèle.

III.4.1. Charger les bibliothèques nécessaires :

```
import numpy as np
import pandas as pd
import seaborn as sns
import matplotlib.pyplot as plt
```

Ces importations importent des bibliothèques couramment utilisées pour l'analyse de données, la visualisation et les tâches d'apprentissage automatique. NumPy et Pandas sont utilisés pour la manipulation et l'analyse des données, Seaborn est utilisé pour la visualisation statistique des données, Scikit-learn (sklearn) fournit des algorithmes et des outils d'apprentissage automatique, et Matplotlib est une bibliothèque de tracé.

```
from sklearn.metrics import classification_report
```

Ceci importe la fonction classification report du module sklearn metrics. Cette fonction est utilisée pour générer un rapport incluant diverses mesures (telles que la précision, le rappel et le score F1) pour évaluer les performances d'un modèle de classification.

```
from sklearn.model_selection import train_test_split
from sklearn.metrics import f1_score
from sklearn.metrics import confusion_matrix
```

Ces importations importent des fonctions supplémentaires de Scikit-learn. train_test_split est utilisée pour diviser un ensemble de données en sous-ensembles d'entraînement et de test, f1_score calcule le score F1 pour l'évaluation d'un modèle, et confusion matrix génère une matrice de confusion pour évaluer les performances d'un modèle de classification.

```
from keras.layers import Dense, Convolution1D, MaxPool1D, Flatten, Dropout
from keras.layers import Input
from keras.models import Model
from tensorflow.keras.layers import (
    BatchNormalization, SeparableConv2D, MaxPooling2D, Activation, Flatten,
    Dropout, Dense)
import keras
from keras.callbacks import EarlyStopping, ModelCheckpoint
```

Ces importations sont liées à Keras, une bibliothèque d'apprentissage profond. `Load_model` est utilisée pour charger un modèle pré-entraîné, `Séquentiel` est un type de modèle dans Keras, `Conv2D`, `MaxPooling2D`, `Dropout`, `Dense`, `Activation` et `Flattent` sont différentes couches qui peuvent être utilisées pour construire des réseaux neuronaux, et `to_categorical` est utilisée pour convertir les étiquettes de classe en vecteurs encodés en one-shot.

```
from keras.utils.np_utils import to_categorical
from sklearn.utils import class_weight
import warnings
warnings.filterwarnings('ignore')
```

Cette importation importe la fonction `class_weight` de Scikit-learn. Elle est utilisée pour calculer les poids de classe qui peuvent être utilisés pour traiter les déséquilibres de classe dans les modèles d'apprentissage automatique

Le module `warnings`, définit un filtre pour ignorer les avertissements. Les avertissements sont généralement émis lorsqu'il existe des problèmes potentiels ou une utilisation non standard de certaines fonctions ou modules. Ignorer les avertissements peut être utile pour sup.

III.4.2. Importe dataset :

```
# import dataset
train_df = pd.read_csv("1_train.csv", header = None)
test_df = pd.read_csv("1_test.csv", header = None)
```

Le code importe un jeu de données à partir de deux fichiers CSV : "1_train.csv" et "1_test.csv". Les données sont ensuite stockées dans les data frames `train_df` et `test_df`. L'argument `header=None` dans les fonctions `read_csv` indique que les fichiers CSV n'ont pas de ligne d'en-tête. Cela signifie que toutes les lignes dans les fichiers seront considérées comme des données, plutôt que des noms de colonnes.

Une fois les fichiers CSV lus, les données sont stockées dans les data frames `train_df` et `test_df`. Ces data frames peuvent être utilisés pour effectuer des opérations d'analyse de données, de prétraitement ou pour entraîner et tester des modèles d'apprentissage automatique.

III.4.3. Valeur de chaque classe :

```
# Value of each class
train_df[187].value_counts()
```

```
187
0.0 72471
4.0 6431
2.0 5788
1.0 2223
3.0 641
```

Name: count, de type: int64

Ces valeurs indiquent la répartition des classes dans la colonne 187 du jeu de données d'entraînement. La classe 0.0 est la classe majoritaire avec 72471 occurrences, tandis que les autres classes ont moins d'occurrences. Cette information peut être utile pour identifier des déséquilibres de classe potentiels dans le jeu de données, ce qui peut influencer le choix d'approches ou d'algorithmes d'apprentissage automatique appropriés pour la tâche en question.

III.4.4. peek on classes

```
# peek on classes
Classes
```

III.5. Result

	0	1	2	3	4	5	...	185	186	187
23282	1.000000	0.942308	0.473776	0.148601	0.152098	0.139860	...	0.0	0.0	0.0
73269	1.000000	0.842105	0.178138	0.000000	0.121457	0.178138	...	0.0	0.0	1.0
79196	0.000000	0.072595	0.206897	0.319419	0.431942	0.488203	...	0.0	0.0	2.0
81067	1.000000	0.947905	0.763307	0.457531	0.160815	0.135900	...	0.0	0.0	3.0

	0	1	2	3	4	5	...	185	186	187
81505	0.974619	0.927665	0.874366	0.828680	0.775381	0.704315	...	0.0	0.0	4.0

Tableau de classe de base des données de signal

5 Rows \times 188 columns

Le tableau que vous avez fourni semble représenter des valeurs numériques pour différentes classes. Chaque ligne du tableau semble représenter une classe différente, tandis que les colonnes représentent des valeurs spécifiques pour chaque classe.

