



UNIVERSITÉ DE BOURGOGNE EUROPE
Master Bases de Données et Intelligence Artificielle

RAPPORT DE STAGE DE MASTER

Sélection et nettoyage automatique de signaux PPG pour la détection d'anomalies cardiaques

Ines Boudjeli

Année universitaire 2025 – 2026

Entreprise d'accueil :	Laboratoire LIRIS (UMR 5205) – INSA Lyon
Adresse :	7 Avenue Jean Capelle, 69621 Villeurbanne Cedex
Encadrante de stage :	Sonia Ben Mokhtar <code>sonia.ben-mokhtar@cnrs.fr</code>
Co-encadrante :	Nelly Barret <code>nelly.barret@insa-lyon.fr</code>
Encadrant universitaire :	Eric Leclercq <code>Eric.leclercq@u-bourgogne.fr</code>

Remerciements

Je tiens à exprimer ma profonde gratitude à toutes les personnes qui ont contribué, de près ou de loin, à la réalisation de ce stage de fin d'études.

Ce travail a été réalisé au sein du laboratoire **LIRIS (Laboratoire d'Informatique en Image et Systèmes d'information)**, unité mixte de recherche rattachée conjointement au **CNRS**, à l'**INSA de Lyon**, à l'**Université Claude Bernard Lyon 1**, à l'**Université Lumière Lyon 2** et à l'**École Centrale de Lyon**.

Je remercie chaleureusement **Madame Sonia Ben Mokhtar**, Directrice de recherche au CNRS, ainsi que **Madame Nelly Barret**, Maîtresse de conférences à l'INSA, pour leur accueil, leur confiance et l'opportunité qui m'a été offerte d'intégrer ce laboratoire dans un environnement scientifique enrichissant.

J'adresse également mes sincères remerciements à mon encadrant universitaire, **Monsieur Eric Leclercq**, professeur en informatique à l'UFR Sciences et Techniques de l'Université de Bourgogne, pour son accompagnement, ses conseils et son suivi tout au long de ce projet.

Je remercie l'ensemble des membres du laboratoire **LIRIS**, en particulier **Côme Perin**, ingénieur d'études de l'équipe, ainsi que les membres de l'équipe **DRIM**, pour leur disponibilité, leur aide précieuse et la qualité des échanges qui ont contribué au bon déroulement de ce stage.

J'exprime également ma reconnaissance à ma famille, notamment à la famille **Boudjeli**, pour leur soutien, leurs encouragements et leur présence constante tout au long de cette expérience.

Enfin, je dédie ce travail à mes parents, **ma mère Fazia et mon père Hamid**, pour leur amour, leur confiance et leurs sacrifices. Leur soutien indéfectible et leurs encouragements ont été une source de motivation essentielle tout au long de mon parcours.


Résumé

Ce stage porte sur le nettoyage automatique de signaux physiologiques PPG (photopléthysmographie) liés à l'activité cardiaque, enregistrés en continu par des montres connectées. Captés au niveau du poignet, ces signaux sont fortement perturbés par les mouvements, ce qui peut réduire leur qualité et rendre leur analyse moins fiable. L'objectif du stage est ainsi **d'améliorer la qualité des signaux PPG afin de faciliter leur exploitation pour l'analyse de l'activité cardiaque et, à terme, la détection d'anomalies**. Le travail a été réalisé au sein de l'équipe DRIM du laboratoire LIRIS, situé à Villeurbanne.

Après un état de l'art portant sur les méthodes classiques de débruitage, telles que le filtrage passe-bande et les ondelettes, ainsi que sur les approches fondées sur l'apprentissage profond, notamment les autoencodeurs, les GAN et les modèles multi-tâches, le stage a porté sur l'implémentation de **DPnet, une architecture de réseau de neurones profond basée sur le modèle à espace d'état Mamba**. Cette architecture est entraînée par apprentissage supervisé et associe la reconstruction du signal PPG à l'estimation de la fréquence cardiaque, utilisée comme tâche auxiliaire lors de l'apprentissage afin de guider le modèle et d'améliorer la qualité du signal reconstruit.

Le modèle a été entraîné à partir de signaux BIDMC propres, utilisés comme référence, auxquels ont été ajoutés des bruits réels issus de WristPPG ainsi que du bruit gaussien synthétique, selon différents niveaux de perturbation. Les résultats montrent une réduction de l'erreur de reconstruction comprise entre 53 % et 70 % selon les niveaux de bruit testés, ainsi qu'une diminution d'environ 70 % de l'erreur d'estimation de la fréquence cardiaque par rapport au signal brut. Ces résultats ont été complétés par une évaluation à l'aide d'un autoencodeur convolutif, qui montre une amélioration de la prédiction de l'état normal/anormal sur plus de 93 % des segments testés. Le débruitage constitue ainsi une étape préalable à la détection fiable d'anomalies cardiaques à partir des signaux PPG nettoyés .

Abstract



This internship focuses on the automatic denoising of physiological PPG (photoplethysmography) signals related to cardiac activity, continuously recorded by smartwatches. Acquired at the wrist, these signals are strongly affected by motion, which can reduce their quality and make their analysis less reliable. The objective of this internship is to improve the quality of PPG signals in order to facilitate their use for cardiac activity analysis and, ultimately, anomaly detection. The work was carried out within the DRIM team of the LIRIS laboratory, located in Villeurbanne .

Following a state-of-the-art review of conventional denoising methods, such as band-pass filtering and wavelets, as well as deep learning approaches, including autoencoders, GANs, and multi-task models, the internship focused on the implementation of DPNet, a deep neural network architecture based on the Mamba state-space model. This architecture is trained using supervised learning and combines PPG signal reconstruction with heart rate estimation, which is used as an auxiliary task during training to guide the model and improve the quality of the reconstructed signal.

The model was trained using clean BIDMC signals as references, to which real noise from WristPPG and synthetic Gaussian noise were added at different levels of perturbation. The results show a reduction in reconstruction error ranging from 53% to 70%, depending on the noise level, as well as an approximately 70% reduction in heart rate estimation error compared with the raw signal. These results were complemented by an evaluation using a convolutional autoencoder, which showed an improvement in normal/abnormal state prediction for more than 93% of the tested segments. Denoising therefore constitutes a preliminary step toward reliable detection of cardiac anomalies from denoised PPG signals.

Table des matières

Remerciements	1
Résumé	3
Abstract	4
1 Présentation de la structure d'accueil	9
1.1 Le LIRIS : un laboratoire de recherche en informatique	9
1.2 L'équipe DRIM : Distribution, Recherche d'Information et Mobilité	10
1.3 Mon positionnement au sein de l'équipe	11
1.4 Environnement et outils de travail	11
2 Introduction	12
2.1 Contexte général	12
2.2 Le signal PPG et les perturbations liées aux mouvement	12
2.3 Choix de la méthode	13
2.4 Environnement de travail spécifique au sujet	13
3 Missions et objectifs du stage	14
4 État de l'art sur les techniques de débruitage du signal PPG	14
4.1 Introduction	14
4.2 Le signal PPG et les artefacts de mouvement	14
4.3 Méthodes classiques de traitement du signal	15
4.4 Méthodes basées sur l'apprentissage profond	15
4.5 Reconstruction d'un ECG à partir d'un signal PPG	16
4.6 Les modèles à espace d'état : Mamba	16
4.7 DPNet : une architecture dédiée au débruitage du PPG	17
4.8 Comparaison des approches et choix de DPNet	17
5 Méthodologie	18
5.1 Architecture de DPNet : principe et description détaillée	18
5.1.1 Construction du signal bruité d'entraînement	19
5.1.2 Architecture du débruiteur DPNet	20
5.1.3 Connexion résiduelle et combinaison finale	22
5.1.4 Prédicteur physiologique auxiliaire (HRP)	22
5.2 Déroulement de l'entraînement	22
5.2.1 Pré-entraînement du prédicteur physiologique HRP	23
5.2.2 Entraînement du débruiteur DPNet	23
5.2.3 Fonctions de perte utilisées	23
5.3 Introduction progressive de la contrainte physiologique	23
5.3.1 Paramètres d'entraînement	24

6	Résultats de l'entraînement DPNet	24
6.1	Résultats pour un faible niveau de bruit	25
6.2	Résultats du débruitage sur différents niveaux de bruit	25
6.3	Résultats du débruitage avec un niveau de bruit élevé	26
6.4	Évaluation de DPNet à l'aide d'un auto-encodeur	26
6.4.1	Évaluation des sorties de DPNet	27
6.5	Résultats	28
6.5.1	Signaux fortement bruités	28
6.5.2	Signaux faiblement bruités	29
6.5.3	Différents niveaux de bruit	29
6.6	Lien avec la détection d'anomalies	30
7	Conclusion	31
7.1	Bilan du travail réalisé	31
7.2	Apports scientifiques et techniques	31
7.3	Difficultés techniques et progression	32
7.4	Organisation et démarche personnelle	32
7.5	Perspectives	33
7.6	Déclaration de l'utilisation de l'IA	33
A	Architecture de DPNet	36
B	Ajout du bruit gaussien	37
C	Signaux propres/bruités	38
D	Signaux PPG bruts	39

