

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



جامعة بجاية
Tasdawit n Bgayet
Université de Béjaïa

Université A/Mira de Béjaïa
Faculté des Sciences Exactes
Département d'Informatique

Mémoire de Master Recherche

En Informatique
Option
Intelligence Artificielle

Thème

Les transformers pour le traitement du signal ECG

Présenté par :

Mehrazi Elhacene
Messaoudi Sidali

Soutenu le 03 juillet 2024 devant le jury composé de :

Président : Mme Tahakourt Zineb	M.C.B	U.A/Mira de Bejaia
Encadreur : Mme Aloui Soraya	M.C.A	U.A/Mira de Bejaia
Examineur : Mr Farah Zoubeyr	M.C.A	U.A/Mira de Bejaia
Co-encadreur : Mr Amroun Kamal	Professeur	U.A/Mira de Bejaia

Bejaia, juillet 2024

Remerciements

Tout d'abord, nous remercions Dieu, Tout-Puissant, pour nous avoir accordé la force, la patience et la persévérance nécessaires pour mener à bien ce travail.

Nous remercions chaleureusement notre encadreur, Mme Alloui, pour son encadrement, ses précieux conseils et sa disponibilité tout au long de ce projet. Nous sommes également très reconnaissants envers notre co-encadreur, M. Amourne, pour son soutien constant et ses orientations éclairées.

Nous tenons à exprimer notre reconnaissance au Dr. Teffahi Nabila pour nous avoir expliqué les signaux ECG avec une grande clarté, facilitant ainsi notre compréhension et notre travail de recherche.

Nous remercions également les membres du jury, M. Farah et Mme Tahakourt, pour leurs lectures attentives de notre mémoire et pour l'honneur qu'ils nous font en participant au jugement de ce travail.

Nous adressons par la suite nos sincères remerciements à tous les professeurs, intervenants et toutes les personnes qui ont guidé nos réflexions et répondu à nos questions durant nos recherches. Leur soutien et leur expertise ont été d'une aide précieuse tout au long de ce parcours.

À tous, nous vous exprimons notre gratitude et vous adressons nos plus sincères remerciements.

Dédicace

Aucune dédicace ne saurait exprimer notre respect, notre amour éternel et notre considération pour les sacrifices que vous avez consenti pour notre instruction et notre bien-être. Votre présence, votre écoute, votre confiance en nous et votre soutien constant nous assurent des bases solides nous permettant de persévérer et de nous surpasser. Nous espérons que votre bénédiction nous accompagne toujours. À nos familles paternelles et maternelles.

A nos amis, qui nous ont accompagnées et soutenus tout au long de ce travail.

« À tous ceux/celles qu'on a omis de citer »

Table de matière

Introduction générale	1
Chapitre 1 Le signal ECG	4
1.1 Introduction :	5
1.2 Définition du signal ECG	6
1.3 Traitement du signal ECG	6
1.3.1 Les ondes de l'ECG	6
1.3.2 Intervalles et complexes	8
1.4 Chaîne d'acquisition de l'ECG par ordinateur	9
1.5 Dérivations d'électrocardiographie	10
1.5.1 Dérivations bipolaires standard	10
1.5.2 Dérivations unipolaires augmentées	11
1.5.3 Dérivations précordiales	11
1.6 Différence de signal ECG	12
1.6.1 Signal ECG normal	12
1.6.2 Les arythmies cardiaques : un battement hors rythme	13
1.6.3 Signal ECG bruité	14
1.7 Détection d'anomalie ECG	15
1.8 Conclusion	17
Chapitre 2 Modèle transformers	18
2.1 Introduction	19
2.2 Définition des transformer	19

2.3	Architecture des transformers	20
2.4	Entraînement des transformers	22
2.5	Domaine d'utilisation	22
2.6	Les différents modèles de transformers.....	23
2.7	Avantage des transformers sur les autres modèles.....	25
2.8	Défis des transformers.....	27
2.9	Conclusion.....	28
Chapitre 3	Etat de l'art	29
3.1	Introduction	30
3.2	Travaux connexes.....	30
3.3	Tableau comparatifs	31
3.4	Conclusion :.....	34
Chapitre 4	Implémentation et Évaluation du Modèle.....	35
4.1	Introduction	36
4.2	Environnement utilisé.....	36
4.3	Principales étapes de notre approche	37
4.4	Données Utilisées (dataset)	38
4.4.1	MIT-BIH Normal Sinus Rhythm Database	38
4.4.2	MIT-BIH Arrhythmia Database	38
4.5	Prétraitement des Données	39
4.5.1	Chargement des Données Normales.....	39
4.5.2	Segmentation des Signaux Normaux.....	40
4.5.3	Chargement des Données Anormales.....	41
4.5.4	Segmentation des Signaux Anormaux.....	41
4.5.5	Combinaison des Données.....	42

4.5.6	Division des Données	42
4.6	Architecture du Modèle	43
4.6.1	Couche Linéaire Initiale	43
4.6.2	Encodeurs Transformer	43
4.6.3	Couche de Sortie.....	44
4.7	Implémentation du Modèle	44
4.8	Entraînement et Évaluation	44
4.8.1	Initialisation de la Perte et de l'Optimiseur	44
4.8.2	Boucle d'Entraînement.....	45
4.9	Évaluation du Modèle	46
4.9.1	Mode d'évaluation.....	47
4.9.2	Prédiction et calcul métrique	47
4.9.3	Les métriques de performance calculées sont	47
4.9.4	Affichage des Résultats	47
4.10	Résultats	48
4.10.1	Score global.....	48
4.10.2	Performance	48
4.10.3	Analyse des résultats	49
4.10.4	Métriques Globales	49
4.11	La Matrice de Confusion	49
4.11.1	Interprétation de la Matrice	50
4.11.2	Calcul des Métriques de Performance	51
4.12	La matrice de corrélation :	52
4.13	La Courbe ROC et l'AUC	53
4.14	Interprétation de la Courbe ROC	54

4.15	Conclusion	55
	CONCLUSION GENERALE & PERSPECTIVES	56
	Bibliographie	58

Liste des figures :

Figure 1-1 physiologie cardiaque [29]	5
Figure 1-2 onde électrique d'un battement cardiaque [3]	6
Figure 1-3 différente courbe d'un signal ECG [4].....	8
Figure 1-4 différente courbe d'un signal ECG [4].....	8
Figure 1-5 chaîne d'acquisition d'un ECG [15].....	9
Figure 1-6 représentation d'un signal ECG normal [8].....	12
Figure 1-7 exemple de signal ECG anormal. [10]	13
Figure 1-8 exemple de signal ECG bruité. [12].....	14
Figure 2-1 schéma d'un modèle transformers. [18].....	19
Figure 2-2 Architecture générale de BERT (Peltarion, 2020). [29]	23
Figure 2-3 Comparaison entre les différentes variantes de BERT (Le et al., 2019). [29]	25
Figure 4-1 étapes de l'approche proposée	37
Figure 4-2 échantillon du code utilisé pour le premier dataset.....	39
Figure 4-3 échantillon du code utilisé pour segmenter le premier dataset	40
Figure 4-4 échantillon du code utilisé pour le deuxième dataset.....	41
Figure 4-5 échantillon du code utilisé pour la combinaison.....	42
Figure 4-6 échantillon du code utilisé pour la division	42
Figure 4-7 schéma explicatif de l'architecture de notre modèle.....	43
Figure 4-8 échantillon du code utilisé pour l'entraînement.....	46
Figure 4-9 échantillon du code utilisé pour l'évaluation	46
Figure 4-10 score global de notre modèle	48
Figure 4-11 performance du modèle.....	48
Figure 4-12 matrice de confusion de notre approche	50
Figure 4-13 La matrice de corrélation	52
Figure 4-14 La courbe ROC	53

Liste des tableaux

Tableau 3-1 tableau explicatif des travaux étudier	33
Tableau 4-1 explication de la matrice.....	50

Listes des équations :

Équation 1 calcul de la précision	51
Équation 2 calcul du rappel.....	51
Équation 3 calcul du F1-Score.....	51
Équation 4 calcul de l'exactitude	52
Équation 5 calcul du taux de Vrais Positifs	54
Équation 6 calcul du taux de faux positifs.....	54

Acronymes

Ad-CNN : Adversarial Convolutional Neural Network

AUC : Aire sous la courbe ROC (Receiver Operating Characteristic)

BCE : Binary Cross-Entropy

CNN : Convolutional Neural Network

ECG : Électrocardiogramme

LDE : Low-Dimensional Denoising Embedding

LDTF : Low-Dimensional Denoising Embedding Transformer

MAE : Erreur absolue moyenne

MIT : Massachusetts Institute of Technology

MPCA : Multiway Principal Component Analysis

MWFE : Multi-Scale Weighted Fusion Ensemble

ML : machine learning

NLP : Natural Language Processing

OSA : Apnée du sommeil obstructive

PVC : Premature Ventricular Contraction

ReLU : Rectified Linear Unit

ROC : Receiver Operating Characteristic

RR : Intervalle RR, qui mesure l'intervalle entre deux complexes QRS consécutifs dans un ECG

SGD : Stochastic Gradient Descent.

Introduction générale

Depuis des millénaires, la cardiologie a évolué de manière significative, passant des premières observations des battements cardiaques aux techniques modernes de diagnostic et de traitement. Dès l'Antiquité, les médecins ont tenté de comprendre le fonctionnement du cœur et son rôle central dans la circulation sanguine. Cependant, ce n'est qu'à la fin du XIXe siècle que l'on a commencé à déchiffrer les signaux électriques émis par le cœur, marquant une avancée majeure dans le domaine de la cardiologie.

L'électrocardiogramme (ECG) est l'une des découvertes les plus révolutionnaires de cette époque. En enregistrant les impulsions électriques produites par les battements du cœur, l'ECG a permis aux médecins de détecter et de diagnostiquer une variété de conditions cardiaques avec une précision sans précédent. Malgré son utilité indéniable, l'interprétation des signaux ECG reste un défi, nécessitant une expertise approfondie et une analyse minutieuse.

Avec l'essor des technologies de l'information et des capacités de calcul avancées, l'automatisation du traitement des signaux ECG est devenue un sujet de recherche intense et prometteur. Parmi les innovations récentes, les modèles Transformers, initialement développés pour des applications de traitement du langage naturel, se sont révélés particulièrement efficaces pour analyser les séries temporelles complexes, telles que les signaux ECG. Ces modèles se distinguent par leur capacité à capturer des dépendances à longue portée dans les données, ce qui est crucial pour une analyse approfondie et précise des signaux cardiaques.

Nous présentons dans ce travail une approche pour le traitement des signaux ECG, en nous basant sur les Transformers pour détecter si le signal est normal ou anormal.

Ce mémoire est structuré en quatre chapitres principaux pour explorer cette intersection entre cardiologie et intelligence artificielle.