Voici quelques observations générales basées sur les valeurs dans le tableau :

- Chaque classe a un identifiant numérique associé à elle, indiqué dans la première colonne.
- Les valeurs dans les autres colonnes représentent les caractéristiques ou les mesures associées à chaque classe.
- Les valeurs dans les colonnes semblent être des nombres décimaux entre 0 et 1, avec différentes valeurs pour chaque classe.
- Certaines classes semblent avoir des valeurs plus élevées dans certaines colonnes, indiquant peut-être une certaine importance ou une caractéristique distinctive pour ces classes.
- Il y a une progression apparente dans les valeurs d'une classe à l'autre dans certaines colonnes, ce qui pourrait indiquer une relation ou une tendance entre les classes.
- Cependant, sans plus de contexte sur les données ou la signification des classes, il est difficile de donner une interprétation précise. Si vous pouvez fournir plus d'informations sur les données ou les objectifs de l'analyse, je pourrais vous fournir une analyse plus détaillée.

III.5.1. Traçage Classes ECG

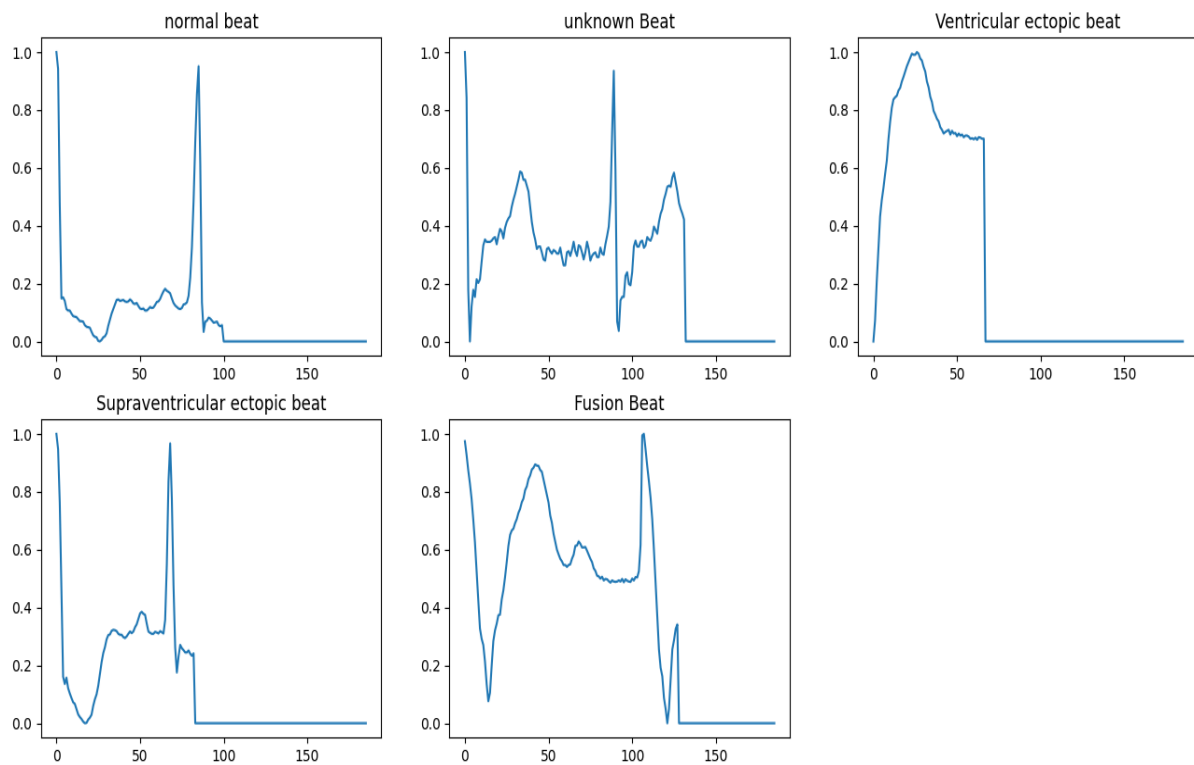


Figure III.13. Classes ECGt

III.5.2. CNN Training

```
def network(X_train,y_train,X_test,y_test):
    im_shape=(X_train.shape[1],1)
    inputs_cnn=Input(shape=(im_shape), name='inputs_cnn')
    conv1_1=Convolution1D(64, (6), activation='relu', input_shape=im_shape)(inputs_cnn)
    conv1_1=BatchNormalization()(conv1_1)
    pool1=MaxPool1D(pool_size=(3), strides=(2), padding="same")(conv1_1)
    conv2_1=Convolution1D(64, (3), activation='relu', input_shape=im_shape)(pool1)
    conv2_1=BatchNormalization()(conv2_1)
    pool2=MaxPool1D(pool_size=(2), strides=(2), padding="same")(conv2_1)
    conv3_1=Convolution1D(64, (3), activation='relu', input_shape=im_shape)(pool2)
    conv3_1=BatchNormalization()(conv3_1)
    pool3=MaxPool1D(pool_size=(2), strides=(2), padding="same")(conv3_1)
    flatten=Flatten()(pool3)
    dense_end1 = Dense(64, activation='relu')(flatten)
    dense_end2 = Dense(32, activation='relu')(dense_end1)
    main_output = Dense(5, activation='softmax', name='main_output')(dense_end2)
    model = Model(inputs= inputs_cnn, outputs=main_output)
    model.compile(optimizer='adam', loss='categorical_crossentropy',metrics = ['accuracy'])
    callbacks = [EarlyStopping(monitor='val_loss', patience=8),
```

```

ModelCheckpoint(filepath='best_model.h5',monitor='val_loss', save_best_only=True)]

history=model.fit(X_train,y_train,epochs=5,callbacks=callbacks,batch_size=32,validation
_data=(X_test,y_test))
model.load_weights('best_model.h5')
return(model,history)

```

Le code définit et entraîne un modèle CNN pour la classification des signaux ECG, évalue ses performances et génère des graphiques et une matrice de confusion pour l'analyse des résultats.

