



**HAL**  
open science

# Fusion par lisseur de Kalman pour l'estimation de la fréquence respiratoire à partir de l'électrocardiogramme ou du photoplethysmogramme

Soumaya Khreis

► **To cite this version:**

Soumaya Khreis. Fusion par lisseur de Kalman pour l'estimation de la fréquence respiratoire à partir de l'électrocardiogramme ou du photoplethysmogramme. Traitement du signal et de l'image [eess.SP]. Université de Rennes, 2019. Français. NNT : 2019REN1S047 . tel-02444302

**HAL Id: tel-02444302**

**<https://theses.hal.science/tel-02444302>**

Submitted on 17 Jan 2020

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

# THESE DE DOCTORAT DE

L'UNIVERSITE DE RENNES 1  
COMUE UNIVERSITE BRETAGNE LOIRE

ECOLE DOCTORALE N° 601  
*Mathématiques et Sciences et Technologies  
de l'Information et de la Communication*  
Spécialité : *Signal, Image et Vision*

Par

**Soumaya KHREIS**

## **Fusion par Lisseur de Kalman pour l'Estimation de la Fréquence Respiratoire à partir de l'Electrocardiogramme ou du Photoplethysmogramme**

Thèse présentée et soutenue à Rennes, le 27 Juin 2019

Unité de recherche : Laboratoire Traitement de Signal et de l'Image LTSI – INSERM UMR1099

### **Rapporteurs avant soutenance :**

Julien OSTER                      CR, INSERM, Université de Lorraine  
Julien DEJONCKHEERE        HDR, Ingénieur de recherche, CHU Lille

### **Composition du Jury :**

Président : Pierre-Yves GUMERY	Professeur, Université de Grenoble
Examineurs : Anne HEURTIER	Professeur, Université d'Angers
Directeur de thèse : Guy CARRAULT	Professeur, Université de Rennes I
Encadrant de thèse : Di GE	Maître de conférences, Université de Rennes I



# Remerciements

Ce travail n'aurait pas été réalisé sans l'aide de nombreuses personnes envers lesquels je suis reconnaissante. Je tiens à exprimer mes remerciements à mon directeur de thèse à l'Université de Rennes 1, Guy Carrault, ainsi que Di Ge, mon encadrant. Votre soutien, votre expertise, vos conseils, vos suggestions ont été plus que précieux pour moi. J'ai appris énormément à vos côtés et je vous en suis très reconnaissante. Je tenais aussi à vous remercier pour la bienveillance dont vous avez fait preuve à mon égard. Travailler avec vous fut un réel plaisir.

J'exprime toute ma gratitude aux membres de mon jury de thèse. Merci à Julien Oster et Julien Dejonckere d'avoir accepté de rapporter mon travail de thèse. La pertinence de vos remarques et commentaires m'a permis d'améliorer à la fois le manuscrit et la présentation orale. Merci également à Anne Heurtier d'avoir accepté d'examiner mon travail. Merci à Pierre-Yves Gumery d'avoir présidé ce jury.

Je tiens à remercier Lotfi Senhadji, directeur du LTSI, pour son accueil et sa gentillesse durant ces trois ans. Un grand merci aux secrétaires du LTSI, Soizic, Patricia et Muriel pour leur support logistique et leur sympathie.

Un grand merci pour tous les collègues que j'ai eu l'occasion de rencontrer pendant ces années de thèse. Je remercie en particulier mes collègues du bureau : Jennifer Rizkallah, Batoul Dahman et Nasrine Tahiri, pour tout leur support et les agréables moments qu'on a passés ensemble.

Pour finir, j'aimerais remercier ma famille et mon mari pour tout leur support pendant les phases de stress. Vous avez toujours fait votre maximum pour ma réussite, je ne saurais jamais vous exprimer à quel point je vous en suis reconnaissante.

---

# Résumé

Ce mémoire de thèse vise à proposer de nouvelles méthodes robustes pour l'estimation de la fréquence respiratoire (FR) à partir des signaux physiologiques souvent utilisés dans la clinique comme l'électrocardiogramme (ECG) ou le photoplethysmogramme (PPG), tout en évitant de porter des capteurs encombrants et inconfortables. En effet, la respiration influence les signaux ECG et/ou PPG. Plusieurs modulations qui décrivent la respiration sont extraites basée principalement sur l'amplitude, la fréquence et la ligne de base. Il est toutefois difficile de déterminer la combinaison optimale des modulations pour obtenir une estimation précise de la FR en raison du bruit, la spécificité de chaque patient et de l'activité. Après une revue de la littérature, il ressort que peu de travaux ont étudié la qualité de ces modulations. Nous proposons donc de quantifier la qualité des modulations à l'aide d'indices de qualité respiratoire (IQR), un nouvel indice basé sur une modulation sinusoïdale est introduit. Puis, deux méthodes sont proposées : la première sélectionne automatiquement la modulation avec l'IQR le plus élevé pour une estimation de la FR, la seconde combine les deux meilleurs modulations avec le lisseur de Kalman (LK). Une nouvelle approche de fusion de modulations basée sur un modèle multimodale est également explorée. Ces méthodes sont évaluées sur trois bases de données de différents contextes cliniques : la surveillance dans les soins postopératoires (où les patients sont immobiles), le suivi pendant les activités physiques quotidiennes et la surveillance néonatale. Les résultats expérimentaux montrent que les IQRs associés à un algorithme de fusion augmentent la précision de l'estimation de la FR à partir des modulations dérivées et montrent des résultats supérieurs aux travaux issus de la littérature.

---

# Table des matières

1	Introduction Générale	9
1.1	Projet SHERPAM . . . . .	9
1.2	Objectifs . . . . .	11
1.3	Organisation . . . . .	12
1.4	Publications . . . . .	13
2	Estimation de la fréquence respiratoire : Contexte Bibliographie	15
2.1	Introduction . . . . .	15
2.2	Importance de surveiller la fréquence respiratoire . . . . .	16
2.3	Méthodes de surveillance de la respiration . . . . .	16
2.3.1	Méthodes directes . . . . .	17
2.3.2	Méthodes indirectes . . . . .	17
2.4	L'Electrocardiogramme et la respiration . . . . .	18
2.5	Le Photopléthysmogramme et la respiration . . . . .	21
2.6	Méthodes indirectes de l'estimation de la FR . . . . .	23
2.6.1	Extraction des modulations respiratoires . . . . .	23
2.6.2	Algorithmes d'estimation de la FR . . . . .	25
2.6.3	Algorithmes de fusion des FRs . . . . .	25
2.6.4	Qualité des modulations . . . . .	26
2.7	Conclusion . . . . .	29
3	Estimation de la Fréquence Respiratoire : Méthodes	31



3.1	Structure globale de la chaîne de traitement . . . . .	31
3.2	Prétraitement des signaux ECG/ PPG . . . . .	32
3.3	Indice de qualité respiratoire (IQR) . . . . .	37
3.3.1	IQR basée sur la Transformée de Fourier . . . . .	37
3.3.2	IQR basé sur l'Autocorrélation . . . . .	38
3.3.3	IQR basé sur un modèle Sinusoidal . . . . .	39
3.4	Estimation de la fréquence respiratoire . . . . .	42
3.4.1	Approche 1 : Sélection automatique des modulations . . . . .	42
3.4.2	Approche 2 : Fusion par le Lisseur de Kalman . . . . .	45
3.4.3	Lisseur de Kalman avec $m$ entrées . . . . .	52
3.5	Détection des cycles respiratoires . . . . .	53
3.6	Conclusion . . . . .	54
4	Estimation de la Fréquence Respiratoire : Résultats . . . . .	57
4.1	Introduction . . . . .	57
4.2	La base de données CAPNOBASE . . . . .	58
4.3	La base de données SHERPAM . . . . .	58
4.4	Evaluation des performances . . . . .	59
4.5	Résultats . . . . .	60
4.5.1	Effet du seuil sur la détection des cycles respiratoires . . . . .	60
4.5.2	Comparaison de la FR estimée avant et après LK . . . . .	63
4.5.3	Evaluation sur les signaux PPG (CAPNOBASE) . . . . .	64
4.5.4	Évaluation sur les signaux ECG (CAPNOBASE) . . . . .	68
4.5.5	Évaluation sur les signaux ECG (SHERPAM) . . . . .	69
4.6	Discussion . . . . .	73
4.7	Conclusion . . . . .	75
5	Fusion par le Lisseur de Kalman avec un modèle multimodal . . . . .	77
5.1	Introduction . . . . .	77
5.2	Motivation . . . . .	78

---

5.3	Méthodes . . . . .	78
5.3.1	Modèle multimodal . . . . .	78
5.3.2	Lisseur de Kalman avec modèle multimodal . . . . .	79
5.3.3	Initialisation Lisseur de Kalman (LK) . . . . .	81
5.4	Résultats . . . . .	82
5.4.1	Modèle unimodal vs bimodal . . . . .	82
5.4.2	Evaluation sur les signaux PPG (CAPNOBASE) . . . . .	86
5.4.3	Evaluation sur les signaux ECG (CAPNOBASE) . . . . .	87
5.4.4	Evaluation sur les signaux ECG (SHERPAM) . . . . .	88
5.5	Conclusion . . . . .	89
6	Estimation de la fréquence respiratoire : Application à la surveillance néonatale	91
6.1	Introduction . . . . .	91
6.2	La Base de données Néonatale . . . . .	92
6.3	Méthodes . . . . .	93
6.4	Estimation de la fréquence respiratoire . . . . .	94
6.5	D'autres applications : repérer des apnées . . . . .	96
6.6	Conclusion . . . . .	97
	Bibliographie	118
	Table des figures	119
	Liste des tableaux	124



# Chapitre 1

## Introduction Générale

La surveillance des signaux vitaux et de l'activité physique (AP) est d'un intérêt majeur dans les applications médicales. De nombreux auteurs ont souligné le bienfait de l'activité physique et de son retentissement sur le système cardio-vasculaire [1], [2], [3]. L'émergence des objets connectés a amplifié leurs mesures et des techniques d'évaluation subjectives ont suppléé les systèmes basés sur des capteurs. En effet, ces objets offrent des perspectives intéressantes pour surveiller la santé des personnes à tout moment et en tout lieu. La mesure et la surveillance de la pression sanguine, le rythme cardiaque, la fréquence respiratoire, qui n'étaient possibles qu'en laboratoire clinique, il y a encore quelques années, sont maintenant possibles à l'extérieur grâce aux bénéfices des nouvelles technologies [4], [5]. C'est l'objet de ce travail de thèse de proposer des solutions permettant une mesure fiable et robuste, en particulier l'estimation de la fréquence respiratoire.

### 1.1 Projet SHERPAM

Cette thèse s'inscrit dans le cadre du projet SHERPAM "Sensors for Health Recording and Physical Activity Monitoring", soutenue par le Labex (CominLabs, 2014). L'objectif du projet était de concevoir, implémenter et valider expérimentalement un système de détection ambulatoire capable d'exploiter en continu les données biophysiques recueillies sur des sujets mobiles. Le système a pour volonté à long terme de surveiller les signaux

vitaux, l'activité physique (AP) et la dépense énergétique liée (DE) pour deux types de populations : des personnes saines effectuant une activité physique et des sujets souffrant des membres inférieurs d'oblitération des artères au cours de leur vie quotidienne.

Le projet SHERPAM a donc eu pour ambition de développer une architecture permettant la quantification et la reconnaissance des activités physiques. Il était important de concevoir un système capable de mesurer des paramètres physiques et physiologiques pertinents qui ne limitent pas la mobilité des sujets. Ces derniers devraient être capables de pratiquer leurs activités quotidiennes de manière normale, tout en surveillant leur état de santé. Dans ce projet, le système est contrôlé par un smartphone qui collecte les données du capteur (Figure 1.1B), puis les transmet en continu sur un serveur local (Figure 1.1C). Pour assurer une transmission appropriée des données collectées, les réseaux de communications (2G/3G/4G et Wi-Fi) sont utilisés pour fournir une connectivité quasi continue des téléphones mobiles. Les données sont ensuite téléchargées et explorées via l'application Web SHERPAM (Figure 1.1D). Deux niveaux d'analyse de données sont considérés ; la première est une analyse préliminaire de données réalisée localement (sur le smartphone) à l'aide d'algorithmes légers, tandis que la seconde, consiste en un traitement plus robuste et effectue une analyse plus approfondie (sur le serveur).

Pour fixer les idées et inscrire le projet dans la réalité, prenant l'exemple d'un homme en sur-poids de 50 ans souffrant d'hypertension modérée et d'hypercholestérolémie. Ses consultants en santé et en forme physique lui ont conseillé de faire de l'exercice régulièrement pour perdre du poids et promouvoir un mode de vie plus sain. Ils lui ont fourni un programme d'entraînement consistant en divers types d'exercices quotidiens et heures hebdomadaires de pratique (par exemple, 1 heure de marche avec 3 séries de 10 minutes de course facile et 1 minute de repos entre les séries répétées chaque jour pendant une semaine). Le sujet utilise la plateforme SHERPAM qui lui permet de suivre son profil d'activité quotidienne et de surveiller ses signes vitaux. Le rôle de la plateforme SHERPAM est d'identifier avec précision, les activités réalisées, leur durée et l'efficacité énergétique liée à chaque activité. Si le sujet est impliqué dans une activité vigoureuse, la plateforme détecte un effort accru et examine sa fréquence cardiaque (FC). S'il entre dans une zone

à risque concernant son activité cardiaque, la plateforme lui recommande de réduire ses efforts, car une activité physique excessive peut affecter son état de santé.

## 1.2 Objectifs

L'objectif de cette thèse s'inscrit bien dans ce scénario. Il est en particulier d'étudier la faisabilité d'une surveillance respiratoire fiable à partir de capteurs non invasifs. L'étude porte sur l'estimation de fréquences respiratoires (FR) à l'aide de l'électrocardiogramme (ECG), et de photopléthysmogramme (PPG), capteurs généralement facilement embarquables. Les modulations de la respiration sont généralement observées sur les signaux ECG/ PPG, et sont étudiées dans les contextes cliniques [6]. Ces signaux sont souvent choisis car ils peuvent être acquis de manière non invasive par des capteurs déjà intégrés, contrairement aux capteurs de respiration (e.g. spiromètre ou magnétomètre) qui sont coûteux et encombrants pour le patient. La solution de l'estimation de la fréquence respiratoire par dérivation ne nécessiterait donc pas de matériel ni de dispositifs de surveillance supplémentaires, mais uniquement du matériel pour l'enregistrement de l'ECG




FIGURE 1.1 – Architecture Générale du projet SHERPAM.

et/ou PPG couramment utilisé pour diagnostiquer et surveiller de nombreux dysfonctionnements cardiaques.

Il existe cependant de nombreuses difficultés. Elles sont liées : aux artefacts nombreux dans les signaux physiologiques ECG et/ou PPG liés au bruit provenant des capteurs, aux mouvements des patients. De plus, les modulations extraites de ces signaux sont multiples mais sont aussi bruitées.

Les contributions de cette thèse tiennent : i) sur la validation et la proposition d'indices de qualité respiratoires (IQRs) qui permettent de quantifier la qualité des modulations extraites, dans le but de choisir la modulation optimale ; ii) sur la proposition de plusieurs techniques d'estimation de la FR à partir des signaux quotidiens qui pourraient être utiles dans de nombreuses applications cliniques. La première consiste la sélection des modulations en se basant sur les IQRs et la seconde approche combine plusieurs modulations avec un Lisseur de Kalman basé sur un modèle multimodal fréquentiel. iii) sur la sélection du mode le plus adapté. Les performances de ces propositions sont également évalués sur plusieurs bases de données de contextes cliniques différents et une comparaison avec les performances des méthodes existantes dans la littérature pour l'estimation de la FR est aussi proposée.

## 1.3 Organisation

Pour répondre à cette problématique, nous aborderons dans le chapitre 2 l'importance de la fréquence respiratoire et les techniques de surveillance. Nous introduisons aussi un bref état de l'art sur les méthodes existantes dans la littérature.

Le chapitre 3 présentera les méthodes de prétraitement des signaux ECG et/ou PPG, les méthodes d'extraction des modulations, ainsi que, les deux approches proposées. L'originalité dans notre proposition est d'obtenir une estimation fiable et robuste de la FR en se basant sur des indices de qualité respiratoire (IQR) qui permettent de quantifier la qualité des modulations extraites dans le but de choisir la modulation optimale.

Le chapitre 4 présentera les résultats obtenus des deux méthodes sur deux bases de

données dans des conditions de mesure différentes. Une comparaison des performances avec les méthodes de la littérature sera également décrite.

Bien qu'intéressant, nous nous sommes interrogés dans le chapitre 5 sur la pertinence d'utiliser plusieurs modes fréquentiels et nous avons mesuré leur impact sur la qualité d'estimation de la FR. Enfin, le chapitre 6, nous ramène au coeur d'une problématique traitée au sein de notre laboratoire. La mesure de la FR chez le nouveau né placé en unité de soins intensifs. Nous avons au cours de ce chapitre tenter de démontrer la portée de nos travaux.

## 1.4 Publications

Les résultats de cette thèse ont fait l'objet des publications suivantes

### Revue Internationales :

1. KHREIS S., GE D., CARRAULT G., Breathing Rate Estimation Using Kalman Smoother with Electrocardiogram and Photoplethysmogram, IEEE Transactions on Biomedical Engineering (TBME), 2019
2. ABDUL RAHMAN H., BAGOT M., KHREIS S., BOULANGER J., DUMONT R., GASTINGER S., GE D., GUIDEC F., Le FAUCHEUR A., LAUNAY P., PRIOUX J., QUINTON P., SOMAT A., VILLE N., CARRAULT G. : SHERPAM : an open, versatile platform for mobile e-Health. Preliminary Results, soumis à Sensors

### Conférences Internationales :

1. KHREIS S., GE D., CARRAULT G., Estimation of Breathing Rate From the Photoplethysmography Using Respiratory Quality Indexes, 45th Computing in Cardiology, Maastricht, Netherlands, 2018
2. KHREIS S., GE D., CARRAULT G., Multi-frequency model fusion for robust breathing rate estimation, 46th Computing in Cardiology, Singapore, 2019 .





# Chapitre 2

## Estimation de la fréquence respiratoire : Contexte Bibliographie

### 2.1 Introduction

La fréquence respiratoire (FR) est un paramètre vital très informatif de l'état physiologique du patient [7], [8], [9]. Elle joue un rôle clef dans différents troubles tels que les troubles du sommeil, et dans les applications telles que la santé et le bien-être [10], [11], [12]. La surveillance continue de la FR fournit donc de précieuses informations sur l'état de santé du patient à l'hôpital ou à la maison [13], [14].

Ce chapitre propose une synthèse sur les recherches effectuées dans le domaine de l'estimation de la FR. Dans un premier temps, nous présentons l'importance de surveiller la FR dans le domaine médical et de la santé. Ensuite, nous présentons les différentes méthodes de surveillance de la FR. Puis, les différentes techniques d'extraction des modulations respiratoires, et d'estimation de la FR sont décrites. Enfin, une description des différentes méthodes de fusion existantes dans la littérature pour combiner les FRs est présentée.

## 2.2 Importance de surveiller la fréquence respiratoire

Il existe de nombreuses raisons cliniques pour estimer de manière fiable la FR [11]. C'est un indicateur très informatif sur l'état physiologique des patients, généralement requis dans les applications cliniques telles que la surveillance ambulatoire, les tests de stress et les études de sommeil. En outre, c'est un indice de diagnostic et pronostic pour différents maladies telles que les maladies rénales, les maladies cardiovasculaires, les maladies pulmonaires [15], [16], [17], [18], [19].

Par ailleurs, la surveillance de la respiration est souvent nécessaire pour comprendre la signification clinique de certaines arythmies cardiaques par référence à la respiration [20]. La mesure de la respiration sans l'utilisation d'appareils encombrants est une technologie particulièrement intéressante dans la synchronisation et la compensation des activités respiratoires durant les examens IRM pour des séquences du cœur et du thorax [21].

L'enregistrement des fonctions cardiaques et respiratoires chez les patients est important pour surveiller la façon dont les analgésiques dépriment la respiration [22]. Pendant les soins d'urgence, c'est aussi un indicateur sensible pour diagnostiquer des maladies graves comme la septicémie, et détecter la nécessité d'une ventilation mécanique [23], [24]. Elle est également très utile dans le sport comme un marqueur fiable pour déterminer le seuil d'anaérobie (le niveau d'exercice le plus élevé pouvant être maintenu pendant de longues périodes) [25], [26]. Ces raisons cliniques montrent l'importance d'une estimation fiable de la FR.

## 2.3 Méthodes de surveillance de la respiration

Les méthodes existantes d'acquisition et d'analyse des signaux respiratoires sont divisées en deux catégories : les méthodes directes et indirectes.

### 2.3.1 Méthodes directes

Parmi les méthodes directes connues pour la mesure de la respiration, on retrouve : i) le spiromètre qui mesure les volumes d'air lors des mouvements respiratoires [27], ii) le thermistance nasale/thermocouple qui mesure la variation de température dans l'air, iii) la pléthysmographie par impédance qui mesure le changement d'impédance électrique dans la poitrine et l'abdomen lors de la respiration [22], iv) la pléthysmographie par inductance qui mesure le changement du volume corporel [28], [29], v) le pneumotachographie qui mesure les variations de pression dans la bouche et/ou le nez [11], vi) la capnographie qui mesure le taux de dioxyde de carbone CO<sub>2</sub> dans l'air inspiré [20], [30].

La pléthysmographie par impédance est le capteur le plus couramment utilisé dans les hôpitaux [31]. Cependant, elle nécessite le placement du capteur autour du thorax et nécessite que les patients soient immobiles. Elle est donc souvent inconfortable à porter pendant des longues durées [32]. Ces techniques nécessitent l'utilisation des dispositifs qui sont généralement encombrants, coûteux, voire même invasifs dans certains cas [33]. Pour ces raisons, des méthodes indirectes ont été étudiées comme étant une solution alternative basée principalement sur les savoir-faire en traitement de signal.

### 2.3.2 Méthodes indirectes

L'inférence des informations respiratoires à partir des dispositifs non invasifs est particulièrement intéressante pour le confort des patients. Parmi les méthodes indirectes, les données issues de l'électrocardiogramme (ECG) et le photoplethysmogramme (PPG) sont souvent utilisées [34]. Les avantages potentiels de ces méthodes sont leur faible coût, le confort pour le patient et la capacité à surveiller simultanément l'activité cardiaque et respiratoire [35]. En effet, l'ECG et le PPG sont les signaux les plus surveillés d'une manière continue et sont largement adoptés en routine clinique. Le premier correspond à la dépolarisation et repolarisation électrique du myocarde, et le deuxième à la saturation en oxygène (SpO<sub>2</sub>) obtenue par oxymètre. Le dernier est largement adopté dans la routine clinique, e.g. pour le diagnostic de l'apnée du sommeil [36].

## 2.4 L'Electrocardiogramme et la respiration

### Le cœur : généralités

L'électrocardiogramme (ECG) est un enregistrement graphique de l'activité électrique produite par le cœur. Le cœur est une pompe à quatre chambres comprenant deux oreillettes (oreillette droite et gauche (OD et OG)) et deux ventricules (ventricules droite et gauche (VD et VG)). Le système nerveux autonome excite le noeud sinusal qui génère une impulsion électrique (voir Figure 2.1). Cette impulsion électrique est transmise le long des oreillettes par les voies internodales, conduisant à une dépolarisation auriculaire et donc à une contraction auriculaire.

A chaque battement du cœur, la dépolarisation synchronisée qui se propage dans le coeur provoque des courants dans le fluide extracellulaire qui établissent des potentiels de champs sur tout le corps [37]. Ces différences de potentiel peuvent être détectées par des électrodes placées à la surface du corps. Ces caractéristiques ont été nommées comme PQRST par Einthoven [38]. Ce cycle est répété à chaque battement de cœur. L'onde P est générée par la dépolarisation auriculaire. Le complexe QRS correspond à la dépolarisation ventriculaire et l'onde T correspond à la repolarisation ventriculaire. Dans la surveillance à court terme à des fins de diagnostic, un ECG à 12 dérivations est généralement utilisé [37]. La morphologie et les variations temporelles de ces ondes représentent des informations utilisées pour le diagnostic des arythmies affectant l'activité électrique du cœur [39].

### Influence de la respiration sur le signal ECG

Au cours de la respiration, des modifications morphologiques surviennent sur le signal ECG en raison des mécanismes physiologiques [40]. Les trois principales modulations extraites sont basés sur l'amplitude (RPA), la fréquence (RSA) et la ligne de base (QRA) [41], [42], [43] [44]. La Figure 2.3 illustre un exemple de ces trois modulations. Les mécanismes physiologiques sont décrites ci-dessous :

1. les modulations RPA et QRA sont décrites par les modifications de l'orientation




FIGURE 2.1 – Représentation d'un électrocardiogramme durant un cycle cardiaque : les différentes ondes caractéristiques (P,Q,R,S et T) sont représentées conjointement avec l'activité électrique du cœur correspondante (Fédération Française de cardiologie).

des axes électriques du cœur par rapport aux électrodes ECG [35], et par les modifications du volume pulmonaire au cours des cycles d'inspiration et d'expiration. L'expansion et la contraction du thorax qui accompagne la respiration entraînent le mouvement des électrodes thoraciques par rapport au cœur (Figure 2.2). Cela peut provoquer une déviation de la ligne de base dans l'ECG, généralement observée uniquement lors d'une respiration profonde ou exagérée [45], [35].

2. les modulations RSA sont représentées par l'augmentation de la fréquence cardiaque pendant l'inspiration et la diminution pendant l'expiration [11]. Ce phénomène est appelé arythmie sinusale respiratoire (ASR).




FIGURE 2.2 – Mécanismes de la respiration (Encyclopédie britannique).




FIGURE 2.3 – A) Exemples de modulations extraites du signal ECG. rouge (QRA), vert (RSA) et orange (RPA). B) signal respiratoire référence.

## 2.5 Le Photopléthysmogramme et la respiration

Le photopléthysmogramme (PPG) est un signal mesuré à l'aide d'un oxymètre (Figure 2.4). Il est mesuré en appliquant un capteur sur la peau ou par imagerie sans contact d'une région de la peau à l'aide d'une caméra [18]. C'est une technique non invasive permettant de quantifier la saturation en oxygène de l'hémoglobine ( $SpO_2$ ) au niveau des capillaires sanguins. Le tissu est illuminé en utilisant une source de lumière (source LED) et la lumière réfléchie est mesurée par un photodétecteur [46]. L'infrarouge est principalement utilisé car elle est relativement bien absorbée par le sang et faiblement absorbée par les tissus.

Le signal PPG est mesuré en continu chez les patients gravement malades et peut être surveillé chez les patients ambulatoires à l'aide d'un capteur portable. Il a l'avantage de pouvoir être acquis dans les différentes parties du corps (les doigts, les oreilles, le front) en fonction de l'activité spécifique.

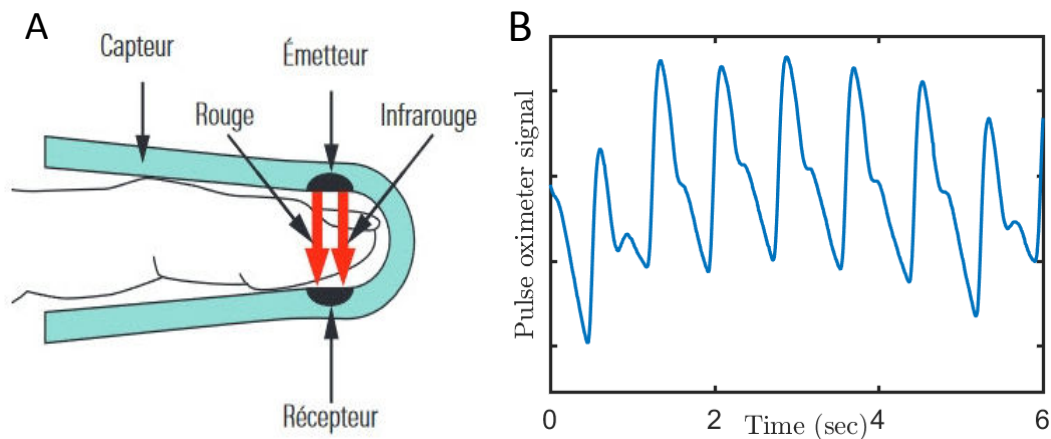


FIGURE 2.4 – A) Oxymètre de pouls qui permet de mesurer la concentration en oxygène  $SpO_2$ . B) Représentation d'un signal d'oxymétrie de pouls [47].



## Influence de la respiration sur le signal PPG

De même que le signal ECG, le signal PPG est influencé par la respiration [48]. Trois principales modulations modifient la morphologie du signal PPG. Elles sont basées sur : l'amplitude (RIIV), la fréquence (RIFV) et la ligne de base (RIAV) (Figure 2.5).

i) la modulation RIIV est due aux variations dans la pression intrathoracique qui se traduit par une modification de l'amplitude des pics du signal PPG [49], [46].

ii) la modulation RIAV est causée par une diminution du débit cardiaque due à une diminution du remplissage ventriculaire réduit pendant l'inspiration [18], [50], [46].

iii) la modulation RIFV est la variation de la fréquence cardiaque instantanée pendant les cycles respiratoires. Ce phénomène est connu sous le nom d'arythmie respiratoire sinusale (ARS) réguler par le nerf vagal [49].