Le premier chapitre est dédié à une présentation détaillée du signal ECG. Nous y explorons les caractéristiques fondamentales du signal, les méthodes de mesure et les principaux défis associés à son interprétation.

Introduction générale

Le deuxième chapitre se concentre sur les modèles Transformers. Nous y présentons les bases théoriques de ces modèles, leur architecture, leurs avantages, ainsi que les différents modèles existants.

Le troisième chapitre constitue un état de l'art des recherches récentes sur l'utilisation des modèles Transformers pour le traitement des signaux ECG. Nous y passons en revue plusieurs articles scientifiques pertinents, en mettant en lumière les approches méthodologiques, les résultats obtenus et les perspectives offertes par ces travaux.

Enfin, le quatrième chapitre est consacré à notre propre contribution : nous y présentons le modèle Transformer que nous avons développé pour le traitement des signaux ECG, ainsi que les résultats des tests et des expérimentations que nous avons menés.

Nous terminons notre travail par une conclusion et quelques perspectives.

Chapitre 1 Le signal ECG

1.1 Introduction :

Ce chapitre expose l'électrocardiogramme (ECG) et son traitement, ce qui permet d'avoir une vision globale et approfondie des éléments essentiels de cette méthode médicale cruciale.

L'ECG joue un rôle primordial dans le diagnostic des maladies cardiaques, la surveillance de la santé cardiovasculaire et la détection précoce des anomalies. Nous examinons les subtilités des différentes formes d'ondes courantes de l'ECG, les intervalles importants, les anomalies détectées et les progrès technologiques qui ont impacté le traitement des signaux ECG. Notre objectif est de mieux comprendre l'importance essentielle de l'ECG dans le domaine médical moderne ainsi que les défis fascinants liés à son interprétation et à son utilisation clinique.

Pour mieux comprendre les zones du cœur humain, **la figure 1.1** représente l'anatomie et la physiologie cardiaques.




Figure 1-1 physiologie cardiaque [29]

1.2 Définition du signal ECG

Un signal électrocardiographique (ECG) est une représentation graphique de l'activité électrique du cœur.

Il est obtenu en plaçant des électrodes sur la surface de la peau, plus précisément au niveau des bras, des jambes et de la poitrine. Ces électrodes détectent les impulsions électriques générées par le cœur lors de ses cycles de contraction et de relaxation [1].

1.3 Traitement du signal ECG

Les débuts du traitement du signal ECG remontent aux premières décennies du XXe siècle avec le développement d'instruments d'enregistrement électrique. Au fil du temps, des méthodes traditionnelles telles que la détection d'ondes, la segmentation du signal et l'extraction de caractéristiques ont été établies pour automatiser l'analyse de l'ECG. Ces approches classiques ont permis des avancées significatives, mais elles présentent des limitations, notamment en termes de complexité de modélisation pour des motifs cardiaques plus complexes et variés [2].

1.3.1 Les ondes de l'ECG




Figure 1-2 onde électrique d'un battement cardiaque [3]

La figure 1-2 représente les ondes électriques d'un battement cardiaque.

Les cellules spécialisées, connues sous le nom de cellules régulatrices du rythme cardiaque, sont présentes dans le cœur et produisent de l'électricité en alternant rapidement entre une charge positive et une charge négative. Ce premier mouvement électrique se propage en ondes, provoquant ainsi une réaction en cascade jusqu'à la surface du corps. Les électrodes ECG sont utilisées sur la peau afin d'enregistrer les potentiels électriques générés par ces ondes.

Sur un ECG, la ligne de base isoélectrique est utilisée comme référence pour représenter l'absence totale d'activité électrique. La courbe qui passe au-dessus de cette ligne est positive, tandis que la courbe qui passe en dessous est négative. Les informations enregistrées sur un ECG se manifestent sous forme de formes d'ondes et d'intervalles présentant des durées et des amplitudes spécifiques, se répétant de manière régulière à chaque battement cardiaque [3].

Les mesures principales de l'ECG sont notées par les lettres suivantes: l'onde P, Q, R, S et enfin de l'onde T comme suit :

L'onde P : Elle indique la contraction des oreillettes (dépolariation auriculaire) et précède régulièrement les complexes ventriculaires. C'est une petite onde positive, arrondie, avec une amplitude inférieure ou égale à 0,2 mV et une durée d'environ 120 ms.

L'onde Q : C'est la première déviation négative dans le complexe QRS, avec une faible amplitude et une durée pouvant atteindre 0,2 s.

L'onde R : Correspondant à la dépolariation des ventricules vers l'extérieur, elle est une onde positive de grande amplitude qui suit directement l'onde Q.

L'onde S : Représentant la repolarisation du reste des ventricules, c'est une déflexion de faible amplitude située sous la ligne de base et constitue la deuxième composante négative dans le complexe QRS.

L'onde T : Elle marque la fin de la contraction ventriculaire et la repolarisation du muscle cardiaque. C'est une onde positive, dont la durée est imprécise en raison de sa fin progressive, avec une amplitude généralement inférieure à 2 mV [4].

1.3.2 Intervalles et complexes




Figure 1-3 différente courbe d'un signal ECG [4]

Comme représenté dans la **figure 1-3**, l'ECG comporte plusieurs intervalles et complexes qui fournissent des informations précieuses sur la fonction cardiaque :

Intervalle PR : Il mesure le temps de propagation de l'influx électrique des oreillettes aux ventricules, allant de l'onde P au début du complexe QRS. Sa durée chez l'adulte moyen varie de 0,12 à 0,21 seconde, en fonction du rythme cardiaque.

Complexe QRS : Il représente la dépolarisation des ventricules et se compose des ondes Q, R et S. Sa grande amplitude, variant entre 5 et 20 mV, en fait un élément crucial du diagnostic. Sa durée est de 0,06 à 0,10 seconde chez un individu sain, indiquant une dépolarisation ventriculaire rapide.

Intervalle QT : C'est la période entre le début du complexe QRS et la fin de l'onde T, reflétant la durée totale de la stimulation et de la relaxation ventriculaire. Sa durée normale est de 0,3 à 0,44 seconde.

Segment ST : C'est la période entre la fin du complexe QRS et le début de l'onde T, correspondant à l'excitation complète des cellules ventriculaires. Ce segment est isoélectrique.

Intervalle RR : Il mesure le temps entre deux ondes R successives et est utilisé pour calculer la fréquence cardiaque [4].

1.4 Chaîne d'acquisition de l'ECG par ordinateur




Figure 1-5 chaîne d'acquisition d'un ECG [15]

La figure 1-5 représente un schéma explicatif de la chaîne d'acquisition d'un ECG.

Avec l'évolution des capacités et des limitations des outils de traitement, le positionnement des électrodes d'acquisition de l'ECG-HR a également évolué. À l'heure actuelle, le système de dérivations suggéré, bien que empirique, est basé sur un consensus international qui recommande l'utilisation de trois dérivations de position comme suis :

- **Électrodes** : Les électrodes sont placées sur la peau du patient à des endroits spécifiques du corps pour détecter les signaux électriques du cœur. Généralement, un ECG standard utilise 10 électrodes (12 dérivations) placées sur les membres et la poitrine.
- **Câbles** : Les électrodes sont connectées à des câbles conducteurs qui transportent les signaux électriques des électrodes vers l'appareil d'acquisition.

- **Amplificateurs** : Les signaux électriques du cœur sont généralement faibles et doivent être amplifiés pour être détectés avec précision. Les amplificateurs ECG amplifient ces signaux pour les rendre plus visibles et exploitables.
- **Filtres** : Les signaux électriques collectés peuvent être perturbés par différents types de bruits, tels que les interférences musculaires ou les mouvements. Les filtres sont utilisés pour éliminer ces bruits indésirables et ne laisser que le signal cardiaque pur.
- **Convertisseur analogique-numérique (CAN)** : Une fois que le signal a été amplifié et filtré, il est converti en signal numérique à l'aide d'un convertisseur analogique-numérique. Cela permet de numériser le signal afin qu'il puisse être traité et analysé par un ordinateur.
- **Carte d'acquisition ou interface informatique** : La carte d'acquisition ou l'interface informatique est le dispositif qui reçoit le signal numérique de l'ECG et le transmet à un logiciel informatique pour l'affichage et l'analyse [5].

1.5 Dérivations d'électrocardiographie

Sur l'électrocardiogramme (ECG), les dérivations cardiaques sont l'enregistrement de la différence de potentiel électrique entre deux points, que ce soit entre deux électrodes (dérivation bipolaire) ou entre un point virtuel et une électrode (dérivation unipolaire).

Il est important de savoir que les dérivations cardiaques ne doivent pas être constatées séparément mais avec l'ensemble de l'électrocardiogramme car chaque dérivation est un point de vue différent du même stimulus électrique [6].

1.5.1 Dérivations bipolaires standard

Il s'agit des dérivations cardiaques traditionnelles de l'électrocardiogramme, où la différence de potentiel entre deux électrodes situées à des extrémités différentes est enregistrée par celles-ci :

D1 ou I : différence de potentiel entre le bras droit et le bras gauche. Son vecteur pointe à 0°.

D2 ou II : différence de potentiel entre le bras droit et la jambe gauche. Son vecteur pointe à 60° .

D3 ou III : différence de potentiel entre le bras gauche et la jambe gauche. Son vecteur pointe à 120° [6].

1.5.2 Dérivations unipolaires augmentées

La différence de potentiel entre un point théorique au centre du triangle de Einthoven, où la valeur est 0, et l'électrode de chaque extrémité est enregistrée par les dérivations unipolaires des extrémités, ce qui permet de déterminer le potentiel absolu dans chaque électrode.

Initialement, ces dérivations étaient nommées VR, VL et VF. Le "V" signifie vecteur, et "R", "L", "F" représentent respectivement droite (right), gauche (left) et pied (foot) en anglais. Plus tard, une minuscule "a" a été ajoutée pour indiquer qu'elles sont amplifiées (les dérivations unipolaires actuelles sont amplifiées par rapport aux premières).

aVR : Potentiel absolu du bras droit. Son vecteur pointe à -150° .

aVL : Potentiel absolu du bras gauche. Son vecteur pointe à -30° .

aVF : Potentiel absolu de la jambe gauche. Son vecteur pointe à 90° .

1.5.3 Dérivations précordiales

Il y a six dérivations précordiales de l'électrocardiogramme désignées par une majuscule V et un numéro de 1 à 6. Ce sont des dérivations unipolaires qui enregistrent le potentiel absolu du point sur lequel l'électrode du même nom est placée.

Ces dérivations de l'électrocardiogramme sont particulièrement pertinentes pour détecter des anomalies du ventricule gauche, en particulier des parois antérieure et postérieure.

V1 : Cette dérivation enregistre les potentiels des oreillettes par le septum et la paroi antérieure du ventricule droit. Le complexe QRS présente une petite onde R (dépolariation du septum intraventriculaire) suivie d'une onde S profonde.