Result

Train on 100000 samples, validate on 21892 samples

Epoch 1/5

100000/100000 [=====] - 102s 1ms/step - loss: 0.1984
- accuracy: 0.9298 - val_loss: 0.1991 - val_accuracy: 0.9333

Epoch 2/5

100000/100000 [=====] - 99s 993us/step - loss: 0.0743
- accuracy: 0.9746 - val_loss: 0.2281 - val_accuracy: 0.9320

Epoch 3/5

100000/100000 [=====] - 101s 1ms/step - loss: 0.0504
- accuracy: 0.9828 - val_loss: 0.1316 - val_accuracy: 0.9604

Epoch 4/5

100000/100000 [=====] - 100s 999us/step - loss: 0.036
5 - accuracy: 0.9880 - val_loss: 0.1318 - val_accuracy: 0.9656

Epoch 5/5


100000/100000 [=====] - 102s 1ms/step - loss: 0.0304
- accuracy: 0.9900 - val_loss: 0.1092 - val_accuracy: 0.9756

III.5.3. Accuracy & loss

```

evaluate_model(history,X_test,y_test,model)
y_pred=model.predict(X_test)

```



Accuracy: 97.56%

Figure III.14. Model Accuracy.




Figure III.15. Model Loss.

I. Matrice de confusion :

```
import itertools
def plot_confusion_matrix(cm, classes,
                          normalize=False,
                          title='Confusion matrix',
                          cmap=plt.cm.Blues):
    if normalize:
        cm = cm.astype('float') / cm.sum(axis=1)[:, np.newaxis]
        print("Normalized confusion matrix")
    else:
        print('Confusion matrix, without normalization')

    plt.imshow(cm, interpolation='nearest', cmap=cmap)
    plt.title(title)
    plt.colorbar()
    tick_marks = np.arange(len(classes))
    plt.xticks(tick_marks, classes, rotation=45)
    plt.yticks(tick_marks, classes)

    fmt = '.2f' if normalize else 'd'
    thresh = cm.max() / 2.
    for i, j in itertools.product(range(cm.shape[0]), range(cm.shape[1])):
        plt.text(j, i, format(cm[i, j], fmt),
                 horizontalalignment="center",
                 color="white" if cm[i, j] > thresh else "black")

    plt.tight_layout()
    plt.ylabel('True label')
    plt.xlabel('Predicted label')
cnf_matrix = confusion_matrix(y_test.argmax(axis=1), y_pred.argmax(axis=1))
np.set_printoptions(precision=2)

plt.figure(figsize=(10, 10))
plot_confusion_matrix(cnf_matrix, classes=['N', 'S', 'V', 'F', 'Q'], normalize=True,
                      title='Confusion matrix, with normalization')
plt.show()
```

Le code fournit une fonction pour afficher une matrice de confusion, avec ou sans normalisation, et l'utilise pour représenter la matrice de confusion calculée à partir des prédictions et des vraies étiquettes.




Figure III.16. Matrice de confusion. avec normalisation.

III.5.4. Save model

```
import torch
torch.save(model.state_dict(), 'trained_model.pt')
model.save('trained_model.h5')
```

Ces blocs de code montrent comment sauvegarder un modèle entraîné dans PyTorch et Keras respectivement, en utilisant différentes méthodes spécifiques à chaque bibliothèque.