Table des figures

1	Organigramme des pôles et équipes du LIRIS	9
2	Vue d'ensemble de l'architecture complète de DPNet	18
3	Comparaison entre un signal PPG propre et un signal PPG bruité	19
4	Couches convolutives d'extraction des caractéristiques (1→64→64→128 canaux)	20
5	Détail interne du bloc BMamba (Bi-Directional Mamba Block)	21
6	Couches convolutives de reconstruction (128→64→1 canal)	22
7	Comparaison de la MSE pour un faible niveau de bruit	25
8	Reconstruction PPG NSR sur les ensembles VAL et TEST.	27
9	Séquence d'évaluation des signaux via l'auto-encodeur.	27
10	Erreurs de reconstruction des signaux PPG fortement bruités	28
11	Erreurs de reconstruction des signaux PPG faiblement bruités	29
12	Erreurs de reconstruction pour différents niveaux de bruit	30
13	Architecture de DPNet, adaptée de Chiu et al. [4].	36
14	Variation du signal d'entrée selon le niveau de bruit	37
15	Bruitage du signal PPG propre à différents niveaux de bruit.	38
16	Exemple de signaux PPG bruts avant traitement.	39

Liste des tableaux

1	Récapitulatif des hyperparamètres d'entraînement	24
2	Comparaison des métriques avant et après débruitage sur le jeu de test.	26
3	Comparaison des performances avant et après débruitage sur le jeu de test.	26

1 Présentation de la structure d'accueil

1.1 Le LIRIS : un laboratoire de recherche en informatique

Mon stage s'est déroulé au sein du **LIRIS** (Laboratoire d'Informatique en Image et Systèmes d'information), une unité mixte de recherche (UMR 5205) rattachée conjointement au CNRS, à l'INSA de Lyon, à l'Université Claude Bernard Lyon 1, à l'Université Lumière Lyon 2 et à l'École Centrale de Lyon. Contrairement à une entreprise classique, le LIRIS est un laboratoire académique dont la mission principale est de produire des connaissances scientifiques en informatique, avec une forte dimension de transfert vers l'enseignement et, plus ponctuellement, vers l'industrie.

Le laboratoire regroupe environ 330 membres (chercheurs, enseignants-chercheurs, doctorants, ingénieurs et personnels administratifs) et couvre un large spectre de la science informatique. Ses activités sont organisées autour de douze équipes regroupées en six pôles de compétences :

- **Données, Système et Sécurité** (équipes BD, DRIM, SOC et DM2L)
- **Informatique Graphique et Géométrie** (équipe ORIGAMI)
- **Images, Vision et Apprentissage** (équipe IMAGINE)
- **Interactions et cognition** (équipes SICAL, SyCoSMA et TWEAK)
- **Algorithmique et Combinatoire** (équipe GOAL)
- **Simulation et Sciences du Vivant** (équipes SAARA et BEAGLE)




FIGURE 1 – Organigramme des pôles et équipes du LIRIS

Les activités du LIRIS couvrent un large éventail de domaines en informatique, notamment l'intelligence artificielle, l'analyse et la gestion des données, la vision par ordinateur, la cybersécurité, la transformation numérique et l'apprentissage humain. Le laboratoire développe

également des travaux à l'interface entre l'informatique et d'autres disciplines, telles que les sciences humaines et sociales, la médecine et les sciences de l'environnement.

Domaine d'activité. Le LIRIS est un laboratoire de recherche publique dont la mission principale est de produire de nouvelles connaissances en informatique et de contribuer à leur valorisation. Ses travaux donnent notamment lieu à des publications scientifiques, au développement de logiciels, à la mise à disposition de jeux de données et à des collaborations avec d'autres organismes de recherche ainsi qu'avec des partenaires industriels.

Le fonctionnement du laboratoire repose sur des financements provenant de ses établissements de tutelle, complétés par des projets de recherche nationaux et européens. Parmi ces projets figure **REDEEM (PEPR IA)**, dans lequel s'inscrit mon stage.

1.2 L'équipe DRIM : Distribution, Recherche d'Information et Mobilité

Plus précisément, mon stage a été réalisé au sein de l'équipe **DRIM** (Distribution, Recherche d'Information et Mobilité), rattachée au pôle « Données, Système et Sécurité ». Elle est dirigée par **Sonia Ben Mokhtar**, Directrice de Recherche au CNRS, avec **Elöd Egyed-Zsigmond**, Maître de conférences à l'INSA Lyon, en tant que responsable adjoint.

Thématiques de recherche. Les activités de DRIM s'articulent autour de trois axes complémentaires :

1. **Documents numériques et recherche d'information sémantique** — extraction, indexation et compréhension de documents textuels ou multimodaux.
2. **Gestion robuste et partage de données dans les systèmes répartis et mobiles** — architectures distribuées, apprentissage fédéré et approches décentralisées.
3. **Confiance, réputation et vie privée dans les systèmes répartis** — sécurité, préservation de la confidentialité et robustesse face aux attaques adverses.

Les travaux de l'équipe trouvent des applications dans plusieurs domaines, notamment la **e-santé**, les **humanités numériques** et la **ville intelligente**. Le domaine de la e-santé est particulièrement pertinent dans le cadre de mon stage, qui porte sur le nettoyage de signaux physiologiques PPG.

Composition et organisation. L'équipe DRIM rassemble des chercheurs, enseignants-chercheurs, ingénieurs, doctorants et stagiaires. Les membres travaillent sur des problématiques variées liées aux données, aux systèmes distribués, à la sécurité et à la protection de la vie privée.

L'organisation de l'équipe favorise les échanges scientifiques à travers des réunions régulières, des séminaires et des discussions entre les différents membres. Cette organisation permet également aux doctorants et aux stagiaires de bénéficier d'un environnement propice à l'apprentissage et au développement de leurs travaux.

DRIM participe à des travaux de recherche publiés dans des conférences et revues scientifiques internationales. Ces travaux témoignent d'un environnement de recherche actif dans les domaines des systèmes distribués, de la gestion des données et de la sécurité.

1.3 Mon positionnement au sein de l'équipe

J'ai intégré l'équipe DRIM en tant que **stagiaire**, au sein du bâtiment Blaise Pascal de l'INSA de Lyon, aux côtés des doctorants, ingénieurs d'études et chercheurs permanents. Mon sujet, encadré par **Sonia Ben Mokhtar** et **Nelly Barret**, s'inscrit dans le cadre du projet REDEEM (PEPR IA), il porte sur le nettoyage automatique de données d'apprentissage à partir de signaux physiologiques PPG, afin d'améliorer leur qualité avant leur exploitation par des méthodes d'apprentissage automatique.

Au quotidien, je partage un bureau avec deux autres stagiaires rattachés à différentes équipes du LIRIS. Cette organisation, fréquente au sein du laboratoire, ne repose pas systématiquement sur un regroupement par thématique scientifique et favorise ainsi les échanges informels entre personnes travaillant sur des sujets variés. Ces interactions m'ont permis de découvrir d'autres problématiques et approches scientifiques au-delà du cadre spécifique de mon stage.

D'un point de vue matériel, je dispose d'un poste de travail fixe dédié aux tâches courantes telles que la rédaction, le développement et la consultation de ressources bibliographiques. Les traitements nécessitant davantage de ressources de calcul, notamment l'entraînement des modèles, sont réalisés sur des infrastructures partagées présentées dans la section suivante.

Le suivi de mon travail avec mes encadrantes repose sur deux modalités complémentaires : des **réunions hebdomadaires**, permettant d'évaluer l'avancement, de discuter des choix méthodologiques et d'identifier d'éventuels blocages ; ainsi qu'un accompagnement continu à distance via les outils numériques du groupe (détaillés en section 1.4), facilitant le suivi régulier de mes travaux entre deux réunions.

1.4 Environnement et outils de travail

Au-delà de mon poste de travail, plusieurs outils logiciels et environnements de calcul ont été utilisés dans le cadre du stage pour réaliser les expérimentations en apprentissage automatique :

- **Environnement de développement** : Visual Studio Code, utilisé pour l'ensemble des développements réalisés durant le stage, notamment pour le prototypage et les scripts d'expérimentation.
- **Gestion de version et suivi de l'avancement** : GitLab, utilisé pour centraliser le code et suivre l'évolution des développements. Les modifications y sont régulièrement mises à jour, permettant à mes encadrantes de suivre l'état d'avancement des travaux indépendamment des réunions hebdomadaires.
- **Communication et échanges** : les échanges avec mes encadrantes et les autres membres du groupe ont principalement été réalisés par e-mail, notamment pour le suivi du stage, les questions techniques et la transmission de documents.
- **Recherche bibliographique** : Google Scholar, utilisé pour rechercher, identifier et consulter les publications scientifiques pertinentes pour la réalisation de l'état de l'art.

- **Accès aux ressources et reproductibilité** : GitHub, utilisé pour consulter les implémentations publiées par d'autres chercheurs (méthodes de référence, ou *baselines*) et, lorsque cela est nécessaire, partager du code associé aux expérimentations.
- **Calcul intensif** : deux infrastructures principales sont utilisées selon les besoins expérimentaux :
 - un serveur de calcul interne au LIRIS, nommé **Pagoda**, utilisé pour les entraînements de modèles nécessitant des ressources importantes tout en conservant un accès rapide ;
 - **Grid'5000** (<https://www.grid5000.fr/w/Grid5000:Home>), une plateforme nationale de calcul distribué dédiée à la recherche expérimentale en informatique, mise à disposition de la communauté académique française et utilisée pour des expérimentations sur des données plus conséquentes.

2 Introduction

2.1 Contexte général

Les données occupent aujourd'hui une place centrale dans le développement des algorithmes et des modèles d'intelligence artificielle. Elles sont collectées massivement sous des formes variées — tableaux, images, sons, textes, données semi-structurées ou graphes — et les modèles de Machine Learning sont de plus en plus souvent entraînés sur des données **multi-modales**, combinant plusieurs types de représentations. Avant leur exploitation, ces données nécessitent des étapes de sélection, de prétraitement et de contrôle de qualité afin de construire des ensembles adaptés aux objectifs d'apprentissage. Ces opérations restent toutefois largement réalisées manuellement, nécessitent une expertise du domaine concerné et deviennent difficiles à maintenir à grande échelle.