FIGURE 2.5 – A) Exemples de modulations extraites du signal PPG. rouge (RIIV), vert (RIFV) et orange (RIAV). B) signal respiratoire référence.

## 2.6 Méthodes indirectes de l'estimation de la FR

Les algorithmes d'estimation de la FR peuvent être divisés en quatre étapes, comme illustré dans la Figure 2.6. i) le prétraitement pour éliminer les très basses fréquences du signal d'entrée (ECG et/ou PPG) ii) l'extraction des modulations contenant de l'information sur les activités respiratoires, iii) l'estimation de la FR, ou éventuellement iv) la fusion des FRs. Ces étapes peuvent être appliquées quelque soit le signal à l'entrée (l'ECG et/ou PPG).

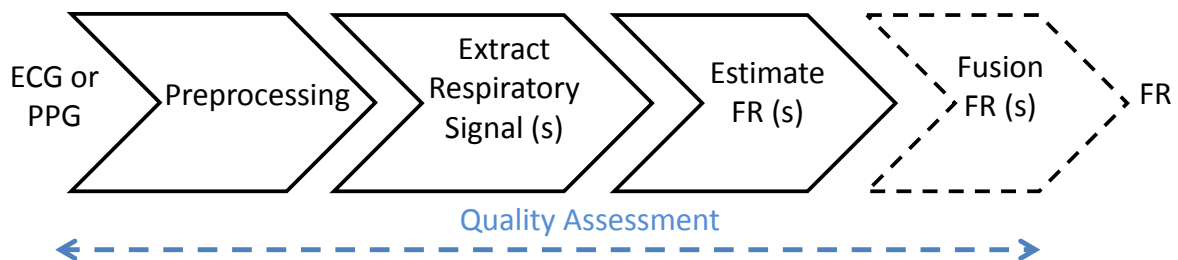


FIGURE 2.6 – Les quatre étapes de l'algorithme d'estimation de la fréquence respiratoire (FR), à partir du signal ECG ou PPG. Le bloc en pointillé est facultative [42].

### 2.6.1 Extraction des modulations respiratoires

Les techniques d'extraction des modulations sont basées sur les variations de morphologie induite par la respiration et on peut les observer sur l'ECG (RPA, QRA) et le PPG (RIAV) [51], tandis que d'autres tentent d'extraire l'information respiratoire à partir de la fréquence cardiaque (FC) (RSA) dans le cas de l'ECG ou PPG [11], [52], [53]. La première méthode d'extraction de modulations basée sur les variations morphologiques du vectocardiogramme (VCG) a été proposée en 1974 par Wan et al. [51]. Ensuite, Moody et al. [20] ont proposé d'exploiter les variations de la direction de l'axe électrique du cœur induit par les cycles respiratoires. Ces algorithmes nécessitent l'utilisation de multiples dérivations de l'ECG.

Plusieurs techniques ont été donc proposées dans la littérature pour extraire les modulations à partir d'une seule dérivation de l'ECG et sont basées sur les variations morphologiques. Ses caractéristiques sont extraites battement par battement telles que l'amplitude de l'onde R [54], [55], [56], la différence d'amplitude entre l'onde Q et R [54], [57], l'aire de l'onde QRS [58], [42], [56], la pente de l'onde QRS [39]. Ces méthodes nécessitent une détection précise de l'onde QRS et des pics R. Des erreurs éventuelles dans la détection des complexes QRS peuvent dégrader leurs performances. Alors que, l'obtention de la FR sur le plan médical est difficile, de nombreuses méthodes différentes ont été utilisées pour essayer d'extraire une ou plusieurs modulations de l'ECG et du PPG, notamment : en appliquant les transformations des complexes QRS identifiés [35] telles que l'analyse en composantes principales (ACP), Kernel ACP (KACP) [59], [60] et l'analyse en composantes indépendantes (ICA) [61]. La méthode ACP prend en compte la relation linéaire entre la respiration et l'ECG tandis que le KACP a été introduite afin de surmonter les inconvénients de la linéarité dans l'ACP. La méthode ICA décompose l'ECG en sous-composants statistiquement indépendants, dont l'un pourrait être corrélé à la respiration [61]. D'autres méthodes sont fondées sur la transformation et la décomposition des modulations de l'ECG. Des méthodes de filtrage telles que le filtre passe-bande [62], la transformée en ondelettes discrète (DWT) [62], la décomposition en mode empirique (EMD) [63], [64] et le filtre homomorphique [65] ont été utilisées pour l'extraction des modulations. L'hypothèse principale de ces techniques est que les informations des activités respiratoires sont contenues dans la bande de fréquence usuelle de la respiration pour l'extraction des modulations. Des méthodes récentes basées sur le processus gaussien et les méthodes de reconstruction de l'espace de phase, ont été proposées dans [35], [66].

Or, les méthodes basées sur la variations de la FC dépendent de l'âge et des maladies des patients et les performances sont sensibles à ces facteurs [11]. Dans notre travail, nous nous sommes concentrés sur l'extraction des modulations à partir d'une seule dérivation de l'ECG et sur les modulations basées sur les variations morphologiques et fréquentielles du signal.

### 2.6.2 Algorithmes d'estimation de la FR

Plusieurs méthodes ont été proposées pour estimer la FR à partir d'une fenêtre de données provenant de la modulation extraite. Cela peut être effectué dans le domaine temporel ou dans le domaine fréquentiel.

Les techniques du domaine temporel impliquent la détection des cycles respiratoires en utilisant un algorithme de détection en identifiant les passages par zéro avec un gradient positif [44]. D'autres méthodes de détection des cycles à partir des pics et des creux en utilisant un seuillage (adaptatif) pour identifier les respirations détectées de manière fiable [67], [68], [69], ont été décrites. Les techniques dans le domaine temporel ont l'avantage de ne pas nécessiter des modulations quasi-stationnaires bien qu'ils soient sensibles à la morphologie des modulations [60].

Les techniques relevant du domaine fréquentiel impliquent d'identifier la composante de fréquence liée à la respiration par la transformée de Fourier [18], la transformation de Fourier à court terme [70], la modélisation autoregressive avec une FR qui correspond au pôle de plus grande amplitude [24], ou de plus faible amplitude [71], [72], [73] le processus de gaussien [35]. Des études ont estimé la fréquence en utilisant un filtre coupe-bande ou filtre adaptatif [70]. Dans notre laboratoire, une approche temporelle pour la détection des cycles respiratoires a été proposé [74]. Succinctement, son principe est basé sur la détection des extrema, qui ne seront validés que si la différence relative entre les pics dépasse un coefficient prédéfini (amplitude entre pics précédents multipliés par un coefficient). Cet algorithme a servi de base à nos travaux et est percuté plus en détail au chapitre 3, section 3.5.

### 2.6.3 Algorithmes de fusion des FRs

La fusion des modulations a été utilisée récemment pour améliorer la robustesse et les performances de l'estimation de la FR. Plusieurs approches ont été proposées pour fusionner les FRs estimées à partir des modulations dérivées. Mason et al. [54] ont démontré qu'en exploitant les signaux de modulation, le pourcentage d'erreur moyen est d'envi-

ron 50% ou plus, tandis que la combinaison des FRs avec le filtre de Kalman améliore considérablement les résultats et réduit le pourcentage d'erreur moyen à 20%. De même, Orphanidou et al. [32] ont proposé de fusionner les informations des modulations RSA et RPA extraites de l'ECG à l'aide d'un modèle autoregressive (AR), une erreur absolue moyenne de 0.81 bpm est rapportée pour les sujets jeunes et de 0.84 bpm pour les sujets âgées. Karlen et al. [18] ont proposé un algorithme de combinaison des FRs extraites à partir des modulations du signal PPG (RIAV, RIIV et RIFV). Bien que leur méthode améliore l'estimation, un grand nombre de fenêtres sont rejetées, aux alentours de 36%. Une étude récente [75] a utilisé les descripteurs de Hjorths pour calculer un métrique de pureté spectrale pour les modulations extraites. Cette mesure a été incorporée dans une méthode de fusion en utilisant le filtre de Kalman afin d'augmenter les performances d'estimation. Birrenkott et al. [43] ont proposé la régression linéaire pour fusionner différents indices de qualité respiratoire (IQRs) en un seul indice. Sur la base d'un seuil ajustable, les IQRs sont utilisés pour rejeter les modulations de mauvaises qualités et conserver celles de bonne qualité pour fournir une estimation de FR. Nous traiterons ce sujet dans le chapitre 3 et montrerons notamment la relation non-linéaire entre les erreurs de l'estimation et les IQRs testés (qualité de modulations).

#### 2.6.4 Qualité des modulations

La méthodologie d'extraction de la FR présente toutefois un certain nombre de limitations liés à la qualité des modulations obtenues, par exemple les fréquences non respiratoires dans les basses fréquences qui ne sont pas été supprimés lors d'extraction des modulations [41]. En particulier, les techniques d'évaluation de la qualité des modulations ne sont pas utilisés dans toutes les études, elles sont divisées en deux catégories : les indices de qualité du signal (IQS) et les indices de qualité de modulations respiratoire (IQR).

Les IQSs sont utilisés pour identifier les segments de faible qualité dans les signaux ECG et/ou PPG [42]. Ces artéfacts sont d'origine de divers facteurs, notamment : câbles détachés, faible rapport signal-bruit, mauvais positionnement du câble, etc. Ces segments

	IQS	IQR
Point commun	Objectif : recherche de la régularité dans un signal	
Différences	appliqué directement sur le PPG pour rejet d'artéfacts	appliqué sur les modulations pour détecter les activités respiratoires
Algorithmes	descripteurs de Hjorths [76], Accord entre plusieurs détecteurs de battements [77], caractéristiques liés aux battements : les intervalles et amplitudes [18]	descripteurs de Hjorths, TF, Autocorrélation, Autorégression [43], [75], analyse statistiques des variations des pics respiratoires [78]

TABLE 2.1 – Tableau de comparaison entre IQS et IQR.

sont généralement rejetées car les FRs estimés de ces segments risquent d'être imprécis [18]. Des paramètres de Hjorths ont également été utilisés pour quantifier la qualité du signal [76]. De plus, la qualité du signal peut être évaluée en utilisant plusieurs détecteurs des ondes QRS de l'ECG, un accord entre les détecteurs indiquent une bonne qualité [77].

En plus des IQSs, un développement récent dans l'évaluation de la qualité des modulations dans les algorithmes de FRs a été la dérivation des indices IQRs qui permettent de quantifier la qualité des modulations dérivées [43], [78], [18], [75]. Les IQRs sont un développement important car la présence ou l'absence d'informations respiratoires extraites de l'ECG ou du PPG est indépendante de la qualité globale de ces signaux et varie en fonction de facteurs tels que le sexe, l'âge, l'état de santé préexistant, le niveau d'hydratation, la position du corps [21], [75], [79]. Les difficultés sont liées au fait que les modulations respiratoires sont spécifiques pour chaque patient et qu'il est difficile de fixer la modulation la plus pertinente pour un patient donné.

Plus précisément, les IQRs évaluent la qualité des modulations respiratoires en fonction de la régularité des cycles respiratoires et de la périodicité de la forme d'onde respiratoire. Des techniques temporelles et fréquentielles ont été utilisées telles que : l'analyse statistique des variations des pics respiratoires [78], les descripteurs de Hjorths, la transformation de Fourier, l'autorégression et l'autocorrélation [43], [75]. Il a été montré que l'utilisation des IQRs permet d'obtenir une estimation plus précise de la FR, en rejetant les segments artéfactés qui ne portent pas l'information respiratoire [21]. Le tableau 2.1

résume les points communs et les points de différences entre les deux indices IQS et IQR.

Birrenkot et al. [43] ont fait une comparaison entre les performances des IQRs basés sur la transformée de Fourier, l'autoregression, l'autocorrélation et les descripteurs de Hjorths et les performances d'un récent algorithme de IQS développé [80]. Le IQS est basé sur un algorithme de comparaison des pics en utilisant deux détecteurs des pics pour le PPG et deux détecteurs de pics de l'onde R pour l'ECG. Le but est de tester si les IQRs améliorent la capacité de déterminer quelles modulations fournissent de bonnes ou mauvaises informations respiratoires par rapport à ceux juger de mauvaises qualités par le IQS. Les tests sont faites sur les signaux ECG et PPG. Les résultats dans la Figure 2.7 montrent que les indices FFT-IQR, AR-IQR et AutoCor-IQR surpassent le IQS [81]. En effet, les indices de qualité des modulations (IQRs) qui sont proposés dans [43] sont utilisés dans la suite de notre thèse.

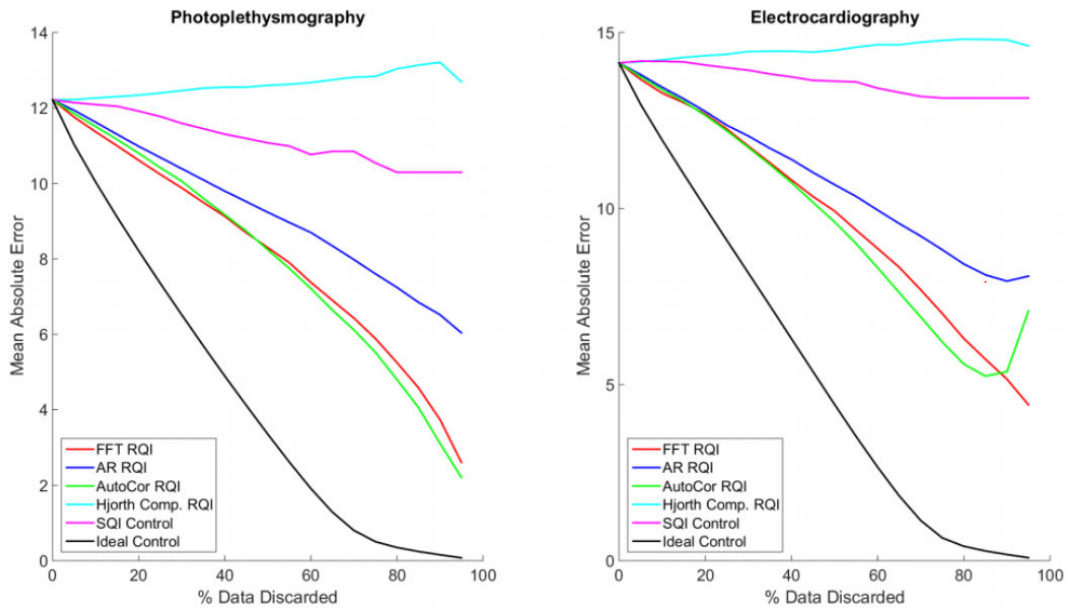


FIGURE 2.7 – Comparaison des performances en erreur absolue moyenne (MAE) entre les indices de qualité respiratoires (IQRs) et l'indice de qualité de signal (IQS) sur les signaux PPG (panneau gauche) et sur les signaux ECG (panneau droite) [81].

## 2.7 Conclusion

Ce chapitre a pour objectif de présenter un large éventail de travaux réalisés dans les domaines d'extraction des modulations et d'estimation de la FR à partir des signaux de modulations. Les différentes techniques d'estimation de la FR dans le domaine temporel et fréquentiel ont été introduites. Les travaux dans la littérature ont montré que la fusion des FRs apporte une nette amélioration dans l'estimation de FR. Or, peu de recherches ont été menées sur l'utilisation d'un modèle pour les modulations respiratoires [42]. Seul Womack et al. [82] ont présenté un modèle reliant l'arythmie sinusale respiratoire à la respiration. Notre hypothèse est que si un tel modèle mathématique est couplé avec un algorithme d'estimation de FR, nous pourrions davantage améliorer les performances tout en rejetant moins de segments. Le chapitre suivant adresse ces problèmes et présente une méthode de fusion des modulations basée sur un modèle paramétrique.





# Chapitre 3

## Estimation de la Fréquence

### Respiratoire : Méthodes

Le chapitre précédent a permis de montrer l'intérêt de l'estimation de la fréquence respiratoire (FR) à partir d'exploration ambulatoire. Nous avons aussi souligné que des voies d'améliorations étaient possibles. C'est l'objet de ce chapitre de présenter les fondements théoriques des approches que nous avons proposées dans ce sens. Ce chapitre présente donc les méthodes de traitement des données appliquées pour l'estimation de la FR. Le prétraitement des signaux, ainsi que l'extraction des modulations à partir des signaux ECG et/ou PPG sont également décrits. Ensuite, les indices de qualité respiratoire (IQRs) utilisés pour quantifier les signaux dérivés sont abordés. Puis, les deux approches proposées pour l'estimation de la FR sont présentées. La première approche se fonde sur une sélection automatique des modulations de bonne qualité. La deuxième approche consiste à fusionner plusieurs modulations en utilisant le Lisseur de Kalman (LK) pour une estimation plus robuste de la FR.

#### 3.1 Structure globale de la chaîne de traitement

L'architecture générale de la chaîne de traitement proposée est décrite dans la Figure 3.1. Elle se compose de cinq étapes principales : 1) l'extraction des modulations à

partir des signaux ECG et/ou PPG (Figure 3.1A), 2) le calcul des indices de qualité respiratoire (IQRs) pour chaque type de modulation dérivée (Figure 3.1B), 3) la sélection de la modulation (première approche) avec l'IQR le plus élevé (Figure 3.1C), 4) l'utilisation du Lisseur de Kalman (seconde approche) pour fusionner plusieurs modulations vérifiant un seuil donné (Figure 3.1D), 5) L'estimation de la FR à partir du signal de sortie obtenu de la première ou seconde approche (Figure 3.1E). Ces méthodes sont détaillées dans les sections suivantes.

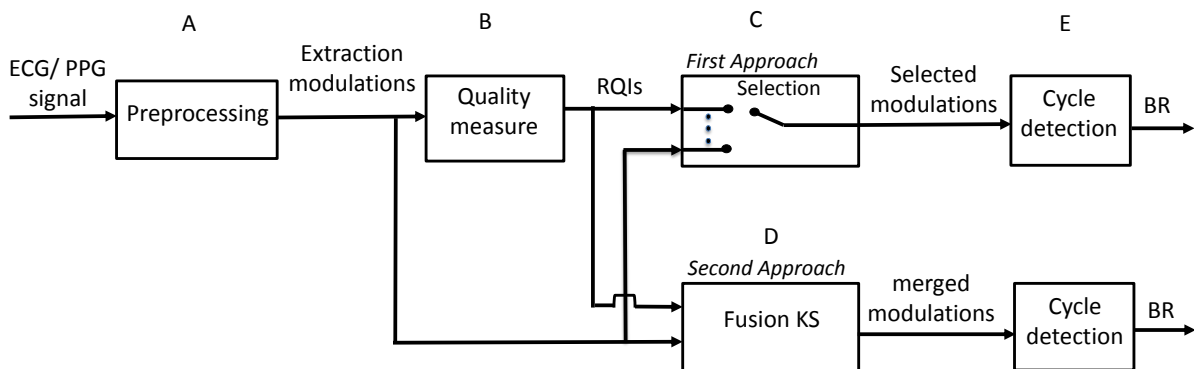


FIGURE 3.1 – Architecture générale de la chaîne de traitement.

## 3.2 Prétraitement des signaux ECG/ PPG

Les signaux ECG sont souvent perturbés par plusieurs types de bruit tels que : l'interférence à 50/60Hz qui provient de l'alimentation des appareils de mesure, le bruit provenant du contact avec les électrodes, le mouvement du patient [83]. Le signal ECG est filtré par un filtre passe-bande, la fréquence de coupure passe-haut est choisie à 0.5Hz pour éliminer l'effet de la ligne de base. La fréquence de coupure du filtre passe-bas est choisie à 45Hz afin d'éliminer le bruit du secteur et tout autre bruit de haute fréquence, tout en préservant les caractéristiques de l'amplitude de l'onde QRS de l'ECG.

Concernant le signal PPG, les artéfacts peuvent être induits par tout phénomène entraînant une variation de la lumière reçue par le capteur PPG. Le mouvement du sujet

pendant que le capteur est attaché à son doigt peut modifier la quantité de lumière transmise (ou reçue) et donne lieu à ce que l'on appelle un artéfact de mouvement. Les signaux PPG sont donc filtrés par un filtre passe-bande [0.05-4 Hz] [43], pour éliminer les basses et les hautes fréquences.

## Extraction des modulations du signal ECG

Les modulations que nous souhaitons estimer imposent la détection du QRS. La détection automatique des complexes QRS a connu depuis de nombreuses années de multiples développements. Une bibliographie est reportée dans [84]. Dans ce travail, nous avons utilisé un algorithme de détection des ondes QRS en temps réel développé dans notre laboratoire [85]. Après la détection des ondes Q, R et S du signal ECG, ces derniers sont utilisés pour la construction des modulations respiratoires (Figure 3.2). Quatre modulations sont dérivées :

1. le RPA qui représente les variations d'amplitude des pics R en anglais R-peaks amplitude [86].
2. le QRA qui correspond à la différence d'amplitude entre les pics Q et R pour réduire l'effet de la ligne de base. Le pic Q est trouvé en recherchant la valeur minimale de l'ECG dans une fenêtre temporelle de 0.2 sec de l'onde R [60].
3. le RSA qui correspond à la différence de temps entre deux pics R successifs, elle fait référence à la variation cyclique de la fréquence cardiaque associée à la respiration (en anglais Respiratory Sinus Arrhythmia RSA).
4. le AQRS qui représente l'aire du triangle formée par les coordonnées des ondes Q, R et S de chaque complexe QRS.

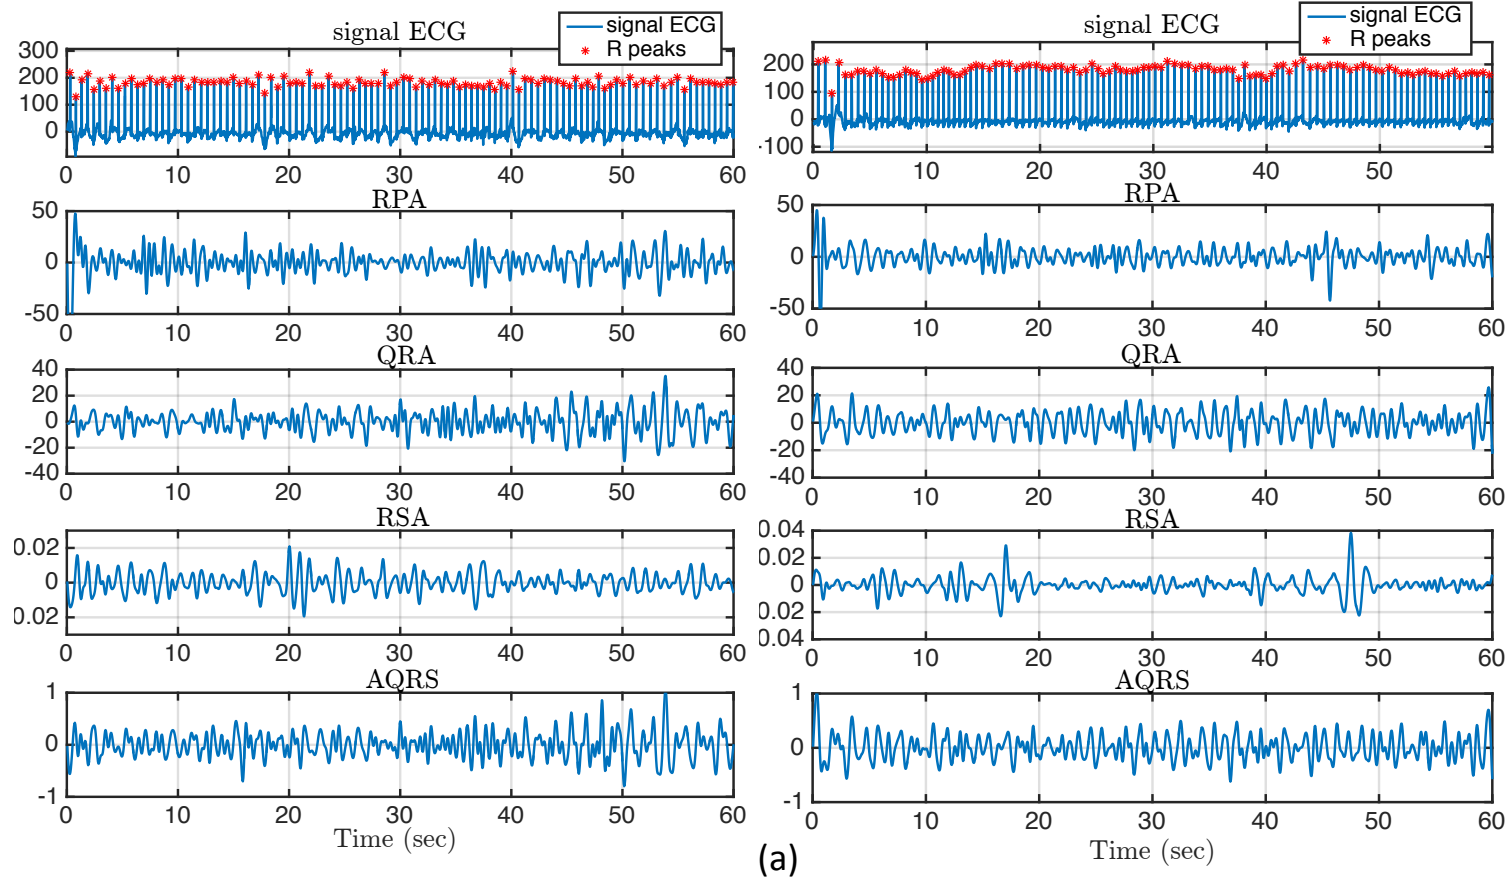


FIGURE 3.2 – Exemples de modulations extraites du signal ECG (RPA, QRA, RSA et AQRS).

## Extraction des modulations du signal PPG

Pour les signaux PPG, un algorithme de détection des maxima et des minima a été développé [74] pour déterminer la série de temps maxima et minima, et est représentée comme une série de paires temps et amplitude. Trois modulations basées sur l'amplitude (RIIV), la ligne de base (RIAV) et la fréquence (RIFV) sont extraites (Figure 3.3) et définies ci-dessous :

1. la RIIV qui représente l'enveloppe du signal PPG influencée par les variations de pression intra-thoracique [46].
2. la RIAV qui est la différence successive entre les maxima et les minima, provoquée par les modifications du débit cardiaque et directement liée à la quantité de remplissage des vaisseaux situés à la périphérie [46].
3. la RIFV qui est la différence de temps entre deux crêtes successives et qui correspond à l'arythmie sinusale respiratoire régulée par le nerf vagal.

Les modulations dérivées des signaux ECG et PPG (respectivement RPA, QRA et AQRS pour le premier, RIIV, RIAV et RIFV pour le deuxième) ont été filtrées par un filtre passe-bande de Butterworth d'ordre 5  $[0.083-1]$  Hz et sont interpolés à 10 Hz comme dans [41]. Des exemples de ces signaux de modulation sont illustrés dans la Figure 3.3. Des formes d'onde oscillatoires apparaissent clairement et correspondent aux activités de la respiration. Les Figures 3.2 et 3.3 donnent également des exemples de signaux PPG et ECG artéfactés dont les modulations de respiration sont difficiles à être exploiter directement. Ce constat a conduit aux études récentes sur le développement de divers indices de qualité de la respiration (IQRs) introduits dans les deux approches de sélection et de fusion que nous proposons.




FIGURE 3.3 – Exemples de modulations extraites du signal PPG (RIIV, RIAV et RIFV).

### 3.3 Indice de qualité respiratoire (IQR)

Étant donné que les modulations dérivées de l'ECG et PPG dépendent fortement du patient et de l'activité, il est très difficile d'identifier à l'avance la modulation la plus adaptée pour un patient donné. La phase cruciale consiste à définir des indices de qualité (IQR) qui permettent de tester la qualité des modulations avant d'être utilisées pour l'estimation de la FR. En fait, un signal respiratoire régulier est un garant d'une meilleure estimation de la FR [79]. En outre, un signal respiratoire peut être modélisé en première approximation par une forme d'onde sinusoïdale avec la fréquence dominante correspondante à la FR [75]. Ces deux remarques nous ont amenés à proposer des indices de qualité qui permettent d'étudier la qualité des modulations. Ces derniers sont introduits brièvement ci-après et sont basés sur la transformée de Fourier et l'autocorrélation [43]. Nous proposons également un nouveau IQR basé sur un modèle sinusoïdal pour mesurer la régularité des modulations dérivées.

#### 3.3.1 IQR basée sur la Transformée de Fourier

La transformée de Fourier (TF) est généralement utilisée pour analyser le contenu harmonique ou fréquentiel dans une série chronologique [7]. Ainsi, la TF peut être utilisée pour définir la concentration en énergie d'une bande de fréquence particulière dans les modulations respiratoires dérivées. En d'autres termes, nous calculons :

$$\text{IQR}_{\text{TF}} = \frac{P_{\text{max}}}{P_{\text{RB}}}, \quad (3.1)$$

où  $P_{\text{max}}$  est la somme des trois coefficients consécutifs entourant la valeur maximale dans la bande de respiration physiologique allant de 0.1 à 1Hz (6 cycles/min à 60 cycles/min), et  $P_{\text{RB}}$  est la somme de tous les coefficients dans cette bande de respiration (voir Figure 3.4). Par conséquent, un  $\text{IQR}_{\text{TF}}$  donne une valeur entre zéro et un. Lorsque la valeur est proche de 1, la modulation dérivée est proche d'une forme d'onde sinusoïdale et cela suggère une concentration d'énergie plus élevée dans la bande de fréquence respiratoire.