III.5.5. Test le model

```
import pandas as pd
from keras.models import load_model
import numpy as np
loaded_model = load_model('trained_model.h5')
test_df = pd.read_csv("b.csv", header=None)
```

```
X_test = test_df.iloc[:, :186].values
X_test = X_test.reshape(len(X_test), X_test.shape[1], 1)
predictions = loaded_model.predict(X_test)
predicted_labels = np.argmax(predictions, axis=1)
test_df['predicted_label'] = predicted_labels

# Save the test dataframe with predicted labels to a new CSV file
test_df.to_csv('test_results.csv', index=False)
```

Le code présent charge un modèle préalablement entraîné à partir du fichier 'trained_model.h5' en utilisant la fonction `load_model ()` de Keras. Ensuite, il charge les données de test à partir d'un fichier CSV avec `pd.read_csv ()`. Les caractéristiques d'entrée sont extraites des données de test.

Les données d'entrée sont ensuite remodelées pour correspondre à la forme attendue par le modèle à l'aide de `reshape ()`. L'inférence est effectuée sur les données de test en utilisant `loaded_model.predict ()`, ce qui renvoie les prédictions pour chaque échantillon.

Les prédictions sont alors converties du format encodé en one-hot en étiquettes de classe en utilisant `np.argmax ()`. Les étiquettes prédites sont ajoutées au dataframe de test avec `test_df['predicted_label'] = predicted_labels`.

Enfin, le dataframe de test avec les étiquettes prédites est sauvegardé dans un nouveau fichier CSV appelé 'test_results.csv' avec `to_csv()`.

En résumé, ce code charge un modèle entraîné, effectue des prédictions sur des données de test, ajoute les étiquettes prédites au dataframe de test, puis sauvegarde les résultats dans un nouveau fichier CSV.

Conclusion

Dans ce chapitre, En conclusion, ce travail a utilisé un modèle de Deep learning basé sur un réseau de neurones convolutifs (CNN) pour effectuer une classification de signaux ECG. Le modèle a été entraîné sur un ensemble de données comprenant différentes classes de battements cardiaques.

La première partie du travail a consisté à prétraiter les données, en effectuant un rééquilibrage des classes pour éviter les biais et en appliquant des transformations telles que l'ajout de bruit gaussien aux signaux ECG.

Ensuite, le modèle CNN a été construit en utilisant des couches de convolution, de normalisation et de pooling pour extraire les caractéristiques pertinentes des signaux. Des

couches denses ont été ajoutées pour la classification finale des battements cardiaques en utilisant la fonction d'activation soft max.

Le modèle a été entraîné sur les données d'apprentissage et évalué sur les données de test. Les résultats ont été analysés à l'aide de métriques telles que l'exactitude (accuracy) et la matrice de confusion pour évaluer les performances du modèle.

Enfin, le modèle entraîné a été sauvegardé pour une utilisation ultérieure, et les prédictions ont été effectuées sur de nouvelles données en utilisant le modèle chargé.

Dans l'ensemble, ce travail a démontré l'utilisation d'un modèle CNN pour la classification des signaux ECG, montrant la capacité des réseaux de neurones profonds à extraire des informations précieuses à partir de données complexes. Il ouvre des perspectives pour l'application de techniques de Deep Learning dans le domaine de la cardiologie et de la détection des anomalies cardiaques.

CONCLUSION ET PERSPECTIVES

Conclusion et perspectives

En conclusion, l'utilisation de l'intelligence artificielle pour la classification des signaux ECG ouvre de nouvelles perspectives dans le domaine de la cardiologie. L'ECG nous fournit des informations précieuses sur l'activité électrique du cœur, et l'intelligence artificielle nous permet d'exploiter ces données de manière à améliorer le diagnostic et la prise en charge des maladies cardiaques.

Notre étude a porté sur les fondements de l'activité cardiaque, de l'ECG et de l'intelligence artificielle. Nous avons développé un modèle de classification des signaux ECG basé sur l'intelligence artificielle en utilisant la base de données MIT-BIH. Les résultats obtenus ont été prometteurs, avec une précision élevée de 97% dans la détection des anomalies cardiaques. Ces résultats démontrent le fort potentiel de l'intelligence artificielle pour améliorer le diagnostic des maladies cardiaques grâce à l'analyse des signaux ECG.

Cependant, des défis subsistent, notamment en ce qui concerne l'interprétabilité des modèles et la qualité des données. Il est important de garantir que les modèles d'intelligence artificielle utilisés pour la classification des signaux ECG soient compréhensibles et transparents pour les praticiens médicaux. De plus, la qualité des données ECG, leur normalisation et leur prétraitement sont des aspects cruciaux à prendre en compte pour assurer des résultats fiables et reproductibles.

Malgré ces défis, l'avenir de l'utilisation de l'intelligence artificielle dans la classification des signaux ECG est prometteur. Des recherches futures pourraient permettre d'améliorer encore davantage les performances du modèle et d'étendre son application clinique. L'intelligence artificielle pourrait jouer un rôle essentiel dans l'identification précoce des maladies cardiaques, la personnalisation des traitements et l'amélioration des résultats pour les patients.