V2 : L'électrode de cette dérivation précordiale se situe au-dessus de la paroi ventriculaire droite, donc l'onde R est légèrement plus grande qu'en V1, suivie d'une onde S profonde.

V3 : Dérivation transitionnelle entre les potentiels gauches et droits de l'ECG due à la présence de l'électrode sur le septum intraventriculaire. L'onde R et l'onde S sont généralement presque égales.

V4 : L'électrode de cette dérivation est placée sur la terminaison du ventricule gauche, où son épaisseur est plus grande. Elle présente une onde R haute suivie d'une petite onde S (activation du ventricule droit).

V5 et V6 : Ces dérivations sont situées sur le myocarde du ventricule gauche, dont l'épaisseur est moindre que celle de V4. C'est pourquoi l'onde R est plus petite qu'en V4, bien qu'elle reste élevée. L'onde R est précédée d'une petite onde Q (dépolarisation du septum) [7].

1.6 Différence de signal ECG

1.6.1 Signal ECG normal




Figure 1-6 représentation d'un signal ECG normal [8]

La figure 1-6 représente un signal ECG normal.

On appelle « ECG normal » d'adulte un ECG avec un rythme sinusal situé entre 60 et 100 battements par minute, sans aucun segment ni déflexion anormaux.

Le rythme d'un tracé normal est sinusal : toutes les ondes P sont identiques, tous les complexes QRS sont identiques, et chaque onde P est suivie d'un complexe QRS. Le rythme cardiaque et la respiration sont parfaitement synchronisés pour obtenir les meilleures performances en circulation sanguine et distribution d'oxygène dans l'organisme.

Rythme cardiaque régulier : En l'absence de toute anomalie, le rythme cardiaque est régulier si l'intervalle R-R est presque constant tout au long de l'enregistrement ECG et si des complexes QRS similaires sont présents.

Rythme sinusal : Le rythme cardiaque est appelé rythme sinusal car l'origine de l'activité électrique du cœur est le nœud sino-auriculaire. Il se caractérise par une onde P précédant chaque complexe QRS [9].

1.6.2 Les arythmies cardiaques : un battement hors rythme



Figure 1-7 exemple de signal ECG anormal. [10]

La figure 1-7 représente un exemple de signal ECG anormal.

Les arythmies cardiaques sont des conditions dans lesquelles le cœur bat de manière anormale. Elles peuvent être temporaires ou persistantes, bénignes ou potentiellement mortelles, et leur diagnostic ainsi que leur traitement dépendent de leur type, de leur gravité et des symptômes qu'elles provoquent. Comme nous le voyons dans la figure ci-

dessus, elles sont détectées sur un ECG par des anomalies dans les ondes, les intervalles ou les segments, comme par exemple :

Fibrillation auriculaire (FA) : Se manifeste généralement par l'absence d'une onde P régulière et des oscillations irrégulières et chaotiques de la ligne de base entre les complexes QRS.

Tachycardie ventriculaire (TV) : Au niveau de l'ECG, la TV se manifeste habituellement par des complexes QRS larges et étranges, souvent liés à un rythme cardiaque rapide et précis.

Fibrillation ventriculaire (FV) : En général, à l'ECG, la FV se manifeste par l'absence de complexes QRS distincts et une activité électrique désordonnée à la place.

Flutter auriculaire : Représenté sur un ECG par des ondes P régulières et rapides qui ressemblent à des "dents de scie" sur la ligne de base.

Bloc auriculo-ventriculaire (BAV) : On peut repérer le BAV en observant un allongement de l'intervalle PR, ce qui indique un retard ou un blocage de la conduction électrique entre les oreillettes et les ventricules [11].

1.6.3 Signal ECG bruité




Figure 1-8 exemples de signal ECG bruité. [12]

La figure 1-8 représente quelques exemples de signaux ECG ayant subi des bruits.

Le bruit est considéré comme une interférence indésirable qui peut perturber ou altérer la qualité du signal électrique du cœur enregistré. Ce bruit peut provenir de diverses sources, notamment :

Interférences électriques : Ces interférences peuvent être dues à des équipements électriques environnants, tels que des câbles d'alimentation, des dispositifs médicaux ou des appareils électroniques.

Mouvements du patient : Les mouvements du patient peuvent causer des artefacts dans le signal ECG, en particulier lorsqu'il s'agit de patients agités ou de ceux qui ne peuvent pas rester immobiles pendant l'enregistrement.

Interférences musculaires : Les contractions musculaires, en particulier celles des membres où les électrodes sont placées, peuvent produire des artefacts dans le signal ECG.

Mauvaise connexion électrode-peau : Une mauvaise connexion entre les électrodes et la peau peut entraîner des artefacts ou une perte de signal dans l'enregistrement de l'ECG.

Mauvais contact électrode-câble : Un mauvais contact entre les électrodes et les câbles de connexion peut également introduire du bruit dans le signal ECG.

Interférences externes : Des sources externes telles que les interférences électromagnétiques (EMI) ou les fluctuations de tension électrique peuvent également perturber le signal ECG [13].

1.7 Détection d'anomalie ECG

Pour détecter une anomalie dans un signal ECG, les professionnels de la santé se concentrent sur plusieurs aspects du tracé ECG :

Forme des ondes : Il est crucial que les ondes P, QRS et T soient de forme et de durée normales. Des déformations, des élargissements ou des absences de ces ondes peuvent indiquer des anomalies.

Segment ST : Le segment ST, situé entre la fin de l'onde QRS et le début de l'onde T, doit être plat et aligné avec la ligne de base. Une augmentation ou une **diminution de ce segment peut être associée à une ischémie du cœur.**

Intervalle QT : La durée de la dépolarisation et de la repolarisation ventriculaire, mesurée par l'intervalle QT, doit être dans une plage normale. Des anomalies dans cet intervalle peuvent être liées à des problèmes de rythme cardiaque.

Fréquence cardiaque et rythme : La fréquence cardiaque doit être constante et dans des limites normales. Des variations excessives de la fréquence ou des arythmies peuvent indiquer des anomalies.

Conduction : La conduction électrique à travers le cœur doit être normale. Des retards ou des blocs dans la conduction peuvent être des signes d'anomalies.

Analyse comparative : Comparer le tracé ECG avec les enregistrements précédents du même patient permet de détecter des changements significatifs dans l'activité électrique du cœur au fil du temps.

Corrélation clinique : Interpréter les résultats de l'ECG en tenant compte des symptômes du patient, de son historique médical et d'autres tests diagnostiques peut aider à confirmer le diagnostic et à élaborer un plan de traitement approprié. Des investigations supplémentaires, comme des tests sanguins, des examens d'imagerie ou une surveillance cardiaque continue, peuvent être nécessaires en cas de détection d'anomalies. En cas de doutes, une consultation avec un cardiologue ou un électro-physiologiste cardiaque peut être recommandée pour obtenir des conseils spécialisés [14].

1.8 Conclusion

Ce chapitre a souligné l'importance cruciale de l'électrocardiogramme (ECG) dans le domaine de la cardiologie et de la médecine en général.

L'ECG, qui enregistre l'activité électrique du cœur, fournit des données essentielles sur la fonction cardiaque, permettant ainsi le diagnostic précoce des troubles cardiaques et la surveillance continue de la santé cardiovasculaire. Ce chapitre a mis en lumière l'importance d'une compréhension approfondie des données électriques du cœur pour une interprétation précise et un suivi efficace des patients, en explorant les caractéristiques des formes d'ondes et les défis associés au traitement des signaux ECG.

Dans le prochain chapitre, nous aborderons les modèles Transformers et expliquerons leur fonctionnement de manière détaillée.

Chapitre 2 Modèle transformer

2.1 Introduction

Dans ce chapitre, nous nous concentrons sur l'étude approfondie des transformers, une classe novatrice d'architectures de modèles neuronaux qui ont profondément transformé le domaine de l'apprentissage automatique. En comparaison avec les architectures récurrentes classiques, les transformers offrent des avantages significatifs en termes de capture des relations complexes à long terme au sein des données séquentielles. À travers l'exploration de leur architecture, de leur entraînement et de leurs applications diverses, allant du traitement du langage naturel à la vision par ordinateur et au traitement du signal, ce chapitre met en lumière l'impact révolutionnaire des transformers dans le domaine de l'intelligence artificielle. En plongeant dans les détails de ces modèles révolutionnaires, nous découvrirons comment les transformers ont ouvert de nouvelles perspectives et redéfini les normes de l'apprentissage automatique moderne.

2.2 Définition des transformers




Figure 2-1 schéma d'un modèle transformers. [18]

La figure 2-1 montre le fonctionnement d'un modèle transformers

Les transformers, dans le domaine de l'apprentissage automatique, représentent une classe d'architectures de modèles neuronaux qui ont révolutionné la façon dont les machines traitent et comprennent les données séquentielles. Contrairement aux architectures récurrentes traditionnelles, les transformers ne sont pas limités par des dépendances séquentielles strictes, ce qui leur permet de capturer des relations complexes et à long terme au sein de séquences de données.

Leur introduction majeure a été publiée dans l'article "Attention is All You Need" par Vaswani et al. en 2017. Le mécanisme d'attention est l'élément clé des transformers, permettant au modèle de pondérer l'importance des différentes parties de la séquence lors du traitement de l'information. Cette approche d'attention permet aux transformers de gérer efficacement des séquences de données de longueur variable en mettant l'accent sur des parties spécifiques de la séquence en fonction de leur pertinence [16] [17].

2.3 Architecture des transformers

L'architecture du réseau neuronal des transformers se compose de plusieurs couches logicielles qui travaillent ensemble pour générer la sortie finale.

Entrée : Les données d'entrée sont généralement représentées sous forme de séquences de vecteurs, où chaque vecteur correspond à un élément de la séquence.

Codage de position : Avant d'entrer dans le réseau, chaque élément de la séquence est enrichi avec des informations de position. Cela peut être réalisé en ajoutant des vecteurs de position à chaque vecteur d'entrée ou en utilisant des encodages de position sinusoïdaux.

Auto-attention : À chaque couche du modèle, une attention multi-têtes est calculée sur la séquence d'entrée. Pour chaque tête d'attention, les poids sont calculés en comparant tous les éléments de la séquence entre eux, permettant au modèle de déterminer les relations les plus pertinentes entre les éléments.

Transformation positionnelle : Après l'auto-attention, les représentations des éléments de la séquence sont transformées à l'aide de réseaux de neurones entièrement connectés. Ces transformations incluent généralement des opérations telles que des multiplications matricielles et des activations non linéaires comme ReLU (Rectified Linear Unit).

Couches de normalisation : Après chaque opération de transformation, une couche de normalisation est souvent ajoutée pour stabiliser l'entraînement du réseau en normalisant les activations.