FIGURE 3.4 – Exemple de TF pour une modulation dérivée de l’ECG a) modulation sans artéfact b) modulation avec artéfact. les lignes noires représente la région de 0.1 à 1 Hz (dont la somme est  $P_{RB}$ ). Les lignes noires en pointillés représentent la région des trois coefficients consécutifs autour du pic maximal.

### 3.3.2 IQR basé sur l’Autocorrélation

L’autocorrélation est souvent utilisée pour trouver des motifs répétitifs, tels que la présence d’un signal périodique noyé dans un bruit [7]. La fonction d’autocorrélation normalisée est estimée par :

$$r_n = \frac{\frac{1}{N-n} \sum_{k=1}^{N-n} (x_k - \bar{x})(x_{k+n} - \bar{x})}{c_0}, \quad (3.2)$$

où  $c_0$ ,  $n$ ,  $\bar{x}$  et  $N$  sont respectivement la variance de l’échantillon, le décalage dans le temps, la moyenne et le nombre d’échantillons. L’indice  $IQR_{\text{Autocor}} = \max(|r_n|)$  indique une autocorrélation maximum dans l’intervalle de temps compris entre 1 et 10 secondes, ce qui correspond à 6 et 60 cycles/min. Plus l’  $IQR_{\text{Autocor}}$  est proche de un, plus la modulation est périodique (comme l’illustre la Figure 3.5).




FIGURE 3.5 – a) Exemple d'autocorrélation pour une modulation dérivée d'une fenêtre de 32s a) modulation sans artéfact. b) modulation avec artéfact. Les lignes noires représentent la région de 1 à 10 sec.

### 3.3.3 IQR basé sur un modèle Sinusoidal

Dans ce cas, le signal de modulation de la respiration est modélisé par une forme d'onde sinusoïdale :

$$x_k = A \cos(2\pi \bar{f} k + \theta) + b_k, \tag{3.3}$$

où  $b_k$  est un processus de bruit blanc gaussien,  $\bar{f} = f_R/f_s$  la fréquence respiratoire  $f_R$  normalisée par la fréquence d'échantillonnage  $f_s$  et  $\theta$  la phase. Le problème posé revient à estimer la fréquence respiratoire normalisée, l'amplitude  $A$  et le déphasage  $\theta$ .

La fréquence  $f_R$  est estimée à l'aide du périodogramme et l'amplitude  $A$  et l'angle  $\theta$  sont estimés par le maximum de vraisemblance. Le bruit est supposé comme étant gaussien indépendant, les estimateurs du maximum de vraisemblance de l'amplitude et de la phase s'écrivent alors :

$$\hat{\theta} = \arctan \left\{ - \frac{\sum_{k=0}^{N-1} x_k \sin(2\pi \bar{f}k)}{\sum_{k=0}^{N-1} x_k \cos(2\pi \bar{f}k)} \right\} \quad (3.4)$$

$$\begin{aligned} \hat{A} &= \frac{\sum_{k=0}^{N-1} x_k \cos(2\pi \bar{f}k + \hat{\theta})}{\sum_{k=0}^{N-1} \cos^2(2\pi \bar{f}k + \hat{\theta})} \\ &\approx \frac{2}{N} \sum_{k=0}^{N-1} x_k \cos(2\pi \bar{f}k + \hat{\theta}) \end{aligned} \quad (3.5)$$

Pour évaluer la qualité de l'estimation, l'erreur quadratique moyenne normalisée (NRMSE) entre le modèle le mieux ajusté et le signal de modulation peut être calculée et est utilisée comme un indice IQR, soit :

$$\text{IQR}_{\text{SINUS}} = \sqrt{\frac{\sum_{k=0}^N \left( x_k - \hat{A} \cos(2\pi \bar{f}k + \hat{\theta}) \right)^2}{\hat{A}^2}} \quad (3.6)$$

Ainsi, une valeur très faible de  $\text{IQR}_{\text{SINUS}}$  avec le modèle sinusoidal signifie une modulation de bonne qualité.

Birrenkot et al. [43] ont proposé dans leurs études une méthode de régression linéaire pour l'ensemble des indices IQRs (Transformée de Fourier, autocorrélation et autoregression).

Néanmoins, nous avons effectué une étude préliminaire pour étudier les performances de chaque IQRs dans les trois modulations (RIIV, RIAV et RIFV) extraites du signal PPG dans la base de données CAPNOBASE<sup>1</sup>(les détails de performances pour les différents IQRs sont décrites dans les sections suivantes). Dans la Figure 3.6, les distributions des erreurs absolues (cycles/min) sont représentées en fonction des valeurs IQRs (sans unité) pour un ensemble de 42 sujets et pour une durée de 8 min (durée totale). Ainsi 630 valeurs ( $42 \times 8 \times 60\text{s}/32\text{s}$ ) de IQRs dans chaque sous-figure sont reportées. Chaque point dans les courbes correspond à la médiane des erreurs absolues et aux 25e-75e percentiles. Il apparaît clairement que les variations tendent à diminuer avec une valeur de IQR

---

1. la base de données CAPNOBASE sera décrite dans le chapitre 4

plus élevée (valeur IQR élevée pour  $IQR_{TF}$  et  $IQR_{Autocorr}$  ; valeur IQR plus faible pour  $IQR_{SINUS}$ ), il est remarqué qu’il n’existe aucune relation linéaire évidente entre les erreurs et les IQRs.

En raison de la variation des erreurs pour les différents IQRs et de son évolution non linéaire, il apparaît clairement qu’une simple combinaison linéaire n’est pas adaptée, comme proposé par [43]. A partir de cette étude préliminaire, nous proposons plutôt d’évaluer chaque IQR individuellement.




FIGURE 3.6 – La distribution des erreurs absolues (en bpm) en fonction des valeurs IQR a)  $IQR_{TF}$  b)  $IQR_{Autocorr}$  c)  $IQR_{SINUS}$ . Chaque point de la courbe correspond à l’erreur absolue médiane et aux 25-75ème percentiles calculés avec 10% de toutes les fenêtres (nombre de sujets  $\times$  durée du signal PPG / taille de la fenêtre = 42 sujets  $\times$  8 min  $\times$  60s / 32s = 630 fenêtres pour chaque sous-figure).

## 3.4 Estimation de la fréquence respiratoire

### 3.4.1 Approche 1 : Sélection automatique des modulations

Après la dérivation des modulations (à partir des signaux ECG ou PPG), les trois indices IQR sont calculés pour chaque patient. Les modulations dérivées avec les meilleurs scores IQR sont sélectionnées pour estimer la FR. Pour apprécier la qualité de l'IQR, l'erreur absolue (EA) est calculée entre la FR estimée et la FR référence.

À titre d'exemple, et pour illustrer notre propos, le pourcentage sélectionné de chaque modulation est présenté dans la Figure 3.7 sur des signaux enregistrés contenant plusieurs activités physiques quotidiennes<sup>2</sup> (coucher, marcher, courir, ...). Nous remarquons que les résultats de la sélection varient d'un IQR à un autre et d'une activité à une autre sans suivre une règle fixe. Par exemple, en position couchée, le pourcentage de sélection basé sur l'indice TF est de 34% pour la modulation RPA, 13% pour la RSA et 26% pour l'AQRS et le QRA. Cela confirme que 1) aucune modulation simple ne surpasse les autres dans toutes les activités et pour tous les patients, 2) les IQRs ne proposent pas le même résultat pour le choix de la meilleure modulation. Ce constat nous a incité à supposer que l'estimation de la FR ne devrait pas être basée sur une seule modulation et qu'il est important d'exploiter toutes les modulations disponibles avec une stratégie de fusion couplée aux valeurs obtenues par les IQRs. Ainsi l'approche consiste à partir du signal PPG/ ECG à dériver les différentes modulations, à calculer l'indice de qualité, à retenir la meilleure modulation et à estimer la fréquence respiratoire. Dans la Figure 3.8 et 3.9, deux exemples illustratifs de l'approche de sélection des différentes modulations extraites du signal PPG et du signal ECG, sont reportés.

---

2. La base de données SHERPAM sera décrite dans le chapitre 4

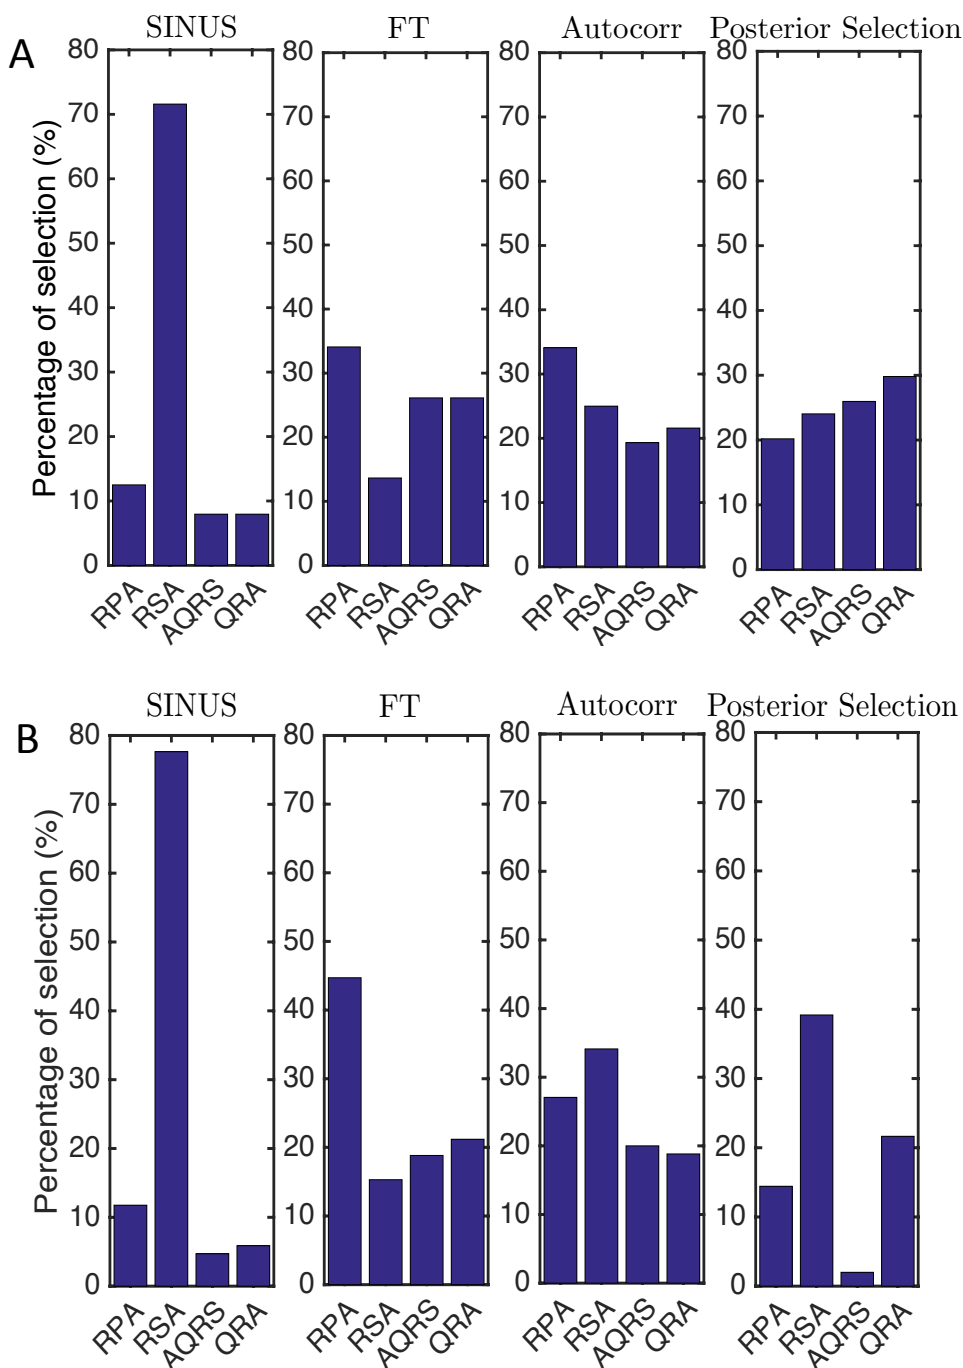


FIGURE 3.7 – Histogramme normalisé (pourcentage) de sélection pour chaque modulation dérivée en utilisant différents indices de qualité (IQRs) et la sélection à postériori pour les activités : a) couché b) marche.




FIGURE 3.8 – Exemple présentant les différentes modulations extraites du signal PPG de la base de donnée CAPNOBASE (RIIV, RIFV et RIAV). Une modulation est sélectionnée toutes les 32 s (en rouge) en se basant sur l'indice  $IQR_{TF}$ .




FIGURE 3.9 – Exemple présentant les différentes modulations extraites du signal ECG de la base de donnée CAPNOBASE (RPA, AQRS, RSA et QRA). Une modulation est sélectionnée toutes les 32 s (en rouge) en se basant sur  $IQR_{TF}$ .

### 3.4.2 Approche 2 : Fusion par le Lisseur de Kalman

Dans une deuxième approche, les signaux de modulation avec des scores  $IQR$  supérieurs à un seuil donné sont utilisés pour alimenter un Lisseur de Kalman (LK) afin de dériver une modulation de respiration. La Figure 3.10 illustre le principe de l'approche pour chaque fenêtre temporelle. Dans ce qui suit et sans perte de généralité, nous allons nous concentrer sur le cas de la fusion de deux signaux de modulation, tandis que son extension à plusieurs canaux (maximum 4 testés dans le présent document) est décrite à la fin de la section. L'algorithme LK consiste en un filtre de Kalman suivi d'un lisseur à un intervalle fixe [87]. Le filtre de Kalman est un algorithme récursif qui met à jour l'esti-



mation de l'état d'un processus  $X_k$ , en fonction de chaque nouvelle donnée de mesure  $Z_k$  dans un système dynamique [88], soit :

$$X_{k+1} = FX_k + W_k \quad (3.7)$$

$$Z_k = HX_k + V_k \quad (3.8)$$

où  $X_k$  est le vecteur d'état actuel et  $Z_k$  est le vecteur de données de mesure. Les processus aléatoires  $W_k$  et  $V_k$  sont supposés être des bruits blancs gaussiens indépendants :  $W_k \sim N(0, Q)$  et  $V_k \sim N(0, R)$ . Les matrices  $Q$  et  $R$  sont respectivement les matrices de covariance de bruit d'état et de bruit de mesure. La matrice de transition d'état  $F$  relie l'état actuel  $X_k$  à l'état futur  $X_{k+1}$ . La matrice de mesure  $H$  relie l'état actuel  $X_k$  au vecteur de mesure  $Z_k$ . L'objectif du Filtre de Kalman est de minimiser l'espérance de l'erreur du vecteur d'état estimé en calculant l'espérance conditionnelle  $\widehat{X}_k = E[X_k | Z_{0:k}]$ . Dans le sens inverse, il s'agit d'estimer le vecteur d'état  $X_k$  à partir des observations  $Z_{0:n}$  pour un instant  $k$  intermédiaire entre l'instant initial 0 et l'instant final  $n$  ; il s'agit donc de calculer l'espérance conditionnelle *a posteriori* tel que  $\widehat{X}_k^n = E[X_k | Z_{0:n}]$ .

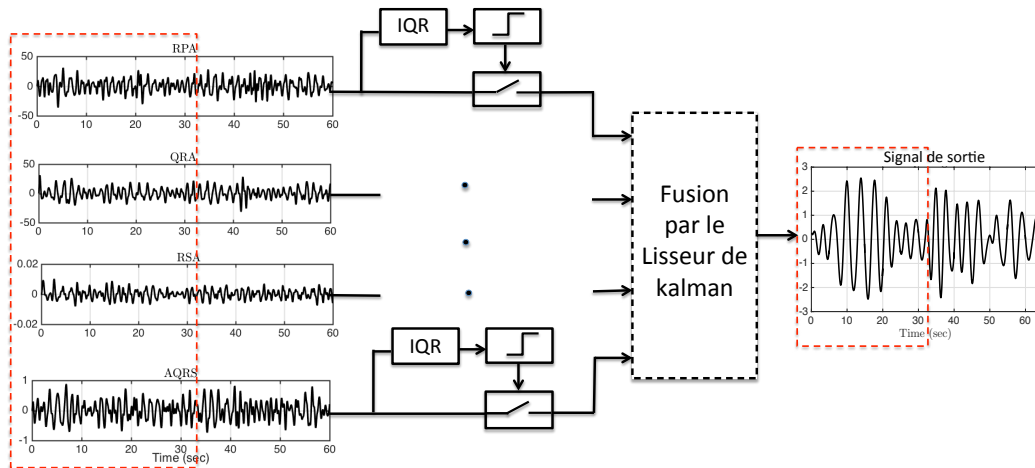


FIGURE 3.10 – Fusion des modulations (deuxième approche) par le Lisseur de Kalman avec l'indice IQR le plus élevé

Dans le cas de deux modulations, ces dernières sont considérées comme l'observation

$Z_k$ , tandis que la séquence d'états inconnus  $X_k$  modélise le signal de respiration. Pour chaque fenêtre d'analyse, deux modulations avec les valeurs IQRs les plus élevées supérieures à un seuil donné sont utilisées comme entrée et la sortie est le signal respiratoire fusionné utilisé pour estimer la FR (voir le bloc diagramme Figure 3.10). Dans la Figure 3.11 et Figure 3.12, un exemple illustratif de fusion des modulations dans les deux cas ECG et PPG, respectivement. Il convient de noter que si aucune des valeurs IQR atteignent le seuil, la fusion n'aura pas lieu pour ces fenêtres temporelles : la modulation avec l'IQR le plus haut (respectant le seuil) est alors directement utilisée pour l'estimation de la FR. Les données d'observation  $Z_k = [z_k^1 \quad z_k^2]^t$  sont modélisées par une dynamique sinusoïdale :

$$z_k^1 = A_1 \cos(2\pi \bar{f} k + \theta_1) + o_k^1 + b_k^1 \quad (3.9)$$

$$z_k^2 = A_2 \cos(2\pi \bar{f} k + \theta_2) + o_k^2 + b_k^2 \quad (3.10)$$

avec  $\bar{f} = f_R/f_s$  est la fréquence respiratoire normalisée,  $A_1, A_2$  les amplitudes,  $\theta_1, \theta_2$  les phases,  $b_k^1, b_k^2$  les bruits de mesure. La variable d'état  $X_k = [x_k, v_k, o_k^1, o_k^2]^t$ , où

$x_k = \cos(2\pi \bar{f} k)$  est le signal de respiration à estimer,  $v_k = \sin(2\pi \bar{f} k)$  sa dérivée négative, et  $o_k^1, o_k^2$  les offsets des deux modulations. Comme dans Spincemaille et al. [88], on a :

$$\begin{aligned} x_{k+1} &= \cos(2\pi \bar{f}(k+1)) = \cos(2\pi \bar{f})x_k - \sin(2\pi \bar{f})v_k \\ &\approx x_k - (2\pi \bar{f})v_k \end{aligned} \quad (3.11)$$

$$\begin{aligned} v_{k+1} &= \sin(2\pi \bar{f}(k+1)) = \cos(2\pi \bar{f})v_k + \sin(2\pi \bar{f})x_k \\ &\approx v_k + (2\pi \bar{f})x_k \end{aligned} \quad (3.12)$$

puisque  $2\pi \bar{f}$  est suffisamment petit (i.e la fréquence d'échantillonnage est grande devant  $f_R$ ), on suppose :  $\cos(2\pi \bar{f}) \approx 1$  and  $\sin(2\pi \bar{f}) \approx 2\pi \bar{f}$ . En exploitant les équations (3.11) et (3.12) dans l'équation (3.7) et (3.8), respectivement, nous déduisons la matrice de

transition d'état  $F$  :

$$X_{k+1} = \underbrace{\begin{bmatrix} 1 & -2\pi\bar{f} & 0 & 0 \\ 2\pi\bar{f} & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}}_F \begin{bmatrix} x_k \\ v_k \\ o_k^1 \\ o_k^2 \end{bmatrix} + W_K \quad (3.13)$$

Dans ce modèle, les décalages de la ligne de base sont supposés varier lentement et les petites variations sont autorisées grâce au terme de bruit d'état  $W_K$ . Spincemaille et al. [88] ont montré l'importance de la matrice de covariance  $Q$ . Ils ont souligné que des valeurs plus élevées permettent une adaptation plus rapide, tandis que des valeurs plus basses améliorent l'effet du lissage des modulations bruitées. Dans ce travail, nous avons retenu des variations de 10% pour  $x_k$  et  $v_k$  (signal respiratoire et sa dérivée), et 10% pour les offsets ( $o_k^1, o_k^2$ ) des deux signaux d'entrées. Ainsi la matrice  $Q$  devient :

$$Q = \begin{bmatrix} 0.1^2 & 0 & 0 & 0 \\ 0 & 0.1^2 & 0 & 0 \\ 0 & 0 & (0.1 \times o_k^1)^2 & 0 \\ 0 & 0 & 0 & (0.1 \times o_k^2)^2 \end{bmatrix} \quad (3.14)$$

Pour la matrice de mesure  $H$ , on remplace l'équation (3.9) et (3.10) dans l'équation (3.8), soit :

$$Z_k = \underbrace{\begin{bmatrix} A_1 \cos \theta_1 & -A_1 \sin \theta_1 & 1 & 0 \\ A_2 \cos \theta_2 & -A_2 \sin \theta_2 & 0 & 1 \end{bmatrix}}_H \begin{bmatrix} x_k \\ v_k \\ o_k^1 \\ o_k^2 \end{bmatrix} + V_k \quad (3.15)$$

où  $V_k = [b_k^1 \quad b_k^2]^t$ .

Suivant Foussier et al. [89], on suppose l'indépendance des bruits de modulations  $V_k$  et de leurs variances, la matrice  $R$  devient alors :

$$R = \begin{bmatrix} \sigma_1^2 & 0 \\ 0 & \sigma_2^2 \end{bmatrix} \quad (3.16)$$

### Initialisation du Lisseur de Kalman (LK)

Pour chaque fenêtre, on initialise le LK en mettant à jour  $\bar{f}$ ,  $A_1$ ,  $A_2$ ,  $\theta_1$ ,  $\theta_2$ ,  $\sigma_1^2$  et  $\sigma_2^2$ , dans la matrice de transition d'état  $F$ , la matrice de mesure  $H$  et les matrices de bruit de covariance  $Q$  et  $R$ . La valeur de la fréquence respiratoire normalisée  $\bar{f}$  est initialisée en tant que valeur de la FR dérivée de la fenêtre précédente, tandis que les amplitudes  $A_1$ ,  $A_2$  et les phases  $\theta_1$  et  $\theta_2$  sont initialisées à l'aide du maximum de vraisemblance décrit par les équations (3.4) et (3.5). Les variances  $\sigma_1^2$  et  $\sigma_2^2$  sont initialisées sous la forme de l'erreur quadratique moyenne (EQM) entre l'observation et le modèle sinusoïdal estimé. À partir des équations (3.9) et (3.10), l'EQM est définie comme suit :

$$\sigma_1^2 = \frac{1}{N} \sum_{k=0}^N \left( (z_k^1 - \bar{z}_k^1) - \hat{A}_1 \cos(2\pi \bar{f} k + \hat{\theta}_1) \right)^2 \quad (3.17)$$

$$\sigma_2^2 = \frac{1}{N} \sum_{k=0}^N \left( (z_k^2 - \bar{z}_k^2) - \hat{A}_2 \cos(2\pi \bar{f} k + \hat{\theta}_2) \right)^2 \quad (3.18)$$

où  $\bar{z}_k^1$  et  $\bar{z}_k^2$  représentent les moyennes de chaque observation.

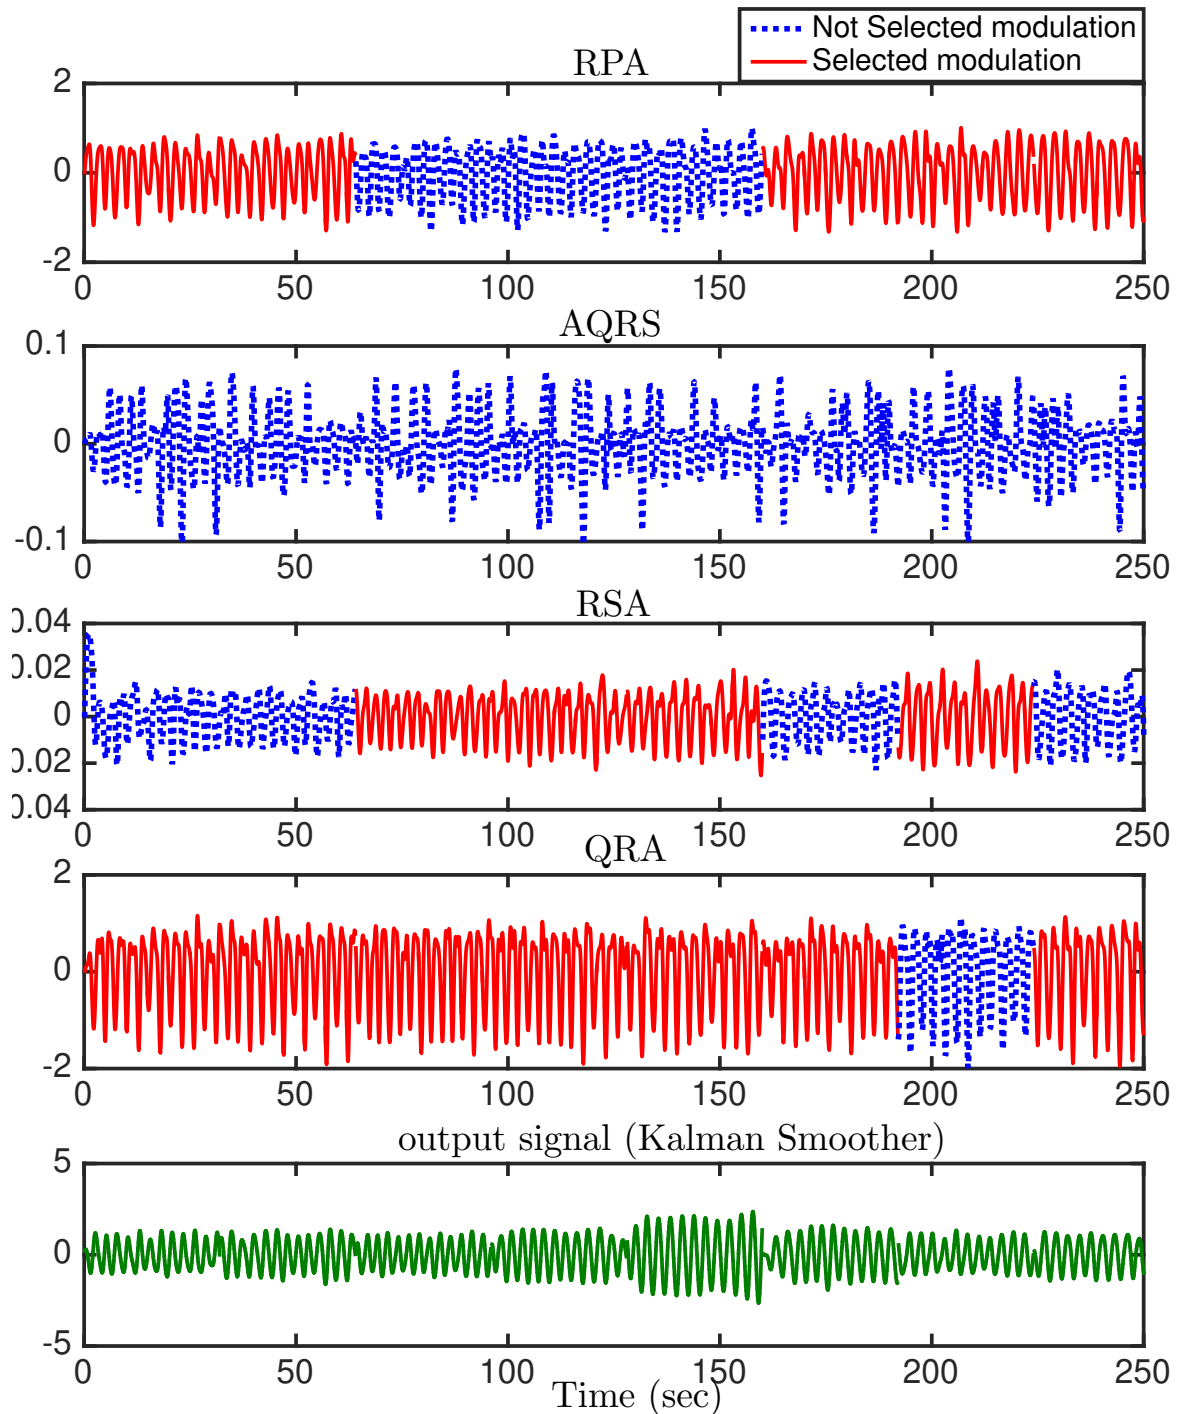


FIGURE 3.11 – Exemple présentant les différentes modulations extraites du signal ECG de la base de données CAPNOBASE (RPA, AQRS, RSA et QRA), pour une durée de 4 min. Toutes les 32 s, deux modulations sont sélectionnées basés sur l'indice  $IQR_{TF}$  et le résultat de fusion par le LK est utilisé pour l'estimation de la FR.




