

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



Ines Boudjeli

Master Bases de Données et Intelligence Artificielle — Université de Bourgogne Europe

Laboratoire LIRIS (UMR 5205), équipe DRIM — INSA Lyon | Encadrantes de stage : Sonia Ben-Mokhtar, Nelly Barret. Encadrant universitaire : Eric Leclercq.



Plan de la présentation

01

Contexte

LIRIS, équipe DRIM, environnement de stage

03

Problématique & objectifs

Problématique, missions de stage

05

Méthodologie

Architecture DPnet et jeux de données

02

Le signal PPG

Définition, artefacts de mouvement

04

État de l'art

Méthodes classiques vs apprentissage profond

06

Résultats

Débruitage, évaluation par auto-encodeur

07

Bilan

Perspectives ,organisation, difficultés et compétences développées

Le LIRIS et l'équipe DRIM

LE LIRIS

Laboratoire d'Informatique en Image et Systèmes d'information

UMR 5205 rattachée au CNRS, à l'INSA de Lyon, à Lyon 1, à Lyon 2 et à l'École Centrale de Lyon

≈330

membres

12

équipes

6

pôles de compétences

Mission : produire des connaissances scientifiques en informatique, avec transfert vers l'enseignement et l'industrie.

L'ÉQUIPE DRIM

Distribution, Recherche d'Information et Mobilité

Dirigée par **Sonia Ben Mokhtar** (DR CNRS), pôle « Données, Système et Sécurité »

- Documents numériques & recherche d'information sémantique
- Gestion robuste et partage de données distribuées / mobiles
- Confiance, réputation et vie privée dans les systèmes répartis

Mon stage s'inscrit dans le projet REDEEM (PEPR IA) : apprentissage automatique de données multimodales

Environnement et outils de travail

Outils de travail quotidiens

1

VS Code

Développement des scripts et du prototype

2

GitLab

Gestion de version, suivi d'avancement du code

3

Overleaf

Rédaction du rapport

4

E-mail

Suivi du stage, échanges techniques

Recherche bibliographique & ressources de calcul

5

Google Scholar

Recherche bibliographique pour l'état de l'art

6

GitHub

Consultation d'implémentations de référence (baselines)

7

Pagoda

Serveur de calcul interne LIRIS pour les entraînements

8

Grid'5000

Plateforme nationale de calcul distribué pour la recherche



Qu'est-ce qu'un signal PPG ?

La photopléthysmographie (PPG) est une technique optique permettant de mesurer les variations du volume sanguin associées aux battements cardiaques.

Modèle du signal :

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

- **$s_{AC}(t)$ — composante cardiaque**
porte l'information utile : forme d'onde, battements.
- **$s_{DC}(t)$ — composante lente**
liée aux tissus et aux conditions d'acquisition.
- **$n(t)$ — perturbations**
artefacts de mouvement, bruit du capteur.



PPG propre (BIDMC, 125 Hz) vs PPG bruité pendant l'exercice (WristPPG, 256 Hz)

Les artefacts de mouvement :

1

Montre connectée

2

Estimation de la fréquence cardiaque

3

Perturbation par le mouvement

4

Conséquences



PROBLÉMATIQUE

Comment nettoyer automatiquement un signal PPG mesuré par une montre connectée afin de faciliter l'analyse de l'activité cardiaque ?



Objectif : développer une méthode efficace de débruitage des signaux PPG afin d'améliorer la détection des anomalies cardiaques.

Missions du stage

M1

État de l'art

Étudier les techniques classiques et les approches par apprentissage profond adaptées à la réduction du bruit dans les signaux PPG.

M2

Choix & étude de l'approche

Analyser l'architecture de DPNet et mettre en place une évaluation complémentaire à l'aide d'un autoencodeur.

M3

Développement


Concevoir et implémenter un prototype logiciel basé sur DPNet et évaluer ses performances sur les données.

Deux familles de méthodes de débruitage

Méthodes classiques

Exemple : le filtrage passe-bande [HA22]

Conserve les fréquences du rythme cardiaque (0,5–4 Hz) et atténue le reste du signal.




Avantage : simple, peu coûteux, temps réel possible.

Limite : artefacts et signal cardiaque partagent la même bande de fréquence pendant l'exercice.

Apprentissage profond

Exemple : l'autoencodeur récurrent BRDAE [LS19]

Comprime le signal bruité puis le reconstruit, en utilisant des LSTM bidirectionnels pour analyser le contexte avant/après.



Avantage : s'adapte à la variabilité des signaux et des artefacts.

Limite : traitement pas à pas → coût de calcul élevé sur de longues séquences.

Comparaison des approches et choix de DPNet

Critère	Filtrage classique	Deep learning (LSTM)	DPNet (Mamba)
Séparation bruit/cœur si bandes proches	Faible	Bonne	Bonne
Coût de calcul (longues séquences)	Très faible	Élevé ($O(L^2)$ /récuratif)	Faible ($O(L)$, linéaire)
Contrainte physiologique	Aucune	Rare	Oui (tâche auxiliaire HRP)
Besoin d'un capteur auxiliaire	Non	Parfois	Non

Jeux de données utilisés

BIDMC

Signal propre de référence

Milieu hospitalier, 125 Hz, 53 sujets, 8 min chacun — sert de vérité terrain pour l'entraînement.

WristPPG

Bruit réel de mouvement

18 enregistrements au poignet pendant marche / course / vélo, 256 Hz → sous-échantillonné à 125 Hz.