Dans ce contexte s'inscrit mon stage, dont **l'objectif général est d'étudier les méthodes permettant d'améliorer automatiquement la qualité des données destinées au Machine Learning**. Cette problématique s'inscrit dans le cadre plus large du projet REDEEM (PEPR IA), qui couvre des données de natures variées (tabulaires, textuelles, images, séries temporelles). Ce stage se concentre sur un cas d'usage précis : la sélection et le nettoyage de signaux physiologiques PPG (photopléthysmographie), issus des bases de données publiques BIDMC et WristPPG. La méthode développée répond spécifiquement aux caractéristiques de ce type de signal et n'a pas vocation à généraliser à d'autres modalités.

Dans ce domaine, les méthodes existantes reposent souvent sur des règles définies manuellement ou sur des approches statistiques, qui montrent leurs limites face à la variabilité des signaux physiologiques rencontrés en pratique, notamment dans des applications de santé connectée telles que le suivi cardiovasculaire par montres connectées.

2.2 Le signal PPG et les perturbations liées aux mouvement

Le cas d'étude abordé durant ce stage illustre cette problématique à travers l'analyse de signaux physiologiques issus de capteurs portables, et plus précisément du signal de **photopléthysmographie (PPG)** utilisé dans les dispositifs de suivi cardiovasculaire.

La photopléthysmographie, intégrée dans la majorité des montres connectées, permet de mesurer l'activité cardiovasculaire de manière non invasive et continue. Contrairement à

l'électrocardiogramme (ECG), qui constitue une référence clinique pour l'analyse de l'activité cardiaque mais qui nécessite un dispositif médical dédié, le PPG peut être acquis facilement au quotidien grâce à un simple capteur optique placé au poignet. Cependant, cette facilité d'utilisation s'accompagne d'une forte sensibilité aux perturbations extérieures. Les mouvements du poignet, les déplacements du capteur sur la peau ou encore la transpiration génèrent des artefacts qui dégradent la composante cardiaque du signal et peuvent entraîner des erreurs importantes dans l'estimation de la fréquence cardiaque.

Cette dégradation constitue aujourd'hui une limite majeure pour l'utilisation fiable des montres connectées dans des applications avancées de suivi cardiovasculaire, notamment pour la détection d'anomalies telles que les arythmies ou la fibrillation auriculaire. Les différentes sources de bruit ainsi que les méthodes existantes permettant de les réduire sont présentées dans l'état de l'art (section 4).

L'objectif principal de ce stage est donc de développer une méthode permettant de **débruiter automatiquement un signal PPG acquis par une montre connectée**, afin d'améliorer sa qualité et de le rendre exploitable pour des analyses ultérieures, notamment la détection d'anomalies cardiaques. Cette tâche constitue une application concrète du problème plus général d'amélioration automatique de la qualité des données.

Une difficulté importante réside dans l'absence fréquente de vérité terrain (*ground truth*) pour les signaux acquis en conditions réelles. L'approche adoptée consiste ainsi à exploiter des signaux de référence de haute qualité afin d'entraîner un modèle capable d'apprendre la relation entre un signal PPG bruité et sa version corrigée, puis de généraliser cette amélioration à de nouveaux enregistrements.

2.3 Choix de la méthode

La contribution principale de ce stage consiste à étudier et implémenter **DPNet**, une architecture de Deep Learning dédiée au débruitage du signal PPG. Cette méthode apprend à extraire la composante cardiaque utile à partir d'un signal PPG perturbé par des artefacts de mouvement, sans nécessiter l'utilisation d'un capteur auxiliaire tel qu'un accéléromètre. La préservation de l'information physiologique est assurée par une tâche auxiliaire d'estimation de la fréquence cardiaque intégrée au modèle.

Avant l'adoption de cette approche, plusieurs pistes ont été explorées. Un filtrage passe-bande classique a d'abord été évalué (section 4.3), puis une approche basée sur l'utilisation de signaux ECG de référence (*ground truth*) afin d'apprendre la correspondance entre des signaux PPG bruités et des signaux cardiaques propres. Ces orientations ont finalement conduit au choix de DPNet, qui présente une approche plus adaptée au débruitage direct du PPG et aux objectifs du stage. Le fonctionnement détaillé de cette architecture est présenté en section 5.

2.4 Environnement de travail spécifique au sujet

Au-delà des outils généraux présentés précédemment (section 1.4), ce travail a nécessité l'utilisation de plusieurs bases publiques de signaux physiologiques, notamment issues de PhysioNet¹. Ces ensembles de données présentent des caractéristiques différentes en termes de niveau de bruit, de fréquence d'échantillonnage, de conditions d'acquisition (environnement contrôlé, contexte médical ou mouvements réels) et de qualité d'annotation.

1. <https://physionet.org/>

Une étape importante du stage a donc consisté à analyser et comparer ces différentes bases afin d’identifier celles qui étaient les plus adaptées à l’entraînement et à l’évaluation du modèle.

3 Missions et objectifs du stage

Mon stage s’est déroulé autour de trois missions principales :

- **Mission 1 — État de l’art** : étude des techniques de débruitage des signaux PPG, classiques et fondées sur l’apprentissage profond, afin d’identifier les approches adaptées au traitement des artefacts de mouvement.
- **Mission 2 — Choix et étude de l’approche** : sélection d’une technique de débruitage adaptée à la problématique étudiée, analyse de son fonctionnement et de son architecture, puis mise en place d’une évaluation complémentaire à l’aide d’un auto-encodeur pour étudier l’impact du débruitage sur la détection d’anomalies.
- **Mission 3 — Développement** : conception et implémentation d’un prototype logiciel permettant de mettre en œuvre la technique retenue et d’évaluer son comportement sur les données étudiées.

4 État de l’art sur les techniques de débruitage du signal PPG

4.1 Introduction

Face aux différentes sources de bruit affectant le signal PPG, de nombreuses méthodes de débruitage ont été proposées dans la littérature. Ces approches ont progressivement évolué des techniques classiques de traitement du signal vers des méthodes fondées sur l’apprentissage profond, capables d’apprendre directement la reconstruction d’un signal PPG à partir de données bruitées.

Cette section présente les principales approches proposées pour le débruitage du signal PPG ainsi que leurs avantages et leurs limites. Elle commence par rappeler les principales caractéristiques du signal PPG et les difficultés liées aux artefacts de mouvement. Les méthodes classiques de traitement du signal sont ensuite présentées, suivies des approches fondées sur l’apprentissage profond. Une attention particulière est ensuite portée aux modèles à espace d’état, et plus spécifiquement à Mamba, qui constitue le principe architectural sur lequel repose DPNet. Enfin, l’architecture DPNet ainsi que les raisons ayant motivé son choix dans le cadre de ce stage sont présentées.

4.2 Le signal PPG et les artefacts de mouvement

Le signal PPG peut être modélisé comme la somme de trois composantes :

$$s(t) = s_{AC}(t) + s_{DC}(t) + n(t)$$

où $s_{AC}(t)$ représente la partie du signal liée aux battements cardiaques, $s_{DC}(t)$ la partie plus stable du signal, dépendante notamment des caractéristiques des tissus et des conditions d’acquisition, et $n(t)$ l’ensemble des perturbations affectant la mesure.

Parmi ces perturbations, les artefacts de mouvement (*Motion Artifacts*) constituent une source majeure de dégradation du signal PPG. Ils apparaissent notamment lors des déplacements du poignet, des gestes du quotidien ou de l’activité physique. Leur amplitude

peut devenir suffisamment importante pour masquer la partie du signal liée aux battements cardiaques et ainsi dégrader l'estimation de paramètres physiologiques tels que la fréquence cardiaque [3, 12].

La principale difficulté réside dans le fait que les artefacts de mouvement peuvent occuper une bande de fréquences proche de celle du signal physiologique. Cette proximité fréquentielle limite l'efficacité des méthodes reposant uniquement sur une séparation fréquentielle, puisqu'un filtrage trop agressif risque également de supprimer une partie de l'information cardiaque utile [3, 10].

Cette limitation a conduit au développement de méthodes plus avancées, présentées dans les sections suivantes.

4.3 Méthodes classiques de traitement du signal

Les premières approches de débruitage reposent sur des méthodes déterministes ne nécessitant aucun apprentissage.

Le filtrage passe-bande constitue une approche couramment utilisée. Son principe consiste à conserver une bande de fréquences contenant les principales composantes cardiaques tout en atténuant les composantes situées en dehors de cette bande. Cette approche est simple à mettre en œuvre et peu coûteuse en calcul [14, 10]. Cependant, elle montre ses limites lorsque les artefacts de mouvement se situent dans une bande fréquentielle proche de celle du signal PPG. Dans ce cas, le filtrage peut difficilement distinguer les composantes physiologiques des composantes indésirables.

D'autres méthodes utilisent des décompositions multi-résolution, notamment la transformée en ondelettes, ainsi que des techniques de décomposition modale. Ces approches permettent d'analyser le signal à différentes échelles et de supprimer certaines composantes considérées comme bruitées. Des méthodes hybrides combinant décomposition en ondelettes et apprentissage automatique ont notamment été proposées pour améliorer le débruitage des signaux PPG [10, 2]. Des approches fondées sur la décomposition modale, telles que la décomposition modale variationnelle associée à un seuillage par ondelettes, ont également été étudiées [8].

Ainsi, bien que ces méthodes soient simples et rapides, leur efficacité dépend fortement des paramètres de décomposition et de filtrage choisis. Elles restent notamment limitées lorsque les caractéristiques des artefacts varient fortement au cours du temps. Ces limites ont motivé le développement d'approches fondées sur l'apprentissage profond.