FIGURE 3.12 – Exemple présentant les différentes modulations extraites du signal PPG de la base de donnée CAPNOBASE (RIIV, RIFV et RIAV), pour une durée de 4 min. Toutes les 32 s, deux modulations sont sélectionnées basés sur l'indice  $IQR_{TF}$

### 3.4.3 Lisseur de Kalman avec $m$ entrées

Si l'approche à 2 voies est intéressante, nous nous sommes interrogés si la prise en compte de plusieurs modulations respectant la condition de seuil imposée pouvait améliorer la qualité d'estimation. Ceci nécessite donc l'extension à  $m$  entrées du Lisseur de Kalman. A notre connaissance, il n'existe pas de travaux antérieurs consistant à la fusion de multiples modulations par le LK. Dans ce cas, le vecteur d'état inclut le signal de respiration  $x_k$ , sa dérivée négative  $v_k$  et les offsets de chaque modulation retenue, soit :  $X_k = [x_k, v_k, o_1, o_2, \dots, o_k^m]^t$ . En s'inspirant de [88], la matrice de transition d'état devient alors :

$$F = \begin{bmatrix} 1 & -2\pi\bar{f} & 0 \dots 0 \\ 2\pi\bar{f} & 1 & 0 \dots 0 \\ 0 & 0 & \\ \vdots & \vdots & I_m \\ 0 & 0 & \end{bmatrix} \quad (3.19)$$

En tenant compte de la même dynamique sinusoïdale et en supposant que les offsets varient lentement, la matrice de covariance  $R$  des observations s'écrit :

$$R = \begin{bmatrix} \sigma_1^2 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \sigma_m^2 \end{bmatrix} \quad (3.20)$$

En admettant toujours que la matrice de covariance  $Q$  de l'état admet une variabilité de 10%, alors :

$$Q = \begin{bmatrix} 0.1^2 & 0 & \dots & \dots & 0 \\ 0 & 0.1^2 & \dots & \dots & 0 \\ 0 & 0 & (0.1 \times o_k^1)^2 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \\ 0 & 0 & \dots & \dots & (0.1 \times o_k^m)^2 \end{bmatrix} \quad (3.21)$$

et finalement, la matrice d'observation  $H$  peut être écrite comme une extension directe de l'équation 3.15 soit :

$$H = \begin{bmatrix} A_1 \cos \theta_1 & -A_1 \sin \theta_1 & \\ \vdots & \vdots & I_m \\ A_m \cos \theta_m & -A_m \sin \theta_m & \end{bmatrix} \quad (3.22)$$

L'initialisation du filtre s'appuie sur les mêmes principes de la section précédente.

### 3.5 Détection des cycles respiratoires

Pour chaque modulation dérivée des signaux ECG ou PPG, les pics et les creux sont détectés à l'aide de l'algorithme proposé dans [74], comme illustré dans la Figure 3.13. Un maximum (pic) n'est validé que si sa différence relative avec son minimum précédent (creux) dépasse le produit de l'amplitude pic-creux (notée  $A$  dans la Figure 3.13) et d'un coefficient de seuil. La validation d'un minimum suit le même principe. Cette technique est plus robuste par rapport aux fluctuations basses fréquences (en raison de l'amplitude entre pic et creux mise à jour) et les oscillations abruptes d'artéfacts à haute fréquence (en raison du seuillage). La différence de temps entre deux maxima consécutifs correspond à un cycle respiratoire ( $t_{tot}$  en secondes) et son inverse (multiplié par 60) est la  $\widehat{FR}$  instantanée (en bpm).

Dans le chapitre 4, nous comparerons les performances d'estimation de la FR des deux approches pour différents coefficients de seuil pour mettre en évidence l'intérêt de cette proposition et les avantages de la fusion par le LK.



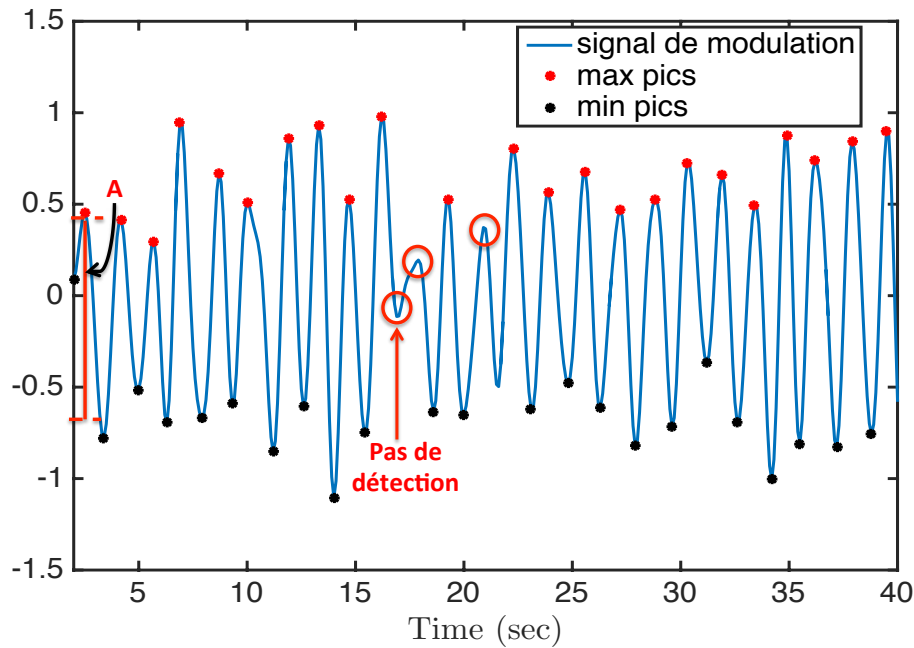


FIGURE 3.13 – Exemple de détection de pics dans la modulation RIIV dérivée à partir du signal PPG avec un coefficient de seuil réglé à 0.7.

### 3.6 Conclusion

La contribution de ce chapitre réside dans la proposition d'une chaîne de traitement permettant l'analyse des signaux physiologiques PPG et/ou ECG pour l'estimation de la fréquence respiratoire. L'objectif global est de pouvoir obtenir une estimation fiable de la fréquence respiratoire à partir d'un nombre minimal de capteurs. Le principe retenu consiste à exploiter les modulations exercées par la respiration sur les signaux PPG et/ou ECG et à dériver des indices de qualité. Ces indices sont alors exploités, soit par choisir la meilleure modulation permettant une estimation robuste de la fréquence respiratoire, soit par choisir les  $m$  meilleures modulations qui seront fusionnées au travers d'un Lisseur de Kalman. Nous avons montré au travers d'un exemple l'intérêt de cette stratégie. Par rapport aux approches reportées dans la littérature, notre démarche consiste à combiner seulement les modulations de bonne qualité contenant l'information respiratoire.

L'ensemble des méthodes proposées dans ce chapitre seront appliqués sur trois bases de données dans la suite de la thèse : i) l'évaluation sur une base de données publique pour

des sujets immobiles, CAPNOBASE ii) l'évaluation sur une base de données avec des sujets pratiquant une activité physique quotidienne (couché, marchant, conduisant,...), cette base de donnée a été enregistrée lors du projet SHERPAM et iii) l'évaluation sur une base de données recueillies en unité de soins intensifs néonatales.



# Chapitre 4

## Estimation de la Fréquence

### Respiratoire : Résultats

#### 4.1 Introduction

Dans ce chapitre, nous allons tester les deux méthodologies décrites au chapitre précédent. Le principal défi consiste à fournir des estimations précises de la FR pendant les activités quotidiennes ou ambulatoires, où les données sont souvent pollués par des artefacts causés par un mauvais contact avec le capteur ou par les mouvements. Dans le but d'améliorer les performances des algorithmes d'estimation de la FR, reportées dans la littérature, deux méthodes ont été proposées au chapitre précédent : i) une approche de sélection basée sur les indices de qualité (IQRs) pour quantifier la qualité des modulations dérivées de l'ECG et/ou PPG ; ii) une approche originale basée sur un modèle qui décrit les modulations respiratoires, et ce dernier est incorporé dans un algorithme de fusion par le Lisseur de Kalman. Ces méthodes sont donc évaluées dans ce chapitre et comparées aux méthodes existantes dans la littérature. Ces comparaisons sont menées sur deux bases de données : i) la base de données 'CAPNOBASE' qui comprend des patients immobiles pendant une anesthésie. Son intérêt est d'être publique et permet directement de comparer nos résultats avec ceux reportés dans la littérature ; et ii) la base de donnée 'SHERPAM' comportant des sujets effectuant des activités quotidiennes (couchée, assis, debout, travail

sur ordinateur, conduire une voiture), d'emblée beaucoup plus difficile mais permettant de situer le travail directement au coeur d'applications plus concrètes.

## 4.2 La base de données CAPNOBASE

La base de données CAPNOBASE contient des enregistrements simultanés du signal ECG, PPG et respiratoire, avec une fréquence d'échantillonnage  $f_s = 300$  Hz . Elle comprend 42 sujets (29 enfants et 13 adultes) et a été décrite dans [90]. Les enregistrements sont d'une durée de 8 minutes, peu bruités, et sont acquises pendant une chirurgie ou une anesthésie de routine pour chaque sujet. Les signaux capnographies sont étiquetés manuellement par les auteurs de l'étude et les annotations des FR sont utilisées comme valeurs de référence.

## 4.3 La base de données SHERPAM

Elle est composée de 10 sujets en bonne santé, âgés entre 18 et 35 ans, qui exercent des activités quotidiennes, suivant un protocole fixé. En particulier les sujets étaient appelés à passer de la position assise, debout, ou encore courir, la durée de ces phases étaient d'au moins 6 min. L'étude a été approuvée par le comité d'éthique de l'école doctorale des sciences et technologies de l'Université libanaise (numéro de référence : CE-EDST-1-2016). Le protocole complet est décrit dans [91]. Sur le plan des observables, un signal ECG continu est collecté à une fréquence d'échantillonnage  $f_s = 250$  Hz à l'aide du capteur Zephyr et simultanément une fréquence respiratoire est obtenue à partir d'un capteur Cosmed à flux d'air nasal (K4B2) qui servira de référence pour la suite de notre étude, voir Figure 4.1.

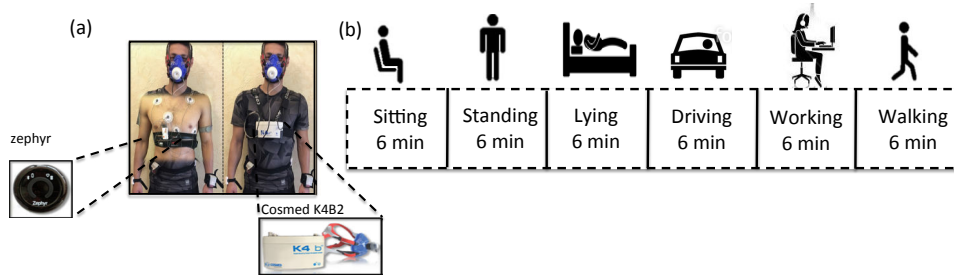


FIGURE 4.1 – a) Le capteur Zephyr à gauche et le capteur Cosmed K4B2 à droite. b) Schéma expliqué des activités.

## 4.4 Evaluation des performances

Les performances de nos deux algorithmes proposés ont été évaluées sur les signaux PPG et ECG de la base de donnée CAPNOBASE; et sur les signaux ECG de la base de donnée SHERPAM; et pour les deux tailles de fenêtres (32 et 64s) comme proposé dans [41]. L'erreur absolue (AE) a été calculée entre la FR estimée à partir des deux méthodes et la FR du signal référence (signal capnographie pour la base de données CAPNOBASE ou FR obtenue par le système cosmed pour SHERPAM). L'erreur absolue (EA) en cycles/min (bpm) est définie comme suit :

$$EA = |FR_{\text{ref}} - \widehat{FR}| \quad (4.1)$$

où  $FR_{\text{ref}}$  et  $\widehat{FR}$  sont respectivement la fréquence respiratoire de référence et estimée.

Afin de mesurer les performances des deux approches proposées parmi les différents indices IQRs :

1. La distribution de l'erreur absolue moyenne (bpm) à l'aide des boxplots est affiché. Un boxplot nommé sélection *a posteriori* est utilisé pour la comparaison. Il s'agit d'une sélection automatique mais postérieure des modulations pour chaque intervalle de temps (32/64s), qui correspond à l'erreur absolue minimale avec le gold standard (annotation pour CAPNOBASE, Cosmed K4B2 pour SHERPAM). Ces erreurs minimales constituent la limite inférieure qu'on peut atteindre compte tenu de toutes les méthodes et sont

calculées avec la reconnaissance de la FR référence.

2. En utilisant la base de données CAPNOBASE, nous comparons les performances de nos algorithmes avec les méthodes précédemment proposées : Pimentel 2016 [41], Karlen 2013 [18], Flemming 2007 [24], Shelly 2006 [70] et Nilson 2000 [6]. Il importe de noter ici que nous avons aussi procédé à la réimplémentation des algorithmes de Pimentel 2016 [41] et Karlen 2013 [18].

3. En utilisant la base de données SHERPAM, nous évaluons l'estimation de la FR sur des activités quotidiennes et nous comparons les performances de nos approches à deux méthodes ré-implémentées de la littérature (Karlen 2013 [18] et Pimentel 2016 [41]).

Pour évaluer statistiquement les performances des deux méthodes proposées, nous avons calculé l'erreur absolue moyenne (EAM) pour chaque enregistrement comme proposé dans la littérature [41]. Ensuite, le test de Wilcoxon a été effectué sur la médiane des EAMs dans la CAPNOBASE *i*) entre deux ensembles différents de modulations dérivées (RIIV, RIAV et RIFV), *ii*) entre la sélection basée sur les IQRs et *iii*) entre les approches de fusion pour tous les IQRs (Transformée de Fourier, autocorrélation et modèle sinusoïdal). Ensuite, nous comparons la médiane des EAMs de la sélection *a posteriori* avec la première et ensuite avec la seconde approche. Les tests statistiques ont été conduits pour des comparaisons multiples en utilisant la méthode de *Bonferroni* (un total de 14 groupes de comparaison, avec un niveau de significativité fixé à  $p = 0.05$ ). En effectuant le test de Wilcoxon, nous avons également comparé les erreurs obtenues de nos méthodes avec les deux méthodes implémentées proposer dans la littérature (Karlen2013 [18], Pimentel2016 [41]).

## 4.5 Résultats

### 4.5.1 Effet du seuil sur la détection des cycles respiratoires

Nous avons étudié l'impact du coefficient de seuil dans l'algorithme de détection des cycles respiratoires en utilisant les signaux PPG de la CAPNOBASE. En particulier, les performances de détection avec différents coefficients de seuil (variant entre 0.1 et

0.9) ont été examinés. La Figure 4.2 compare les erreurs absolues de la FR estimée (en bpm) en fonction des coefficients de seuil obtenues par les deux approches. Les médianes et les interquartiles (25e-75e) sont présentés. On note que pour la première approche, plus les coefficients de seuil sont proches de 0.1 ou 0.9, plus les erreurs absolues sont importantes. Au contraire, celles de la deuxième approche sont presque stables quelque soient les coefficients de seuil et sont systématiquement plus faibles en médiane et en interquartiles. La Figure 4.3 explique le phénomène en comparant les résultats de la détection des cycles avec les pics et les creux marqués pour trois coefficients de seuil, sur la modulation sélectionnée (A) vs le signal de fusion LK (B). En effet, les cas de sous-détection (coefficients élevés) et de surdétection (coefficients faibles) sont réduits en raison de la régularité des résultats de la fusion par le LK par rapport à la forme de modulation sélectionnée par le IQR. Le signal à l'issue de la fusion est plus régulier dont la détection des cycles ne dépend plus du coefficient de seuil choisi. Cet exemple illustre également la raison pour laquelle l'approche LK fournit une estimation de FR avec moins




FIGURE 4.2 – Exemple de distribution d'erreur absolue (bpm) en fonction des coefficients de seuil (entre 0.1 et 0.9) pour les deux approches proposées (sélection et fusion) en utilisant l'indice d'autocorrélation, à partir des signaux PPG de la base de données CAPNOBASE.



d'erreur absolue que l'approche de sélection des modulations par les IQRs.

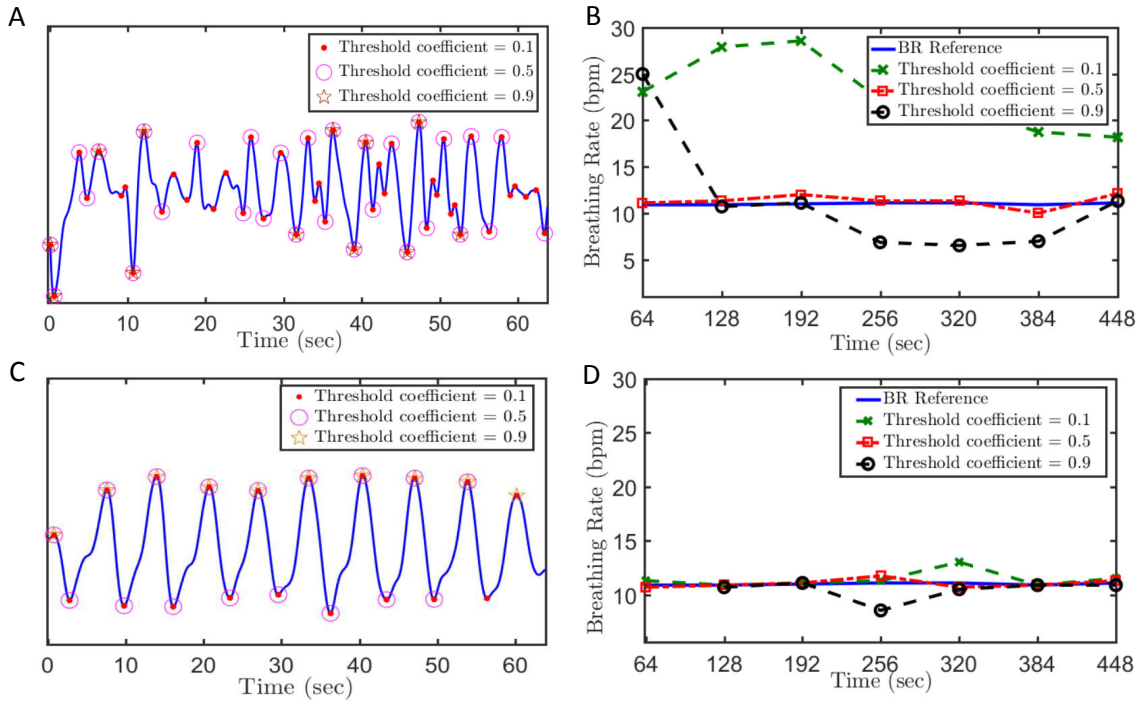


FIGURE 4.3 – Exemple de détection de cycle respiratoires sur la modulation sélectionnée (1ère approche avec un fenêtre de 64s en A) et sur le signal fusionné (seconde approche en C). Les pics et les creux sont détectés en utilisant trois coefficients de seuil (0.1, 0.5 et 0.9). Les séries FR correspondantes du sujet sont comparées en B) et D) avec la série FR référence.

### 4.5.2 Comparaison de la FR estimée avant et après LK

Dans cette partie, pour montrer l'avantage qu'apporte le LK dans l'estimation de la FR, nous avons comparé la FR initialisée à l'entrée du LK (delta1) et la FR estimée à partir du signal fusionné par le LK (delta2) avec la FR obtenue du signal référence. Les erreurs absolues (bpm) des versions de FRs sont comparées.

Ce test a été mené sur les 42 sujets (42 sujets \* durée signal 8min) de la base de données CAPNOBASE. Pour chaque patient cinq fenêtres (32sec) sont choisis aléatoirement parmi les 15 fenêtres, pour respecter les conditions d'indépendance d'échantillons pour appliquer le test de Wilcoxon. Ensuite, le test de Wilcoxon est effectué entre delta1 et delta2. Dans la Figure 4.4, les boxplots montrent une amélioration dans l'estimation de la FR après la fusion, la médiane d'erreur et les interquartiles sont diminués pour les trois indices de qualité  $IQR_{\text{SINUS}}$ ,  $IQR_{\text{FT}}$  et  $IQR_{\text{autocor}}$  ( $p < 0.001$ ).

La Figure 4.5 compare ces erreurs selon les différentes bandes de respiration, en se

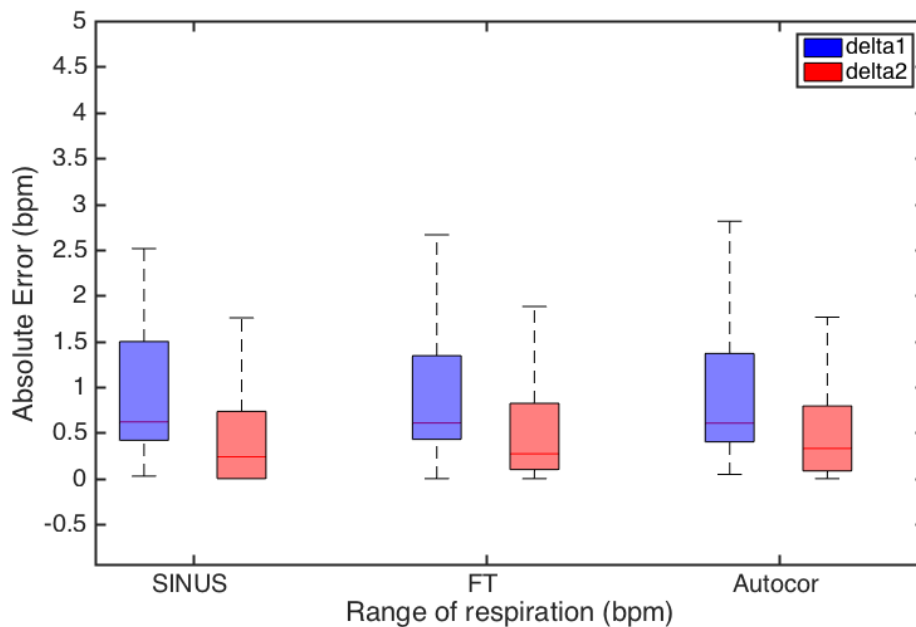


FIGURE 4.4 – Comparaison des résultats des erreurs absolues (en bpm) entre la FR de référence et la FR à l'entrée du LK (delta1) et la FR estimée à la sortie du LK (delta2), pour les trois indices de qualité ( $IQR_{\text{SINUS}}$ ,  $IQR_{\text{FT}}$  et  $IQR_{\text{autocor}}$ ), à partir des signaux PPG de la base de données CAPNOBASE. En moyenne, le pourcentage d'outliers est 15 %.

basant sur l'indice  $IQR_{FT}$ . Il est remarqué que dans les basses fréquences (entre 5 et 10bpm ou de 0.08 à 0.16 Hz), le LK n'apporte pas d'améliorations significatives ( $p>0.05$ ). De même dans les hautes fréquences (entre 30 et 35bpm ou de 0.5 à 0.6 Hz)( $p>0.05$ ). En revanche, entre 10 et 35bpm, ce qui correspond à la FR chez l'adulte et l'adolescent, les améliorations sont plus nettes ( $p<0.001$ ).

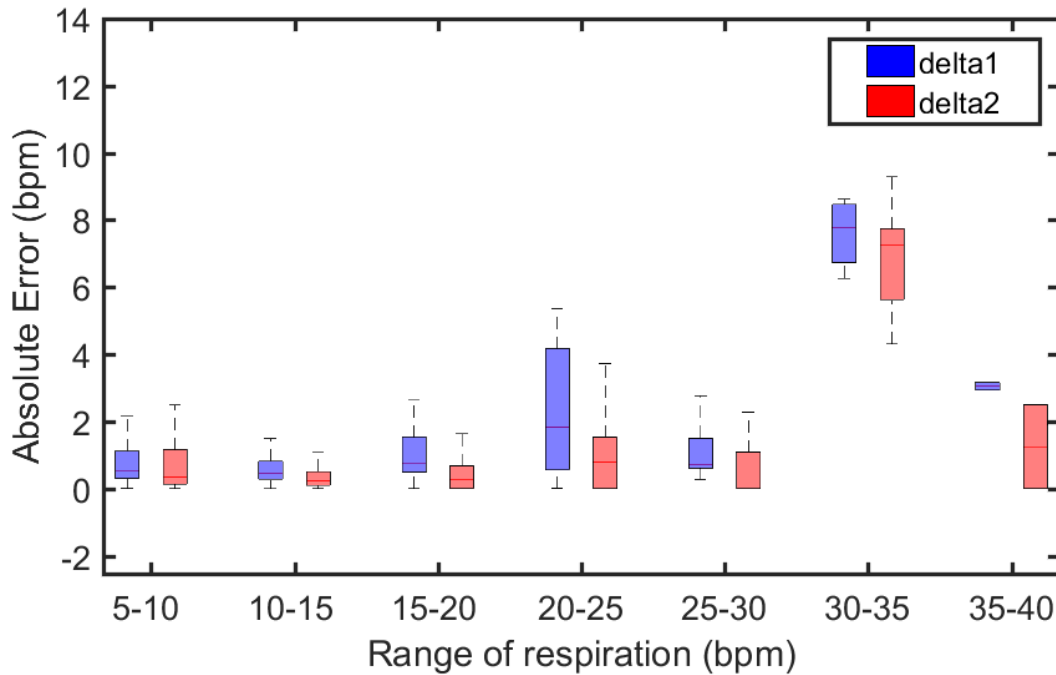


FIGURE 4.5 – Comparaison entre les FRs estimées à l'entrée du LK (delta1) et les FRs estimées à la sortie du LK avec les FRs références, pour les différentes range de respiration, à partir des signaux PPG de la base de données CAPNOBASE en se basant sur l'indice  $IQR_{FT}$ .

### 4.5.3 Evaluation sur les signaux PPG (CAPNOBASE)

Nous étudions les performances des deux méthodes à partir de la base de données publique CAPNOBASE en se basant sur les modulations extraites du PPG (RIIV, RIAV et RIFV), et pour les deux tailles de fenêtres 32s et 64s. Chaque IQR est testé indépendamment :  $IQR_{SINUS}$ ,  $IQR_{FT}$ ,  $IQR_{Autocor}$ . Nous avons comparé nos résultats avec cinq méthodes publiées dans la littérature (voir Tableau 4.1). En outre, nous avons également réimplémenté les approches Pimentel [41]) et Karlen [18], notées sous Pimentel\* (notre

implémentation) et Karlen\* (notre implémentation).

Nous avons également essayé d’apprécier statistiquement nos performances. Le test de Wilcoxon (Figure 4.6) a montré qu’il existe une différence significative entre les modulations : RIIV versus RIFV et RIAV versus RIIV ( $p < 0.001$ ) et entre RIAV et RIFV ( $p < 0.05$ ). Selon les tests de multicomparaison de *Bonferroni*, il existe également une différence significative entre les erreurs obtenues à partir de la sélection basée sur les IQRs et les approches de fusion basées sur les différents IQRs.

De plus, il y a une différence significative entre la sélection basée sur l’IQR et la sélection *a posteriori* ( $p < 0.05$ ). Cependant, il n’y a pas de différence significative entre la méthode de fusion et la sélection *a posteriori* selon les tests de Bonferroni (voir Figure 4.6). Nous avons également calculé la valeur-p entre chaque deux ensembles de fusion (pour tous les IQRs). Aucune différence significative, les erreurs sont comparables pour la méthode de fusion basée sur  $IQR_{FT}$  ou  $IQR_{Autocor}$ . Enfin, le test de Wilcoxon selon la méthode de *Bonferroni* a révélé des différences significatives entre notre méthode de fusion proposée et les méthodes de référence proposées par [18] et [41] ( $p < 0.001$ ). Alors que, la meilleure méthode rapportée dans la littérature donne une médiane d’erreur absolue de 1.2 bpm (0.5-3.4 bpm) pour une fenêtre de 32 sec (voir Table 4.1), notre réimplémentation des approches de Pimentel et Karlen avec l’optimisation des paramètres pour obtenir des meilleurs performances : la médiane d’erreur est de = 0.9 bpm pour la réimplémentation de Pimentel par rapport à une médiane d’erreur de = 1.5 bpm, et la médiane d’erreur de = 1.1 bpm pour la réimplémentation de Karlen par rapport à une médiane d’erreur de = 1.2 bpm. Les interquartiles ont également diminué pour la méthode de Karlen réimplémentée et comparables pour la méthode de Pimentel.