MIMIC-III


Évaluation par auto-encodeur

Segments PPG NSR (rythme sinusal normal) utilisés pour entraîner l'auto-encodeur convolutif de contrôle.

Construction du jeu d'entraînement :

- Segments de 6 s (750 pts, chevauchement de 4 s).
- Filtrage qualité HeartPy (fréquence 40–135 BPM, RMSSD < 100, SD1/SD2 < 6) → **10 662 segments valides**.
- Répartition : **72 % entraînement, 8 % validation, 20 % test**.

Architecture DPNet — vue d'ensemble




Signal PPG bruité → extraction de caractéristiques → modélisation temporelle bidirectionnelle → reconstruction → signal débruité, validé par une tâche auxiliaire de fréquence cardiaque.

Mamba & HRP : les deux briques clés de DPNet

Mamba

Bidirectional Mamba

Pour chaque pic du signal PPG, Mamba regarde ce qui se passe avant et après, afin de savoir s'il s'agit d'un vrai battement ou d'un artefact.



→ Mamba exploite ce contexte temporel pour distinguer le rythme cardiaque des perturbations.

HRP

Heart Rate Predictor

Le HRP estime la fréquence cardiaque (BPM) du signal débruité, et la compare à celle du signal propre.

Signal débruité

BPM estimé

↓
comparaison

Signal propre (référence)

BPM réel

L'écart entre les deux guide l'entraînement de DPNet

Lire les résultats : 5 métriques clés

Pour un bon débruitage, chaque métrique doit évoluer dans un sens précis :



MSE

Erreur de reconstruction entre le signal débruité et le signal propre : plus elle se rapproche de 0, mieux c'est.



CoS

Similarité de forme avec le signal propre : plus elle se rapproche de 1, mieux c'est.



SNRimp

Amélioration du rapport signal/bruit : une valeur positive indique un débruitage efficace.



HR-MAE

Erreur sur la fréquence cardiaque estimée : plus elle se rapproche de 0, mieux c'est.



Pearson (r)

Corrélation avec le signal propre de référence : plus elle se rapproche de 1, mieux c'est.

Débruitage : bruit modéré vs bruit élevé

Ensemble « bruit modéré » (3 000 segments)

Métrique	Bruité (avant)	Débruité (après)	Idéal
MSE ↓	0,0964	0,0289	0
Similarité cosinus ↑	0,957	0,987	1
SNRimp (dB) ↑	—	+5,82	positif
HR-MAE (BPM) ↓	38,4	10,0	0

Ensemble « bruit élevé » (10 662 segments)

Métrique	Bruité (avant)	Débruité (après)	Idéal
MSE ↓	0,0777	0,0367	0
Similarité cosinus ↑	0,964	0,983	1
SNRimp (dB) ↑	—	+4,03	positif
HR-MAE (BPM) ↓	42,6	11,8	0

Réduction de la MSE comprise entre 53 % et 70 % selon le niveau de bruit, et réduction d'environ 70 % de l'erreur d'estimation de la fréquence cardiaque (HR-MAE).

L'auto-encodeur convolutif

Objectif: confirmer les résultats du débruitage et évaluer son impact sur la détection des anomalies cardiaques.




- **Principe de l'évaluation**

Une MSE élevée = signal éloigné des caractéristiques normales.

Une MSE faible = signal cohérent avec un rythme sain


Distributions de la MSE de reconstruction



Bruit faible

raw → denoised : 0,1305 → 0,0475


-64 % de MSE médiane



Niveaux variés

raw → denoised : 0,2982 → 0,0651

-78 % de MSE médiane



Bruit élevé

raw → denoised : 0,4415 → 0,0714

-84 % de MSE médiane

Dans les trois cas, la courbe verte (denoised) se rapproche nettement de la courbe bleue (clean) et s'éloigne de la courbe rouge (raw) : le débruitage DPNet est confirmé de façon indépendante.

Lien avec la détection d'anomalies cardiaques

Le débruitage réduit l'erreur de reconstruction des signaux normaux bruités, ce qui peut limiter les fausses détections d'anomalies cardiaques :

- **Faible erreur de reconstruction → signal normal**
- **Forte erreur de reconstruction → signal potentiellement anormal**
- **Le débruitage réduit l'erreur des signaux normaux bruités**
- **DPNet peut ainsi améliorer la détection des anomalies cardiaques**

CONCLUSION

- **DPNet réduit efficacement le bruit**

-53 % à -70 % de MSE selon le niveau de bruit ; -70 % d'erreur sur la fréquence cardiaque estimée.

- **Validation indépendante confirmée**

Amélioration de la prédiction normal/anormal sur plus de 93 % des segments via l'auto-encodeur.



Perspectives

1

Signaux réels ambulatoires

Évaluer DPNet sur des enregistrements réellement acquis en conditions de mouvement.

2

Vrais signaux anormaux

Étudier l'effet du débruitage sur des cas réels d'arythmie ou de fibrillation auriculaire.

3

Données accéléromètre

Intégrer les données d'accélérométrie pour aider le modèle à mieux identifier et supprimer les bruits liés aux mouvements.

Organisation, difficultés et compétences

Organisation

- Suivi hebdomadaire avec les encadrantes
- Autonomie encadrée, étape par étape

Difficultés

- Architecture DPNet complexe au départ
- Entraînements longs (600 epochs)

Compétences développées

- Traitement du signal & architecture complexe
- Évaluation multi-critères, analyse critique

Ce stage m'a permis de mener un travail de recherche complet : compréhension d'une méthode existante, implémentation, évaluation critique et analyse de ses limites.

Merci de votre attention

Questions ?