Connexions résiduelles : Pour faciliter l'apprentissage des réseaux profonds, des connexions résiduelles sont souvent utilisées. Ces connexions permettent aux informations de passer directement à travers les couches sans être altérées, ce qui facilite l'apprentissage des modèles profonds.

Empilement de couches : Les différentes étapes ci-dessus sont répétées dans plusieurs couches empilées verticalement. Chaque couche utilise les sorties de la couche précédente comme entrée, ce qui permet au modèle de capturer des informations complexes à différentes échelles.

Sortie : La sortie du modèle peut varier en fonction de la tâche spécifique. Par exemple, pour le traitement du langage naturel (NLP), la sortie peut être une séquence de tokens représentant une traduction, une classification ou une génération de texte.

Cette architecture permet aux transformers de traiter efficacement des données séquentielles complexes en capturant des dépendances à long terme et en adaptant leur représentation interne aux spécificités de la tâche à accomplir [19].

2.4 Entraînement des transformers

Les modèles Transformers sont souvent entraînés à l'aide de techniques d'optimisation telles que la descente de gradient stochastique (SGD) et des algorithmes plus récents comme Adam. Ils sont généralement pré-entraînés sur de grands ensembles de données non supervisées, puis fine-tunés sur des tâches spécifiques à l'aide de données supervisées [20].

2.5 Domaine d'utilisation

Les transformers sont utilisés dans une variété de domaines de l'intelligence artificielle et de l'apprentissage automatique, tels que :

Traitement du Langage Naturel (NLP) : Ils sont employés pour des tâches telles que la traduction automatique, la compréhension de texte, la génération de texte et l'analyse sentimentale.

Vision par Ordinateur : Des modèles comme ViT (Vision Transformer) ont démontré leur efficacité dans la représentation visuelle.

Traitement du Signal : Dans le domaine du traitement du signal, les transformers sont utilisés pour modéliser des séquences temporelles complexes. Par exemple, dans le traitement du signal ECG (électrocardiogramme), les transformers peuvent être employés pour détecter des anomalies cardiaques.

Recommandation : Ils sont adoptés pour améliorer les systèmes de recommandation en analysant des séquences d'interactions utilisateur, permettant ainsi de capturer des motifs temporels dans le comportement de l'utilisateur.

Biologie et Génomique : Utilisés pour la prédiction de structures protéiques, l'analyse de séquences génétiques et d'autres tâches liées à la biologie moléculaire.

Finance : Ils sont appliqués à la modélisation des séries temporelles, la prédiction des cours boursiers et l'analyse de données économiques [21] [25].

2.6 Les différents modèles de transformers




Figure 2-2 Architecture générale de BERT (Peltarion, 2020). [29]

La figure 2-2 explique en détail l'architecture du modèle BERT.

Les transformers sont largement utilisés dans l'industrie et la recherche pour une variété de tâches dans le traitement du langage naturel, la vision par ordinateur, la génération de texte et d'autres domaines de l'intelligence artificielle. Plusieurs modèles existent, tels que :

BERT (Bidirectional Encoder Representations from Transformers) : Développé par Google, BERT a révolutionné le domaine du NLP en étant pré-entraîné sur de vastes corpus de texte pour capturer les représentations contextuelles bidirectionnelles des mots.

GPT (Generative Pre-trained Transformer) : La série GPT, développée par OpenAI, se concentre sur la génération de texte. Elle utilise une architecture transformers pour générer des séquences de texte de manière cohérente et contextuellement appropriée.

XLNet : également développé par Google, étend les capacités de BERT en introduisant une approche permutationnelle pour le pré-entraînement. Cela

permet d'exploiter toutes les permutations possibles des mots dans une phrase pour mieux capturer les dépendances contextuelles.

RoBERTa (Robustly optimized BERT approach) : développé par Facebook, est une amélioration de BERT qui bénéficie de diverses techniques d'optimisation, telles que des durées d'entraînement plus longues, une augmentation des données, etc., pour améliorer les performances sur une gamme de tâches NLP.

T5 (Text-to-Text Transfer Transformer) : également développé par Google, adopte une approche unifiée pour différentes tâches NLP en les formulant toutes comme des tâches de génération de texte. Il peut être finement réglé pour des tâches spécifiques en fournissant des exemples d'entrée-sortie textuels.

ELECTRA :développé par Google, propose une approche innovante pour l'entraînement préalable en utilisant un modèle discriminatoire pour remplacer des mots par des faux dans le texte et en formant le modèle à les détecter. Cela permet une utilisation plus efficace des données et des ressources de calcul.

DistilBERT : Développé par Hugging Face, DistilBERT est une version allégée de BERT, conçue pour être plus rapide et plus légère tout en conservant une grande partie de sa puissance de modélisation.

ALBERT (A Lite BERT) : également développé par Google, vise à réduire le nombre de paramètres de BERT tout en maintenant ou même en améliorant ses performances. Il utilise une approche de partage de paramètres et une méthodologie d'entraînement spécifique pour atteindre cet objectif.

BART (Bidirectional and Auto-Regressive Transformers) : Développé par Facebook, BART est un modèle qui combine les caractéristiques des modèles auto-régressifs (comme GPT) et bidirectionnels (comme BERT) en utilisant une architecture transformer.

Ces modèles représentent une avancée significative dans le domaine des transformers, chacun ayant ses propres caractéristiques et applications spécifiques dans le domaine de l'intelligence artificielle [26].

	BERT	RoBERTa	CamemBERT	FlauBERT
Langue	Anglais	Anglais	Français	Français
Données d'entraînement	13 Go	160 Go	138 Go	71 Go
Objectifs de pré-entraînement	NSP et MLM	MLM	MLM	MLM
Nombre de paramètres	110 million	125 million	110 million	138/373 million
Tokenizer	WordPiece 30K	BPE 50K	SentencePiece 32K	BPE 50K
Stratégie de masquage	Statique + Masquage de sous-mots Dynamique + Masquage de sous-mots Dynamique + Masquage de mots entiers Dynamique + Masquage de sous-mots			

Figure 2-3 Comparaison entre les différentes variantes de BERT (Le et al., 2019). [29]

La figure 2-3 montre plusieurs variantes de BERT avec des comparaisons entre elles.

2.7 Avantage des transformers sur les autres modèles

Les transformers offrent plusieurs avantages significatifs par rapport à d'autres architectures de modèles dans le domaine de l'apprentissage automatique, en particulier pour le traitement du langage naturel (NLP) :

Modélisation des relations à longue distance : Les transformers captent les dépendances à long terme dans les séquences grâce à leur mécanisme d'attention. Cela leur permet de donner plus de poids aux éléments importants sur de longues distances, ce qui est crucial pour des tâches comme la traduction automatique et la génération de texte.

Parallélisme efficace : Contrairement aux réseaux de neurones récurrents (RNN) qui traitent les données séquentiellement, les transformers peuvent traiter les éléments de manière parallèle. Cela les rend plus efficaces pour le traitement de grands ensembles de données et pour l'entraînement sur des systèmes distribués.

Gestion efficace des dépendances non linéaires : Les transformers sont capables de modéliser efficacement les relations complexes et subtiles entre les

éléments de la séquence, ce qui se traduit par de meilleures performances dans des tâches telles que la compréhension du langage naturel et la génération de texte.

Transférabilité : Les modèles transformers pré-entraînés sur de vastes ensembles de données textuelles montrent une grande transférabilité dans une variété de tâches NLP. Ils peuvent être fine-ajustés pour des tâches spécifiques avec des jeux de données plus petits, réduisant ainsi le besoin de données étiquetées et le temps d'entraînement.

Évitement des problèmes de vanishing gradient : Contrairement aux RNN qui peuvent rencontrer des problèmes de vanishing gradient sur de longues séquences, les transformers sont moins sensibles à ce problème grâce à leur mécanisme d'attention et à leur capacité à traiter efficacement les dépendances à long terme.

Facilité d'implémentation : Les architectures de transformers sont souvent plus simples à implémenter que les RNN, en raison de leur parallélisme plus facile à exploiter et des implémentations pré-construites disponibles dans des bibliothèques comme TensorFlow et PyTorch.

Scalabilité : Les transformers peuvent facilement être adaptés à des modèles plus grands grâce à leur architecture modulaire. Des modèles comme GPT-3 d'OpenAI utilisent des centaines de milliards de paramètres, ce qui leur permet de capturer des relations complexes et d'obtenir des performances exceptionnelles dans diverses tâches.

Interprétabilité : Les mécanismes d'attention des transformers offrent une certaine interprétabilité du modèle en indiquant quelles parties de la séquence ont été les plus importantes pour les prédictions ou les générations. Cela est précieux dans des domaines où la transparence du modèle est cruciale, comme la santé ou le droit [22] [23].

2.8 Défis des transformers

Bien qu'ils aient révolutionné de nombreux domaines de l'apprentissage automatique, les transformers sont confrontés à plusieurs défis :

Longues séquences : Les transformers peuvent rencontrer des difficultés à gérer efficacement de très longues séquences en raison de contraintes de mémoire et de calcul. Cela limite leur capacité à capturer les dépendances à très long terme dans les données, ce qui peut être un inconvénient pour certaines tâches nécessitant une compréhension approfondie du contexte.

Généralisation hors distribution : Les transformers ont tendance à surapprendre les caractéristiques spécifiques du corpus d'entraînement et peuvent avoir du mal à généraliser correctement à des données qui diffèrent significativement de celles sur lesquelles ils ont été entraînés. Cela peut poser un défi pour les applications où les données d'entraînement sont limitées ou non représentatives de la distribution réelle des données.

Explication des prédictions : Les transformers sont souvent perçus comme des "boîtes noires", ce qui rend difficile l'explication des décisions prises par ces modèles, notamment dans des contextes où la transparence et l'interprétabilité sont cruciales, comme dans les soins de santé ou le droit.

Robustesse aux données bruitées : Les transformers peuvent être sensibles aux données bruitées ou mal étiquetées, ce qui peut entraîner des performances dégradées ou des prédictions erronées. Assurer la robustesse des transformers face à des données de qualité variable reste un défi.

Éviter le biais et la discrimination : Comme tous les modèles d'apprentissage automatique, les transformers peuvent être sujets au biais et à la discrimination, reproduisant ainsi les préjugés présents dans les données d'entraînement. Il est crucial de mettre en œuvre des mécanismes pour détecter et atténuer ces biais afin de garantir des prédictions justes et équitables [24] [27] [28].

2.9 Conclusion

Depuis son lancement en 2017, l'architecture Transformer a bouleversé le secteur de l'intelligence artificielle. Le Transformer a permis des progrès remarquables dans des domaines tels que la traduction automatique, la génération de texte et la reconnaissance d'images, grâce à sa capacité à traiter efficacement de grandes quantités de données et à capturer les dépendances à long terme.

Toutefois, cette technologie prometteuse présente également des obstacles à surmonter, tels que les coûts de calcul, les risques de biais dans les données d'entraînement et l'interprétabilité des modèles. La recherche et le développement sont indispensables pour surmonter ces obstacles et tirer pleinement parti du potentiel de l'architecture Transformer.