Nos résultats surpassent les méthodes existantes de la littérature lors de l’application de l’algorithme de fusion avec une médiane d’erreur de 0.5 bpm (0.2-1.1 bpm). Il convient de rappeler que les méthodes proposées par Flemming(2007) [24], Shelly(2006) [70] et Nilsson(2000) [6] ne sont basées que sur une seule modulation dérivée (les modulations dérivés du RIIV). Notre approche est également supérieure à la méthode de Karlen [18] (tableau 4.1), qui dans son principe supprime un grand nombre de segments temporels




FIGURE 4.6 – Boxplots des résultats de l’estimation de la FR à partir des signaux PPG (médianes et 25e au 75e percentiles en bpm) pour une fenêtre de 32 s. Les trois premières boxplots concernent les modulations dérivées (RIAV, RIIV et RIFV), suivies de la comparaison entre la sélection basée sur IQR (première approche) et la fusion des deux modulations par le LK (seconde approche). Les résultats de la sélection *a posteriori* sont également affichés à titre de référence. Le pourcentage d’outliers est en moyenne de 7 %. L’étoile unique \* correspond à une valeur- $p$   $p < 0.05$ , tandis que les deux étoiles \*\* correspondent à une valeur- $p$   $p < 0.001$ .

si la qualité du segment est jugé insuffisante : 36% de fenêtres par enregistrement ont été éliminés, et une estimation de la FR n’est générée que si l’écart type du signal de modulation est inférieur à 4 bpm [18].

Les boxplots des erreurs absolues sont représentés dans la Figure 4.6. Les trois premiers boxplots correspondent aux modulations dérivées (RIAV, RIIV et RIFV), suivi de trois boxplots représentant la comparaison entre la sélection basée sur l’IQR (première approche) et la fusion de deux meilleures modulations par le LK (seconde approche). Les deux modulations sont choisies en ayant l’IQR considéré minimale. Le dernier boxplot

Signals PPG de la base de données CAPNOBASE		
	32s window	64s window
<b>Proposed methods</b>		
1st approach : FT	1.7 (0.6-3.1)	1.2 (0.2-2.7)
2nd approach : FT + 2 channel KS	0.5 (0.2-1.1)	0.2 (0.1-0.9)
<b>Pimentel (2016)</b>	1.5 (0.5z-3.4)	0.7(0.3-3.4)
<b>Pimentel*</b>	0.9 (0.5-3.5)	0.8(0.5-2.6)
<b>Karlen (2013)</b>	1.2 (0.5-3.4)	0.8 (0.3-2.7)
<b>Karlen*</b>	1.1 (0.3-2.6)	1 (0.3-2.5)
<b>Flemming (2007)</b>	1.4 (0.5-3.8)	1.1 (0.4-3.5)
<b>Shelly (2006)</b>	4.5 (0.8-10.5)	2.2 (0.2-8.3)
<b>Nilsson (2000)</b>	10.5 (4.9-12.7)	10.2 (4.8-12.4)

\* Our implementation.

TABLE 4.1 – Performance d’estimation de la FR en utilisant les signaux PPG de la base de donnée CAPNOBASE, comparé avec les méthodes de la littérature pour les 2 fenêtres 32s et 64s. Médiane (bpm) et les interquartiles (25th-75th) sont présentés.

est destiné à la sélection *a posteriori* où pour chaque intervalle de temps, un opérateur automatique sélectionne la modulation ayant une erreur minimale avec la référence (signal capnographie). Les résultats de la sélection *a posteriori* sont également présentés comme une référence de comparaison. La médiane (25e-75e percentiles) sont rapportées dans le tableau 4.1.

Les boxplots montrent clairement que le  $IQR_{TF}$  présente le meilleur résultat avec le LK. Cette analyse montre également l’intérêt de la fusion pour améliorer systématiquement les performances, par exemple la médiane d’erreur obtenue en utilisant  $IQR_{TF}$  est diminué de 1.7 bpm (0.6-3.1 bpm) à 0.5 bpm (0.2-1.1 bpm), pour une taille de fenêtre 32s. De plus, en utilisant une taille de fenêtre 64s, la médiane de l’erreur diminue à 0.2 bpm (0.1-0.9 bpm). En général, l’utilisation d’une fenêtre plus petite réduit la complexité du calcul, tandis que une taille de fenêtre plus grande améliore la précision de l’estimation.

#### 4.5.4 Évaluation sur les signaux ECG (CAPNOBASE)

Dans cette partie, nous validons nos deux méthodes proposées sur les signaux ECG de la base de données CAPNOBASE. Il convient de rappeler qu’aucun résultat comparable n’est reproduit dans la littérature. Le meilleur résultat obtenu est celui de  $\text{IQR}_{\text{TF}}$ , avec une médiane de 0.3 bpm pour une taille de fenêtre 32s et une médiane de 0.2 bpm pour une taille de fenêtre 64s. Nous avons également comparé nos résultats avec les méthodes de Karlen [18] et de Pimentel [41] en utilisant nos méthodes implémentées optimiser. Là encore, nous avons obtenu de meilleures performances par rapport à ces deux méthodes réimplémentées (voir tableau 4.2 pour une explication quantitative).

Les résultats statistiques obtenus du test de Wilcoxon ont montré des différences significatives ( $p < 0.05$ ) entre la méthode de sélection basée sur les IQRs et la fusion. Au contraire, il n’y avait pas de différences significatives entre l’approche de fusion et la sélection *a posteriori*.

ECG signals of CAPNOBASE dataset		
	32s window	64s window
<b>Proposed methods</b>		
1st approach : FT	0.7 (0.6-3.04)	0.5 (0.4-2.1)
2nd approach : FT + 2 channel KS	0.3 (0.2-0.7)	0.2 (0.1-0.4)
<b>Pimentel*</b>	1.4 (0.8-3.6)	1.1(0.6-3.3)
<b>Karlen*</b>	1.1 (0.3-2.6)	1 (0.3-2.5)

\* Our implementation.

TABLE 4.2 – Performance d’estimation de la FR à partir des signaux ECG de la base de donnée CAPNOBASE, comparé avec les méthodes de la littérature, pour les deux fenêtres 32s and 64s. La médiane (bpm) et les interquartiles (25th-75th) sont présentées.

### 4.5.5 Évaluation sur les signaux ECG (SHERPAM)

Dans cette section, nous avons évalué les performances avec une base de données enregistrée au cours d'activités quotidiennes. Les résultats détaillés sont rapportés dans la Figure 4.8 et l'EAM dans le tableau 4.3. La qualité des modulations dépend de l'activité et il est difficile de choisir la meilleure. Par exemple, l'EAM varie de 1.4bpm en position assise à 5.5bpm en marche à l'aide de la modulation RSA. En outre, ces modulations dépendent également des patients et peuvent être influencées par des artefacts. La Figure 4.8 propose une comparaison de performances par activité. Pour chaque cas, 11 boxplots sont représentés : les 4 premiers utilisent les modulations simples (RPA, RSA, AQRS et QRA), les 6 suivants exploitent la sélection automatique basée sur IQR contre la fusion par le LK, et le dernier s'appuie sur les modulations sélectionnées manuellement. Les 25e, 75e percentiles et les valeurs médianes (ligne médiane) sont illustrés. Le dernier est obtenu par sélection manuelle.

Clairement, les résultats ont été améliorés lorsque l'algorithme de fusion a été appliqué, indépendamment de l'activité ou du type d'IQR. Les boxplots montrent également que les performances de la fusion LK sont proches de celles de la méthode de sélection manuelle. Dans toutes les activités, la dispersion des erreurs absolues est réduite.

En outre, nous avons également testé l'algorithme de fusion à  $m$  entrées (voir le tableau 4.3), dans lequel le nombre maximal d'entrées  $m$  de modulation est défini par seuillage de l'IQR pour sélectionner plusieurs modulations (jusqu'à  $m$ ). Si aucune des modulations ne satisfait le seuil IQR, la modulation présentant l'IQR la plus élevée parmi les mauvais est utilisé pour une estimation de la FR directement sans fusion.

La Figure 4.7 montre un exemple de l'effet de seuillage en fonction du pourcentage de modulations rejetées. Les meilleurs résultats ont été obtenus lorsque le seuil IQR est défini pour ignorer 20% des segments de modulation dans l'algorithme de fusion. Le seuil IQR dans l'algorithme de fusion LK agit donc un compromis entre l'efficacité de la fusion (en incluant plus de modulations) et le rejet d'artefacts (en excluant les modulations à faible IQR). Ceci est un autre avantage de notre approche automatique proposée par rapport aux méthodes de la littérature.



Notons que les courbes obtenues dans la Figure 4.7 sont les performances obtenues de la première approche en utilisant uniquement les valeurs IQRs. En effet, les résultats ont été améliorés par rapport à la fusion à 2 entrées, sauf pour la position assise. Par exemple, en position couchée : la médiane d'erreur est diminué de 1.2 à 0.8 bpm avec  $\text{IQR}_{\text{SINUS}}$ , de 0.8 à 0.6 bpm avec  $\text{IQR}_{\text{TF}}$  et de 1.1 à 0.7 bpm avec  $\text{IQR}_{\text{Autocorr}}$ .

Enfin, les méthodes proposées par [41] et [18] ont également été testées avec la base de données SHERPAM (voir Tableau 4.3). Là encore, les performances mesurées étaient inférieures à celles obtenues par notre approche. Il est utile de rappeler que Karlen et al. [18] supprime un grand nombre de fenêtres alors que notre méthode proposée ne le fait pas.

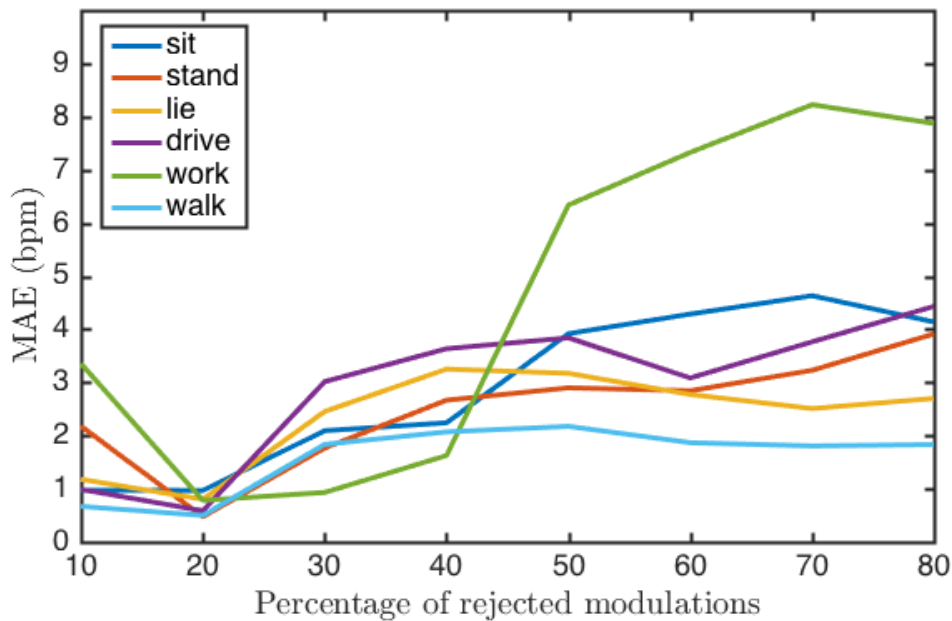


FIGURE 4.7 – Exemple d'évolution de l'erreur absolue médiane (EAM) d'estimations de la FR issues de la fusion LK à 4 entrées utilisant  $\text{IQR}_{\text{autocorr}}$  en fonction du pourcentage de modulations rejetées, de la base de données SHERPAM.

EAM and 25-75 percentile (bpm), SHERPAM (10 subjects)						
	sit	stand	lie	drive	work	walk
<b>Modulation</b>						
RPA	6.9(3.3-15.2)	5.7(1.9-11.2)	4.1(1.2-10)	12.8(6.7-16.1)	7.1(2.1-12.9)	12.0(5.6-17.6)
RSA	1.4(0.5-2.6)	4.4(1.5-9.7)	1.3(0.4-2.2)	4.4 (1.5-12.6)	2.2(0.7-3.7)	5.5(2.1-10.8)
AQRS	5.1(1.6-11.3)	2.8(1.4-6.6)	3.1(1.6-8.4)	8.7(2.7-12.4)	3.7(1.4-10.2)	8.9(4.7-13.5)
QRA	4.1(2.1-10.3)	2.2(0.9-5.4)	1.8(1.1-4.7)	5.5(1.1-10.8)	1.6(0.7-6.6)	7.3(5.6-14.4)
<b>1st Appr Selection</b>						
SINUS	5.6(2.2-15.2)	4.4(1.5-10.4)	4.0(1.8-7.4)	8.7(2.5-15.1)	3.7(1.2-12.2)	11.9(6.1-15.1)
FT	1.3(0.6-2.6)	3.4(1.3-10.4)	1.2(0.5-2.6)	3.3(1.1-11.7)	1.2(0.4-3.6)	4.1(1.6-8.7)
Autocorr	1.4(0.7-4.9)	3.1(1.3-9.8)	1.3(0.7-3.8)	4.1(1.2-12.3)	1.4(0.6-4.6)	6.4 (3.4-13.3)
<b>2nd Appr Fusion</b>						
SINUS	2.2(0.4-3.6)	1.1(0.4-2.9)	1.2(0.6-2.0)	2.1(1.2-3.3)	2.1(1.4-3)	1.8(0.9-3.6)
FT	1.1(0.4-2.2)	1.4(0.5-3.1)	0.8(0.3-1.6)	1.8(0.8-3.7)	0.7(0.1-1.4)	0.7(0.9-3.6)
Autocorr	0.9(0.3-1.9)	1.2(0.5-2.3)	1.1(0.4-2.2)	2.4(0.6-4.3)	1.4(0.6-2.5)	1.1(0.6-2.4)
<b>Fusion m inp</b>						
SINUS+ KS	1.0(0.4-3.2)	1.2(0.4-3.1)	0.8(0.4-1.9)	1.4(0.4-2.5)	1.6(1.5-2.2)	1.4(0.6-2.0)
FT+ KS	1.1(0.4-2.3)	1.2(0.6-2.9)	0.6(0.3-1.5)	1.1(0.4-1.7)	1.2(0.8-2.1)	0.3(0.1-0.8)
Autocorr+ KS	1.1(0.4-2.2)	1.3(0.3-3.6)	0.7(0.3-1.9)	1.2(0.6-1.6)	1.4(0.6-2.2)	0.7(0.2-1.9)
<b>Post Selec</b>	0.9(0.4-2.0)	0.7(0.2-1.4)	0.5(0.2-1.2)	1.1(0.3-2.8)	0.6(0.2-1.1)	2.1(0.9-4.3)
<b>Literature</b>						
Karlen <sup>*</sup>	3.4(1.3-6.2)	2.6(0.9-5.7)	1.8(1.0-4.4)	4.6(2.1-7.2)	2.4(1.2-5.2)	6.3(4.3-11.5)
pimentel <sup>*</sup>	3.7(1.3-9.2)	3.1(1.3-4.8)	1.8 (1.1-3.9)	5.6(1.7-8.4)	2.3(0.8-4.7)	2.4(1.2-5.2)

<sup>\*</sup> Optimized implementation.

TABLE 4.3 – Comparaison d'estimation de la FR avec ECG de la base de SHERPAM, entre la sélection des modulations (approche 1), la fusion à deux modulations (approche 2), la fusion à  $m$  entrées, la sélection *a posteriori* et les méthodes de référence de la littérature. Les médianes des erreurs absolues (bpm) et les interquartiles des 10 sujets sont présentées.




FIGURE 4.8 – Les boxplots de l’erreur absolue d’estimation de la respiration (bpm) pour six activités quotidiennes : assis, debout, coucher, conduire, travailler et marcher pour les 10 patients. Chaque sous-figure comprend quatre boxplots de l’estimation de la FR en utilisant la première approche à partir de RPA, RSA, AQRS et QRA, trois résultats comparatifs entre la première approche et la seconde approche (par fusion LK), ainsi que les résultats de la sélection manuelle de modulation. Chaque boxplot représente les 25ème et 75ème percentiles et la valeur médiane au centre des Boxplots.

## 4.6 Discussion

Étant donné l'importance de l'estimation de la FR de manière efficace et indirecte, l'estimation robuste de la FR est un sujet sur lequel plusieurs études ont été réalisées au cours de ces dernières décennies [41]. Les travaux antérieurs se sont concentrés sur l'étude de la qualité des signaux ECG et/ou PPG au lieu d'étudier la qualité des modulations. Il a été montré que l'indice de qualité du signal (IQS) n'était pas un moyen efficace pour déterminer la présence d'informations respiratoires [43],[81]. L'utilisation des IQRs est ainsi proposée pour étudier la qualité des modulations extraites des signaux physiologiques. Nous avons montré que chaque indice de qualité (IQRs) fournit des informations utiles sur la qualité des modulations extraites. Aucun des IQRs ne surpasse les autres. Les signaux respiratoires peuvent ne pas toujours être sinusoïdaux, comme par exemple une expiration longue ou courte [92].

Nous avons conclu que la qualité des modulations extraites à partir de la base de données SHERPAM, dépend de l'activité et qu'il est difficile de choisir les meilleures modulations. Des recherches antérieures ont montré que la modulation RSA dépend fortement du niveau d'activité fait par le patient, de son âge et de son état de santé [21]. De plus, l'amplitude du signal ECG et/ou PPG est très sensible au bruit.

Un nouvel algorithme de fusion basé sur un modèle paramétrique sinusale a été proposé, en utilisant des indices de qualité (IQRs). Ces indices permettent de distinguer entre une modulation de bonne ou de mauvaise qualité.

Plusieurs approches ont été proposées dans la littérature pour combiner les multiples FRs obtenus à partir des modulations extraites du signal PPG et/ou ECG. Birrenkott et al. [43] ont proposé la régression linéaire pour fusionner les indices IQRs. Ensuite, une FR estimée est obtenue en combinant les FRs calculées des six modulations de l'ECG et de PPG tout en vérifiant un seuil de contrôle ajustable, l'erreur médiane est de 0.4 bpm (0.2-0.7 bpm). Cependant, on a trouvé qu'il n'existe pas une relation linéaire entre la qualité des modulations et les erreurs d'estimations de la FR. Karlen et al. [18] ont proposé la combinaison des FRs des trois modulations de PPG quand l'écart-type de ces trois estimations

ne dépasse pas 4 bpm. Alors que leur méthode semble améliorer les performances d'estimation, 36% de fenêtres sont rejetés de chaque patient, faisant des trous dans la série de FR estimée.

Nous avons proposé une nouvelle stratégie de fusion avec le Lisseur de Kalman basée sur un modèle paramétrique sinusoïdale comme modèle d'état. Peu de recherches ont été menées sur l'utilisation d'un modèle pour les modulations respiratoires [42], [82]. Les résultats de fusion ont montré des gains notables dans les performances d'estimation de la FR, par rapport aux méthodes existantes dans la littérature. Les IQRs jouent un rôle dans la sélection des modulations à fusionner par le LK. Seules les modulations de bonnes qualités sont donc utilisées comme signaux d'entrée.

L'algorithme de fusion (à 2 entrées) proposé améliore globalement les résultats dans toutes les activités. Ceci est particulièrement vrai pour la marche et la conduite, avec une réduction de l'erreur médiane de 1.1 bpm et de 0.7bpm par rapport à la meilleure modulation (RSA), respectivement. Cela montre que la fusion en utilisant le LK est capable de s'adapter à une activité de haut niveau et d'améliorer l'estimation du signal respiratoire. La généralisation de l'algorithme de LK à  $m$  entrées améliore encore l'estimation de la FR dans toutes les activités dans la base de données SHERPAM, et par rapport aux méthodes réimplémentées de la littérature [18], [41]. En outre, il a été montré qu'il existe un consensus entre les avantages de la fusion et le rejet des artéfacts, pour lesquels le seuil IQR est configurable pour différentes applications.

Néanmoins, cette approche de fusion par le LK présente quelques limitations. En effet, la régularité des modulations est souvent nécessaire pour obtenir une amélioration de performances par la fusion. Si les IQRs sont insuffisants (aucune modulation est jugée suffisamment régulière), la fusion n'est pas appliquée et par conséquent la fusion n'apporte aucune amélioration. L'amélioration est plus nette quand les IQRs permettent de sélectionner les multiples entrées en fusion. Nous observons également que la méthode proposée sous-estime parfois la FR, ceci est dû à la présence des activités non respiratoires de basses fréquences. Comme indiqué dans [41], il existe des fluctuations de base dans le signal PPG qui sont indépendantes de la respiration et qui font partie d'une réponse

vasculaire distincte au système nerveux sympathique. Ces fluctuations de basse fréquence (0.12 Hz) sont souvent appelées ondes de Mayer. Le LK est incapable de ne pas tenir compte de cette modulation régulière, mais non-respiratoire.

## 4.7 Conclusion

Dans ce travail, deux méthodes sont présentées pour l'estimation indirecte de la FR. La première consiste à sélectionner le meilleur signal de modulation avec les scores IQRs les plus élevés. La seconde consiste à combiner des modulations via les IQRs à l'aide d'un Lisseur de Kalman. Nous avons évalué la performance et la capacité de généralisation des approches sur deux ensembles de base de données indépendantes : 1) la base de donnée CAPNOBASE recueillis chez des patients pendant l'anesthésie et 2) la base de données SHERPAM recouvrant un ensemble d'activités quotidiennes courantes.

Sur la base de données CAPNOBASE, nous avons comparé notre proposition à plusieurs solutions reportées dans la littérature et montré au travers des tests statistiques le bien fondé de la fusion par le lisseur de Kalman sur les signaux PPG. C'est en effet ce dernier qui apparaît comme le moins différent de la référence. On a en effet retrouvé une erreur de 0.5 bpm sur la base CAPNOBASE. Cette erreur est largement diminué par rapport aux meilleurs résultats reportés dans la littérature (1.2 bpm) Pour la première fois, et à notre connaissance, des expérimentations ont été conduites sur les signaux ECG de la base de données CAPNOBASE. Une nouvelle fois, l'approche par fusion et lisseur de Kalman s'est montrée intéressante. Ces résultats conduisent à une erreur de 0.3 bpm. Ils deviennent un support de comparaison pour d'autres travaux.

La deuxième expérimentation avait pour objectif de nous rapporter de conditions réelles d'utilisation sur une base de données enregistrées lors d'activités quotidiennes. Dans cette optique, nous avons utilisé la base de données SHERPAM. Les performances comme on pouvait s'attendre fluctuent avec l'activité mais il importe de souligner que l'approche qui fusionne plusieurs modulations respectant un seuil pré-établi est particulièrement pertinente pour le problème posé. L'erreur fluctue de 0.5 à 3 bpm en la comparant à la

référence, quelque soit la position et est largement inférieure aux méthodes de la littérature que nous avons réimplémentées ou l'erreur varie approximativement de 2 à 6 bpm.

Les suites à donner à ce travail sont naturelles, nous visons à valider ces méthodes sur un grand ensemble de données d'activités quotidiennes et à étendre leur utilisation à d'autres contextes cliniques tels que la surveillance néonatale où il est crucial de réduire le nombre de capteurs sans perte d'observabilité et de précision du diagnostic.

# Chapitre 5

## Fusion par le Lisseur de Kalman avec un modèle multimodal

### 5.1 Introduction

Dans le chapitre 3, nous avons proposé une méthode de fusion des modulations par le Lisseur de Kalman en exploitant un modèle sinusoïdal unimodal. Il était intéressant de s'interroger sur la pertinence d'utiliser une ou plusieurs sinusoïdes dans le modèle. Dans ce chapitre, une extension de notre méthode basée sur un modèle multimodal représentatif des modulations, est donc décrite. L'étude présentée propose une approche originale de fusion de modulations basée sur un modèle à multiples modes fréquentiels dans l'objectif d'augmenter les performances de l'estimation de la fréquence respiratoire (FR).

Ce chapitre est organisé en trois sections principales. La section 5.2 présente les motivations et les contributions de l'extension du modèle multimodal. Dans la section 5.3, nous présentons une description détaillée du modèle à multiples fréquences ainsi que la fusion à 2 entrées par le Lisseur de Kalman avec ce modèle. Enfin, les résultats et la conclusion sont discutés dans la section 5.4.



## 5.2 Motivation

L'originalité de cette étude est de proposer un modèle de signal à multiples modes fréquentiels dans l'étape de fusion par le LK. La stratégie est justifiée par l'observation que les énergies spectrales des signaux de respiration se répartissent dans des multiples bandes fréquentielles, en particulier pour les signaux de forme plus carrée. La Figure (5.1) présente plusieurs exemples de modulations et leur spectre et montre que plusieurs modes peuvent co-exister.

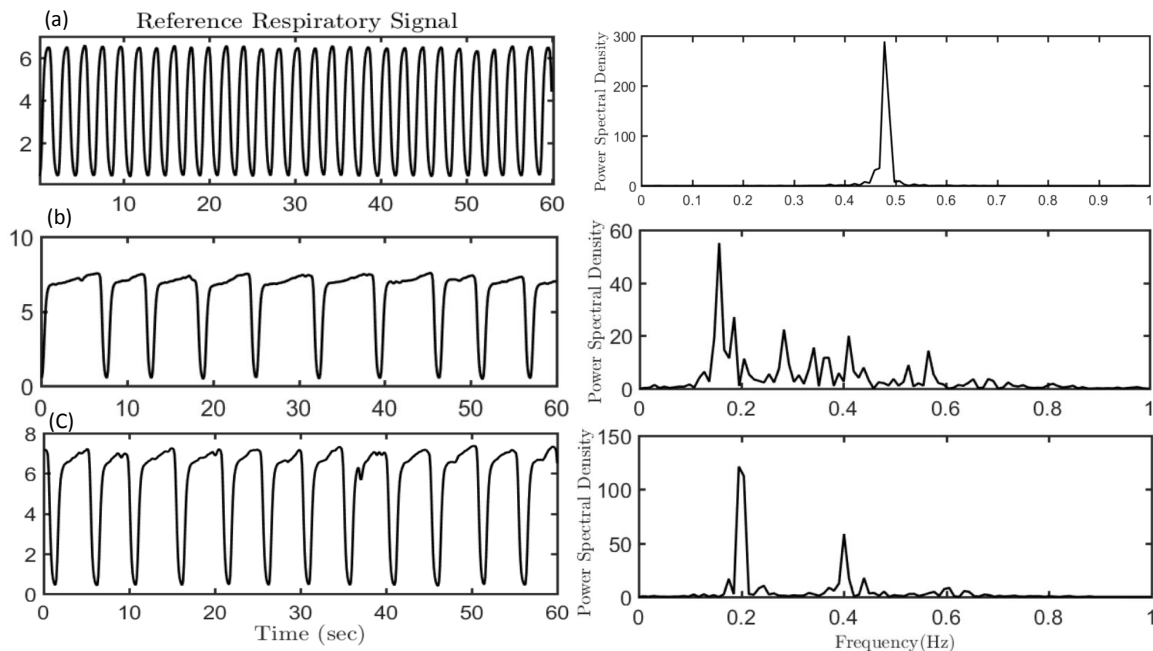


FIGURE 5.1 – Exemples de signaux respiratoires (à gauche) et leur spectre de fréquence (à droite).

## 5.3 Méthodes

### 5.3.1 Modèle multimodal

On suppose ici que le signal de modulation extrait des signaux ECG et/ou PPG, est représenté par une forme d'onde sinusoïdale à multiples modes fréquentiels. Sans perte de

généralité, on expose dans la suite un modèle avec 2 modes sinusoïdaux :

$$y_k = A_1 \cos(2\pi \bar{f}_1 k + \theta_1) + A_2 \cos(2\pi \bar{f}_2 k + \theta_2) + o_k + b_k, \quad (5.1)$$

où  $b_k$  est un bruit blanc gaussien,  $\bar{f}_1, \bar{f}_2$  les fréquences normalisées des modes de la respiration avec les amplitudes  $A_1, A_2$  et les déphasages  $\theta_1, \theta_2$  respectivement.

### 5.3.2 Lisseur de Kalman avec modèle multimodal

Dans cette section, nous présentons une application du Lisseur de Kalman avec un modèle à 2 modes sinusoïdaux défini par :

$$X_{k+1} = F X_k + W_k \quad (5.2)$$

$$Z_k = H X_k + V_k \quad (5.3)$$

où  $X_k$  est le vecteur d'état à estimer (résultat de la fusion) et  $Z_k$  le vecteur d'observation. Les processus aléatoires  $W_k$  et  $V_k$  sont supposés blancs, gaussiens centrés et indépendants :  $W_k \sim N(0, Q)$  et  $V_k \sim N(0, R)$ . Les matrices  $Q$  et  $R$  sont les covariances de la commande et du bruit de mesure. La matrice de transition d'état  $F$  relie l'état actuel  $X_k$  à l'état futur  $X_{k+1}$ . La matrice de mesure  $H$  relie l'état  $X_k$  à l'observation  $Z_k$ .