4.4 Méthodes basées sur l'apprentissage profond

Afin de s'affranchir des limites des approches classiques, de nombreux travaux utilisent désormais des modèles d'apprentissage profond capables d'apprendre automatiquement la relation entre un signal bruité et un signal de référence.

Les autoencodeurs constituent l'une des premières familles de modèles appliquées au débruitage du PPG. Le modèle BRDAE proposé par Lee et al. utilise des couches récurrentes bidirectionnelles de type LSTM afin de reconstruire un signal PPG à partir d'un signal contaminé [9]. Cette approche permet de prendre en compte les dépendances temporelles du signal, mais les architectures récurrentes peuvent devenir coûteuses lorsque la longueur des séquences augmente.

D'autres travaux exploitent directement **des architectures neuronales** pour apprendre les caractéristiques pertinentes du signal PPG. Par exemple, des approches fondées sur des

autoencodeurs ont été étudiées pour améliorer la fiabilité des signaux PPG acquis dans des contextes réels, notamment lors d’activités professionnelles [5].

Certaines approches combinent également des techniques classiques de traitement du signal avec **l’apprentissage profond**. FWT-FFNN associe ainsi une transformée en ondelettes rapide à un réseau de neurones afin d’exploiter simultanément les caractéristiques fréquentielles du signal et les capacités d’apprentissage du modèle [2].

Les réseaux génératifs adversariaux (GAN) constituent une autre famille d’approches permettant d’apprendre des représentations complexes des signaux physiologiques. Ces modèles sont notamment utilisés pour la génération ou la reconstruction de signaux physiologiques, mais leur entraînement peut être plus délicat que celui de modèles de reconstruction classiques.

Enfin, **des architectures multi-tâches** ont été proposées afin de réaliser simultanément plusieurs objectifs liés aux signaux physiologiques. Cette stratégie permet notamment d’exploiter des informations complémentaires pour améliorer les performances du modèle [16].

Malgré leurs bonnes performances, ces méthodes présentent encore plusieurs limites. Les réseaux récurrents peuvent être coûteux à entraîner sur de longues séquences, tandis que les architectures génératives peuvent être difficiles à optimiser. Ces différents compromis entre qualité de reconstruction, complexité du modèle et coût computationnel motivent l’étude d’architectures plus adaptées au traitement de longues séquences temporelles.

4.5 Reconstruction d’un ECG à partir d’un signal PPG

En parallèle des travaux consacrés au débruitage, plusieurs études cherchent à reconstruire directement un signal ECG à partir d’un signal PPG. Cette problématique est différente du débruitage classique puisqu’elle consiste à prédire un signal appartenant à une autre modalité physiologique.

Différentes architectures ont été proposées pour cette tâche, notamment des méthodes de régression sur représentation transformée [18], des réseaux génératifs adversariaux conditionnels [17, 13], ainsi que des modèles adaptés à chaque patient [15].

Ces travaux montrent qu’un signal PPG peut contenir suffisamment d’informations physiologiques pour permettre la reconstruction partielle de caractéristiques de l’ECG. Toutefois, cette tâche reste plus ambitieuse que le débruitage d’un PPG, car elle nécessite d’apprendre la relation entre deux modalités physiologiques différentes.

Les travaux consacrés à l’analyse de données physiologiques acquises par des dispositifs portables illustrent également le potentiel de ces technologies dans ce domaine [7, 11]. Néanmoins, cette approche reste différente de celle retenue dans ce stage. L’objectif n’est pas de reconstruire un ECG de référence, mais d’améliorer directement la qualité du signal PPG afin de le rendre exploitable pour des traitements ultérieurs.

4.6 Les modèles à espace d’état : Mamba

Plus récemment, les modèles à espace d’état (*State Space Models*, SSM) ont été proposés comme une alternative aux architectures récurrentes et aux transformers pour le traitement de séquences longues. Ces modèles permettent de représenter efficacement les dépendances temporelles tout en conservant une complexité linéaire par rapport à la longueur de la séquence.

Parmi ces architectures, Mamba introduit un mécanisme de sélection dynamique permettant au modèle de sélectionner les informations pertinentes au cours du traitement de la séquence [6]. Cette propriété permet de mieux adapter la représentation interne aux différentes parties du signal tout en conservant une complexité linéaire.

Ces caractéristiques rendent les modèles de type Mamba particulièrement intéressants pour le traitement de séries temporelles longues, notamment dans le domaine des signaux physiologiques.

4.7 DPNet : une architecture dédiée au débruitage du PPG

Dans la continuité des modèles à espace d'état, Chiu et al. proposent DPNet, une architecture spécifiquement conçue pour le débruitage des signaux PPG [4]. Une représentation détaillée de son architecture est présentée en Figure 13, située dans l'Annexe A. DPNet combine des couches convolutives chargées d'extraire les caractéristiques locales du signal avec plusieurs blocs Mamba bidirectionnels permettant de modéliser les dépendances temporelles. L'architecture intègre également un prédictor auxiliaire de fréquence cardiaque. Cette tâche auxiliaire vise à contraindre le modèle à préserver les informations physiologiques essentielles lors de la reconstruction, plutôt qu'à optimiser uniquement la similarité numérique entre le signal reconstruit et le signal de référence [4].

4.8 Comparaison des approches et choix de DPNet

Les différentes familles de méthodes présentées précédemment répondent à la problématique du débruitage du PPG avec des niveaux de complexité et des capacités différentes. Les méthodes classiques sont simples, rapides et relativement faciles à interpréter. Cependant, dans notre cas, elles présentent certaines limites, car les artefacts de mouvement peuvent occuper une bande fréquentielle proche de celle du signal cardiaque, ce qui rend leur séparation difficile par des approches reposant principalement sur le filtrage fréquentiel [3, 10].

Les approches fondées sur l'apprentissage profond permettent quant à elles d'apprendre des représentations plus complexes et de mieux s'adapter à la variabilité des signaux et des artefacts [9, 2, 5]. En contrepartie, elles nécessitent généralement des données d'apprentissage représentatives et en quantité suffisante. Dans notre cas, cette contrainte est particulièrement importante en raison du nombre limité de signaux disponibles et de l'absence d'un jeu de données complet regroupant à la fois des signaux PPG propres et des signaux bruités correspondants. Les modèles à espace d'état constituent une évolution intéressante pour le traitement de longues séquences temporelles. Leur capacité à modéliser efficacement les dépendances temporelles tout en conservant une complexité linéaire les rend particulièrement adaptés aux signaux physiologiques [6].

Dans le cadre de ce stage, l'objectif est de débruiter directement un signal PPG acquis par une montre connectée, tout en préservant l'information physiologique utile. Le choix doit donc privilégier une méthode capable de reconstruire la composante cardiaque sans dépendre systématiquement d'un capteur auxiliaire.

Au regard de ces critères, l'architecture **DPNet** a été retenue. Elle associe des couches convolutives à des blocs Mamba bidirectionnels et intègre une tâche auxiliaire d'estimation de la fréquence cardiaque [4]. Cette conception permet de prendre en compte à la fois les caractéristiques locales du signal et ses dépendances temporelles, tout en favorisant la préservation des informations physiologiques essentielles lors du débruitage.

Le fonctionnement détaillé de DPNet ainsi que les choix liés à son implémentation sont présentés dans la suite du rapport.

5 Méthodologie

5.1 Architecture de DPNet : principe et description détaillée

DPNet est une architecture de réseau de neurones profond (*deep neural network*) conçue pour le débruitage des signaux PPG. Son objectif est de reconstruire un signal PPG propre à partir d'un signal bruité, en apprenant à distinguer les composantes physiologiques des perturbations liées notamment aux mouvements.

Une particularité importante de DPNet est l'intégration d'un prédicteur auxiliaire de fréquence cardiaque. Celui-ci introduit une contrainte physiologique lors de l'apprentissage, afin d'encourager le modèle à préserver les informations liées au rythme cardiaque. Ainsi, le débruitage ne repose pas uniquement sur la similarité entre le signal reconstruit et le signal de référence, mais cherche également à conserver les caractéristiques physiologiques essentielles du PPG.

Les différentes étapes de l'architecture DPNet, qui permettent de traiter et de reconstruire le signal PPG, sont présentées dans la Figure 2. Le signal PPG bruité est obtenu en mélangeant un signal propre normalisé et du bruit selon un facteur α . Un réseau DPNet (Conv1D $\rightarrow$ BMamba $\rightarrow$ Conv1D) apprend ensuite à débruiter ce signal, tandis que le signal PPG débruité final est obtenu en combinant la sortie du réseau avec le signal bruité via une connexion résiduelle. Un module HRP (Conv1D + BMamba + AvgPool + MLP) estime ensuite la fréquence cardiaque (en BPM) à partir du PPG débruité afin de guider l'apprentissage.




FIGURE 2 – Vue d'ensemble de l'architecture complète de DPNet

5.1.1 Construction du signal bruité d'entraînement

Avant même d'entraîner le réseau, il faut lui fournir des exemples de signaux bruités à nettoyer. Ceux-ci sont fabriqués en combinant un signal propre de référence dataset BIDMC, segmenté en fenêtres de 6 secondes (750 points à 125 Hz) avec un chevauchement de 4 secondes entre segments consécutifs (10662 segments), avec du bruit — soit du bruit synthétique (notamment gaussien, voir figure 14), parmi sept types différents, soit du bruit de mouvement réel enregistré lors d'une activité physique (WristPPG), voir figure 15.