. Les perspectives de futurs travaux de classification des signaux ECG sont prometteuses et offrent de nombreuses opportunités pour améliorer la détection et la classification précise des troubles cardiaques. Voici quelques pistes de recherche qui pourraient être explorées :

1. Utilisation de l'apprentissage en profondeur : les réseaux de neurones profonds, tels que les réseaux de neurones convolutifs (CNN) et les réseaux de neurones récurrents (RNN), ont montré d'excellentes performances dans la classification des signaux ECG. Les études futures

pourraient se concentrer sur l'exploration de ces architectures d'apprentissage en profondeur pour améliorer la précision et la robustesse de la classification des signaux ECG.

2. Approches multimodales : les signaux ECG peuvent être combinés avec des données cliniques ou d'autres données de surveillance, telles que l'imagerie médicale ou des données provenant de capteurs portables, pour améliorer la classification des affections cardiaques. L'intégration de ces différentes approches pourrait permettre une meilleure compréhension des schémas complexes et une classification plus précise des troubles cardiaques.

3. Développer des modèles spécifiques à des maladies : les travaux futurs pourraient se concentrer sur le développement de modèles de maladies cardiaques spécifiques. Par exemple, des modèles spécialisés pourraient être développés pour détecter les arythmies, l'ischémie ou l'insuffisance cardiaque, permettant une classification plus précise et une meilleure gestion de ces maladies spécifiques.

4. Interprétation des modèles : L'interprétation des modèles de classification est un aspect essentiel de la confiance des cliniciens et de la prise de décision clinique. Les recherches futures pourraient envisager de développer des moyens d'expliquer les décisions prises par les modèles d'apprentissage automatique afin de mieux comprendre les modèles affectant la classification des signaux ECG.

5. Validation clinique complète : Une validation clinique rigoureuse des modèles de classification des signaux ECG est essentielle pour garantir leur fiabilité et leur utilité dans la pratique clinique. Les travaux futurs devraient inclure des études prospectives sur des cohortes de patients pour évaluer les performances des modèles et leur impact réel sur les résultats cliniques.

Les futurs travaux de classification des signaux ECG devraient se concentrer sur l'utilisation de méthodes avancées d'apprentissage automatique, la fusion de données multimodales, le développement de modèles spécifiques à la maladie, l'interprétabilité des modèles et la validation clinique complète. Ces avancées pourraient contribuer à une meilleure détection précoce, une classification plus précise et une meilleure prise en charge des troubles cardiaques.

REFERENCES

BIBLIOGRAPHIQUES

Références bibliographiques

- [1] Guyton AC, Hall JE, Textbook of Medical Physiology, 13th edition. Philadelphia, PA: Elsevier; 2015.
- [2] Goldberger AL, Goldberger ZD, Shvilkin A. Handbook of Clinical Electrocardiography. 2nd edition. Philadelphia, PA: Elsevier; 2020.
- [3] Thaler MS. The Only EKG Book You'll Ever Need. 9th edition. Philadelphia, PA: Lippincott Williams & Wilkins; 2020
- [4] D'Alch E.-P., comprendre la physiologie cardiovasculaire, Flammarion médecine-sciences. 2003.
- [5] Zipes, D.P., Heart-brain interactions in cardiac arrhythmias: role of the autonomic nervous system. Cleveland Clinic journal of medicine,2008. 75(2):pS94
- [6] K.Rogers, "The Cardiovascular System," United States :Britannica Digital Learning, 2011.
- [7] "Hypertension pulmonaire : Causes, symptômes, diagnostic et traitements,"2020. From <https://www.sante-sur-le-net.com/maladies/cardiologie/hypertension-pulmonaire>.
- [8] Etienne-Paul D'Alché, "comprendre la physiologie, Flammarion médecine-science ". Medicine Sciences PublicationsLivre .2003.
- [9] R Dubios" Application des nouvelles méthodes d'apprentissage à la détection précoce d'anomalies en électrocardiographie"thèse doctorat 2004.
- [10] L. S. Lilly, "Pathophysiology of heart disease a collaborative project of medical students and faculty," Philadelphia, Pa: Wolters Kluwer, 2016.
- [11] Viricel, G., et al. Évaluation d'un support d'aide à l'analyse de l'électrocardiogramme par les internes des urgences. Annales de Cardiologie et d'Angéiologie. 2020. Elsevier.
- [12] Bergman, K.S., et al., Effect of body position on the diagnostic accuracy of the electrocardiogram. American heart journal, 1989. 117(1): p. 204-206.
- [13] de Jager, J., L. Wallis, and D. Maritz, ECG interpretation skills of South African Emergency Medicine residents. International journal of emergency medicine, 2010. 3(4) : p. 309-314.
- [14] MESSIOUD M, Classification des signaux ECG en utilisant les réseaux de neurones .2019. Page (26,27)
- [15] KRICHANE.N et TAZBOUDJT.S "Classification des signaux ECG par les réseaux de neurone probabiliste 2015. Page (6,7,8)
- [16] Benchaib. Classification neuronale spécialisée des arythmies cardiaques. mémoire page (33,34).