Dans le prochain chapitre, nous nous concentrerons sur des articles portant sur l'utilisation des transformers pour le traitement des ECG, afin de mieux comprendre leur fonctionnement dans ce domaine.

Chapitre 3 Etat de l'art

3.1 Introduction

L'électrocardiographie (ECG) est une technique fondamentale en cardiologie, fournissant des informations cruciales sur l'activité électrique du cœur. Avec les avancées dans le domaine de l'intelligence artificielle, notamment l'émergence des transformers, de nouvelles approches ont été explorées pour analyser les signaux ECG de manière plus efficace et précise. Dans cet état de l'art, nous examinerons l'utilisation des transformers dans le domaine de l'ECG, mettant en lumière les travaux de recherche récents qui exploitent cette technologie pour des tâches telles que la détection des battements cardiaques et la classification des arythmies.

3.2 Travaux connexes

Shuaicong Hu , Wenjie Cai , Tijie Gao , and Mingjie Wang présentent un modèle hybride de transformateur pour détecter l'apnée du sommeil obstructive (OSA) en utilisant un électrocardiogramme à une seule dérivation, impliquant un mécanisme d'auto-attention. L'objectif de ce modèle est d'améliorer la détection de l'OSA en associant des éléments clés extraits de l'ECG à un mécanisme d'auto-attention afin de prédire de manière précise la présence de l'OSA. Les caractéristiques multiperspectives des signaux d'entrée sont extraites par le modèle en utilisant un bloc MPCA, puis encodées à l'aide de blocs transformateurs avec un mécanisme d'auto-attention. Les résultats expérimentaux ont démontré une grande précision de classification et une performance supérieure par rapport aux algorithmes existants, ce qui laisse entendre que ce modèle pourrait être une solution précise et pratique pour détecter cliniquement l'OSA [30].

Genshen Yan, Shen Liang, Fan Liu, Yanchun Zhang proposent un modèle de classification des battements de cœur qui utilise le Transformer, une architecture de séquence à séquence, en combinant des caractéristiques temporelles avec des caractéristiques apprises par le Transformer afin de mieux comprendre les motifs rythmiques présents dans les signaux ECG. Les intervalles RR ont également été employés afin d'intégrer des données morphologiques et temporelles, et les couches de désactivation ont été remplacées par des couches de normalisation de lot afin d'éviter

tout surajustement. Dans les expériences menées sur la base de données MIT-BIH, leur modèle a démontré des résultats supérieurs à la plupart des méthodes de pointe [31].

Behnam Behinaein, Anubhav Bhatti, Dirk Rodenburg, Paul Hungler et Ali Etemad proposent un réseau neuronal profond basé sur des couches convolutionnelles et un mécanisme de transformer pour détecter le stress à partir des signaux ECG. Leur approche est end-to-end, ne nécessite pas de caractéristiques fabriquées à la main et peut apprendre des représentations robustes avec seulement quelques blocs convolutionnels et le composant transformer [32].

Jian Guan , Wenbo Wang , Pengming Feng , Xinxin Wang , Wenwu Wang ont proposé une nouvelle méthode appelée Low-Dimensional Denoising Embedding Transformer (LDTF) pour la classification des signaux ECG. Cette méthode combine un embedding à faible dimension avec un modèle de transformer pour améliorer la classification des signaux ECG tout en préservant les informations temporelles propres aux signaux [33].

3.3 Tableau comparatifs

auteurs	Dataset	Objectifs	Méthode	résultats
Shuaicong Hu, Wenjie Cai , Tijie Gao , and Mingjie Wang	apnée-ECG	développer un modèle hybride de transformateur pour la détection de l'apnée du sommeil obstructive (OSA) en utilisant un électrocardiogramme à une seule dérivation.	"modèle hybride de transformateur basé sur un mécanisme d'auto-attention" pour la détection de l'apnée du sommeil obstructive (OSA) en utilisant un électrocardiogramme à une seule dérivation	Précision de classification par segment : 91% Aire sous la courbe ROC (AUC) : 96% Précision de classification par enregistrement : 100% Erreur absolue moyenne (MAE) : 2.71

Genshen Yan, Shen Liang, Fan Liu, Yanchun Zhang	MIT-BIH	proposer un modèle basé sur le Transformer pour la classification des battements de cœur dans les signaux ECG en intégrant des caractéristiques temporelles et morphologiques pour améliorer les performances de classification des arythmies cardiaques	modèle Transformer, qui est un modèle séquence à séquence avec une architecture relativement simple et un degré élevé de parallélisme	une précision de 95,09% une sensibilité de 94,12% Lorsqu'il a été testé sur un ensemble de données augmenté avec des données plus équilibrée : une précision de 99,74% une sensibilité de 99,74%
Behnam Behinaein, Anubhav Bhatti, Dirk Rodenburg, Paul Hungler et Ali Etemad.	WESAD SWELL-KW	modèle basé sur des architectures convolutionnelles et transformer pour détecter le stress à partir des signaux ECG. Les auteurs cherchent démontrer que leur approche end-to- end, qui ne nécessite pas de caractéristiques fabriquées à la main, peut apprendre des représentations robustes avec seulement quelques blocs convolutionnels et le composant transformer. L'objectif est d'améliorer la détection du stress à partir des signaux ECG en utilisant des méthodes d'apprentissage profond	un réseau end-to-end comprenant trois sous-réseaux : un sous-réseau convolutionnel, un encodeur transformers et un sous-réseau entièrement connecté	WESAD : Précision (Accuracy) : 80.4% Score F1 : 69.7% Après un ajustement fin (fine-tuning) avec seulement 10% des données spécifiques à l'utilisateur : Précision de 91.1% et Score F1 de 83.3% .SWELL-KW : Précision : 58.1% Score F1 : 58.8% Après un ajustement fin avec seulement 10% des données spécifiques à l'utilisateur : Précision de 71.6% et Score F1 de 74.2%

Jian Guan , Wenbo Wang , Pengming Feng, Xinxin Wang , Wenwu Wang	MIT-BIH	proposer une nouvelle méthode de classification des signaux ECG, appelée "low-dimensional denoising embedding transformer (LDTF)". Cette méthode combine deux composants, à savoir le "low-dimensional denoising embedding (LDE)" et l'apprentissage par transformateur. L'approche vise à obtenir une représentation en basse dimension du signal dans le domaine temps-fréquence tout en préservant ses informations temporelles, puis à utiliser l'apprentissage par transformateur pour obtenir une structure plus profonde et plus étroite avec moins de paramètres d'entraînement que celle du FusingTF. L'efficacité et les performances supérieures de cette méthode sont démontrées à travers des expériences menées sur le dataset MIT-BIH, comparativement aux méthodes de pointe existantes.	Low-Dimensional Denoising Embedding (LDE) Transformer Learning	LDTF : Rappel moyen de 98.39% et Précision moyenne de 98.41% WCNN : Rappel moyen de 93.55% et Précision moyenne de 96.72% MWFE : Rappel moyen de 96.86% et Précision moyenne de 98.92% Ad-CNN : Rappel moyen de 93.90% et Précision moyenne de 98.90%
---	----------------	---	--	---

Tableau 3-1 tableau explicatif des travaux étudiés

3.4 Conclusion :

L'utilisation des transformers dans l'analyse des signaux ECG offre des perspectives prometteuses pour améliorer la détection des battements cardiaques et la classification des arythmies. Les différentes approches proposées par les chercheurs, telles que le modèle hybride de transformer pour la détection de l'apnée du sommeil, l'intégration des caractéristiques temporelles avec le modèle Transformer pour la classification des battements de cœur, et l'approche end-to-end basée sur des couches convolutionnelles et un mécanisme de transformer pour détecter le stress à partir des signaux ECG, démontrent l'efficacité et la supériorité de ces méthodes par rapport aux approches traditionnelles. Ces avancées ouvrent la voie à des applications cliniques plus précises et efficaces dans le domaine de la santé cardiovasculaire, offrant ainsi de nouvelles perspectives pour améliorer la prise en charge des patients.

Dans le prochain chapitre, nous proposerons notre propre modèle pour le traitement des signaux ECG avec les transformers.

Chapitre 4 Implémentation et Évaluation du Modèle

4.1 Introduction

Ce chapitre explore en détail la mise en place, l'entraînement et l'évaluation de notre modèle Transformer pour la détection des anomalies dans les signaux ECG. Cette étude repose sur les bases de données MIT-BIH Normal Sinus Rhythm et MIT-BIH Arrhythmia. Les enregistrements ECG de ces bases de données sont essentiels pour le développement et la validation des algorithmes de détection et de classification des rythmes cardiaques. Nous décrirons les différentes phases de prétraitement des données, l'architecture du modèle, le processus d'apprentissage et les résultats obtenus.

4.2 Environnement utilisé

Pour notre approche, nous avons utilisé l'environnement de Kaggle qui est une plateforme en ligne dédiée aux data scientists et aux professionnels de l'analyse de données. Lancée en 2010 et rachetée par Google en 2017, elle propose plusieurs fonctionnalités clés :

Compétitions de Data Science : Kaggle est surtout connue pour ses compétitions où des entreprises et des organisations posent des défis de machine learning et d'analyse de données. Les participants peuvent soumettre leurs solutions et concourir pour des prix en argent, des stages ou d'autres opportunités.

Datasets : La plateforme offre une vaste collection de datasets publics gratuits que les utilisateurs peuvent explorer, analyser et utiliser pour leurs projets. Ces datasets couvrent une multitude de domaines et sujets.

Kernels (Notebooks) : Kaggle permet aux utilisateurs de créer et de partager des notebooks Jupyter, ce qui facilite le prototypage et le partage de solutions. Ces notebooks peuvent inclure du code Python, des visualisations de données, et des explications détaillées.

Apprentissage et Formations : Kaggle propose des cours interactifs gratuits couvrant des sujets tels que Python, le machine learning, l'analyse de données,

et bien plus encore. Ces cours sont conçus pour aider les débutants à développer leurs compétences en data science.

Communauté : Avec une communauté active de millions de membres, Kaggle est un lieu où les data scientists peuvent partager des idées, collaborer sur des projets, poser des questions, et apprendre des autres.

Kaggle est donc une ressource précieuse pour les data scientists de tous niveaux, offrant des opportunités d'apprentissage, de compétition et de collaboration dans le domaine de la science des données et du machine learning [34].

4.3 Principale étapes de notre approche




Figure 4-1 étapes de l'approche proposée

La figure 4-1 montre en détail les différentes étapes de notre approche proposée.

4.4 Données Utilisées (dataset)

4.4.1 MIT-BIH Normal Sinus Rhythm Database

En collaboration avec l'hôpital Beth Israël (BIH), le Massachusetts Institute of Technology (MIT) a développé la base de données MIT-BIH Normal Sinus Rhythm. Cette base de données contient des enregistrements électrocardiographiques de patients présentant des rythmes sinusoïdaux normaux.