Nous supposons que les observations (modulations extraites de l'ECG et/ou PPG) sont caractérisées par deux composantes fréquentiels  $Z_k = [z_k^1 \quad z_k^2]^t$  tels que :

$$z_k^1 = A_1 \cos(2\pi \bar{f}_1 k + \theta_1) + A_2 \cos(2\pi \bar{f}_2 k + \theta_2) + o_k^1 + b_k^1 \quad (5.4)$$

$$z_k^2 = A_3 \cos(2\pi \bar{f}_1 k + \theta_3) + A_4 \cos(2\pi \bar{f}_2 k + \theta_4) + o_k^2 + b_k^2 \quad (5.5)$$

avec les fréquences normalisées  $\bar{f}_1, \bar{f}_2$  identiques, mais les amplitudes  $A_1, A_2, A_3, A_4$  et les déphasages  $\theta_1, \theta_2, \theta_3, \theta_4$  différents dans chaque observation. les bruits de mesure  $b_k^1, b_k^2$ , et les lignes de base  $o_k^1, o_k^2$  sont définis comme précédemment. Le vecteur d'état sera donc défini par  $X_k = [\cos(2\pi \bar{f}_1 k), \sin(2\pi \bar{f}_1 k), \cos(2\pi \bar{f}_2 k), \sin(2\pi \bar{f}_2 k), o_k^1, o_k^2]^t$ , et la matrice  $F$

est déterminée en réécrivant l'équation 5.2 :

$$X_{k+1} = \underbrace{\begin{bmatrix} \cos(2\pi\bar{f}_1) & -\sin(2\pi\bar{f}_1) & 0 & 0 & 0 & 0 \\ \sin(2\pi\bar{f}_2) & -\sin(2\pi\bar{f}_2) & 0 & 0 & 0 & 0 \\ 0 & 0 & \cos(2\pi\bar{f}_2) & -\sin(2\pi\bar{f}_2) & 0 & 0 \\ 0 & 0 & \sin(2\pi\bar{f}_2) & \cos(2\pi\bar{f}_2) & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}}_F X_k + W_K \quad (5.6)$$

Comme dans le chapitre 3, on définit la matrice de covariance  $Q$  par :

$$Q = \begin{bmatrix} 0.1^2 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0.1^2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.1^2 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0.1^2 & 0 & 0 \\ 0 & 0 & 0 & 0 & (0.1 \times o_k^1)^2 & 0 \\ 0 & 0 & 0 & 0 & 0 & (0.1 \times o_k^2)^2 \end{bmatrix} \quad (5.7)$$

Pour la matrice de mesure  $H$ , les équations des 2 observations (5.4) and (5.5) sont remplacées dans l'équation d'observation (5.3) :

$$Z_k = \underbrace{\begin{bmatrix} A_1 \cos\theta_1 & -A_1 \sin\theta_1 & A_2 \cos\theta_2 & -A_2 \sin\theta_2 & 1 & 0 \\ A_3 \cos\theta_3 & -A_3 \sin\theta_3 & A_4 \cos\theta_4 & -A_4 \sin\theta_4 & 0 & 1 \end{bmatrix}}_H X_k + V_k, \quad (5.8)$$

Comme dans [89], la covariance des bruits d'observations  $R$  est définie par :

$$R = \begin{bmatrix} \sigma_1^2 & 0 \\ 0 & \sigma_2^2 \end{bmatrix} \quad (5.9)$$

### 5.3.3 Initialisation Lisseur de Kalman (LK)

Pour chaque fenêtre, on initialise le LK en fixant les paramètres  $\bar{f}_1, \bar{f}_2, A_1, A_2, \theta_1, \theta_2, \sigma_1^2$  et  $\sigma_2^2$  pour construire les matrices  $F, H, Q, R$ . Les fréquences  $\bar{f}_1, \bar{f}_2$  d'une fenêtre donnée sont initialisées par les valeurs estimées dans la fenêtre précédente (hypothèse de continuité). Les amplitudes  $A_1, A_2$  et les phases  $\theta_1, \theta_2$  sont estimées par la méthode des moindres carrés, soit :

$$\widehat{A}_{ML} = \begin{bmatrix} \widehat{A}_1 \cos(\widehat{\theta}_1) \\ -\widehat{A}_1 \sin(\widehat{\theta}_1) \\ \widehat{A}_2 \cos(\widehat{\theta}_2) \\ -\widehat{A}_2 \sin(\widehat{\theta}_2) \end{bmatrix} = (L^t \times L)^{-1} L^t \times Z \quad (5.10)$$

où  $Z$  est un des signaux d'observations de longueur  $N$  et la matrice  $L$  est définie par :

$$L = \begin{bmatrix} \cos(2\pi \bar{f}_1 (-\frac{N-1}{2})) & \sin(2\pi \bar{f}_1 (-\frac{N-1}{2})) & \cos(2\pi \bar{f}_1 (-\frac{N-1}{2})) & \sin(2\pi \bar{f}_1 (-\frac{N-1}{2})) \\ \vdots & \vdots & \vdots & \vdots \\ \cos(2\pi \bar{f}_1 \frac{N-1}{2}) & \sin(2\pi \bar{f}_1 \frac{N-1}{2}) & \cos(2\pi \bar{f}_1 \frac{N-1}{2}) & \sin(2\pi \bar{f}_1 \frac{N-1}{2}) \end{bmatrix}_{N \times 4}$$

En posant ensuite  $\widehat{A}_{ML} = [\alpha_1, \alpha_2, \alpha_3, \alpha_4]^t$ , nous obtenons les estimations de nos inconnues, soit :

$$\widehat{A}_1 = \sqrt{\alpha_1^2 + \alpha_2^2} \quad \widehat{A}_2 = \sqrt{\alpha_3^2 + \alpha_4^2} \quad (5.11)$$

$$\widehat{\theta}_1 = \arctan(-\alpha_2/\alpha_1) \quad \widehat{\theta}_2 = \arctan(-\alpha_4/\alpha_3) \quad (5.12)$$

Les variances  $\sigma_1^2$  et  $\sigma_2^2$  sont initialisées sous la forme de l'erreur quadratique moyenne (EQM) entre l'observation et le modèle estimé :

$$\sigma_1^2 = \frac{1}{N} \sum_{k=0}^{N-1} \left( (z_k^1 - \bar{z}_k^1) - \widehat{A}_1 \cos(2\pi \bar{f}_1 k + \widehat{\theta}_1) - \widehat{A}_2 \cos(2\pi \bar{f}_2 k + \widehat{\theta}_2) \right)^2$$

$$\sigma_2^2 = \frac{1}{N} \sum_{k=0}^{N-1} \left( (z_k^2 - \bar{z}_k^2) - \widehat{A}_3 \cos(2\pi \bar{f}_1 k + \widehat{\theta}_3) - \widehat{A}_4 \cos(2\pi \bar{f}_2 k + \widehat{\theta}_4) \right)^2$$

avec  $\bar{z}_k^1$  et  $\bar{z}_k^2$  les moyennes pour chaque observation. Remarquons que le choix de  $Z$  dans l'équation 5.10 pour l'initialisation est totalement arbitraire et ne devrait pas avoir d'impact majeur sur le résultat du signal fusionné.

Les performances de l'algorithme proposé ont été évaluées avec des fenêtres de 32 s en utilisant le même critère  $EA = |\text{FR}_{\text{ref}} - \widehat{\text{FR}}|$ . Les performances de notre algorithme sont comparées i) avec deux méthodes dans la littérature et réimplémentées avec optimisation de paramètres : Pimentel 2016 [41] et Karlen 2013 [18] (cf chapitre 4) ainsi que ii) l'approche unimodal du chapitre précédent.

## 5.4 Résultats

### 5.4.1 Modèle unimodal vs bimodal

A présent, nous comparons les deux modèles sur la même CAPNOBASE (cf. chapitre 3). Pour mémoire, les signaux de modulations (RIAV, RIIV et RIFV) sont extraits du signal PPG et échantillonnées à 10 Hz. Toutes les 32s, les deux modulations avec les meilleurs indices de qualité (IQRs) sont l'entrée du LK, dont la sortie est un signal respiratoire lissé pour estimer la FR. Les résultats ont montré que l'erreur d'estimation de la FR du modèle bimodal est diminuée par rapport aux résultats du modèle unimodal dans certains cas et d'une manière remarquable. Dans d'autres cas, en revanche, la précision de l'estimation a été fortement dégradée.

La Figure 5.2 présente des exemples sur quatre patients (A, B, C et D). Les erreurs absolues (en bpm) sont obtenues par fenêtre de 32s avec le modèle unimodal (mode 1) et celui de bimodal (mode 2). Nous remarquons l'amélioration des résultats du patient B et C. Par contre chez le patient D, l'erreur absolue obtenue est ponctuellement plus élevée avec le modèle bimodal.

Sont illustrés dans la Figure 5.3 et 5.4, deux exemples de signaux à l'issue de la fusion par LK afin d'expliquer le changement brutal de la précision de l'estimation. La détection des cycles respiratoires est réalisée dans chaque cas. Dans la Figure 5.3, la régularité du signal fusionné par le modèle à deux modes permet une meilleure détection de maxima

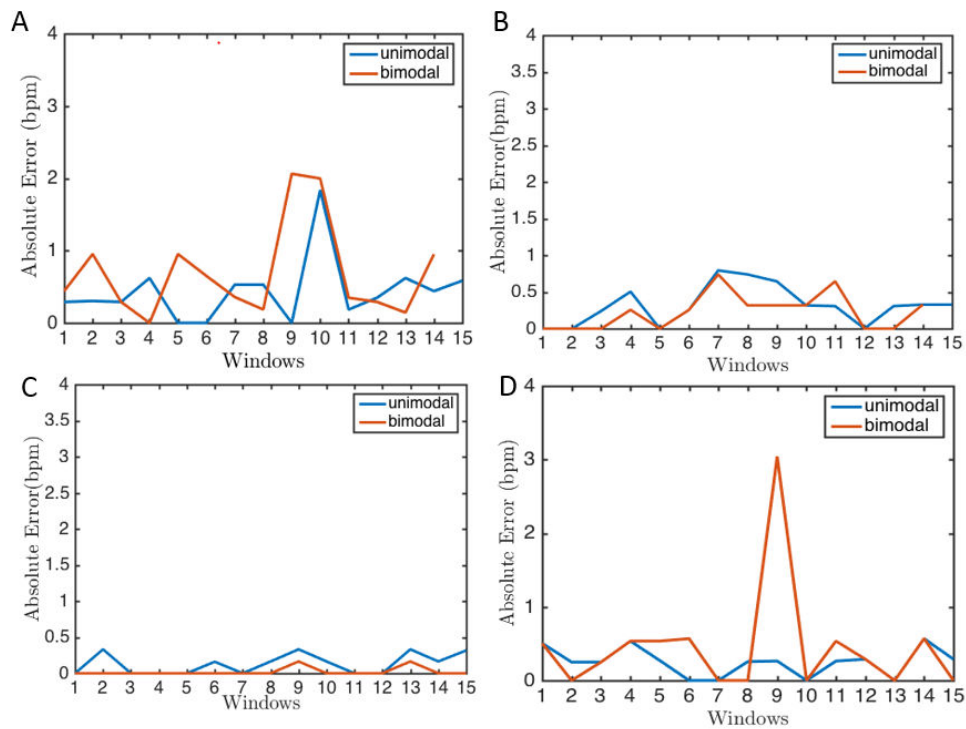


FIGURE 5.2 – Exemples (de quatre patients A, B, C et D) des erreurs absolues (en bpm) d’estimation avec les modèles unimodal et bimodal.




FIGURE 5.3 – Exemple de comparaison de détection des pics dans le signal obtenu à la sortie du LK en appliquant le modèle unimodal (mode 1) et le modèle bimodal (mode 2).




FIGURE 5.4 – Autre exemple de comparaison de détection des pics dans le signal obtenu à la sortie du LK en appliquant le modèle unimodal (mode 1) et le modèle bimodal (mode 2).

(la base de l'estimation de FR). Inversement dans la Figure 5.4, la grande fluctuation de l'amplitude (non régularité) du signal fusionné par le modèle à deux modes a perturbé la détection de cycles et par conséquent introduit une dégradation au sens d'EA.

Ce phénomène est synthétisé par la Figure 5.5 : trois boxplots correspondent aux trois IQRs. Les résultats montrent que le modèle unimodal (0.16-0.73 bpm) présente toujours de meilleurs résultats que le modèle bimodal (0.12-1.45 bpm), principalement à cause du phénomène illustré dans la Figure 5.4. Par conséquent, nous devons garantir la régularité du signal lissé de LK en proposant une sélection automatique du modèle selon les contextes.

Dans la suite, nous allons tester une simple sélection du modèle minimisant l'écart type des ttots détectés. L'idée est de favoriser l'estimation de la FR avec les ttots les plus réguliers parmi les deux modèles.




FIGURE 5.5 – Les boxplots d’estimation de la FR à partir des signaux PPG de CAPNO-BASE en se basant sur le modèle unimodal (mode 1) et le modèle bimodal (mode 2). Les boxplots correspondent aux résultats de fusion par le LK pour les trois indices  $IQR_{\text{SINUS}}$ ,  $IQR_{\text{FT}}$  et  $IQR_{\text{Autocor}}$ .

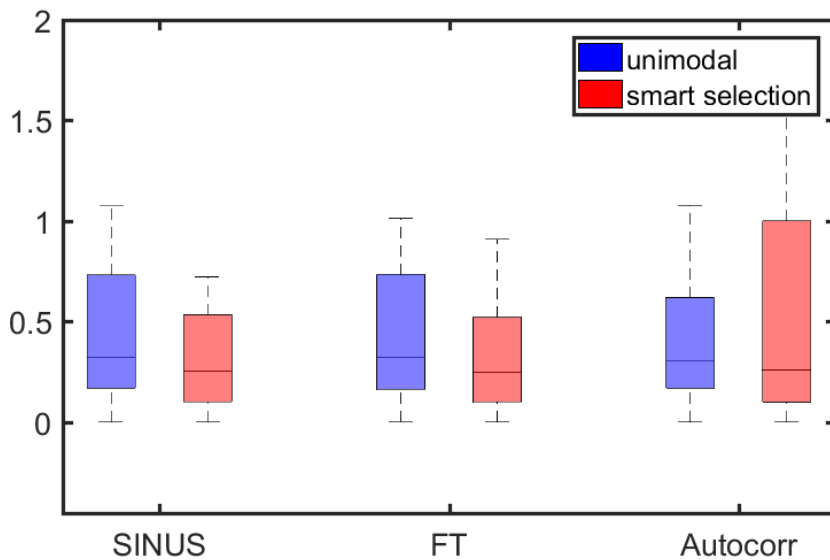


FIGURE 5.6 – Les erreurs médianes d’estimation de la FR à partir des signaux PPG de CAPNOBASE avec la méthode *Smart Selection* pour les trois indices.



### 5.4.2 Evaluation sur les signaux PPG (CAPNOBASE)

Nous avons validé cette méthode sur la base de données CAPNOBASE à l'aide des modulations du signal PPG (RIIV, RIAV et RIFV), et pour la taille de fenêtre 32s. Chaque IQR est testé indépendamment :  $IQR_{FT}$ ,  $IQR_{SINUS}$ ,  $IQR_{Autocor}$ . Comme au chapitre 4, nous avons également réimplémenté les approches de Pimentel [41]) et Karlen [18]. Les performances sont présentées dans le tableau 5.1. Les résultats obtenus avec le nouveau modèle, appelé *Smart Selection*, surpassent la méthode implémentée avec le modèle bimodal et le modèle unimodal (Figure 5.5) avec une médiane d'erreur de 0.27 bpm (0.13-0.57 bpm). De plus, elle dépasse également les méthodes existantes dans la littérature. Les boxplots des erreurs sont représentés dans la Figure 5.6, les trois boxplots correspondent aux résultats de la fusion obtenus pour les différents indices. Les boxplots indiquent clairement que le  $IQR_{TF}$  atteint le meilleur résultat avec le LK avec l'approche *smart selection*. Le tableau 5.1 montre que nos résultats sont également meilleurs que ceux de la méthode de Karlen [18], qui supprime 36% de fenêtres par enregistrement pour lesquels l'écart entre les différents modulations est supérieur à 4 bpm [18].

<b>MAE(bpm) on PPG CAPNOBASE</b>			
	<b>1 mode</b>	<b>2 mode</b>	<b>Smart Selection</b>
<b>Proposed Methods</b>			
SINUS + 2 inputs KS	0.32 (0.17-0.52)	0.27 (0.13-1.15)	0.26 (0.12-0.61)
TF + 2 inputs KS	0.34 (0.19-0.73)	0.28 (0.12-1.45)	0.27 (0.13-0.57)
Autocor + 2 inputs KS	0.54 (0.33-0.54)	0.29 (0.13-1.25)	0.26 (0.12-0.61)
<b>Literature Methods</b>			
Pimentel (2016)		0.9 (0.5-3.5)	
Karlen (2013)		1.1 (0.3-2.6)	

TABLE 5.1 – Erreurs d'estimation de la FR avec les signaux PPG dans CAPNOBASE. La médiane de L'erreur absolue (bpm) et l'interquartile (25e-75e) sont présentées.

### 5.4.3 Evaluation sur les signaux ECG (CAPNOBASE)

De même, nous avons validé cette méthode sur les signaux ECG de la base de données CAPNOBASE à l'aide des modulations extraites RPA, RSA, QRA et AQRS, et pour une taille de fenêtre 32 s. Les résultats obtenus sont présentés dans le tableau 5.2 .

Là encore, les résultats obtenus avec le nouveau modèle appelé *smart selection* surpassent les méthodes implémentées avec le modèle unimodal et bimodal. Le meilleur résultat obtenu est celui de  $IQR_{TF}$ , avec une médiane de 0.24 (0.15-0.41) bpm pour une taille de fenêtre 32 s. De plus, ce résultat dépasse les méthodes existantes de la littérature de Karlen [18] et de Pimentel [41] en utilisant nos méthodes implémentées optimiser (voir tableau 5.2).

<b>MAE(bpm) on ECG CAPNOBASE</b>			
	<b>Unimodal</b>	<b>Bimodal</b>	<b>Smart Selection</b>
<b>Proposed Methods</b>			
SINUS + 2 inputs KS	0.36 (0.25-0.55)	0.41 (0.25-1.5)	0.27 (0-0.63)
TF + 2 inputs KS	0.34 (0.25-0.51)	0.51 (0.21-1.2)	0.24 (0.15-0.41)
autocor + 2 inputs KS	0.35 (0.28-0.89)	0.33 (0.21-1.6)	0.22 (0.16-0.64)
<b>Literature Methods</b>			
Pimentel (2016)		1.4 (0.8-3.6)	
Karlen (2013)		1.1 (0.3-2.6)	

TABLE 5.2 – Erreurs d'estimation de la FR avec les signaux ECG de la base de données CAPNOBASE. La médiane de L'erreur absolue (bpm) et l'interquartile (25e-75e) sont présentées.

### 5.4.4 Evaluation sur les signaux ECG (SHERPAM)

Nous avons validé la méthode proposée sur les signaux ECG de la base de données SHERPAM. Cette base de données comporte six activités quotidiennes. Pour mémoire, la référence est le dispositif cosmed K4B2 (Voir chapitre 4).

Les résultats obtenus sont reportés dans le tableau 5.3 avec la méthode *smart selection*, les résultats surpassent ceux obtenus avec le modèle unimodal. Par exemple, dans l'activité "assise" et en se basant sur l'indice  $IQR_{\text{SINUS}}$  l'erreur diminue de 1 bpm (0.4-3.2) bpm à 0.8 bpm (0-1.7) bpm. Il en est de même pour "l'activité de travail" ou l'erreur absolue passe de 1.6 bpm (1.5-2.2) à 1.1 bpm (0.6-2.2) bpm. Les mêmes constats ont été pour les autres activités, les erreurs d'estimation de la FR ont diminué par rapport à la référence.

EAM and 25-75 percentile (bpm), SHERPAM (10 subjects)						
	sit	stand	lie	drive	work	walk
<b>Fusion</b>						
SINUS	1.0(0.4-3.2)	1.2(0.4-3.1)	0.8(0.4-1.9)	1.4(0.4-2.5)	1.6(1.5-2.2)	1.4(0.6-2)
FT	1.1(0.4-2.3)	1.2(0.6-2.9)	0.6(0.3-1.5)	1.1(0.4-1.7)	1.2(0.8-2.1)	0.3(0.1-0.8)
Autocorr	1.1(0.4-2.2)	1.3(0.3-3.6)	0.7(0.3-1.9)	1.2(0.6-1.6)	1.4(0.6-2.2)	0.7(0.2-1.9)
<b>Smart Selection</b>						
SINUS	0.6(0.0-1.7)	1.2(0.6-2.7)	0.8(0.0-1.9)	0.0(0.0-1.7)	1.1(0.6-2.2)	0.6(0.3-0.9)
FT	0.7(0.0-2.1)	1.1(0.6-2.3)	0.7(0-1.5)	1.1 (0.4-1.8)	1.1(0.6-2.2)	0.7(0.3-1.4)
Autocorr	0.8(0.2-2.3)	1.1(0.5-2.7)	0.7(0.0-1.3)	1.1(0.0-1.7)	1.9(1.4-2.7)	0.6(0.3-1.1)

TABLE 5.3 – Performance d'estimation de la FR en appliquant la nouvelle méthode proposée *smart selection*, avec ECG de la base de SHERPAM (fenêtre de 32 s). Sont rapportées les médianes des erreurs absolues et interquartiles en bpm des 10 sujets.

## 5.5 Conclusion

Nous avons étendu notre modèle de fusion en considérant deux modes fréquentiels partant de l'hypothèse que pratiquement un signal respiratoire régulier n'est pas simplement sinusoïdal, mais peut être mieux représenté par un modèle plus riche.

Les résultats obtenus sur CAPNOBASE montrent des améliorations du lissage. Cependant, dans certains cas, le modèle bimodal reste moins robuste face aux modulations moins régulières et peut parfois amplifier les variations non liées à la respiration. Un simple arbitrage par l'écart type des ttots détectés permet de choisir entre le modèle bimodal ou le unimodal. Cette dernière approche a montré un gain notable dans les performances. Cette preuve de faisabilité et d'intérêt a aussi été montrée sur la deuxième base d'étude de ce mémoire de thèse, la base de données SHERPAM.



# Chapitre 6

## Estimation de la fréquence respiratoire : Application à la surveillance néonatale

### 6.1 Introduction

Ce dernier chapitre rentre dans le contexte de l'étude des rythmes cardiaques et respiratoires pour le développement d'outils d'aide à la décision en néonatalogie. Le travail de recherche mené ces dernières années par notre laboratoire (PHRC Intem, PHRC Caress-premi, Projet européen DigiNewB) vise à développer de tels outils en particulier pour la détection des infections nosocomiales qui sont une cause majeure de morbidité et mortalité [93] et qui augmentent la durée d'hospitalisation [94]. Le signal cardiaque et respiratoire sont monitorés en continu et leur recueil est non-invasif. L'altération du comportement cardiorespiratoire au cours de l'infection permet d'envisager une évaluation continue du risque infectieux. Des travaux ont été menés par notre équipe tels que ceux conduits par A. Beuchée [95] ou encore X. Navaro [96]. L'inconvénient, et en particulier dans l'analyse du rythme respiratoire, est que les signaux enregistrés sont très bruités. Il était donc intéressant de tester la pertinence de notre approche dans l'estimation de la fréquence respiratoire à partir du signal ECG, même si la FR du prématuré est beaucoup élevée que celle de l'adulte et peut d'emblée représenter une limitation dans son estimation (Figure 6.1.

Dans ce chapitre, nous exploitons essentiellement les signaux ECG dans le but de déterminer si les modulations dérivées du signal ECG peuvent donner des informations fiables sur la fréquence respiratoire (FR). Dans ce contexte, deux points sont étudiés : 1) nous évaluons l'estimation de la FR à partir des signaux ECG des nourrissons en comparant l'estimation de la FR à celle d'un signal de référence, et 2) nous étudions la capacité à repérer des apnées à partir des modulations dérivées de l'ECG. Dans un premier temps nous présentons la base de données que nous avons utilisé. Pour faciliter la lecture de ce chapitre de manière indépendante, un bref rappel de la méthode utilisée est proposée. Puis les performances suivant les deux points mentionnés ci-dessus (estimer la FR et repérer les apnées) sont décrits. Il importe ici de souligner que l'objectif de ce chapitre est de montrer la faisabilité et l'extension de notre approche à des données ECG plus difficiles. En effet, le signal ECG du prématuré est d'amplitude plus réduite, la durée de l'onde QRS est plus fine et la FR est plus élevée.




FIGURE 6.1 – Cette figure présente un exemple du signal ECG A) pour un adulte (à B) pour un nouveau-né prématuré (à droite).

## 6.2 La Base de données Néonatale

La base de données est constituée de nourrissons nés très prématurés entre 27 et 29 semaines de gestation et ayant au moins sept semaines d'âge postnatal [74]. Les nourrissons

qui présentaient des infections, une dysrythmie cardiaque, un reflux gastro-oesophagien nécessitant un traitement, des lésions intra-cérébrales graves, ou qui étaient actuellement traités au doxapram, à la caféine, sont exclus de l'étude. Dans cette étude, les données sont obtenues à partir de 11 bébés avec des enregistrements simultanés des signaux ECG et respiratoires pour une durée de 30 min. La respiration est mesurée par un capteur piézoélectrique. Vingt-cinq segments propres de signaux ECG et respiratoires d'une durée de 4 min, ont été extraits. Les deux signaux sont échantillonnés avec une fréquence d'échantillonnage  $f_s = 512$  Hz.

## 6.3 Méthodes

La chaîne de traitement décrite au chapitre 3 a été appliquée dans cette application pour évaluer les performances d'estimation de la FR. Les résultats des deux approches : (1) la sélection des modulations extraites du signal ECG (RPA, RSA, AQRS et QRA) basées sur les indices de qualité (IQRs) et (2) la fusion automatique des modulations par le lisseur de Kalman sont présentés dans cette section.

Comme déjà présenté dans le chapitre 3, le signal ECG est filtré pour éliminer différents types de bruit tout en conservant les caractéristiques de l'amplitude de l'onde QRS de l'ECG. Ensuite, un algorithme de détection des ondes QRS en temps réel développé dans notre laboratoire est utilisé pour la détection des ondes Q, R et S [85]. Ces derniers sont utilisés pour la construction des modulations respiratoires RPA, QRA, RSA et AQRS (voir Figure 6.2). Les modulations sont ensuite interpolées à 10 Hz et filtrées par un filtre passe-bande de range de respiration compris entre (0.3-1.5 Hz) [74] qui correspondent à des respirations compris entre 18 et 90 cycles/ min. La FR est estimée toutes les 32s. Dans cette phase préliminaire, les études sont faites sur des segments de 4 min toutes les 32s. Le bloc diagramme qui résume les principales étapes est décrit dans la Figure 3.1 du chapitre 3.






FIGURE 6.2 – Exemple d'un signal ECG et des signaux dérivées de la base de données .

## 6.4 Estimation de la fréquence respiratoire

Dans cette partie, nous avons testé nos deux méthodes proposées sur les signaux ECG. Comme mentionné auparavant la référence est ici le signal respiratoire mesurée par capteur piézoélectrique. L'erreur est donc calculée comme dans les chapitres précédents avec  $EA = |FR_{\text{ref}} - \widehat{FR}|$ . Les boxplots des erreurs absolues sont représentés dans la Figure 6.3 et tableau 6.1. Les quatre premiers boxplots correspondent aux modulations dérivées (RPA, RSA, et RIFV), suivi de trois boxplots représentant la comparaison entre

la sélection basée sur l'IQR (première approche) et la fusion à  $m$  modulations (le principe est décrit dans le chapitre 4) par le LK (seconde approche). Le dernier boxplot est destiné à la sélection *aposteriori*. Les boxplots montrent clairement que le  $IQR_{Autocorr}$  avec une médiane d'erreur 1.8 bpm (0.8- 3.8 bpm), pour une taille de fenêtre 32 s, présente le meilleur résultat lorsqu'il est associé avec le LK. Cette analyse montre tout l'intérêt de la fusion pour améliorer systématiquement les performances de l'estimation de la FR.




FIGURE 6.3 – Boxplots des résultats de l'estimation de la FR à partir des signaux ECG (médianes et 25e au 75e percentiles en bpm) pour une fenêtre de 32 s. Les quatre premières boxplots concernent les modulations dérivées (RPA, RSA, AQRS et QRA), suivies de la comparaison entre la sélection basée sur IQR (première approche) et la fusion des deux modulations par le LK (seconde approche). Les résultats de la sélection *a posteriori* sont également affichés à titre de référence.

<b>MAE(bpm) on ECG Néonatale</b>	
	<b>32s</b>
RPA	2.3 (1.4-3.8)
QRA	5.1 (2.2-8.1)
RSA	8.6 (4.8-12.2)
AQRS	3.5 (1.3-9.5)
<b>First Approach : selection</b>	
SINUS	2.8 (0.9-7.9)
FT	2.3 (1.1-7.3)
Autocor	2.1 (1.1-7.1)
<b>Second Approach : Fusion</b>	
SINUS + 2 entrées LK	2.2(0.9-3.6)
FT + 2 entrées LK	2.2(0.9-3.8)
Autocor + 2 entrées LK	1.8(0.8-3.8)

TABLE 6.1 – Les performances d'estimation de la FR en utilisant les signaux ECG de la base de données Néonatale pour une fenêtre de taille 32s. La médiane de L'erreur absolue (bpm) et l'interquartile (25e-75e), sont présentées.