- [17] B. Surawicz, T. K. Knilans, and T. Chou, "Chou's electrocardiography in clinical practice," Philadelphia, PA: Saunders/Elsevier, 2008.
- [18] N. Kannathal, U. R. Acharya, P. Joseph, L. C. Min, J. S. Suri, "Analysis of electrocardiograms," Advances in cardiac signal processing, (eds). U. R. Acharya, J. S. Suri, J. A. E. Spaan, and S. M. Krishnan, Springer, Berlin, pp. 55–81, 2007.
- [19] KASTOR, John A. (ed.). Arrhythmias. WB Saunders Company, 2000.
- [20] Schläpfer, J. and P. Staeger. Extrasystoles supraventriculaires et ventriculaires. in Forum Médical Suisse. 2017. EMH Media.
- [21] François Portet. Pilotage d'algorithmes pour la reconnaissance en ligne d'arythmies cardiaques. Artificial Intelligence [cs.AI]. Université Rennes 1, 2005. French.
- [22] Y. LeCun, Y. Bengio, G. Hinton Deep learning Nature, 521 (2015), pp. 436-444, 10.1038/nature14539
- [23] J. Schmidhuber Deep learning in neural networks: an overview Neural Network., 61 (2015), pp. 85-117, 10.1016/j.neunet.2023.04.16
<https://www.sciencedirect.com/science/article/pii/S0893608014002135>
- [24] A. Krizhevsky, I. Sutskever, G.E. Hinton Imagenet classification with deep convolutional neural networks Adv. Neural Inf. Process. Syst., 25 (2012), pp. 1097-1105
- [25] G. Aresta, T. Araújo et al Bach: grand challenge on breast cancer histology images Med. Image Anal., 56 (2019), pp. 122-139, 10.1016/j.media.2023.04.16
<https://www.sciencedirect.com/science/article/pii/S1361841518307941>
- [26] P. Bándi, O. Geessink, et al From detection of individual metastases to classification of lymph node status at the patient level: the camelyon17 challenge IEEE Trans. Med. Imag., 38 (2019), pp. 550-560, 10.1109/TMI.2018.2867350
- [27] V.M. Campello, P. Gkontra, et al. Lekadir Multi-centre, multi-vendor and multi-disease cardiac segmentation: the m amp;ms challenge IEEE Trans. Med. Imag. (2021), 10.1109/TMI.2021.3090082.
- [28] J. Yang, H. Veeraraghavan, S. Armato, K. Farahani, J. Kirby, J. Kalpathy-Kramer, W.V. van Elmpt, A. Dekker, X. Han, X. Feng, P. Aljabar, B. Oliveira, B. van der Heyden, L. Zamdborg, D. Lam, M. Gooding, G. Sharp Autosegmentation for thoracic radiation treatment planning: a grand challenge at aapm 2017.
- [29] X. Zhuang, L. Li, C. Payer, D. Štern, M. Urschler, M.P. Heinrich, J. Oster, C. Wang, Örjan Smedby, C. Bian, X. Yang, P.A. Heng, A. Mortazi, U. Bagci, G. Yang, C. Sun, G. Galisot, J.Y. Ramel, T. Brouard, Q. Tong, W. Si, X. Liao, G. Zeng, Z. Shi, G. Zheng, C. Wang, T. MacGillivray, D. Newby, K. Rhode, S. Ourselin, R. Mohiaddin, J. Keegan, D. Firmin, G. Yang

Evaluation of algorithms for multi-modality whole heart segmentation: an open-access grand challenge *Med. Image Anal.*, 58 (2019), p. 101537,

10.1016/j.media.2019.101537.

[30] Z. Salahuddin, M. Lenga, H. Nickisch Multi-resolution 3d convolutional neural networks for automatic coronary centerline extraction in cardiac ct angiography scans

2021 IEEE 18th International Symposium on Biomedical Imaging, ISBI (2021), pp. 91-95, 10.1109/ISBI48211.2021.9434002.

[31] Jiang, Y., Li, X., Luo, H. et al. Quo vadis artificial intelligence ? *Discov Artif Intell* 2, 4 (2022). <https://doi.org/10.1007/s44163-022-00022-8>

[32] Hinton G, Deng L, Yu D, Dahl GE, et al. Deep neural networks for acoustic modeling in speech recognition: the shared views of four research groups. *IEEE Signal Process Mag.* 2012;29(6):82–97.

[33] Graves A, Mohamed AR, Hinton G. Speech recognition with deep recurrent neural networks. In: *IEEE international conference on acoustics, speech and signal processing*. IEEE: Piscataway; 2013. p. 6645–9.

[34] Chollet F. Xception: deep learning with depthwise separable convolutions. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. IEEE: Piscataway; 2017. p. 1251–8.

[35] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. IEEE: Piscataway; 2016. p. 770–8.