Ces enregistrements sont couramment utilisés comme référence pour les études visant à identifier les anomalies et à catégoriser les rythmes cardiaques. Les enregistrements typiques de la base de données MIT-BIH Normal Sinus Rhythm durent 24 heures et impliquent des adultes ordinaires, âgés de 20 à 50 ans. Les données sont généralement disponibles au format '.dat', accompagnées de fichiers de métadonnées '.hea' décrivant les enregistrements.

Cette base de données a été largement utilisée pour développer et valider des algorithmes de détection d'arythmies telles que les contractions ventriculaires prématurées (PVC) et la fibrillation auriculaire. Elle a servi de référence pour l'entraînement de modèles de machine learning et de deep learning pour la classification des rythmes cardiaques. Elle est fréquemment utilisée comme benchmark pour évaluer les performances des nouveaux algorithmes de classification d'ECG [36].

4.4.2 MIT-BIH Arrhythmia Database

Le MIT a développé la base de données MIT-BIH Arrhythmia Database en partenariat avec l'hôpital Beth Israël (BIH). Cette base de données contient des données ECG de patients souffrant de différentes formes d'arythmies et est l'un des ensembles de données les plus utilisés pour l'analyse des arythmies cardiaques. Ce corpus est une référence classique pour la recherche sur la détection d'arythmies et est couramment utilisé pour entraîner et évaluer des algorithmes de classification d'ECG.

Les enregistrements typiques de la base de données MIT-BIH Arrhythmia durent de 30 minutes à 2 heures. Ils incluent des patients présentant différents types d'arythmies, assurant une représentation équilibrée des diverses conditions. Les données sont disponibles au format '.dat' pour les signaux ECG bruts et '.atr' pour les annotations d'arythmies.

Des algorithmes de détection d'arythmies comme les contractions ventriculaires prématurées (PVC) et la fibrillation auriculaire ont été développés et validés à l'aide de la base de données MIT-BIH Arrhythmia Database. Cette base de données a également été utilisée pour entraîner des modèles de machine learning et de deep learning destinés à la classification des rythmes cardiaques. En outre, elle est fréquemment utilisée comme référence pour comparer les performances des nouveaux algorithmes de classification d'ECG [38].

4.5 Prétraitement des Données

Il est essentiel de procéder au prétraitement des données ECG afin de convertir les signaux bruts en un format adapté pour l'entraînement du modèle.

4.5.1 Chargement des Données Normales

```
normal_base_path = '/kaggle/input/mitbih-normal-sinus-rh
normal_files = [f.split('.')[0] for f in os.listdir(norm
def load_normal_ecg(file):
    record = wfdb.rdrecord(normal_base_path + file)
    signal = record.p_signal[:, 0]
    scaler = StandardScaler()
    signal = scaler.fit_transform(signal.reshape(-1, 1))
    return signal
normal_signals = [load_normal_ecg(file) for file in norm
```

Figure 4-2 échantillon du code utilisé pour le premier dataset

La **figure 4-2** montre un bref échantillon du code utilisé pour charger le dataset normal sinus.

La base de données MIT-BIH Normal Sinus Rhythm Database fournit des données sur les rythmes sinusoïdaux normaux. Chaque fichier de cette base contient des enregistrements ECG de patients présentant des rythmes cardiaques normaux. Pour préparer ces données, nous avons d'abord collecté tous les fichiers disponibles dans le répertoire spécifié. Ensuite, nous avons extrait le signal ECG de chaque fichier en utilisant la première dérivation, puis nous l'avons standardisé. La standardisation implique de transformer le signal de manière à ce qu'il ait une moyenne de zéro et un écart-type de un, ce qui est essentiel pour améliorer la convergence du modèle lors de l'entraînement.

4.5.2 Segmentation des Signaux Normaux

```
def segment_signal(signal, window_size=200):
    segments = []
    for i in range(0, len(signal), window_size):
        segment = signal[i:i + window_size]
        if len(segment) == window_size:
            segments.append(segment)
    return np.array(segments)

normal_segments = [segment_signal(signal) for signal in normal_signals]
normal_segments = [seg.reshape(seg.shape[0], seg.shape[1]) for seg in normal_segments]
normal_labels = [np.zeros(seg.shape[0]) for seg in normal_segments]
```

Figure 4-3 échantillon du code utilisé pour segmenter le premier dataset

La figure 4-3 montre un bref échantillon du code utilisé pour segmenter le dataset normal sinus.

Une fois que les signaux ECG ont été chargés et standardisés, ils sont divisés en fenêtres de taille fixe de 200 échantillons. Cette segmentation permet de diviser un signal long en plusieurs segments plus courts et de taille uniforme, ce qui facilite le traitement par

le modèle. Ensuite, chaque segment est préparé pour correspondre à la structure requise par le modèle, et des étiquettes de classe 0 (pour normal) sont assignées à chaque segment.

4.5.3 Chargement des Données Anormales

```
anormal_base_path = '/kaggle/input/mit-bih-arrhythmia-da

anormal_files = [f for f in os.listdir(anormal_base_path

def load_anormal_ecg(file):
    df = pd.read_csv(anormal_base_path + file)
    print(f"Colonnes disponibles dans {file}: {df.columns}
    if 'MLII' in df.columns:
        signal = df['MLII'].values
    elif 'V5' in df.columns:
        signal = df['V5'].values
    else:
        raise KeyError(f"La colonne de signal n'est pas
    scaler = StandardScaler()
    signal = scaler.fit_transform(signal.reshape(-1, 1))
    return signal
```

Figure 4-4 échantillon du code utilisé pour le deuxième dataset

La figure 4-4 montre un bref échantillon du code utilisé pour charger le dataset arrhythmia.

Les enregistrements ECG de patients souffrant de différentes arythmies sont extraits de la base de données MIT-BIH Arrhythmia Database. Tout d'abord, nous avons répertorié tous les fichiers disponibles au format CSV pour ces données. Ensuite, nous avons enregistré le signal ECG pour chaque fichier à partir de la colonne appropriée (MLII ou V5), puis nous avons ajusté le signal de la même manière que pour les données normales

4.5.4 Segmentation des Signaux Anormaux

Les signaux anormaux sont également segmentés en fenêtres de 200 échantillons. Chaque segment est mis en forme de la même manière que pour les signaux normaux, et des étiquettes de classe 1 (pour anormal) sont assignées à chaque segment.

4.5.5 Combinaison des Données

```
Combiner les segments et les labels des deux datasets  
ll_segments = np.concatenate(normal_segments + anormal_seg  
ll_labels = np.concatenate(normal_labels + anormal_labels
```

Figure 4-5 échantillon du code utilisé pour la combinaison

La figure 4-5 montre un bref échantillon du code utilisé pour la combinaison des ensembles de données.

Un ensemble de données unifié est créé en combinant les segments et les labels des deux ensembles de données (normaux et anormaux) après la segmentation. Cela nécessite de regrouper les segments et les labels des données normales et anormales en une seule entité.

4.5.6 Division des Données

```
# Diviser les données en ensembles d'entraînement (80%)  
train_segments, test_segments, train_labels, test_labels,  
    all_segments, all_labels, test_size=0.2, random_state=42  
)  
  
# Créer les DataLoader  
train_dataset = TensorDataset(torch.tensor(train_segments),  
test_dataset = TensorDataset(torch.tensor(test_segments),  
train_loader = DataLoader(train_dataset, batch_size=32,  
test_loader = DataLoader(test_dataset, batch_size=32)
```

Figure 4-6 échantillon du code utilisé pour la division

La figure 4-6 montre un bref échantillon du code utilisé pour la division des données.

Finalement, les informations regroupées sont réparties en ensembles d'entraînement (80 %) et de test (20 %). La stratification de cette division permet de maintenir la proportion des classes dans les deux ensembles. Cela assure une représentation équilibrée des classes normales et anormales dans les ensembles d'entraînement et de test, ce qui est

essentiel pour obtenir des évaluations de performance fiables lors de l'entraînement et du test du modèle.

4.6 Architecture du Modèle




Figure 4-7 schéma explicatif de l'architecture de notre modèle.

La figure 4-7 montre un schéma qui explique les différentes couches du modèle proposé.

4.6.1 Couche Linéaire Initiale

L'étape initiale de l'architecture du modèle implique d'augmenter la taille du signal ECG. Une couche linéaire effectue cette transformation en projetant les données d'entrée dans un espace de dimension supérieure. Le but est d'adapter les données aux encodeurs du Transformer afin de faciliter la capture des caractéristiques complexes du signal.

4.6.2 Encodeurs Transformer

Le modèle est basé sur deux niveaux d'encoder Transformer. Il y a plusieurs sous-couches dans chaque couche d'encoder, telles qu'une couche d'attention multi-tête et une couche de réseau de neurones feedforward. Les transformateurs ont été développés dans le but de détecter les liens temporels et les dépendances à long terme présents dans les signaux ECG. Grâce à l'attention multi-tête, le modèle peut se focaliser simultanément sur plusieurs parties du signal, ce qui améliore sa capacité à repérer des anomalies ou des caractéristiques spécifiques dans les données.

4.6.3 Couche de Sortie

Les représentations transformées par les encodeurs sont prises en compte dans la couche de sortie du modèle, qui génère une prédiction finale. Puisque la tâche implique une classification binaire (normale ou anormale), la couche de sortie comprend un seul neurone avec une activation spécifique pour la classification binaire.

4.7 Implémentation du Modèle

Le modèle est initialisé avec des paramètres spécifiques :

Dimension d'entrée : Correspond à la dimension des segments de signal après prétraitement.

Nombre de couches : Deux couches d'encoder pour capturer des relations complexes dans les signaux.

Nombre de têtes d'attention : Deux têtes d'attention pour permettre au modèle de se concentrer sur différentes parties du signal simultanément.

Dimension cachée : 256 unités pour les réseaux de neurones feedforward dans chaque couche d'encoder.

Dimension de sortie : Un neurone pour la classification binaire.

Dimension augmentée : La dimension dans laquelle les données sont projetées par la couche linéaire initiale.

4.8 Entraînement et Évaluation

Le modèle ECGTransformer a été entraîné en utilisant l'optimiseur Adam et la fonction de perte BCEWithLogitsLoss. Voici une explication détaillée du processus d'entraînement et d'évaluation.

4.8.1 Initialisation de la Perte et de l'Optimiseur

La fonction de perte utilisée est la Binary Cross-Entropy with Logits Loss (BCEWithLogitsLoss). Cette fonction combine une couche de sigmoïde et la perte de cross-entropy, ce qui est adapté pour les tâches de classification binaire.

L'optimiseur choisi est Adam, un algorithme d'optimisation stochastique basé sur l'estimation adaptative des moments d'ordre inférieur. Adam est populaire pour ses bonnes performances sur une large gamme de problèmes d'apprentissage.