Jeux de données utilisés. BIDMC² (BIDMC PPG and Respiration Dataset) fournit les signaux propres de référence : il s'agit d'enregistrements collectés en environnement contrôlé (milieu hospitalier), échantillonnés à 125 Hz, comprenant 53 sujets pour une durée de 8 minutes chacun. WristPPG³ (Wrist PPG During Exercise), à l'inverse, fournit le bruit réel de mouvement : 18 enregistrements de PPG au poignet, réalisés pendant différentes activités physiques (marche, course, vélo à résistance variable), échantillonnés à 256 Hz puis sous-échantillonnés à 125 Hz pour correspondre au signal propre.

La Figure 3 ci-dessous présente deux signaux PPG : l'un issu du dataset BIDMC et l'autre du signal Wrist-PPG, présentés dans leurs versions bruitée et propre, avant toute étape de traitement ou de rééchantillonnage.




FIGURE 3 – Comparaison entre un signal PPG propre et un signal PPG bruité

Filtrage qualité (HeartPy). Avant d'être retenu comme référence pour l'entraînement, chaque segment de signal propre est soumis à un filtre de qualité basé sur la bibliothèque HeartPy, qui détecte les pics du signal et calcule la fréquence cardiaque correspondante. Seuls les segments respectant l'ensemble des critères suivants sont **sélectionnés** : fréquence cardiaque entre 40 et 135 BPM, intervalle inter-battements (IBI) entre 400 et 2000 ms, RMSSD inférieur à 100, et rapport SD1/SD2 inférieur à 6. Ce filtrage écarte les segments physiologiquement peu plausibles ou de mauvaise qualité, avant même la phase de contamination par le bruit. Les

2. <https://physionet.org/content/bidmc/1.0.0/>

3. <https://physionet.org/content/wrist/1.0.0/>

segments retenus sont ensuite répartis en 80% pour l’entraînement (dont 72% d’entraînement + 8% de validation) et 20% pour le test.

Les deux signaux sont d’abord normalisés, puis combinés selon une somme pondérée :

$$\text{signal bruité} = (1 - \alpha) \cdot s_{norm} + \alpha \cdot n_{norm}$$

où s_{norm} est le signal propre normalisé (BIDMC) et n_{norm} le bruit normalisé, composé du bruit réel WristPPG auquel s’ajoute du bruit synthétique, avec α tiré aléatoirement entre 0 et 1 pour chaque paire de segments. Cette étape est cruciale : c’est elle qui détermine sur quel type et quel niveau de bruit le réseau va apprendre à être robuste.

Pourquoi normaliser avant de mélanger ? Le signal propre (BIDMC) et le bruit WristPPG proviennent de sources différentes : rien ne garantit qu’ils aient naturellement la même amplitude (voir figure 16). Sans normalisation préalable, le paramètre α ne contrôlerait pas réellement la proportion de bruit introduite : si le bruit a une amplitude bien plus grande que le signal propre, même un α faible produirait un signal presque entièrement dominé par le bruit ; à l’inverse, un bruit de faible amplitude resterait négligeable même avec un α élevé. La normalisation ramène les deux signaux à une échelle d’amplitude comparable avant leur mélange, ce qui rend le paramètre α réellement interprétable comme une proportion signal/bruit.

5.1.2 Architecture du débruiteur DPNet

Extraction des caractéristiques locales (Conv1D, $1 \rightarrow 64 \rightarrow 64 \rightarrow 128$ canaux). Le signal bruité d’entrée ne comporte qu’un seul canal, correspondant à une valeur du signal à chaque instant. Une première couche Conv1D est donc utilisée pour extraire des caractéristiques locales directement à partir de ce signal. Le nombre de canaux est ensuite fixé à 64 afin de disposer d’un nombre suffisant de filtres pour détecter différentes caractéristiques du signal, tout en conservant une complexité raisonnable. Une deuxième couche de 64 canaux permet de combiner et d’affiner les caractéristiques extraites par la première couche, sans augmenter trop rapidement la complexité du réseau. Enfin, le passage à 128 canaux permet d’obtenir une représentation plus riche et plus diversifiée, adaptée à l’extraction de caractéristiques de plus haut niveau. Ainsi, les trois premières couches convolutives transforment progressivement la représentation de $1 \rightarrow 64 \rightarrow 64 \rightarrow 128$ canaux. Ce choix constitue un compromis entre la richesse des représentations apprises et la complexité du modèle.




FIGURE 4 – Couches convolutives d’extraction des caractéristiques ($1 \rightarrow 64 \rightarrow 64 \rightarrow 128$ canaux)

Modélisation temporelle (BMamba x5, bidirectionnels). C’est le cœur de l’architecture. Chaque bloc repose sur un modèle de séquence à état (SSM), qui maintient un état interne $h(t)$

résumant récursivement le signal :

$$h_n = \bar{A}h_{n-1} + \bar{B}x_n, \quad y_n = Ch_n$$

où $\bar{A}$, $\bar{B}$ et C sont des matrices apprises pendant l’entraînement. Ce calcul, bien que récursif dans son principe, [6] peut être reformulé comme un produit de convolution calculable en parallèle, avec une complexité qui ne croît que linéairement avec la longueur du signal ($O(L)$) — contrairement aux Transformers, dont le coût croît quadratiquement ($O(L^2)$), ou aux réseaux récurrents classiques (LSTM), qui traitent le signal strictement point par point sans parallélisation possible.

Le caractère bidirectionnel (*forward* et *backward*) permet au modèle de regarder à la fois ce qui précède et ce qui suit chaque instant, et l’empilement de cinq blocs capture des échelles de dépendance de plus en plus larges, de la relation entre montée et descente d’un même battement jusqu’à la cohérence du rythme sur l’ensemble du segment de 6 secondes.




FIGURE 5 – Détail interne du bloc BMamba (Bi-Directional Mamba Block)

Reconstruction du signal (Conv1D, $128 \rightarrow 64 \rightarrow 1$ canal). Une fois le contexte temporel capturé, ces deux couches font le chemin inverse des premières : elles recompressent la représentation riche à 128 canaux en un seul canal ($128 \rightarrow 64 \rightarrow 1$), c’est-à-dire un signal temporel classique — la reconstruction du signal PPG propre estimée par le réseau.



sortie: 1 canal, signal reconstruit avant combinaison résiduelle

FIGURE 6 – Couches convolutives de reconstruction (128→64→1 canal)

5.1.3 Connexion résiduelle et combinaison finale

Plutôt que d'utiliser directement la reconstruction du réseau comme sortie finale, DPNet la combine avec le signal bruité d'origine :

$$y = (1 - \alpha) \cdot x_{bruite} + \alpha \cdot \text{reconstruction}$$

où α est un paramètre scalaire appris pendant l'entraînement (et non fixé a priori). Ce mécanisme joue un double rôle : d'une part une sécurité — si la reconstruction est imparfaite sur un segment particulier, une partie du signal d'origine est tout de même préservée — d'autre part, α étant appris plutôt que fixé, le réseau ajuste lui-même le niveau de confiance à accorder à sa propre reconstruction, plutôt que de dépendre d'un compromis choisi arbitrairement par le concepteur du modèle (voir Figure 2 pour la vue d'ensemble incluant cette combinaison).

5.1.4 Prédicteur physiologique auxiliaire (HRP)

Toutes les étapes précédentes visent à produire un signal dont la forme ressemble au signal propre, évaluée par une erreur de reconstruction de type MSE (Mean Squared Error) :

$$\mathcal{L}_{MSE} = \frac{1}{N} \sum_{i=1}^N (g[i] - d[i])^2$$

où g est le signal propre de référence et d le signal débruité. Or, un signal peut avoir une MSE très faible tout en ayant ses pics légèrement décalés en position, ce qui fausserait le calcul de la fréquence cardiaque sans être pénalisé par cette seule erreur.

Le HRP résout ce problème en estimant le rythme cardiaque (BPM) directement à partir du signal débruité, via sa propre architecture (Conv1D×3 + BMamba×5 + AvgPool + MLP, voir Figure 13). L'erreur entre ce BPM estimé et le vrai BPM du signal propre est ajoutée comme terme de perte supplémentaire, mais seulement après une phase d'amorçage de 300 epochs (sur 600 au total), le temps que le débruiteur produise des signaux suffisamment corrects pour ne pas déstabiliser cette supervision par un gradient trop violent.

Pré-entraîné puis gelé pendant l'entraînement de DPNet, le HRP sert de référence fixe et fiable. Il permet ainsi au réseau de produire des signaux cohérents sur le plan physiologique, plutôt que de simplement s'adapter au cours de l'apprentissage.

5.2 Déroulement de l'entraînement

L'entraînement du modèle DPNet s'effectue en deux phases successives : une première phase dédiée à l'apprentissage du prédicteur physiologique HRP, puis une seconde phase consacrée à l'entraînement du débruiteur DPNet guidé par les différentes fonctions de perte.

5.2.1 Pré-entraînement du prédicteur physiologique HRP

Avant l'entraînement commun, le réseau HRP est entraîné indépendamment afin d'apprendre la relation entre un signal PPG propre et la fréquence cardiaque correspondante. Le réseau reçoit en entrée des segments PPG de référence ainsi que leurs valeurs BPM associées, et apprend à estimer directement le rythme cardiaque.

Cette phase de pré-entraînement est réalisée pendant 200 epochs. Une fois l'apprentissage terminé, les paramètres du réseau HRP sont gelés afin de conserver un prédicteur fixe durant l'entraînement de DPNet. HRP joue ainsi le rôle d'un évaluateur physiologique indépendant, capable de mesurer si le signal reconstruit conserve une information cardiaque cohérente.