## 6.5 D'autres applications : repérer des apnées

Notre deuxième objectif est de mesurer la capacité des modulations (RPA, QRA, AQRS et RSA) à détecter les épisodes d'apnées. Une nouvelle base de données *DiginewB* (incomplète, en voie d'acquisition) est utilisée dans cette application. Le test est effectué sur 4 segments d'ECG de nouveaux-nés prématurés avec des apnées entre 10s et 20s. La fréquence d'échantillonnage du signal ECG est 1000 Hz, et celle du signal respiratoire 62.5 Hz. La durée des enregistrements est de 10 min chacun. Deux exemples sont présentés dans les Figure 6.4 et Figure 6.5. Les signaux respiratoires avec des épisodes d'apnées de 10s et 20s par segment (zones délimitées par les tirets vert et rouge, respectivement) sont représentés. On remarque une modification dans les amplitudes des modulations lors des épisodes d'apnées : les amplitudes diminuent dans RPA et QRA, et augmente dans RSA. Les caractéristiques extraites du signal ECG sont particulièrement intéressantes car une

étude récente réalisée chez les adultes souffrant d'apnée obstructive du sommeil indique que les changements de pression intra-thoracique lors de l'épisode d'apnée obstructive du sommeil peuvent se traduire par des changements dans les ondes QRS de l'ECG [97].

## 6.6 Conclusion

Dans ce chapitre, nous montrons l'application de notre approche proposée dans un contexte de surveillance en pédiatrie. L'objectif était d'adapter nos algorithmes à des signaux ECG très différents chez les nouveau-nés prématurés, tant au niveau cardiaque qu'au niveau respiration. La fusion par le LK montre une nouvelle fois un grand intérêt dans ce domaine. D'autre part, l'observation des modifications dans les amplitudes des ondes QRS associée à la survenue des épisodes d'apnée est une motivation supplémentaire pour tester notre algorithme d'estimation de la FR lors de la présence des apnées. Il convient ici de préciser que ce chapitre doit être vu comme les prémisses d'un travail futur. Il permet de poser les bases de la mesure des cycles respiratoires à partir de l'ECG dans le contexte du monitoring en unités de soins intensifs néonatales. De nombreuses difficultés seront à gérer telles que la présence d'artéfacts sur l'ECG, la déconnexion des voies. Les premiers résultats enregistrés sont encourageants et laissent espérer une mesure fiable de la FR pour apprécier sa variabilité à la place de l'ECG. L'analyse de quelques situations arythmiques et d'apnées est aussi encourageante et ouvre là tout un pan de recherche.

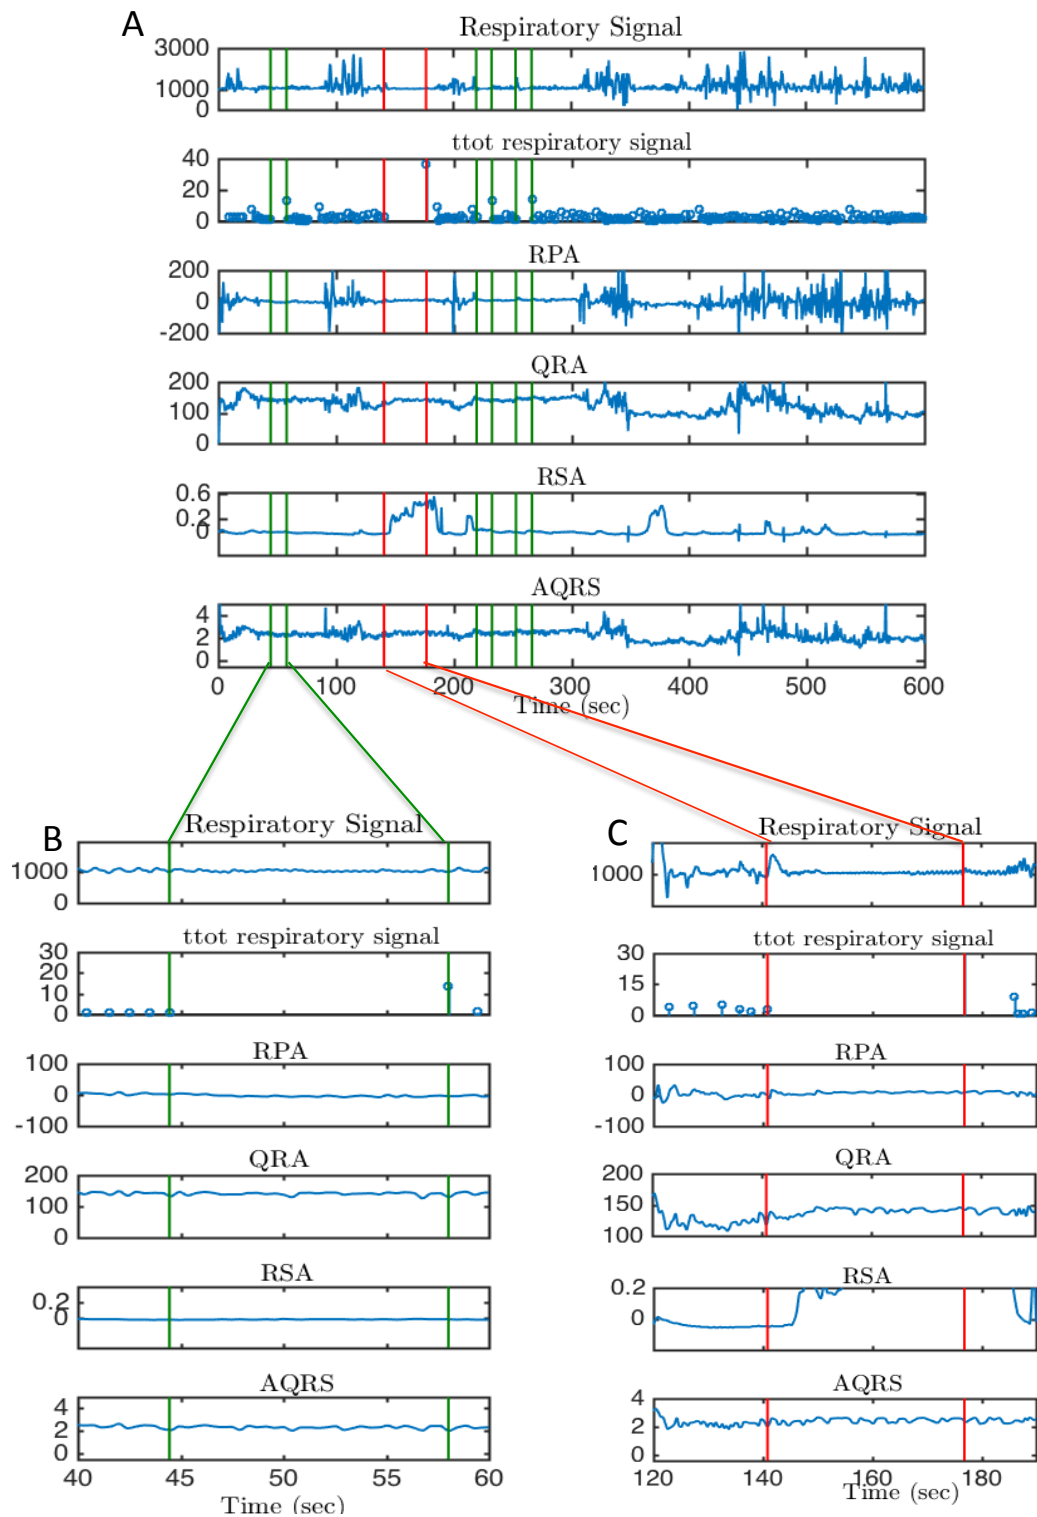


FIGURE 6.4 – La figure A présente un exemple d'un signal respiratoire et des cycles respiratoires extraites (ttot respiratoire), et les quatre modulations extraites de l'ECG (RPA, QRA, RSA et AQRS). Les figure B et C correspondent aux zones d'apnées de 10 s et 20 s, respectivement.

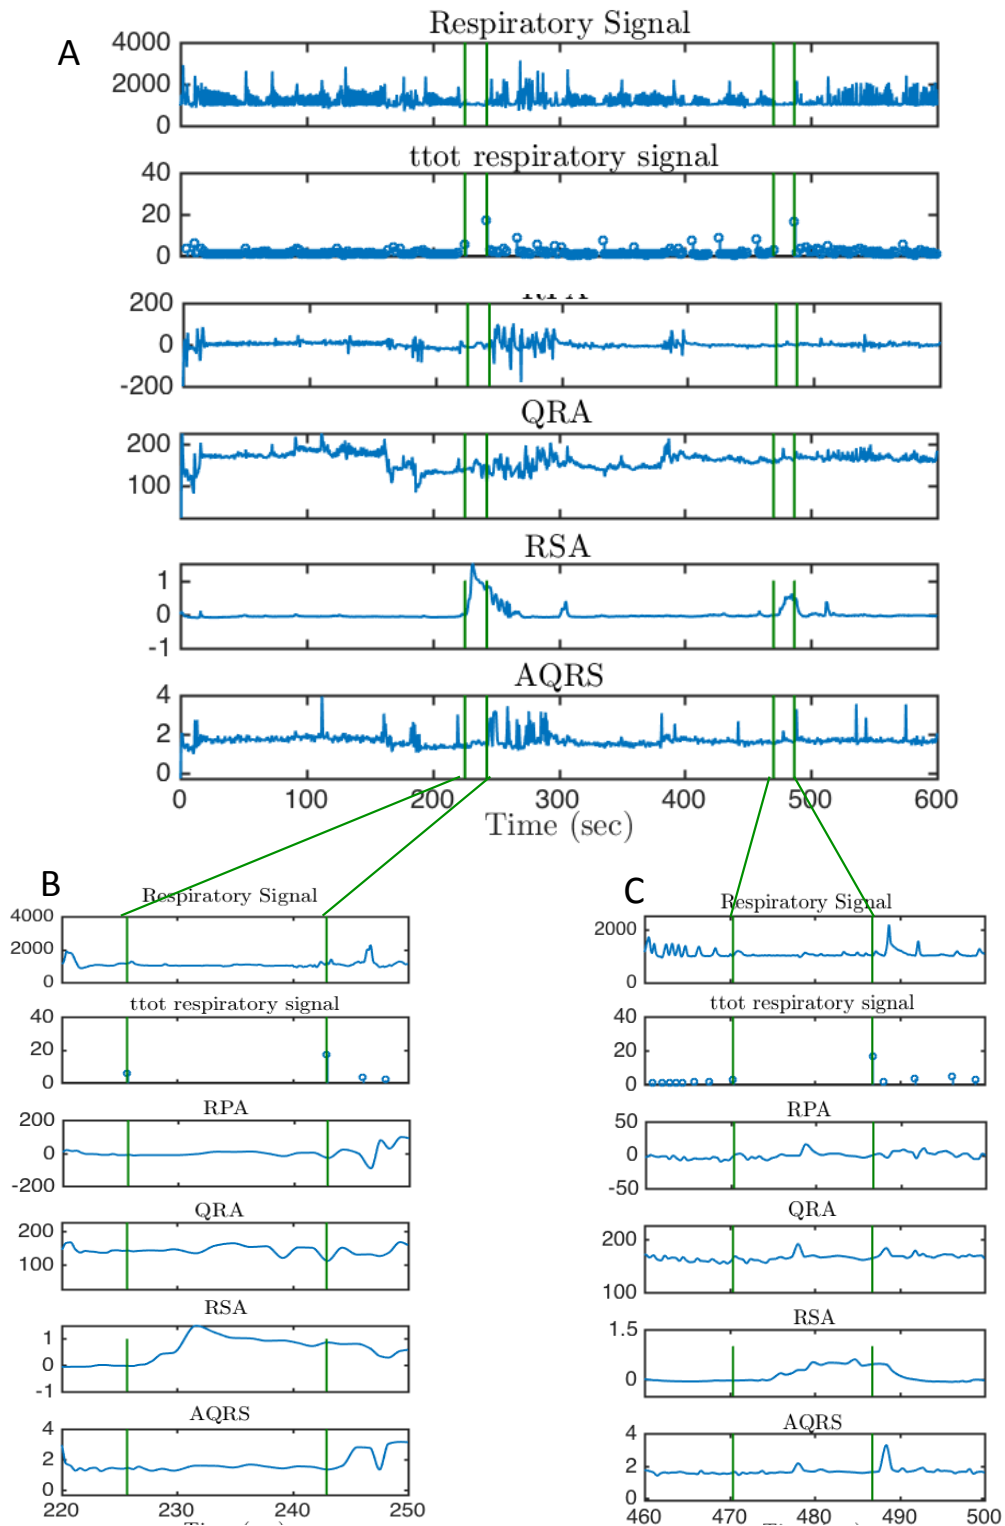


FIGURE 6.5 – La figure A présente un exemple d’un signal respiratoire et des cycles respiratoire extraites (ttot respi), et les 4 modulations extraites de l’ECG (RPA, QRA, RSA et AQRS). Les Figures B et C correspondent aux zones d’apnées de 10 s.



# Conclusion et Perspectives

Le projet SHERPAM, dans lequel la thèse s'inscrit, a eu pour objectif de concevoir, implémenter et valider un dispositif capable de recueillir en continu des données de santé et de surveiller en permanence l'état de santé des personnes au cours de leurs activités quotidiennes. Quatre domaines d'application sont impliqués : 1) l'artériopathie, 2) la reconnaissance d'arythmies cardiaques, 3) le cyclotourisme, 4) la reconnaissance et la quantification de l'activité physique. Une facette importante de l'activité physique est la surveillance continue des cycles respiratoires. En effet, l'insuffisance respiratoire affecte des millions de personnes [98], chez qui les poumons ne peuvent pas inspirer suffisamment d'oxygène (O<sub>2</sub>) ni expirer suffisamment de dioxyde de carbone (CO<sub>2</sub>) pour répondre aux besoins de l'organisme. Elle est difficile de prévoir et peut mettre la vie en danger. La surveillance continue fournissant une évaluation respiratoire en temps réel est une solution intéressante permettant des interventions rapides. La ventilation minute (VE), le volume courant (VT) et la fréquence cardiaque sont des variables importantes en médecine respiratoire et peuvent généralement être obtenus à l'aide d'un spiromètre [99], [100]. Malgré sa précision, il nécessite l'utilisation d'un masque facial ou d'un embout buccal, généralement encombrant à porter. Par conséquent, des méthodes alternatives ont été développées pour estimer les variables respiratoires à partir d'autres capteurs corporels, telles que les systèmes Visuresp [101], LifeShirt [102], [103], la pléthysmographie par magnétomètre respiratoire (RMP-S) [104]. Dans le cadre du projet SHERPAM, des solutions du type RMP-S ont été développées. Elle proposait une nouvelle technique d'estimation du volume respiratoire (V) et des paramètres ventilatoires associés (TV, RR, temps inspiratoire (TI), temps expiratoire (TE), temps total d'un cycle respiratoire (TTOT)) à l'aide des modèles



de régressions multilinéaires (RML) et de réseaux de neurones artificiels (ANN) [105]. Nous avons également abordé le problème de l'obtention d'une estimation précise de la FR, en utilisant uniquement des signaux ECG ou photopléthysmographiques (PPG) pour remplacer les mesures directes, généralement difficiles à porter pendant les activités quotidiennes.

Le but de cette conclusion n'est pas de revenir aux principaux résultats obtenus tout au long de cette thèse. Ces résultats peuvent être trouvés à la fin de chaque chapitre. Nous préférons insister sur les contributions intéressantes fournies par cette thèse qui sont rappelés ci-dessous.

La première propose une revue de la littérature qui montre que plusieurs algorithmes ont été proposés pour l'estimation de la fréquence respiratoire (FR) à partir de signaux de modulations dérivés du PPG ou de l'ECG. Il ressort de cette étude que peu de travaux ont étudié la qualité de ces modulations.

Nous avons donc repris ce principe. Les modulations dérivées de ces 2 signaux sont celles qui exploitent l'amplitude des maxima, la fréquence (différence temporelle entre les maxima) et les variations d'amplitude (l'aire du QRS pour le l'ECG ou la différence d'amplitude crête à crête sur le PPG). Notre deuxième contribution a donc été de proposer deux méthodes robustes d'estimation de la FR à partir des modulations dérivées de l'ECG ou du PPG. La première consiste à sélectionner les modulations avec le IQR le plus élevé (TF, autocorrélation et le modèle sinusoïdal). La deuxième consiste à fusionner plusieurs modulations par un lisseur de Kalman. Il est cependant difficile de déterminer leur combinaison optimale pour l'estimation de la FR en raison du bruit et de la spécificité du patient. Pour déterminer la combinaison optimale, nous avons utilisé la notion d'indice de qualité respiratoire (IQR). Plusieurs indices de qualité (IQR) développés récemment ont été retenus : la transformée de Fourier (TF), l'autocorrélation (AC). Un nouvel indice, et qui constitue une troisième contribution, basée sur un modèle paramétrique sinusoïdal (MPS), est proposée également. Ces deux méthodes sont évaluées sur deux ensembles de données indépendants : 1) 'CAPNOBASE' : base de données publique et annotée, acquises pendant une anesthésie. Elle est utilisée pour valider nos méthodes et comparer les perfor-

mances avec les méthodes existantes dans la littérature ; 2) 'SHERPAM' : base de données d'enregistrements recueillis chez des patients en activités physiques quotidiennes libres. Les résultats obtenus sur la base de données 'CAPNOBASE' et 'SHERPAM' montrent des performances supérieures à celles reportées dans la littérature en appliquant l'algorithme de fusion. Ces travaux ont fait l'objet d'une communication dans le cadre de la conférence « Computing in cardiology 2018 » et d'un article accepté avec révision dans les IEEE-TBME (révision re-soumise)

La quatrième contribution s'est intéressée à étendre le modèle monomodal au cas multimodal tout en exploitant la fusion par le lisseur de Kalman. Dans ce contexte, notre méthode consiste à présenter une méthode agile qui permet de rechercher le/les meilleures modulations et la meilleure représentation par le modèle mono ou multimodal. Les tests montrent tout l'intérêt de cette approche agile.

La cinquième contribution se tourne vers les perspectives et l'extension de nos propositions au contexte des unités de soins intensifs néonatalité. L'objectif long terme vise à développer des outils d'aide à la décision. Ce travail s'inscrit donc naturellement dans le cadre du développement de nouvelles méthodes de monitoring, d'explorations fonctionnelles multiparamétriques et d'analyse des signaux électrophysiologiques adaptés à une physiologie de la régulation des systèmes cardiaques et respiratoires immatures. Des résultats préliminaires sont présentés montrant l'intérêt de notre démarche, tout en étant conscient que des tests complémentaires devront être menés.

L'approche proposée dans ce manuscrit a été testée dans différents contextes cliniques : surveillance en post-opératoire, pendant des activités physiques quotidiennes et surveillance néonatale. L'un des postulats de base était la régularité de rythme du cœur et de la respiration. Il serait pertinent d'étudier le comportement de notre estimateur en présence d'apnées (partiellement abordées au chapitre 6), d'hypopnée et de soupire. Parallèlement, les applications de la détection et caractérisation d'arythmies ouvre un nouvel horizon de recherche.

Outre ces perspectives à orientation clinique, se dégagent aussi des perspectives méthodologiques. La présente étude vise à fournir une approche de fusion efficace et générale

de divers signaux de modulation (extraites de l'ECG ou de PPG), plusieurs développements récents basés sur les processus gaussiens [35] sont introduits dans des domaines liés à la respiration tels que les détections d'apnées et semblent montrer des performances intéressantes. Ces approches pourraient contribuer davantage à la précision de l'estimation de la FR s'ils étaient intégrés dans notre méthode de fusion générale.

# Bibliographie

- [1] D. Crone, *Physical activity and health promotion : evidence-based approaches to practice*. John Wiley and sons, 09 2009.
- [2] J. Parkka, “Analysis of personal health monitoring data for physical activity recognition and assessment of energy expenditure, mental load and stress,” *VTT Publications*, pp. 1–157, 01 2011.
- [3] E. M. Tapia, S. S. Intille, W. Haskell, K. Larson, J. Wright, A. King, and R. Friedman, “Real-time recognition of physical activities and their intensities using wireless accelerometers and a heart rate monitor,” in *2007 11th IEEE International Symposium on Wearable Computers*, Oct 2007, pp. 37–40.
- [4] R. Dumond, S. Gastinger, H. Abdul Rahman, A. Le Faucheur, P. Quinton, H. Kang, and J. Prioux, “Estimation of respiratory volume from thoracoabdominal breathing distances : comparison of two models of machine learning,” *European journal of applied physiology*, vol. 117, 06 2017.
- [5] S. Gastinger, A. Donnelly, R. Dumond, and J. Prioux, “A review of the evidence for the use of ventilation as a surrogate measure of energy expenditure,” *JPEN. Journal of parenteral and enteral nutrition*, vol. 38, 04 2014.
- [6] L. Nilsson, A. Johansson, and S. Kalman, “Monitoring of respiratory rate in post-operative care using a new photoplethysmographic technique,” *Journal of clinical monitoring and computing*, vol. 16, pp. 309–15, 05 2000.
- [7] R. G. Lyons, *Understanding Digital Signal Processing*. Upper Saddle River : Prentice Hall, 2011.

- [8] A. M. Cretikos, R. Bellomo, K. Hillman, J. Chen, S. Finfer, and A. Flabouris, “Respiratory rate : The neglected vital sign,” *The Medical journal of Australia*, vol. 188, pp. 657–9, 07 2008.
- [9] J. F. Fieselmann, M. S. Hendryx, C. M. Helms, and D. S. Wakefield, “Respiratory rate predicts cardiopulmonary arrest for internal medicine inpatients,” *Journal of General Internal Medicine*, vol. 8, no. 7, pp. 354–360, Jul 1993. [Online]. Available : <https://doi.org/10.1007/BF02600071>
- [10] D. Oreggia, S. Guarino, A. Parisi, R. Pernice, G. Adamo, L. Mistretta, P. Di Buono, G. Fallica, G. Ferla, A. C. Cino, C. Giaconia, and A. C. Busacca, “Physiological parameters measurements in a cardiac cycle via a combo ppg-ecg system,” in 2015 AEIT International Annual Conference (AEIT), Oct 2015, pp. 1–6.
- [11] R. Bailon, L. Sornmo, and P. Laguna, “A robust method for ecg-based estimation of the respiratory frequency during stress testing,” *IEEE Transactions on Biomedical Engineering*, vol. 53, no. 7, pp. 1273–1285, July 2006.
- [12] D. Goldhill, S. White, and A. Sumner, “Physiological values and procedures in the 24 h before icu admission from the ward,” *Anaesthesia*, vol. 54, pp. 529–34, 07 1999.
- [13] P. Bonato, “Wearable sensors and systems,” *IEEE Engineering in Medicine and Biology Magazine*, vol. 29, no. 3, pp. 25–36, May 2010.
- [14] M. Cretikos, J. Chen, K. Hillman, R. Bellomo, S. Finfer, and A. Flabouris, “The objective medical emergency team activation criteria : A case-control study,” *Resuscitation*, vol. 73, no. 1, pp. 62 – 72, 2007. [Online]. Available : <http://www.sciencedirect.com/science/article/pii/S0300957206005648>
- [15] W. T. McNicholas and D. Rodenstein, “Sleep apnoea and driving risk : the need for regulation,” *European Respiratory Review*, vol. 24, no. 138, pp. 602–606, 2015. [Online]. Available : <http://err.ersjournals.com/content/24/138/602>
- [16] R. Schein, N. Hazday, M. Pena, B. H Ruben, and C. Sprung, “Clinical antecedents to in-hospital cardiopulmonary arrest,” *Chest*, vol. 98, pp. 1388–92, 01 1991.

- [17] T. R. Gravelyn and J. G. Weg, "Respiratory rate as an indicator of acute respiratory dysfunction," *JAMA : the journal of the American Medical Association*, vol. 244, pp. 1123–5, 10 1980.
- [18] W. Karlen, S. Raman, J. M. Ansermino, and G. A. Dumont, "Multiparameter respiratory rate estimation from the photoplethysmogram," *IEEE Transactions on Biomedical Engineering*, vol. 60, no. 7, pp. 1946–1953, July 2013.
- [19] A. Khalil, G. Kelen, and R. Rothman, "A simple screening tool for identification of community-acquired pneumonia in an inner city emergency department," *Emergency medicine journal : EMJ*, vol. 24, pp. 336–8, 05 2007.
- [20] G. B. Moody, R. G. Mark, A. Zoccola, and S. Mantero, "Derivation of respiratory signals from multilead eegs," *Computers in Cardiology*, vol. 12, 01 1985.
- [21] F. Yasuma and J. ichiro Hayano, "Respiratory sinus arrhythmia : Why does the heartbeat synchronize with respiratory rhythm ?" *Chest*, vol. 125, no. 2, pp. 683 – 690, 2004.
- [22] L. G. Lindberg, H. Ugnell, and P. Å. Öberg, "Monitoring of respiratory and heart rates using a fibre-optic sensor," *Medical and Biological Engineering and Computing*, vol. 30, no. 5, pp. 533–537, Sep 1992. [Online]. Available : <https://doi.org/10.1007/BF02457833>
- [23] C. W. Seymour, J. M. Kahn, C. R. Cooke, T. R. Watkins, S. R. Heckbert, and T. D. Rea, "Prediction of Critical Illness During Out-of-Hospital Emergency Care," *JAMA*, vol. 304, no. 7, pp. 747–754, 08 2010. [Online]. Available : <https://doi.org/10.1001/jama.2010.1140>
- [24] S. Fleming and L. Tarassenko, "A comparison of signal processing techniques for the extraction of breathing rate from the photoplethysmogram," *Int J Biol Med Sci*, vol. 2, 01 2007.
- [25] G. Blain, O. Meste, T. Bouchard, and S. Bermon, "Assessment of ventilatory thresholds during graded and maximal exercise test using time varying analysis of

- respiratory sinus arrhythmia,” *British Journal of Sports Medicine*, vol. 39, no. 7, pp. 448–452, 2005. [Online]. Available : <https://bjsm.bmj.com/content/39/7/448>
- [26] U. Reinhard, P. H. Maoeller, and R. M. Schmaoelling, “Determination of anaerobic threshold by the ventilation equivalent in normal individuals,” *Respiration ; international review of thoracic diseases*, vol. 38, pp. 36–42, 02 1979.
- [27] D. Schriger, “Approach to the patient with abnormal vital signs,” *Goldman’s Cecil Medicine : Twenty Fourth Edition*, vol. 1, pp. 27–30, 07 2011.
- [28] J. W. Jeong, Y. W. Jang, I. Lee, S. Shin, and S. Kim, “Wearable respiratory rate monitoring using piezo-resistive fabric sensor,” in *World Congress on Medical Physics and Biomedical Engineering*, September 7 - 12, 2009, Munich, Germany, O. Dössel and W. C. Schlegel, Eds. Berlin, Heidelberg : Springer Berlin Heidelberg, 2009, pp. 282–284.
- [29] A. Garbino, R. Blue, J. M. Pattarini, J. Law, and J. Clark, “Physiological monitoring and analysis of a manned stratospheric balloon test program,” *Aviation, space, and environmental medicine*, vol. 85, pp. 177–82, 02 2014.
- [30] P. Leonard, N. R. Grubb, P. S. Addison, D. Clifton, and J. N. Watson, “An algorithm for the detection of individual breaths from the pulse oximeter waveform,” *Journal of Clinical Monitoring and Computing*, vol. 18, no. 5, pp. 309–312, Dec 2004. [Online]. Available : <https://doi.org/10.1007/s10877-005-2697-z>
- [31] M. D. Revow, S. J. England, and H. O’Beirne, “Robust computer algorithm for detecting breaths in noisy ventilatory waveforms from infants,” *Medical and Biological Engineering and Computing*, vol. 24, no. 6, pp. 609–615, Nov 1986. [Online]. Available : <https://doi.org/10.1007/BF02446264>
- [32] C. Orphanidou, S. Fleming, S. Shah, and L. Tarassenko, “Data fusion for estimating respiratory rate from a single-lead ecg,” *Biomedical Signal Processing and Control*, vol. 8, no. 1, pp. 98 – 105, 2013. [Online]. Available : <http://www.sciencedirect.com/science/article/pii/S1746809412000699>

- [33] C. O'Brien and C. Heneghan, "A comparison of algorithms for estimation of a respiratory signal from the surface electrocardiogram," *Computers in Biology and Medicine*, vol. 37, no. 3, pp. 305 – 314, 2007. [Online]. Available : <http://www.sciencedirect.com/science/article/pii/S0010482506000357>
- [34] K. Davidson and V. Barber, "Electronic monitoring of patients in general wards," *Nursing Standard*, vol. 18, pp. 42–46, 08 2004.
- [35] P. Janbakhshi and M. B. Shamsollahi, "Ecg-derived respiration estimation from single-lead ecg using gaussian process and phase space reconstruction methods," *Biomedical Signal Processing and Control*, vol. 45, pp. 80 – 90, 2018. [Online]. Available : <http://www.sciencedirect.com/science/article/pii/S1746809418301332>
- [36] J. Allen, "Photoplethysmography and its application in clinical physiological measurement," *Physiol. Meas*, vol. 28, 01 2007.
- [37] L. Opie, *Heart physiology : from cell to circulation*. LWW, 01 2003.
- [38] J. Hall, "Guyton and hall textbook of medical physiology," *Secretory Functions of the Alimentary Tract*, pp. 773–788, 01 2011.
- [39] J. Lázaro, A. Alcaine, D. Romero, E. Gil, P. Laguna, E. Pueyo, and R. Bailón, "Electrocardiogram derived respiratory rate from qrs slopes and r-wave angle," *Annals of Biomedical Engineering*, vol. 42, no. 10, pp. 2072–2083, Oct 2014. [Online]. Available : <https://doi.org/10.1007/s10439-014-1073-x>
- [40] K. McLeish, D. Hill, D. Atkinson, J. Blackall, and R. Razavi, "A study of the motion and deformation of the heart due to respiration," *IEEE transactions on medical imaging*, vol. 21, pp. 1142–50, 10 2002.
- [41] M. A. F. Pimentel, A. E. W. Johnson, P. H. Charlton, D. Birrenkott, P. J. Watkinson, L. Tarassenko, and D. A. Clifton, "Toward a robust estimation of respiratory rate from pulse oximeters," *IEEE Transactions on Biomedical Engineering*, vol. 64, no. 8, pp. 1914–1923, Aug 2017.
- [42] P. H. Charlton, D. A. Birrenkott, T. Bonnici, M. A. F. Pimentel, A. E. W. Johnson, J. Alastruey, L. Tarassenko, P. J. Watkinson, R. Beale, and D. A. Clifton, "Breathing



- rate estimation from the electrocardiogram and photoplethysmogram : A review,” *IEEE Reviews in Biomedical Engineering*, vol. 11, pp. 2–20, 2018.
- [43] D. A. Birrenkott, M. A. F. Pimentel, P. J. Watkinson, and D. A. Clifton, “A robust fusion model for estimating respiratory rate from photoplethysmography and electrocardiography,” *IEEE Transactions on Biomedical Engineering*, vol. 65, no. 9, pp. 2033–2041, Sep. 2018.
- [44] A. Johansson, “Neural network for photoplethysmographic respiratory rate monitoring,” *Medical and Biological Engineering and Computing*, vol. 41, no. 3, pp. 242–248, May 2003. [Online]. Available : <https://doi.org/10.1007/BF02348427>
- [45] A. Travaglini, C. Lamberti, J. DeBie, and M. Ferri, “Respiratory signal derived from eight-lead ecg,” in *Computers in Cardiology 1998*. Vol. 25 (Cat. No.98CH36292), Sept 1998, pp. 65–68.
- [46] D. Meredith, D. Clifton, P. Charlton, J. Brooks, C. W Pugh, and L. Tarassenko, “Photoplethysmographic derivation of respiratory rate : a review of relevant physiology,” *Journal of medical engineering & technology*, vol. 36, pp. 1–7, 12 2011.
- [47] M. Doyen, “Méthodes probabilistes pour le monitoring cardio-respiratoire des nouveau-nés prématurés,” Ph.D. dissertation, Université Rennes1, 2018.
- [48] L. Nilsson, A. Johansson, and S. Kalman, “Respiratory variations in the reflection mode photoplethysmographic signal. relationships to peripheral venous pressure,” *Medical and Biological Engineering and Computing*, vol. 41, no. 3, pp. 249–254, May 2003. [Online]. Available : <https://doi.org/10.1007/BF02348428>
- [49] M. van Gastel, S. Stuijk, and G. de Haan, “Robust respiration detection from remote photoplethysmography,” *Biomedical Optics Express*, vol. 7, p. 4941, 12 2016.
- [50] E. G. Caiani, A. Porta, M. Terrani, S. Guzzetti, A. Malliani, and S. Cerutti, “Minimal adaptive notch filter for respiratory frequency tracking,” in *Computers in Cardiology 1999*. Vol.26 (Cat. No.99CH37004), Sept 1999, pp. 511–514.