4.8.2 Boucle d'Entraînement

Le modèle est entraîné pendant 10 époques. Une époque représente un passage complet sur l'ensemble des données d'entraînement.

À chaque époque, le modèle passe en mode entraînement, ce qui active le calcul des gradients et la mise à jour des paramètres du modèle.

Pour chaque lot de données dans le DataLoader d'entraînement :

1. Les gradients sont remis à zéro pour éviter l'accumulation des gradients des étapes précédentes.
2. Les données d'entrée (segments de signaux ECG) sont passées à travers le modèle pour obtenir les prédictions.
3. La perte est calculée en comparant les prédictions aux étiquettes réelles.
4. La rétropropagation est effectuée pour calculer les gradients de la perte par rapport aux paramètres du modèle.
5. Les paramètres du modèle sont mis à jour en utilisant l'optimiseur Adam.
6. La perte pour le lot actuel est ajoutée au total de la perte pour cette époque.

À la fin de chaque époque, la perte moyenne est calculée et affichée. Cela permet de suivre la convergence du modèle au fil des époques.

```

num_epochs = 10
for epoch in range(num_epochs):
    model.train()
    running_loss = 0.0
    for X_batch, y_batch in train_loader:
        optimizer.zero_grad()
        outputs = model(X_batch)
        loss = criterion(outputs.squeeze(), y_batch)
        loss.backward()
        optimizer.step()
        running_loss += loss.item()
    average_loss = running_loss / len(train_loader)
    print(f'Epoch {epoch+1}/{num_epochs}, Loss: {average

```

Figure 4-8 échantillon du code utilisé pour l'entraînement

La figure 4-8 montre un bref échantillon du code utilisé pour l'entraînement du modèle.

4.9 Évaluation du Modèle

```

model.eval()
all_preds = []
all_labels = []

with torch.no_grad():
    for X_batch, y_batch in test_loader:
        outputs = model(X_batch)
        predicted = torch.round(torch.sigmoid(outputs.squeeze()).numpy())
        all_preds.extend(predicted)
        all_labels.extend(y_batch.numpy())

accuracy = accuracy_score(all_labels, all_preds)
f1 = f1_score(all_labels, all_preds)
print(f'Accuracy: {accuracy * 100:.2f}%')
print(f'F1 Score: {f1:.4f}')

```

Figure 4-9 échantillon du code utilisé pour l'évaluation

La figure 4-9 montre un bref échantillon du code utilisé pour évaluer le modèle.

4.9.1 Mode d'évaluation

Après l'entraînement, le modèle est mis en mode évaluation. Cela désactive certaines fonctionnalités comme le dropout et la mise à jour des gradients, ce qui est nécessaire pour une évaluation correcte

4.9.2 Prédiction et calcul métrique

Le modèle est évalué sur l'ensemble de test. Pour chaque lot de données dans le DataLoader de test :

Les données d'entrée sont passées à travers le modèle pour obtenir les prédictions.

Les prédictions sont converties en valeurs binaires (0 ou 1) en appliquant une fonction sigmoïde suivie d'un arrondi.

Les prédictions et les étiquettes réelles sont stockées pour le calcul des métriques.

4.9.3 Les métriques de performance calculées sont

Précision : La proportion de prédictions correctes parmi le total des prédictions. Elle est calculée en comparant les prédictions binaires aux étiquettes réelles

F1 Score : La moyenne harmonique de la précision et du rappel. Elle est particulièrement utile pour évaluer les modèles de classification sur des données déséquilibrées.

4.9.4 Affichage des Résultats

La précision et le F1 Score sont calculés et affichés. Ces métriques fournissent une évaluation quantitative de la performance du modèle sur l'ensemble de test, permettant de comprendre son efficacité à différencier les signaux ECG normaux et anormaux.

4.10 Résultats

4.10.1 Score global

Nous présentons les résultats obtenus par notre modèle basé sur les Transformers pour la détection des anomalies dans les signaux ECG. L'objectif est d'évaluer les performances du modèle à travers des métriques standard telles que la précision, le rappel, le F1-score, et le support pour chaque classe (normale et anormale).

Pour le modèle, nous avons obtenu un taux de réussite de 96 % et un score F1 de 88%.

Accuracy: 96.94%
F1 Score: 0.8893

Figure 4-10 score global de notre modèle

La figure 4-10 La figure 4-10 montre le score global de notre modèle.

4.10.2 Performance

La figure 4-11 ci-dessous résume les performances du modèle pour les deux classes : normale (0.0) et anormale (1.0)

	precision	recall	f1-score	support
0.0	0.99	0.98	0.98	201596
1.0	0.86	0.92	0.89	31200
accuracy			0.97	232796
macro avg	0.93	0.95	0.94	232796
weighted avg	0.97	0.97	0.97	232796

Figure 4-11 performances du modèle

4.10.3 Analyse des résultats

Classe 0.0 (Normale) : La précision de 0.99 indique que le modèle identifie correctement presque tous les battements cardiaques normaux. Le rappel de 0.98 montre que le modèle détecte la majorité des battements normaux.

Classe 1.0 (Anormale) : La précision de 0.86 est légèrement inférieure, ce qui signifie que quelques battements normaux peuvent être incorrectement classés comme anormaux. Cependant, le rappel de 0.92 montre une bonne capacité de détection des anomalies.

Le F1-score de 0.98 pour la classe normale et de 0.89 pour la classe anormale indique un bon équilibre entre la précision et le rappel pour les deux classes. Ces scores élevés montrent que le modèle est performant pour distinguer entre les battements cardiaques normaux et anormaux.

Le support indique le nombre de véritables échantillons pour chaque classe dans l'ensemble de test. Un nombre élevé de supports (201596 pour les normaux et 31200 pour les anormaux) renforce la fiabilité des résultats obtenus.

4.10.4 Métriques Globales

Les métriques globales suivantes résument les performances du modèle :

Précision globale : 0.97

Rappel : 0.97

F1-Score : 0,88

Ces métriques globales montrent une performance équilibrée et robuste du modèle sur l'ensemble des données testées.

4.11 La Matrice de Confusion

La matrice de confusion est un outil essentiel pour évaluer les performances d'un modèle de classification. Elle permet de visualiser les performances du modèle en termes de nombre de prédictions correctes et incorrectes pour chaque classe. Cette section

explique la matrice de confusion et comment elle a été utilisée pour évaluer notre modèle de détection d'anomalies dans les signaux ECG.




Figure 4-12 matrice de confusion de notre approche

La figure 4-12 représente la matrice de confusion de notre modèle de détection d'anomalies dans les signaux ECG.

Dans le tableau suivant vous trouverez une explication détaillée de cette matrice :

	Prédiction Positive (1)	Prédiction Négative (0)
Classe Positive (1)	True Positive (TP) = 28580	False Negative (FN) = 2620
Classe Négative (0)	False Positive (FP) = 4498	True Negative (TN) = 197098

Tableau 4-1 explication de la matrice

4.11.1 Interprétation de la Matrice

True Positives (TP) : 28580

Nombre de fois où le modèle a correctement prédit une anomalie lorsque celle-ci était présente.

True Negatives (TN) : 197098

Nombre de fois où le modèle a correctement prédit un signal normal lorsqu'il était réellement normal.

False Positives (FP) : 4498

Nombre de fois où le modèle a prédit une anomalie alors que le signal était normal (fausse alarme).

False Negatives (FN) : 2620

Nombre de fois où le modèle a prédit un signal normal alors qu'il y avait une anomalie (anomalies manquées).

4.11.2 Calcul des Métriques de Performance

À partir de cette matrice de confusion, nous pouvons calculer plusieurs métriques de performance :

Précision (Precision) : La proportion des prédictions positives qui sont correctes.

$$\text{Précision} = \frac{TP}{TP + FP} = \frac{28580}{28580 + 4498} \approx 0.86$$

Équation 1 calcul de la précision

Rappel (Recall) : La proportion des véritables positifs qui sont correctement identifiés par le modèle.

$$\text{Rappel} = \frac{TP}{TP + FN} = \frac{28580}{28580 + 2620} \approx 0.92$$

Équation 2 calcul du rappel

F1-Score : La moyenne harmonique de la précision et du rappel

$$\text{F1-Score} = \frac{2 \times \text{Précision} \times \text{Rappel}}{\text{Précision} + \text{Rappel}} \approx \frac{2 \times 0.86 \times 0.92}{0.86 + 0.92} \approx 0.89$$

Équation 3 calcul du F1-Score

Exactitude (Accuracy) : La proportion de toutes les prédictions qui sont correctes.

$$\text{Exactitude} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{28580 + 197098}{28580 + 197098 + 4498 + 2620} \approx 0.97$$

Équation 4 calcul de l'exactitude

4.12 La matrice de corrélation :

La matrice de corrélation est un outil statistique utilisé pour quantifier la relation linéaire entre plusieurs variables. Elle est particulièrement utile pour comprendre comment les variables d'un dataset interagissent entre elles. Dans cette section, nous allons expliquer l'importance de la matrice de corrélation dans le contexte de l'analyse des signaux ECG et comment elle peut être interprétée.




Figure 4-13 La matrice de corrélation

La figure 4-13 montre une matrice de corrélation pour un sous-ensemble de variables. Voici comment interpréter cette matrice :

Diagonale principale : Les éléments de la diagonale principale sont tous égaux à 1, car chaque variable est parfaitement corrélée avec elle-même.

Couleurs : Les couleurs représentent les valeurs des coefficients de corrélation. Généralement, les couleurs rouges indiquent des corrélations positives élevées, les couleurs bleues indiquent des corrélations négatives élevées, et les couleurs blanches représentent des corrélations proches de zéro.

4.13 La Courbe ROC et l'AUC

La courbe ROC (Receiver Operating Characteristic) est un outil essentiel pour évaluer la performance des modèles de classification, notamment dans le contexte des systèmes de détection d'anomalies. Elle illustre la capacité du modèle à distinguer entre les classes positives et négatives en traçant le taux de vrais positifs (TPR) contre le taux de faux positifs (FPR) à différents seuils de classification. L'aire sous la courbe ROC (AUC - Area Under the Curve) est une métrique qui résume cette performance en un seul nombre.




Figure 4-14 La courbe ROC

La courbe ROC est tracé en plaçant le TPR sur l'axe vertical et le FPR sur l'axe horizontal. Voici les définitions de ces termes :

Taux de Vrais Positifs (TPR) : Aussi appelé Sensibilité ou Rappel, il est défini comme la proportion des vrais positifs parmi les positifs réels.

$$TPR = \frac{TP}{TP + FN}$$

Équation 5 calcul du taux de Vrais Positifs

Taux de Faux Positifs (FPR) : Il est défini comme la proportion des faux positifs parmi les négatifs réels.

$$FPR = \frac{FP}{FP + TN}$$

Équation 6 calcul du taux de faux positifs

4.14 Interprétation de la Courbe ROC

L'image fournie montre une courbe ROC pour notre modèle de détection d'anomalies dans les signaux ECG. Voici comment interpréter cette courbe :

Courbe orange : Représente la performance du modèle à différents seuils. Une courbe qui s'approche du coin supérieur gauche indique une meilleure performance, car elle correspond à un TPR élevé et un FPR faible.