5.2.2 Entraînement du débruiteur DPNet

Après le pré-entraînement de HRP, le réseau DPNet est entraîné à partir des signaux PPG bruités afin de reconstruire les signaux propres correspondants. Durant cette phase, le débruiteur apprend à supprimer les perturbations tout en conservant les caractéristiques morphologiques et physiologiques du signal.

L'entraînement de DPNet est effectué pendant 600 epochs. À chaque itération, la sortie reconstruite est comparée au signal de référence à travers plusieurs fonctions de perte complémentaires (présentées en section 5.2.3). Les gradients obtenus permettent d'ajuster progressivement les paramètres du réseau afin d'améliorer la qualité de reconstruction.

5.2.3 Fonctions de perte utilisées

La qualité du signal reconstruit ne peut pas être évaluée par une seule métrique. Plusieurs critères sont donc combinés dans DPNet afin de prendre en compte à la fois la fidélité temporelle, la forme du signal et la cohérence physiologique.

- **Erreur MSE** : elle mesure l'écart point par point entre le signal débruité et le signal de référence. Elle constitue le terme principal d'apprentissage en évaluant directement la précision de reconstruction.
- **SI-SDR** : cette métrique évalue la similarité entre les deux signaux en étant moins sensible aux variations d'amplitude. Elle permet de favoriser la conservation de la forme générale du signal PPG.
- **Terme d'amplitude** : ce terme a été ajouté afin de corriger la diminution systématique d'amplitude observée dans les signaux reconstruits. En effet, le SI-SDR étant invariant à l'échelle, il ne pénalise pas directement ce type de différence.
- **Terme de phase** : il permet de limiter les décalages temporels entre le signal reconstruit et le signal propre, notamment au niveau de la position des pics cardiaques. Ce terme est basé sur une corrélation de Pearson entre les deux signaux.
- **Erreur BPM via HRP** : ce terme mesure l'écart entre la fréquence cardiaque estimée à partir du signal débruité et la fréquence cardiaque réelle. Il apporte une contrainte physiologique complémentaire aux critères de reconstruction.

5.3 Introduction progressive de la contrainte physiologique

La perte associée à l'erreur BPM n'est pas activée dès le début de l'entraînement. Une phase d'amorçage de 300 epochs permet d'abord à DPNet d'apprendre les caractéristiques fondamentales du débruitage à partir des pertes de reconstruction.

Après cette phase initiale, la contrainte physiologique est introduite progressivement pendant 100 epochs afin d’éviter une modification brutale de l’objectif d’apprentissage et de permettre une adaptation stable du réseau.

5.3.1 Paramètres d’entraînement

L’optimisation des paramètres est réalisée avec l’algorithme Adam⁴. Deux taux d’apprentissage différents sont utilisés : un taux de 10^{-5} pour les paramètres principaux du réseau et un taux plus élevé de 10^{-3} pour le paramètre scalaire α de la connexion résiduelle, qui nécessite une adaptation plus rapide.

À chaque epoch, les performances du modèle sont évaluées sur l’ensemble de validation. Le modèle sauvegardé correspond uniquement à celui présentant les meilleures performances observées durant l’entraînement.

Le Tableau 1 présente les principaux hyperparamètres utilisés.

Paramètre	Valeur
Epochs de pré-entraînement HRP	200
Epochs d’entraînement DPNet	600
Epochs d’amorçage (warmup)	300
Epochs de montée progressive (ramp)	100
Taux d’apprentissage réseau	10^{-5}
Taux d’apprentissage du paramètre α	10^{-3}
Taille du batch	16
Dropout	0,1
Dimension du modèle (d_{model})	128
Nombre de blocs BMamba	5
Poids λ_1 (SI-SDR)	10^{-4}
Poids λ_2 (erreur BPM)	10^{-3}
Poids λ_3 (amplitude)	10^{-2}
Poids λ_4 (phase)	10^{-2}

TABLE 1 – Récapitulatif des hyperparamètres d’entraînement

6 Résultats de l’entraînement DPNet

Pour interpréter ces résultats, il faut d’abord savoir dans quel sens chaque métrique doit évoluer pour indiquer un bon débruitage. Le choix de ces cinq métriques s’inspire de l’approche proposée par Chiu et al. [4]. Elles ont été retenues afin d’évaluer de manière complémentaire la qualité du débruitage, en considérant à la fois la fidélité du signal reconstruit par rapport à la référence, l’amélioration du rapport signal/bruit et la préservation des informations physiologiques

- **MSE** : doit diminuer (se rapprocher de 0) — plus l’erreur de reconstruction est faible, plus le signal débruité se rapproche du signal propre de référence.
- **CoS** (similarité cosinus) : doit augmenter, en se rapprochant de 1 — une valeur de 1 signifierait que la forme d’onde est identique à celle du signal propre.
- **SNRimp** (amélioration du rapport signal/bruit) : doit être **positive** — elle mesure l’évolution du rapport signal/bruit entre le signal bruité d’origine et le signal débruité. Une valeur positive indique que le débruitage a augmenté le rapport signal/bruit, tandis

4. <https://arxiv.org/abs/1412.6980>

qu'une valeur négative indique une diminution de celui-ci. Une valeur nulle signifie que le rapport signal/bruit n'a pas été modifié.

- **HR-MAE** : doit diminuer (se rapprocher de 0 BPM) — il s'agit de l'erreur sur la fréquence cardiaque estimée, qui constitue la métrique la plus directement liée à la qualité physiologique du signal.
- **Corrélation de Pearson (r)** : doit augmenter et se rapprocher de 1 — une valeur proche de 1 indique une forte corrélation linéaire entre le signal débruité et le signal propre de référence. Une valeur proche de 0 indique une faible corrélation, tandis qu'une valeur négative traduit une relation inverse entre les deux signaux.

6.1 Résultats pour un faible niveau de bruit

Comme le montre la figure 7 pour un faible niveau de bruit, la MSE entre le signal bruité et le signal propre est de 0,0290. Après débruitage, elle diminue à 0,0118, soit une réduction d'environ **59.31 %**. Le signal débruité est donc nettement plus proche du signal propre que le signal bruité

Le graphique de droite de la Figure 7 montre que le signal débruité (orange) suit fidèlement le signal propre (vert). Le signal bruité (rose), bien que proche du signal propre en raison du faible niveau de bruit, présente quelques oscillations parasites et de légères variations au niveau des pics cardiaques. Après débruitage, ces perturbations sont atténuées, ce qui permet au signal orange de se rapprocher davantage du signal vert. Cet exemple illustre visuellement l'amélioration obtenue grâce au débruitage.




FIGURE 7 – Comparaison de la MSE pour un faible niveau de bruit

6.2 Résultats du débruitage sur différents niveaux de bruit

Les performances de DPNet sont évaluées sur un ensemble de 3000 segments couvrant différents niveaux de bruit, le jeu de données est réparti en 2160 s segments pour l'entraînement, 240 pour la validation et 600 pour le test. Les résultats avant et après débruitage sont comparés à l'aide de plusieurs métriques (**70 % de réduction de la MSE**).

TABLE 2 – Comparaison des métriques avant et après débruitage sur le jeu de test.

Métrique	Bruité (avant)	Débruité (après)	Valeur idéale
MSE ↓	0,0964	0,0289	0
CoS ↑	0,957	0,987	1
Pearson ↑	–	0,776	1
SNRimp (dB) ↑	–	5,817	valeur positive
HR-MAE (BPM) ↓	38,411	10,021	0

6.3 Résultats du débruitage avec un niveau de bruit élevé

Cette expérience est réalisée sur l’ensemble des 10662 segments disponibles, avec un niveau de bruit élevé. Le jeu de données est réparti en 7677 segments pour l’entraînement, 853 pour la validation et 2132 pour le test. Les performances sont évaluées avant et après le débruitage à l’aide de plusieurs métriques (**53 % de réduction de la MSE**).

TABLE 3 – Comparaison des performances avant et après débruitage sur le jeu de test.

Métrique	Bruité (avant)	Débruité (après)	Valeur idéale
MSE ↓	0,0777	0,0367	0
CoS ↑	0,964	0,983	1
Pearson ↑	–	0,691	1
SNRimp (dB) ↑	–	4,034	valeur positive
HR-MAE (BPM) ↓	42,584	11,755	0

6.4 Évaluation de DPNet à l’aide d’un auto-encodeur

Afin de confirmer l’amélioration apportée par DPNet, un auto-encodeur convolutif a été entraîné sur des segments PPG NSR (*Normal Sinus Rhythm*, i.e., sans anomalie cardiaque) propres issus de la base de données MIMIC-III. Le modèle apprend à reconstruire les caractéristiques des signaux normaux en minimisant l’erreur quadratique moyenne MSE :

$$MSE = \frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2. \quad (1)$$

Une faible MSE indique que le signal présente des caractéristiques proches de celles des signaux NSR appris par l’auto-encodeur. À l’inverse, une MSE élevée indique un écart plus important par rapport aux caractéristiques normales. L’erreur de reconstruction peut ainsi servir d’indicateur pour la détection d’anomalies.




FIGURE 8 – Reconstruction PPG NSR sur les ensembles VAL et TEST.

La Figure 8 montre que les signaux reconstruits des ensembles VAL et TEST présentent une morphologie similaire, malgré des différences entre les signaux originaux. Cela s'explique par le fait que l'auto-encodeur, entraîné uniquement sur des segments NSR, apprend les caractéristiques générales des signaux normaux plutôt que de reproduire exactement chaque signal d'entrée. Cette propriété est recherchée pour utiliser l'erreur de reconstruction comme indicateur d'anomalie.