[36] Devlin J, Chang MW, Lee K, Toutanova K. Bert: pre-training of deep bidirectional transformers for language understanding. *Comput Lang.* 2018.

doi.org/10.48550/arXiv.1810.04805.

[37] Sutskever I, Vinyals O, Le QV. Sequence to sequence learning with neural networks. In: *Advances in neural information processing systems*. Canada: NeurIPS; 2014. p. 3104–12

[38] Gualtieri L, Rauch E, Vidoni R. Emerging research fields in safety and ergonomics in industrial collaborative robotics: a systematic literature review. *Robot Comput Integr Manuf.* 2021; 67:101998.

[39] Palagi S, Fischer P. Bioinspired microrobots. *Nat Rev Mater.* 2018.

doi.org/10.1038/s41578-018-0016-9.

[40] Menouar H, Guvenc I, Akkaya K, et al. UAV-enabled intelligent transportation systems for the smart city: applications and challenges. *IEEE Commun Mag.* 2017;55(3):22–8.

- [41] Grigorescu S, Trasnea B, et al. GA survey of deep learning techniques for autonomous driving. *J Field Robotics*. 2019;37(3):362–86.
- [42] Lu R, Hong SH. Incentive-based demand response for smart grid with reinforcement learning and deep neural network. *Appl Energy*. 2019; 236:937–49.
- [43] Raza MQ, Khosravi A. A review on artificial intelligence-based load demand forecasting techniques for smart grid and buildings. *Renew Sustain Energy Rev*. 2015; 50:1352–72.
- [44] Yu KH, Beam AL, Kohane S. Artificial intelligence in healthcare. *Nat Biomed Eng*. 2018;2(10):719–31.
- [45] Me A, Mc A, Fkhg A, et al. Harnessing artificial intelligence for the next generation of 3D printed medicines. *Adv Drug Deliv Rev*. 2021. doi.org/10.1016/j.addr.2021.05.015.
- [46] Jaksic M, Marinc M. Relationship banking and information technology: the role of artificial intelligence and FinTech. *Risk Manag*. 2017;21(1):1–18.
- [47] Aurélien Géron. *Hands-on Machine Learning with Scikit-Learn, Keras & TensorFlow. Concepts, Tools, and Techniques to Build Intelligent Systems*, O'Reilly Media, 2e édition, Sebastopol, 2019.
- [48] Moez Krichen. *Les méthodes formelles sont-elles applicables à l'apprentissage automatique et à l'intelligence artificielle*. 2022. hal-03751705.
- [49] C. Thornton, F. Hutter, H.H. Hoos, K. Leyton-Brown Auto-weka: Combined selection and hyperparameter optimization of classification algorithms *Proceedings of the 19th ACM SIGKDD international conference on Knowledge discovery and data mining (2013)*, pp. 847-855.
- [50] L. Kotthoff, C. Thornton, H.H. Hoos, F. Hutter, K. Leyton-Brown Auto-weka: Automatic model selection and hyperparameter optimization in weka *Automated Machine Learning*, Springer, Cham (2019), pp. 81-95
- [51] M. Feurer, A. Klein, K. Eggenberger, J.T. Springenberg, M. Blum, F. Hutter, Auto-sklearn: efficient and robust automated machine learning, in: *Automated Machine Learning*, Springer, Cham, 2019, pp. 113–134.
- [52] R. Caruana, A. Niculescu-Mizil, G. Crew, A. Ksikes Ensemble selection from libraries of models *Proceedings of the twenty-first international conference on Machine learning (2004)*, p. 1
- [53] M. Feurer, J.T. Springenberg, F. Hutter Using meta-learning to initialize bayesian optimization of hyperparameters. *MetaSel@ ECAI, Citeseer (2014)*, pp. 3-10
- [54] de Beauville, J.-P.A. and F.-Z. Kettaf, *Bases théoriques pour l'apprentissage et la décision en reconnaissance des formes*. 2005 : Cépaduès.