Ligne bleue en pointillés : Représente une classification aléatoire avec une AUC de 0.5. Toute courbe au-dessus de cette ligne indique une performance supérieure à une classification aléatoire.

Aire sous la courbe (AUC) : L'AUC est de 0.95, ce qui signifie que le modèle a une excellente capacité à distinguer entre les classes positives et négatives. Une AUC de 1.0 représente une classification parfaite, tandis qu'une AUC de 0.5 représente une classification aléatoire.

4.15 Conclusion

Dans ce chapitre, nous avons exploré en profondeur les performances de notre modèle de détection d'anomalies dans les signaux ECG, basé sur une architecture de Transformers. Les résultats obtenus montrent que notre modèle est capable de distinguer efficacement entre les signaux ECG normaux et anormaux, avec des métriques de performance élevées sur un ensemble de données de test robuste.

CONCLUSION

GENERALE &

PERSPECTIVES

Tout au long de notre travail, nous nous sommes intéressés aux signaux ECG, avons cherché à comprendre leur fonctionnement, à les déchiffrer et à connaître leur utilité. Nous avons également exploré les Transformers et montré le potentiel de ces modèles pour le traitement et l'analyse des signaux ECG. Nous avons commencé par lire des articles qui mettent en œuvre la capacité des Transformers dans le traitement des signaux ECG.

L'adoption de cette technologie innovante offre des perspectives prometteuses pour améliorer la précision des diagnostics cardiaques et la qualité des soins médicaux. Les résultats obtenus dans ce travail mettent en lumière les avantages significatifs des Transformers et ouvrent la voie à de futures recherches pour exploiter pleinement leur potentiel dans le domaine médical.

Notre approche a permis de développer un modèle qui classe les signaux ECG comme normaux ou anormaux. Les différentes étapes de ce travail ont contribué à construire une base solide de connaissances, à explorer les avancées technologiques et à valider expérimentalement l'efficacité des Transformers en obtenant un score de 0,88 et une précision de 96%.

Nous espérons que ce travail contribuera à l'avancement des technologies de diagnostic médical et inspirera d'autres chercheurs à poursuivre dans cette voie prometteuse. Comme perspectives, il serait intéressant d'explorer davantage l'optimisation des hyperparamètres des modèles Transformers pour améliorer encore leurs performances. Malgré leur complexité, le développement de versions plus légères et plus rapides pourrait rendre ces modèles plus accessibles pour des applications en temps réel et sur des dispositifs embarqués.

Les modèles développés pourraient être intégrés dans des systèmes de diagnostic assistés pour aider les médecins dans la détection précoce des anomalies cardiaques.

Bibliographie

- [1] Bayés de Luna, A. Électrocardiographie : les bases. Éditions Médecine-Sciences, 2012.
- [2] Arora, N., and B. Mishra. Origins of ECG and Evolution of Automated DSP Techniques: A Review. 2021.
- [3] Gamouri, Sabah. Analyse et Interprétation du Signal ECG. Thèse de doctorat, Université Badji Mokhtar-Annaba, Faculté des Sciences de l'Ingénierat, Département d'Electronique, 2018/2019.
- [4] Saritha, C., V. Sukanya, and Y. N. Murthy. "ECG Signal Analysis Using Wavelet Transforms." Bulgarian Journal of Physics 35, no. 1 (2008): 68-77.
- [5] Van Bommel, J. H., C. Zywietz, and J. A. Kors. "Signal Analysis for ECG Interpretation." Methods of Information in Medicine 29, no. 4, 1990.
- [6] Van Bommel, J. H., C. Zywietz, and J. A. Kors. "Signal Analysis for ECG Interpretation." Methods of Information in Medicine 29, no. 4 (1990): 317-329.
- [7] <https://fr.my-ekg.com/generalites-ecg/derivations-ecg.html>, (Consulté le 20 mars 2024).
- [8] <https://www.bhf.org.uk/information-support/tests/ecg>,). (Consulté le 22 mars 2024).
- [9] Celin, S., and K. Vasanth. "ECG Signal Classification Using Various Machine Learning Techniques." Journal of Medical Systems, vol. 42, no. 12, 2018.
- [10] https://www.researchgate.net/figure/Surface-ECGs-from-the-bedside-monitor-in-a-postoperative-pediatric-cardiac-patient-The_fig1_355779984, (Consulté le 22 mars 2024).
- [11] <https://www.nature.com/articles/s41572-020-0188-7> (Consulté le 21 mars 2024).
- [12] Gamouri, Sabah. Analyse et Interprétation du Signal ECG. Thèse de doctorat, Université Badji Mokhtar-Annaba, Faculté des Sciences de l'Ingénierat, Département d'Electronique, 2018/2019.

- [13] Celin, S., and Vasanth, K. "ECG Signal Classification Using Various Machine Learning Techniques." *Journal of Medical Systems* 42.12 (2018).
- [14] www.louvainmedical.be/fr/article/rappels-des-principes-fondamentaux-en-electrocardiographie, (Consulté le 21 mars 2024).
- [15] Gomes, J. A. "Signal Averaged Electrocardiography " (p. 51). New York, 1993.
- [16] Yvon, François. "Le modèle Transformer: un 'couteau suisse' pour le traitement automatique des langues." *Techniques de l'Ingénieur*. Université Paris-Saclay, CNRS, LISN, 2022.
- [17] Amatriain, Xavier, et al. "Transformer Models: An Introduction and Catalog." *arXiv*, 12 Feb. 2023.
- [18] Harsoor, S. "Transformer Model And variants of Transformer (ChatGPT)." *Medium*, 20 July 2023.
- [19] Xu, Y., et al. "Transformers in Computational Visual Media: A Survey." *Computational Visual Media*, vol. 8, no. 1, 2021.
- [20] Wang, P., et al. "Learning to Grow Pretrained Models for Efficient Transformer Training." *arXiv.org*, 2 March 2023.
- [21] Somma, B. "L'architecture Transformer : la révolution de l'IA." *Alberteam*, 16 April 2024.
- [22] Michel, Hugo. "Les modèles génératifs (Partie 3) | Les Transformers." *Hugo Michel*, 16 May 2024.
- [23] Tomorrow, A. F. "Pourquoi les Transformers sont-ils en train de remplacer les réseaux récurrents sur les données textuelles ?" *Théo Viel*, 6 January 2022.
- [24] Khan, Suleman, Muhammad Naseer, et al. "Transformers in Vision: A Survey." *ACM Computing Surveys*, vol. 54, no. 10s, 2022.
- [25] Khan, Suleman, Muhammad Naseer, et al. "Transformers in Vision: A Survey." *ACM Computing Surveys*, vol. 54, no. 10s, 2022.

- [26] <https://france.devoteam.com/paroles-dexperts/lstm-transformers-gpt-bert-guide-des-principales-techniques-en-nlp/>, (Consulté le 13 mars 2024).
- [27] Bondarenko, Y., Nagel, M., & Blankevoort, T. "Understanding and Overcoming the Challenges of Efficient Transformer Quantization." *Proceedings Of The 2021 Conference On Empirical Methods In Natural Language Processing*, 2021.
- [28] Swin Transformer: Hierarchical Vision Transformer using Shifted Windows, 2021
- [29] <https://www.ikonet.com/fr/ledictionnairevisuel/static/qc/coeur>, (Consulté le 13 mars 2024).
- [30] Hu, S., Cai, W., Gao, T., & Wang, M. "A Hybrid Transformer Model for Obstructive Sleep Apnea Detection Based on Self-Attention Mechanism Using Single-Lead ECG." *IEEE Transactions on Instrumentation and Measurement*, vol. 71, no. 2022.
- [31] Yan, G., Liang, S., Liu, F., et al. "Fusing Transformer Model with Temporal Features for ECG Heartbeat Classification." In *Proceedings of the International Conference on Bioinformatics and Biomedicine*, San Diego, Californie, États-Unis, 2019.
- [32] Behinaein, B., Bhatti, A., Rodenburg, D., Hungler, P., & Etemad, A. "A Transformer Architecture for Stress Detection from ECG." *Department of Electrical and Computer Engineering, Ingenuity Labs Research Institute, Queen's University, Kingston, Canada*, 2021.
- [33] Guan, J., Wang, W., Feng, P., Wang, X., & Wang, W. "Low-Dimensional Denoising Embedding Transformer for ECG Classification.", 2021.
- [34] <https://www.kaggle.com>, (Consulté le 03 avril 2024).
- [35] <https://www.kaggle.com/datasets/shymammoth/mitbih-normal-sinus-rhythm-database>, (Consulté le 25 avril 2024).
- [36] <https://www.physionet.org/content/nsrdb/>, (Consulté le 04 mai 2024).
- [37] <https://www.kaggle.com/datasets/protobioengineering/mit-bih-arrhythmia-database-modern-2023>, (Consulté le 28 avril 2024).

[38] <https://www.physionet.org/content/mitdb/>, (Consulté le 04 mai 2024).

Résumé

Les dernières années ont vu émerger plusieurs modèles d'intelligence artificielle dans le domaine médical. Ce mémoire explore en profondeur les signaux ECG et examine à quel point l'utilisation des modèles transformers peuvent être influent dans le traitement de ces signaux.

Après l'étude de plusieurs articles présents dans l'état de l'art, nous avons proposé notre propre modèle transformer pour classifier les signaux ECG en deux catégories : normal ou anormal. Il est composé de couches d'encodeurs pour extraire des caractéristiques importantes des segments de signal. Le modèle est entraîné et évalué à l'aide de DataLoaders afin d'optimiser ses performances sur des ensembles de données prétraitées.

Notre modèle a atteint une précision de 96 % et un F1 score de 0,88, ce qui démontre l'efficacité des transformer pour traiter les signaux ECG.

Mots clés : transformer, signal ECG, apprentissage automatique, électrocardiogramme

Abstract

Recent years have seen the emergence of several models of artificial intelligence in the medical field. This dissertation explores ECG signals in depth and examines how influential the use of transformative models can be in the processing of these signals.

After studying several state-of-the-art articles, we proposed our own transformative model to classify ECG signals into two categories: normal or abnormal. It is composed of layers of encoders to extract important features from signal segments. The model is trained and evaluated using DataLoaders to optimize its performance on preprocessed datasets.

Our model achieved an accuracy of 96% and an F1 score of 0.88, which demonstrates the effectiveness of transformers for processing ECG signals.

Keywords: transformer, ECG signal, machine learning, electrocardiogram