6.4.1 Évaluation des sorties de DPNet

L'auto-encodeur est ensuite utilisé pour évaluer les sorties produites par DPNet. À partir d'un signal PPG propre (*clean*), un bruit est ajouté afin d'obtenir le signal *raw*. Celui-ci est ensuite fourni à DPNet afin d'obtenir le signal débruité (*denoised*).

Le protocole suivi est présenté dans la figure 9 :




FIGURE 9 – Séquence d'évaluation des signaux via l'auto-encodeur.

Les trois versions du signal sont évaluées avec le même auto-encodeur. Le signal *clean* constitue la référence. Si DPNet réalise correctement son débruitage, la MSE du signal *denoised*

doit diminuer par rapport au signal *raw* et se rapprocher de celle du signal *clean*.

6.5 Résultats

6.5.1 Signaux fortement bruités




FIGURE 10 – Erreurs de reconstruction des signaux PPG fortement bruités

La Figure 10 présente la **distribution des erreurs de reconstruction (MSE)** pour les trois types de signaux évalués. La courbe **bleue** correspond aux signaux *clean*, c'est-à-dire aux signaux propres et normaux. La forte densité de cette courbe autour des faibles valeurs de MSE montre que la plupart de ces signaux sont facilement reconstruits par l'auto-encodeur. Cela est attendu puisqu'ils ne contiennent pas d'artefacts de bruit et correspondent aux signaux normaux utilisés lors de l'entraînement.

La courbe **rouge** correspond aux signaux bruités avant débruitage. Sa densité est davantage répartie vers des valeurs élevées de MSE, ce qui indique que la présence de bruit rend la reconstruction plus difficile pour une grande partie des signaux.

La courbe **verte** correspond aux signaux *denoised*, après débruitage avec DPNet. On observe une forte densité de valeurs de MSE dans une zone plus faible que pour les signaux bruités. La distribution se rapproche ainsi de celle des signaux *clean*, ce qui montre que le débruitage permet de rendre les signaux plus facilement restructuribles par l'auto-encodeur.

La MSE médiane est de 0,4415 pour les signaux bruités, contre 0,0714 pour les signaux *denoised* et 0,0242 pour les signaux *clean*. Le débruitage permet ainsi de réduire la MSE médiane d'environ 84 % par rapport aux signaux bruités.

6.5.2 Signaux faiblement bruités




FIGURE 11 – Erreurs de reconstruction des signaux PPG faiblement bruités

La Figure 11 présente la **distribution des erreurs de reconstruction (MSE)** pour les signaux *clean*, *raw* et *denoised*. La courbe **bleue** correspond aux signaux *clean*, c'est-à-dire aux signaux propres. Elle présente une forte densité autour des faibles valeurs de MSE, ce qui indique que ces signaux sont généralement bien reconstruits par l'auto-encodeur.

La courbe **rouge** correspond aux signaux faiblement bruités avant débruitage. Elle reste proche de la courbe bleue, avec une densité principalement concentrée autour de faibles valeurs de MSE. L'écart limité entre les deux distributions s'explique par le faible niveau de bruit présent dans les signaux.

La courbe **verte** correspond aux signaux *denoised* après débruitage avec DPNet. Sa forte densité se situe davantage vers les faibles valeurs de MSE et se rapproche de la courbe bleue. Cela montre que le débruitage réduit l'erreur de reconstruction et rapproche les signaux des caractéristiques des signaux propres.

La MSE médiane diminue de 0,1305 pour les signaux *raw* à 0,0475 pour les signaux *denoised*, contre 0,0237 pour les signaux *clean*, soit une réduction d'environ 64 % après débruitage.

6.5.3 Différents niveaux de bruit

La Figure 12 regroupe les résultats obtenus pour l'ensemble des niveaux de bruit étudiés.




FIGURE 12 – Erreurs de reconstruction pour différents niveaux de bruit

Dans cette expérience, le paramètre α est appris automatiquement au cours de l’entraînement afin de s’adapter aux différents niveaux de bruit. La MSE médiane passe de 0,2982 pour les signaux *raw* à 0,0651 pour les signaux *denoised*, contre 0,0241 pour les signaux *clean*, soit une réduction d’environ 78 % après débruitage. Cette diminution montre que DPNet réduit fortement l’écart entre les signaux bruités et les signaux propres. La valeur obtenue après débruitage reste proche de celle des signaux *clean*, ce qui indique que le débruitage permet de retrouver des caractéristiques plus proches des signaux normaux.

6.6 Lien avec la détection d’anomalies

Dans les trois expériences, l’auto-encodeur montre une diminution importante et systématique de l’erreur de reconstruction après le passage des signaux par DPNet. Les sorties *denoised* se rapprochent ainsi des caractéristiques des signaux *clean*, alors que les signaux *raw* présentent des erreurs nettement plus élevées.

Ces résultats confirment donc, à travers l’auto-encodeur, que DPNet réduit efficacement l’influence du bruit et restaure des caractéristiques proches de celles des signaux PPG normaux.

Cette amélioration est directement intéressante pour la détection d’anomalies. En effet, l’auto-encodeur utilise l’erreur de reconstruction comme indicateur : une MSE élevée peut conduire à considérer un signal comme *Anormal*. Or, un signal NSR simplement perturbé par du bruit peut également produire une MSE élevée et entraîner une fausse détection. En réduisant cette erreur, DPNet permet aux signaux normaux bruités de retrouver une MSE plus proche de celle des signaux propres, ce qui peut limiter les fausses détections liées au bruit.

Ainsi, **l’auto-encodeur constitue une validation complémentaire des résultats de DPNet** : le débruitage améliore la compatibilité des signaux avec les caractéristiques normales apprises, ce qui est favorable à leur utilisation dans un système de détection d’anomalies.

7 Conclusion

7.1 Bilan du travail réalisé

Ce stage, réalisé au sein de l'équipe DRIM du laboratoire LIRIS, avait pour objectif d'étudier le débruitage de signaux PPG acquis par des montres connectées. Ces signaux sont particulièrement sensibles aux mouvements, ce qui peut modifier leur forme et compliquer leur utilisation pour l'analyse de l'activité cardiaque.

Le travail a commencé par une étude des différentes méthodes utilisées pour réduire le bruit dans les signaux physiologiques, allant des méthodes classiques de traitement du signal aux approches basées sur l'apprentissage profond. Cette première étape m'a permis de mieux comprendre les avantages et les limites des différentes solutions avant de me concentrer sur DPNet.

J'ai ensuite mis en œuvre et évalué cette architecture, qui combine des couches convolutives, des blocs Mamba bidirectionnels et une tâche auxiliaire d'estimation de la fréquence cardiaque. Les expérimentations ont été réalisées à partir de signaux propres de BIDMC auxquels différents niveaux de bruit réel provenant de WristPPG et de bruit synthétique ont été ajoutés, suivant le protocole présenté dans l'article de référence.

Les résultats obtenus montrent une amélioration importante de la qualité des signaux après débruitage. La MSE diminue d'environ 59 % pour les niveaux de bruit les plus faibles et jusqu'à 78 % pour les niveaux les plus élevés. L'estimation de la fréquence cardiaque est également améliorée, avec une erreur passant notamment de plus de 42 BPM à environ 12 BPM dans le cas le plus bruité.

Une seconde évaluation a été réalisée avec un auto-encodeur convolutif entraîné indépendamment sur des données de MIMIC-III. Les résultats obtenus vont dans le même sens, avec des réductions de MSE comprises entre 64 % et 84 % par rapport aux signaux bruts. Cette expérience apporte donc un résultat complémentaire et montre que l'amélioration observée ne dépend pas uniquement de l'évaluation réalisée avec DPNet.

7.2 Apports scientifiques et techniques

Ce stage m'a permis de développer mes compétences en traitement du signal et en apprentissage profond appliqué aux séries temporelles. J'ai travaillé en Python et PyTorch pour implémenter et entraîner DPNet, préparer les données et réaliser les différentes expérimentations. J'ai notamment réalisé la sélection des segments de bonne qualité à l'aide de HeartPy, ainsi que la génération de signaux bruités à différents niveaux. J'ai également réalisé les différents réglages des paramètres d'entraînement afin d'améliorer la reconstruction des signaux et analysé les résultats à l'aide de plusieurs métriques. Enfin, j'ai utilisé GitLab pour le suivi du code et Pagoda ainsi que Grid'5000 pour les entraînements.

L'utilisation de l'estimation de la fréquence cardiaque comme tâche auxiliaire m'a également permis de mieux comprendre l'intérêt d'ajouter une information liée au problème étudié lors de l'apprentissage. Dans le cas du PPG, cela permet de ne pas uniquement chercher une ressemblance numérique avec le signal de référence, mais aussi de prendre en compte l'information liée à l'activité cardiaque.

Le stage m'a aussi appris à construire une évaluation plus complète d'un modèle. Au lieu de me baser sur une seule mesure, j'ai utilisé plusieurs métriques et une seconde méthode d'évaluation. Cela m'a permis de mieux interpréter les résultats et de prendre davantage de

recul sur les performances obtenues.

7.3 Difficultés techniques et progression

Les principales difficultés rencontrées ont été d'ordre technique. La première concernait la mise en œuvre du protocole décrit dans l'article de référence. Il a fallu comprendre les différentes étapes du protocole ainsi que le rôle des bases BIDMC, WristPPG et MIMIC-III dans les expérimentations.

La compréhension de l'architecture générale de DPNet a également demandé du temps. Même si je connaissais déjà le fonctionnement de Mamba, l'organisation des différents blocs et leurs interactions étaient au début assez complexes à comprendre. J'ai donc pris le temps d'étudier l'architecture, de suivre les différentes étapes du modèle et de vérifier progressivement son fonctionnement. Les échanges avec mes encadrantes et l'ingénieur de l'équipe (Côme Perin) m'ont également permis de confirmer certains choix et de mieux comprendre les différentes parties du réseau.