- [55] Dreyfus, G., *Apprentissage statistique*. 2008 : Editions Eyrolles.
- [56] Rajkomar, A., Dean, J., & Kohane, I. (2019). Machine learning in medicine. *New England Journal of Medicine*, 380(14), 1347-1358.
- [57] Topol, E. J. (2019). High-performance medicine: The convergence of human and artificial intelligence. *Nature Medicine*, 25(1), 44-5.
- [58] Batta, M., 2020. Machine Learning Algorithms. *International Journal of Science and Research*, 9. 381- 385.
- [59] Z. Shi, S. Zhang, J. Yuan, B. Zhu, Y. Jiang, X. Shen, and Y. Wang, "Spatiotemporal summation and correlation mimicked in a four-emitter light-induced artificial synapse," *Scientific Reports*, vol. 8, no. 1, pp. 2159–2159, 2018
- [60] J. Defelipe, L. Alonsoanclares, and J. I. Arellano, "Microstructure of the neocortex: Comparative aspects," *Journal of Neurocytology*, vol. 31, no. 3, pp. 299–316, 2002.
- [61] S. Sardi, R. Vardi, A. Sheinin, A. Goldental, and I. Kanter, "New types of experiments reveal that a neuron functions as multiple independent threshold units," *Scientific Reports*, vol. 7, no. 1, pp. 18036–18036, 2017.
- [62] Y. Timofeeva, S. Coombes, and D. Michieletto, "Gap junctions, dendrites and resonances: A recipe for tuning network dynamics," *Journal of Mathematical Neuroscience*, vol. 3, no. 1, pp. 15–15, 2013
- [63] H. Mohan, M. B. Verhoog, K. K. Doreswamy, G. Eyal, R. Aardse, B. Lodder, N. A. Goriounova, B. Asamoah, A. B. C. B. Brakspear, and C. Groot, "Dendritic and axonal architecture of individual pyramidal neurons across layers of adult human neocortex," *Cerebral Cortex*, vol. 25, no. 12, pp. 4839–4853, 2015.
- [64] A. Gidon, T. A. Zolnik, P. Fidzinski, F. Bolduan, A. Papoutsi, P. Poirazi, M. Holtkamp, I. Vida, and M. E. Larkum, "Dendritic action potentials and computation in human layer 2/3 cortical neurons," *Science*, vol. 367, no. 6473, pp. 83–+, 2020.
- [65] P. Poirazi and A. Papoutsi, "Illuminating dendritic function with computational Models," *Nature Reviews Neuroscience*, vol. 21, no. 6, pp. 303–321, 2020
- [66] Mohamed Benmeddour, "Contrôle par réseau de neurones", mémoire de magistère en informatique industrielle, université de Oum El Bouaghi, Algérie, 2012.
- [67] Pascal Monasse, et al., « Découvrez les différentes couches d'un CNN ». <https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/5083336-decouvrez-les-differentes-couches-dun-cnn> (consulté le aout. 16, 2020).

- [68] Prabhu, « Understanding of Convolutional Neural Network (CNN) — Deep Learning | by Prabhu | Medium ». Mar 4, 2018 <https://medium.com/@RaghavPrabhu/understanding-of-convolutional-neural-network-cnn-deep-learning-99760835f148> (consulté le aout. 16, 2020).
- [69] C. Barès, « Python–Informatique », 2020.
- [70] R. Python, « Python Tutorials – Real Python ». <https://realpython.com/> (consulté le oct. 04,2020).
- [71] « Plot with Pandas: Python Data Visualization for Beginners – Real Python ». <https://realpython.com/pandas-plot-python/> (consulté le oct. 04, 2020).
- [72] « wfdb - documentation wfdb 3.1.1 ». <https://wfdb.readthedocs.io/en/latest/> (consulté le oct.04, 2020).
- [73] « Warning — Programmation avec le langage Python ». <http://www.xavierdupre.fr/app/teachpyx/helpsphinx/c-exception/warning.html> (consulté le oct. 11,2020).

ملخص :

يقدم هذا الموجز تحقيقًا شاملاً في تصنيف إشارات تخطيط القلب باستخدام الذكاء الاصطناعي. ينصب التركيز على تطوير نموذج تصنيف قوي. تكشف النتائج عن قدرة النموذج على التمييز بشكل فعال MIT-BIH استغلال قاعدة بيانات بين فئات مختلفة من دقات القلب، مما يقدم وجهات نظر جديدة للتشخيص المبكر والدقيق لاضطرابات القلب. يقدم هذا البحث مساهمة كبيرة في مجال الطب ويفتح فرصًا واعدة لتحسين الرعاية الصحية للقلب والأوعية الدموية.

الكلمات المفتاحية:

، الذكاء الاصطناعي ، التعلم العميق ، التصنيف CNN ، ECG

Abstract :

This brief presents a thorough investigation of the classification of ECG signals using artificial intelligence. The focus is on the exploitation of the MIT-BIH database to develop a powerful classification model. The results reveal the ability of the model to effectively discriminate between different categories of heartbeats, offering new perspectives for the early and accurate diagnosis of heart disorders. This research makes a significant contribution to the field of medicine and opens up promising opportunities to improve cardiovascular health care.

Keywords :

ECG, CNN, Artificial Intelligences, Deep Learning, classification.

Résumé :

Ce mémoire présente une investigation approfondie sur la classification des signaux ECG en utilisant l'intelligence artificielle. L'accent est mis sur l'exploitation de la base de données MIT-BIH pour développer un modèle de classification performant. Les résultats obtenus révèlent la capacité du modèle à discriminer efficacement entre les différentes catégories de battements cardiaques, offrant ainsi de nouvelles perspectives pour un diagnostic précoce et précis des troubles cardiaques. Cette recherche apporte une contribution significative au domaine de la médecine et ouvre des opportunités prometteuses pour améliorer les soins de santé cardiovasculaire.

Mots clés :

ECG, CNN, Intelligences artificielles, Deep Learning, classification