La partie calculatoire a également demandé une certaine organisation. Les entraînements étaient relativement longs et nécessitaient plusieurs centaines d'epochs. J'ai donc dû utiliser le serveur Pagoda et Grid'5000, ce qui m'a permis de me familiariser avec ces environnements et avec la gestion de ressources de calcul pour des expériences de ce type.

Au cours du stage, j'ai progressivement gagné en autonomie. J'ai appris à avancer par étapes, à vérifier mes résultats et à adapter mes expériences en fonction de ce que j'observais. Le changement de direction entre la première approche basée sur la reconstruction d'ECG à partir du PPG et le travail sur DPNet montre également que j'ai appris à remettre en question une piste lorsque celle-ci ne répondait pas suffisamment aux objectifs du projet.

7.4 Organisation et démarche personnelle

Mon organisation s'est principalement construite autour des expérimentations et d'un suivi régulier avec mes encadrantes. Les points hebdomadaires permettaient de faire le bilan des résultats obtenus et de définir les étapes suivantes. Entre ces échanges, je pouvais avancer de manière autonome sur l'implémentation et les différentes expériences.

La diversité des expériences réalisées m'a également obligée à être plus rigoureuse dans leur suivi. Il était important de conserver les paramètres utilisés, les configurations testées et les résultats obtenus afin de pouvoir comparer les différentes expériences. L'utilisation de GitLab m'a notamment permis de mieux organiser le code et de garder une trace des différentes modifications.

Mon temps a été principalement partagé entre la compréhension des méthodes, la préparation des données, l'implémentation et l'analyse des résultats. Une part importante a été consacrée à la compréhension de l'architecture DPNet et à sa mise en œuvre. Les différents entraînements ont également demandé du temps, notamment pour tester et régler les paramètres afin d'améliorer progressivement la reconstruction des signaux PPG. Le reste du travail a porté sur le nettoyage des données, l'analyse des résultats et la rédaction du rapport.

Les échanges avec mes encadrantes et avec les autres membres de l'équipe m'ont aussi permis de progresser dans ma manière de présenter mon travail. J'ai appris à expliquer plus clairement mes choix, à présenter les résultats de manière synthétique et à distinguer les résultats importants des observations secondaires.

7.5 Perspectives

Le travail réalisé peut encore être poursuivi sur plusieurs points. Une première étape serait d'évaluer DPNet sur des signaux PPG réellement enregistrés dans des conditions ambulatoires et soumis aux mouvements de l'utilisateur. Les expériences réalisées pendant ce stage reposent en effet sur des signaux propres auxquels du bruit a été ajouté, ce qui permet de contrôler les conditions d'évaluation mais ne reproduit pas toutes les situations rencontrées avec une montre connectée.

Il serait également intéressant d'étudier l'effet du débruitage sur de véritables signaux anormaux, par exemple dans le cas d'arythmies ou de fibrillation auriculaire. Cela permettrait de vérifier que le débruitage améliore la qualité du signal sans supprimer les caractéristiques utiles à la détection d'une anomalie.

Enfin, l'utilisation de données d'accéléromètre pourrait être étudiée lorsque celles-ci sont disponibles. Elles pourraient apporter des informations supplémentaires sur les mouvements responsables des perturbations. Cette approche pourrait être comparée au fonctionnement de DPNet à partir du PPG seul, qui présente l'avantage de ne pas nécessiter de capteur supplémentaire.

Pour conclure, ce stage m'a permis de mettre en pratique des connaissances en traitement du signal et en apprentissage profond dans le cadre d'un problème concret lié aux données physiologiques. Les résultats obtenus avec DPNet sont encourageants et montrent qu'un débruitage adapté peut améliorer sensiblement la qualité des signaux PPG. Au-delà des résultats techniques, ce stage m'a surtout permis de gagner en autonomie, en rigueur et en confiance dans ma capacité à mener un travail de recherche, depuis la compréhension d'une méthode existante jusqu'à son implémentation, son évaluation et l'analyse de ses limites.

7.6 Déclaration de l'utilisation de l'IA

Au cours de ce stage, j'ai choisi d'utiliser des outils d'intelligence artificielle générative comme support ponctuel. Ils m'ont principalement aidée à mieux comprendre le domaine de la santé, notamment le fonctionnement des signaux PPG et les notions liées à l'activité cardiaque. Ils m'ont également permis de clarifier certaines notions techniques, d'avancer sur certains points d'implémentation et d'améliorer la formulation de certains passages du rapport. L'utilisation de ces outils est restée complémentaire au travail réalisé, et les résultats obtenus ont été vérifiés et adaptés au contexte du projet.

Références

- [1] Abdelmadjid, M. A., & Boukadoum, M. (2022). Neural network-based signal translation with application to the ECG. *2022 20th IEEE Interregional NEWCAS Conference (NEWCAS)*, 542–546.
- [2] Ahmed, R., Mehmood, A., Rahman, M. M. U., & Dobre, O. A. (2023). A Deep Learning and Fast Wavelet Transform-Based Hybrid Approach for Denoising of PPG Signals. *IEEE Sensors Letters*, 7(7), 1–4.
- [3] Barker, S. J., & Shah, N. K. (1996). The effects of motion on the performance of pulse oximeters in volunteers. *Anesthesiology*, 85(4), 774–781.
- [4] Chiu, I., Liu, Y.-T., Wang, K.-C., Wei, H.-Y., & Tsao, Y. (2025). Robust Photoplethysmography Signal Denoising via Mamba Networks. *arXiv preprint arXiv :2510.11058*.
- [5] Gautam, Y., & Jebelli, H. (2024). Autoencoder-based Photoplethysmography (PPG) signal reliability enhancement in construction health monitoring. *Automation in Construction*, 165, 105537.
- [6] Gu, A., & Dao, T. (2023). Mamba : Linear-Time Sequence Modeling with Selective State Spaces. *arXiv preprint arXiv :2312.00752*.
- [7] Hannun, A. Y., Rajpurkar, P., Haghighpanahi, M., et al. (2019). Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nature Medicine*, 25, 65–69.
- [8] Hu, Q., Li, M., Jiang, L., & Liu, M. (2024). A hybrid denoising approach for PPG signals utilizing variational mode decomposition and improved wavelet thresholding. *Technology and Health Care*.
- [9] Lee, J., Sun, S., Yang, S. M., Sohn, J. J., Park, J., Lee, S., & Kim, H. C. (2018). Bidirectional Recurrent Auto-Encoder for Photoplethysmogram Denoising. *IEEE Journal of Biomedical and Health Informatics*, 23(6), 2375–2385.
- [10] Mishra, B., & Nirala, N. S. (2020). A Survey on Denoising Techniques of PPG Signal. *Proc. INOCON*, IEEE, 1–8.
- [11] Perez, M. V., et al. (2019). Large-Scale Assessment of a Smartwatch to Identify Atrial Fibrillation. *New England Journal of Medicine*, 381, 1909–1917.
- [12] Petterson, M. T., Begnoche, V. L., & Graybeal, J. M. (2007). The effect of motion on pulse oximetry and its clinical significance. *Anesthesia & Analgesia*, 105(6), S78–S84.
- [13] Sarkar, P., & Etemad, A. (2021). CardioGAN : Attentive Generative Adversarial Network with Dual Discriminators for the Synthesis of ECG from PPG. *Proceedings of the AAAI Conference on Artificial Intelligence*, 35, 488–496.
- [14] Sheno, B. A. (2005). *Introduction to Digital Signal Processing and Filter Design*. John Wiley & Sons.
- [15] Tang, Q., Chen, Z., Guo, Y., Liang, Y., Ward, R., Menon, C., & Elgendi, M. (2022). Robust reconstruction of electrocardiogram using photoplethysmography : a subject-based model. *Frontiers in Physiology*, 13, 859763.
- [16] Torres-Soto, J., & Ashley, E. A. (2020). Multi-task deep learning for cardiac rhythm detection in wearable devices. *npj Digital Medicine*, 3, 116.

- [17] Vo, K., Naeini, E. K., Naderi, A., Jilani, D., Rahmani, A. M., Dutt, N., & Cao, H. (2021). P2E-WGAN : ECG waveform synthesis from PPG with conditional Wasserstein generative adversarial networks. *Proceedings of the 36th Annual ACM Symposium on Applied Computing*, 1030–1036.
- [18] Zhu, Q., Tian, X., Wong, C. W., & Wu, M. (2021). Learning Your Heart Actions From Pulse : ECG Waveform Reconstruction From PPG. *IEEE Internet of Things Journal*, 8(23), 16734–16748.

A Architecture de DPNet




Fig. 1. Architectures of (a) DPNet, (b) Mamba layer, and (c) HRP.

FIGURE 13 – Architecture de DPNet, adaptée de Chiu et al. [4].

B Ajout du bruit gaussien

La figure suivante présente un exemple d'ajout de bruit gaussien au signal PPG utilisé dans le protocole expérimental.




FIGURE 14 – Variation du signal d'entrée selon le niveau de bruit

C Signaux propres/bruités

La figure suivante présente un segment propre validé à l'aide de la bibliothèque HeartPy, ainsi que des signaux soumis à différents niveaux de bruit.




FIGURE 15 – Bruitage du signal PPG propre à différents niveaux de bruit.

D Signaux PPG bruts

La figure suivante présente les signaux PPG bruts avant l'application des étapes de débruitage.




FIGURE 16 – Exemple de signaux PPG bruts avant traitement.