- [51] R. C. Wang and T. W. Calvert, "A model to estimate respiration from vectorcardiogram measurements," *Annals of Biomedical Engineering*, vol. 2, no. 1, pp. 47–57, Mar 1974. [Online]. Available : <https://doi.org/10.1007/BF02368085>
- [52] M. Varanini, M. Emdin, F. Allegri, M. Raciti, F. Conforti, A. Macerata, A. Taddei, R. Francesconi, G. Kraft, A. L. Abbate, and C. Marchesi, "Adaptive filtering of ecg signal for deriving respiratory activity," in [1990] *Proceedings Computers in Cardiology*, Sept 1990, pp. 621–624.
- [53] O. Meste, G. Blain, and S. Bermon, "Analysis of the respiratory and cardiac systems coupling in pyramidal exercise using a time-varying model," in *Computers in Cardiology*, Sep. 2002, pp. 429–432.
- [54] C. L. Mason and L. Tarassenko, "Quantitative assessment of respiratory derivation algorithms," in 2001 *Conference Proceedings of the 23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, vol. 2, 2001, pp. 1998–2001 vol.2.
- [55] Z. B. Khaled and G. Farges, "First approach for respiratory monitoring by amplitude demodulation of the electrocardiogram," in 1992 *14th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, vol. 6, Oct 1992, pp. 2535–2536.
- [56] M. Schmidt, A. Schumann, J. Mueller, K.-J. Baer, and G. Rose, "Ecg derived respiration : Comparison of time-domain approaches and application to altered breathing patterns of patients with schizophrenia," *Physiological Measurement*, vol. 38, 02 2017.
- [57] D. Dobrev and I. Daskalov, "Two-electrode telemetric instrument for infant heart rate and apnea monitoring," *Medical engineering & physics*, vol. 20, pp. 729–34, 02 1999.
- [58] P. de Chazal, C. Heneghan, E. Sheridan, R. Reilly, P. Nolan, and M. O'Malley, "Automated processing of the single-lead electrocardiogram for the detection of obstruc-

- tive sleep apnoea,” *IEEE Transactions on Biomedical Engineering*, vol. 50, no. 6, pp. 686–696, June 2003.
- [59] P. Langley, E. J. Bowers, and A. Murray, “Principal component analysis as a tool for analyzing beat-to-beat changes in ecg features : Application to ecg-derived respiration,” *Biomedical Engineering, IEEE Transactions on*, vol. 57, pp. 821 – 829, 05 2010.
- [60] P. Charlton, T. Bonnici, L. Tarassenko, D. Clifton, R. Beale, and P. J Watkinson, “An assessment of algorithms to estimate respiratory rate from the electrocardiogram and photoplethysmogram,” *Physiological measurement*, vol. 37, pp. 610–626, 03 2016.
- [61] S. Tiinainen, K. Noponen, M. Tulppo, A. Kiviniemi, and T. Seppänen, “Ecg-derived respiration methods : adapted ica and pca,” *Medical engineering and physics*, vol. 37, 04 2015.
- [62] J. Boyle, N. Bidargaddi, A. Särelä, and M. Karunanithi, “Automatic detection of respiration rate from ambulatory single-lead ecg,” *IEEE Transactions on Information Technology in Biomedicine*, vol. 13, pp. 890–896, 11 2009.
- [63] M. Campolo, D. Labate, F. La Foresta, F. C. Morabito, A. Lay-Ekuakille, and P. Vergallo, “Ecg-derived respiratory signal using empirical mode decomposition,” in *2011 IEEE International Symposium on Medical Measurements and Applications*, May 2011, pp. 399–403.
- [64] D. Labate, F. L. Foresta, G. Occhiuto, F. C. Morabito, A. Lay-Ekuakille, and P. Vergallo, “Empirical mode decomposition vs. wavelet decomposition for the extraction of respiratory signal from single-channel ecg : A comparison,” *IEEE Sensors Journal*, vol. 13, no. 7, pp. 2666–2674, July 2013.
- [65] H. Sharma, K. Sharma, and O. L. Bhagat, “Respiratory rate extraction from single-lead ecg using homomorphic filtering,” *Computers in Biology and Medicine*, vol. 59, pp. 80 – 86, 2015. [Online]. Available : <http://www.sciencedirect.com/science/article/pii/S0010482515000414>

- [66] P. Janbakhshi and M. Shamsollahi, "Sleep apnea detection from single-lead ecg using features based on ecg-derived respiration (edr) signals," *IRBM*, vol. 39, no. 3, pp. 206 – 218, 2018. [Online]. Available : <http://www.sciencedirect.com/science/article/pii/S1959031818300794>
- [67] D. Cysarz, R. Zerm, H. Bettermann, M. Fr̃Ehwirth, M. Moser, and M. Kr̃Ez, "Comparison of respiratory rates derived from heart rate variability, ecg amplitude, and nasal/oral airflow," *Annals of biomedical engineering*, vol. 36, pp. 2085–94, 10 2008.
- [68] A. Schaefer and K. Kratky, "Estimation of breathing rate from respiratory sinus arrhythmia : Comparison of various methods," *Annals of biomedical engineering*, vol. 36, pp. 476–85, 04 2008.
- [69] B. Mazzanti, C. Lamberti, and J. De Bie, "Validation of an ecg-derived respiration monitoring method," *Computers in Cardiology*, vol. 30, pp. 613 – 616, 10 2003.
- [70] K. H. Shelley, A. A. Awad, R. G. Stout, and D. G. Silverman, "The use of joint time frequency analysis to quantify the effect of ventilation on the pulse oximeter waveform," *Journal of clinical monitoring and computing*, vol. 20, pp. 81–7, 05 2006.
- [71] S. Fleming, M. Thompson, R. Stevens, C. Heneghan, A. Plaeddemann, I. Macnochie, L. Tarassenko, and D. Mant, "Normal ranges of heart rate and respiratory rate in children from birth to 18 years of age : A systematic review of observational studies," *Lancet*, vol. 377, pp. 1011–8, 03 2011.
- [72] J. F. Thayer, J. J. Sollers, E. Ruiz-Padial, and J. Vila, "Estimating respiratory frequency from autoregressive spectral analysis of heart period," *IEEE Engineering in Medicine and Biology Magazine*, vol. 21, no. 4, pp. 41–45, July 2002.
- [73] R. Takalo, H. Hytti, and H. Ihalainen, "Tutorial on univariate autoregressive spectral analysis," *Journal of clinical monitoring and computing*, vol. 19, pp. 401–10, 10 2006.
- [74] X. Navarro, "Analysis of cerebral and respiratory activity in neonatal intensive care units for the assessment of maturation and infection in the early premature

- infant,” Ph.D. dissertation, Université de Rennes 1, 2013. [Online]. Available : <http://www.theses.fr/2013REN1S133/document>
- [75] S. Nemati, A. Malhotra, and G. D. Clifford, “Data fusion for improved respiration rate estimation,” *EURASIP J. Adv. Signal Process*, vol. 2010, pp. 1–10, Feb. 2010. [Online]. Available : <http://dx.doi.org/10.1155/2010/926305>
- [76] M. Peláez-Coca, M. Orini, J. Lázaro, R. Bailón, and E. Gil, “Cross time-frequency analysis for combining information of several sources : Application to estimation of spontaneous respiratory rate from photoplethysmography,” *Computational and Mathematical Methods in Medicine*, vol. 2013, pp. Article ID 631 978, 8 pages, 11 2013.
- [77] N. A. Nayan, N. S. Risman, and R. Jaafar, “Breathing rate estimation from a single-lead electrocardiogram acquisition system,” *International Journal of Applied Engineering Research*, vol. 10, pp. 38 154–38 158, 01 2015.
- [78] A. Chan, N. Ferdosi, and R. Narasimhan, “Ambulatory respiratory rate detection using ecg and a triaxial accelerometer,” *Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference*, vol. 2013, pp. 4058–4061, 07 2013.
- [79] J. Li, J. Jin, X. Chen, W. Sun, and P. Guo, “Comparison of respiratory-induced variations in photoplethysmographic signals,” *Physiological Measurement*, vol. 31, no. 3, p. 415, 2010. [Online]. Available : <http://stacks.iop.org/0967-3334/31/i=3/a=009>
- [80] A. E W Johnson, J. Burgess, M. Pimentel, D. Clifton, J. Duncan Young, P. J Watkinson, and L. Tarassenko, “Physiological trajectory of patients pre and post icu discharge1,” *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBC 2014*, vol. 2014, pp. 3160–3, 08 2014.
- [81] D. A. Birrenkott, M. A. F. Pimentel, P. J. Watkinson, and D. A. Clifton, “Robust estimation of respiratory rate via ecg- and ppg-derived respiratory quality indices,”

- in 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Aug 2016, pp. 676–679.
- [82] B. F. Womack, “The analysis of respiratory sinus arrhythmia using spectral analysis and digital filtering,” *IEEE Transactions on Biomedical Engineering*, vol. BME-18, no. 6, pp. 399–409, Nov 1971.
- [83] C. L. Levkov, G. Mihov, R. M. Ivanov, I. K. Daskalov, I. I. Christov, and I. Dotsinsky, “Removal of power-line interference from the ecg : a review of the subtraction procedure,” *BioMedical Engineering OnLine*, vol. 4, pp. 50 – 50, 2005.
- [84] B. . Kohler, C. Hennig, and R. Orglmeister, “The principles of software qrs detection,” *IEEE Engineering in Medicine and Biology Magazine*, vol. 21, no. 1, pp. 42–57, Jan 2002.
- [85] M. Doyen, D. Ge, A. Beuchée, G. Carrault, and A. Hernández, “Robust, real-time generic detector based on a multi-feature probabilistic method,” Feb. 2018, working paper or preprint. [Online]. Available : <https://hal.archives-ouvertes.fr/hal-01619803>
- [86] S. Arunachalam and L. Brown, “Real-time estimation of the ecg-derived respiration (edr) signal using a new algorithm for baseline wander noise removal,” *Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference*, vol. 2009, pp. 5681–4, 09 2009.
- [87] M. P. Tarvainen, S. Georgiadis, J. A. Lipponen, M. Hakkarainen, and P. A. Karjalainen, “Time-varying spectrum estimation of heart rate variability signals with kalman smoother algorithm,” in *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Sep. 2009, pp. 1–4.
- [88] P. Spincemaille, T. D. Nguyen, M. R. Prince, and Y. Wang, “Kalman filtering for real-time navigator processing.” *Magnetic resonance in medicine*, vol. 60 1, pp. 158–68, 2008.

- [89] J. Foussier, D. Teichmann, J. Jia, B. Misgeld, and S. Leonhardt, “An adaptive kalman filter approach for cardiorespiratory signal extraction and fusion of non-contacting sensors,” *BMC Medical Informatics and Decision Making*, vol. 14, no. 1, p. 37, May 2014. [Online]. Available : <https://doi.org/10.1186/1472-6947-14-37>
- [90] W. Karlen, M. Turner, E. Cooke, G. Dumont, and M. Ansermino, “Capnibase : Signal database and tools to collect, share and annotate respiratory signals,” in *Annual Meeting of the Society for Technology in Anesthesia (STA)*. West Palm Beach, 01 2010, p. 25.
- [91] H. Abdul Rahman, “Multi-Sensor Based Activity Recognition : Development and Validation in Real-Life context,” *Theses, École normale supérieure de Rennes*, Dec. 2017. [Online]. Available : <https://tel.archives-ouvertes.fr/tel-01895685>
- [92] N. A. Bergman, M.D., “Effects of varying respiratory waveforms on gas exchange,” *Anesthesiology*, vol. 28, no. 2, pp. 390–395, 1967. [Online]. Available : <http://dx.doi.org/>
- [93] J. Molina-Cabrillana, C. Santana-Reyes, J. Hernández, I. Lapez, and E. Dorta, “[incidence of nosocomial infections at a neonatal intensive care unit : a six-year surveillance study],” *Enfermedades infecciosas y microbiología clinica*, vol. 24, no. 5, pp. 307–312, May 2006. [Online]. Available : <https://doi.org/10.1157/13089665>
- [94] J. Wong, K. Dow, P. S. Shah, W. Andrews, and S. Lee, “Percutaneously placed central venous catheter-related sepsis in canadian neonatal intensive care units,” *American journal of perinatology*, vol. 29, no. 8, pp. 629–634, September 2012. [Online]. Available : <https://doi.org/10.1055/s-0032-1311978>
- [95] A. Beuchée, G. Carrault, J. Yves Bansard, E. Boutaric, P. Batramieux, and P. Pladys, “Uncorrelated randomness of the heart rate is associated with sepsis in sick premature infants,” *Neonatology*, vol. 96, pp. 109–14, 03 2009.
- [96] X. Navarro-Sune, F. Poree, A. Beuchée, and G. Carrault, “Performance analysis of hurst exponent estimators using surrogate-data and fractional lognormal noise

- models : Application to breathing signals from preterm infants,” *Digital Signal Processing*, vol. 23, pp. 1610–1619, 09 2013.
- [97] T. Penzel, M. Nottrott, S. Canisius, T. Greulich, H. F. Becker, and C. Vogelmeier, “P428 ecg morphology changes improves detection of obstructive sleep apnea,” *Sleep Medicine - SLEEP MED*, vol. 7, 09 2006.
- [98] S. K. H and Farrugia, “Methods and apparatus for monitoring and treating respiratory insufficiency,” U.S. Patent 20 130 340 758, 2013.
- [99] S. Chhabra, “Interpretation of spirometry : Selection of predicted values and defining abnormality,” *The Indian Journal of Chest Diseases & Allied Sciences*, vol. 57, pp. 91–105, 04 2015.
- [100] M. R. Miller, J. Hankinson, V. Brusasco, F. Burgos, R. Casaburi, A. Coates, R. Crapo, P. Enright, C. P. M. van der Grinten, P. Gustafsson, R. Jensen, D. C. Johnson, N. MacIntyre, R. McKay, D. Navajas, O. F. Pedersen, R. Pellegrino, G. Viegi, and J. Wanger, “Standardisation of spirometry,” *European Respiratory Journal*, vol. 26, no. 2, pp. 319–338, 2005. [Online]. Available : <https://erj.ersjournals.com/content/26/2/319>
- [101] G. Emeriaud, A. Eberhard, G. Benchetrit, T. Debillon, and P. Baconnier, “Calibration of respiratory inductance plethysmograph in preterm infants with different respiratory conditions,” *Pediatric pulmonology*, vol. 43, pp. 1135–41, 11 2008.
- [102] C. A. Hollier, A. R. Harmer, L. J. Maxwell, C. Menadue, G. N. Willson, D. A. Black, and A. J. Piper, “Validation of respiratory inductive plethysmography (lifeshirt) in obesity hypoventilation syndrome,” *Respiratory Physiology & Neurobiology*, vol. 194, pp. 15 – 22, 2014. [Online]. Available : <http://www.sciencedirect.com/science/article/pii/S1569904814000159>
- [103] L. Kent, B. Neill, G. Davison, A. Nevill, J. S. Elborn, and J. M. Bradley, “Validity and reliability of cardiorespiratory measurements recorded by the lifeshirt during exercise tests,” *Respiratory Physiology & Neurobiology*, vol. 167, no. 2, pp.



- 162–167, 2009. [Online]. Available : <http://www.sciencedirect.com/science/article/pii/S156990480900087>
- [104] S. Gastinger, H. Sefati, G. Nicolas, S. Anthony, A. Delamarche, and J. Prioux, “Estimates of ventilation from measurements of rib cage and abdominal distances : A portable device,” *European journal of applied physiology*, vol. 109, pp. 1179–89, 04 2010.
- [105] R. Dumont, “Contrôle du profil de courant par ondes cyclotroniques électroniques dans les tokamaks,” Ph.D. dissertation, Université Henri Poincaré Nancy 1, 2001, 2001NAN10036. [Online]. Available : <http://www.theses.fr/2001NAN10036/document>

# Table des figures

1.1	Architecture Générale du projet SHERPAM. . . . .	11
2.1	Représentation d'un électrocardiogramme durant un cycle cardiaque : les différentes ondes caractéristiques (P,Q,R,S et T) sont représentées conjointement avec l'activité électrique du cœur correspondante (Fédération Française de cardiologie). . . . .	19
2.2	Mécanismes de la respiration (Encyclopédie britannique). . . . .	20
2.3	A) Exemples de modulations extraites du signal ECG. rouge (QRA), vert (RSA) et orange (RPA). B) signal respiratoire référence. . . . .	20
2.4	A) Oxymètre de pouls qui permet de mesurer la concentration en oxygène SpO2. B) Représentation d'un signal d'oxymétrie de pouls [47]. . . . .	21
2.5	A) Exemples de modulations extraites du signal PPG. rouge (RIIV), vert (RIFV) et orange (RIAV). B) signal respiratoire référence. . . . .	22
2.6	Les quatre étapes de l'algorithme d'estimation de la fréquence respiratoire (FR), à partir du signal ECG ou PPG. Le bloc en pointillé est facultative [42].	23
2.7	Comparaison des performances en erreur absolue moyenne (MAE) entre les indices de qualité respiratoires (IQRs) et l'indice de qualité de signal (IQS) sur les signaux PPG (panneau gauche) et sur les signaux ECG (panneau droite) [81]. . . . .	28
3.1	Architecture générale de la chaîne de traitement. . . . .	32

3.2	Exemples de modulations extraites du signal ECG (RPA, QRA, RSA et AQRS). . . . .	34
3.3	Exemples de modulations extraites du signal PPG (RIIV, RIAV et RIFV. . . . .	36
3.4	Exemple de TF pour une modulation dérivée de l'ECG a) modulation sans artéfact b) modulation avec artéfact. les lignes noires représente la région de 0.1 à 1 Hz (dont la somme est $P_{RB}$ ). Les lignes noires en pointillés représentent la région des trois coefficients consécutifs autour du pic maximal. . . . .	38
3.5	a) Exemple d'autocorrélation pour une modulation dérivée d'une fenêtre de 32s a) modulation sans artéfact. b) modulation avec artéfact. Les lignes noires représentent la région de 1 à 10 sec. . . . .	39
3.6	La distribution des erreurs absolues (en bpm) en fonction des valeurs IQR a) $IQR_{TF}$ b) $IQR_{Autocorr}$ c) $IQR_{SINUS}$ . Chaque point de la courbe correspond à l'erreur absolue médiane et aux 25-75ème percentiles calculés avec 10% de toutes les fenêtres (nombre de sujets $\times$ durée du signal PPG / taille de la fenêtre = 42 sujets $\times$ 8 min $\times$ 60s / 32s = 630 fenêtres pour chaque sous-figure). . . . .	41
3.7	Histogramme normalisé (pourcentage) de sélection pour chaque modulation dérivée en utilisant différents indices de qualité (IQRs) et la sélection à posteriori pour les activités : a) couché b) marche. . . . .	43
3.8	Exemple présentant les différentes modulations extraites du signal PPG de la base de donnée CAPNOBASE (RIIV, RIFV et RIAV). Une modulation est sélectionnée toutes les 32 s (en rouge) en se basant sur l'indice $IQR_{TF}$ . . . . .	44
3.9	Exemple présentant les différentes modulations extraites du signal ECG de la base de donnée CAPNOBASE (RPA, AQRS, RSA et QRA). Une modulation est sélectionnée toutes les 32 s (en rouge) en se basant sur $IQR_{TF}$ . . . . .	45
3.10	Fusion des modulations (deuxième approche) par le Lisseur de Kalman avec l'indice IQR le plus élevé . . . . .	46

3.11	Exemple présentant les différentes modulations extraites du signal ECG de la base de données CAPNOBASE (RPA, AQRS, RSA et QRA), pour une durée de 4 min. Toutes les 32 s, deux modulations sont sélectionnées basés sur l'indice $IQR_{TF}$ et le résultat de fusion par le LK est utilisé pour l'estimation de la FR. . . . .	50
3.12	Exemple présentant les différentes modulations extraites du signal PPG de la base de donnée CAPNOBASE (RIIV, RIFV et RIAV), pour une durée de 4 min. Toutes les 32 s, deux modulations sont sélectionnées basés sur l'indice $IQR_{TF}$ . . . . .	51
3.13	Exemple de détection de pics dans la modulation RIIV dérivée à partir du signal PPG avec un coefficient de seuil réglé à 0.7. . . . .	54
4.1	a) Le capteur Zephyr à gauche et le capteur Cosmed K4B2 à droite. b) Schéma expliqué des activités. . . . .	59
4.2	Exemple de distribution d'erreur absolue (bpm) en fonction des coefficients de seuil (entre 0.1 et 0.9) pour les deux approches proposées (sélection et fusion) en utilisant l'indice d'autocorrélation, à partir des signaux PPG de la base de données CAPNOBASE. . . . .	61
4.3	Exemple de détection de cycle respiratoires sur la modulation sélectionnée (1ère approche avec un fenêtre de 64s en A) et sur le signal fusionné (seconde approche en C). Les pics et les creux sont détectés en utilisant trois coefficients de seuil (0.1, 0.5 et 0.9). Les séries FR correspondantes du sujet sont comparées en B) et D) avec la série FR référence. . . . .	62
4.4	Comparaison des résultats des erreurs absolues (en bpm) entre la FR de référence et la FR à l'entrée du LK (delta1) et la FR estimée à la sortie du LK (delta2), pour les trois indices de qualité ( $IQR_{SINUS}$ , $IQR_{FT}$ et $IQR_{autocor}$ ), à partir des signaux PPG de la base de données CAPNOBASE. En moyenne, le pourcentage d'outliers est 15 %. . . . .	63

4.5	Comparaison entre les FRs estimées à l'entrée du LK ( $\delta_1$ ) et les FRs estimées à la sortie du LK avec les FRs références, pour les différentes range de respiration, à partir des signaux PPG de la base de données CAPNO-BASE en se basant sur l'indice $IQR_{FT}$ . . . . .	64
4.6	Boxplots des résultats de l'estimation de la FR à partir des signaux PPG (médianes et 25e au 75e percentiles en bpm) pour une fenêtre de 32 s. Les trois premières boxplots concernent les modulations dérivées (RIAV, RIIV et RIFV), suivies de la comparaison entre la sélection basée sur IQR (première approche) et la fusion des deux modulations par le LK (seconde approche). Les résultats de la sélection <i>a posteriori</i> sont également affichés à titre de référence. Le pourcentage d'outliers est en moyenne de 7 %. L'étoile unique * correspond à une valeur-p $p < 0.05$ , tandis que les deux étoiles ** correspondent à une valeur-p $p < 0.001$ . . . . .	66
4.7	Exemple d'évolution de l'erreur absolue médiane (EAM) d'estimations de la FR issues de la fusion LK à 4 entrées utilisant $IQR_{autocorr}$ en fonction du pourcentage de modulations rejetées, de la base de données SHERPAM. . . . .	70
4.8	Les boxplots de l'erreur absolue d'estimation de la respiration (bpm) pour six activités quotidiennes : assis, debout, coucher, conduire, travailler et marcher pour les 10 patients. Chaque sous-figure comprend quatre boxplots de l'estimation de la FR en utilisant la première approche à partir de RPA, RSA, AQRS et QRA, trois résultats comparatifs entre la première approche et la seconde approche (par fusion LK), ainsi que les résultats de la sélection manuelle de modulation. Chaque boxplot représente les 25ème et 75ème percentiles et la valeur médiane au centre des Boxplots. . . . .	72
5.1	Exemples de signaux respiratoires (à gauche) et leur spectre de fréquence (à droite). . . . .	78
5.2	Exemples (de quatre patients A, B, C et D) des erreurs absolues (en bpm) d'estimation avec les modèles unimodal et bimodal. . . . .	83

5.3	Exemple de comparaison de détection des pics dans le signal obtenu à la sortie du LK en appliquant le modèle unimodal (mode 1) et le modèle bimodal (mode 2). . . . .	83
5.4	Autre exemple de comparaison de détection des pics dans le signal obtenu à la sortie du LK en appliquant le modèle unimodal (mode 1) et le modèle bimodal (mode 2). . . . .	84
5.5	Les boxplots d'estimation de la FR à partir des signaux PPG de CAPNO-BASE en se basant sur le modèle unimodal (mode 1) et le modèle bimodal (mode 2). Les boxplots correspondent aux résultats de fusion par le LK pour les trois indices $IQR_{\text{SINUS}}$ , $IQR_{\text{FT}}$ et $IQR_{\text{Autocor}}$ . . . . .	85
5.6	Les erreurs médianes d'estimation de la FR à partir des signaux PPG de CAPNOBASE avec la méthode <i>Smart Selection</i> pour les trois indices. . .	85
6.1	Cette figure présente un exemple du signal ECG A) pour un adulte (à B) pour un nouveau-né prématuré (à droite). . . . .	92
6.2	Exemple d'un signal ECG et des signaux dérivées de la base de données . .	94
6.3	Boxplots des résultats de l'estimation de la FR à partir des signaux ECG (médianes et 25e au 75e percentiles en bpm) pour une fenêtre de 32 s. Les quatre premières boxplots concernent les modulations dérivées (RPA, RSA, AQRS et QRA), suivies de la comparaison entre la sélection basée sur IQR (première approche) et la fusion des deux modulations par le LK (seconde approche). Les résultats de la sélection <i>a posteriori</i> sont également affichés à titre de référence. . . . .	95
6.4	La figure A présente un exemple d'un signal respiratoire et des cycles respiratoires extraites (ttot respiratoire), et les quatre modulations extraites de l'ECG (RPA, QRA, RSA et AQRS). Les figure B et C correspondent aux zones d'apnées de 10 s et 20 s, respectivement. . . . .	98

---

6.5 La figure A présente un exemple d'un signal respiratoire et des cycles respiratoire extraites (ttot respi), et les 4 modulations extraites de l'ECG (RPA, QRA, RSA et AQRS). Les Figures B et C correspondent aux zones d'apnées de 10 s. . . . . 99

# Liste des tableaux

2.1	Tableau de comparaison entre IQS et IQR. . . . .	27
4.1	Performance d'estimation de la FR en utilisant les signaux PPG de la base de donnée CAPNOBASE, comparé avec les méthodes de la littérature pour les 2 fenêtres 32s et 64s. Médiane (bpm) et les interquartiles (25th-75th) sont présentés. . . . .	67
4.2	Performance d'estimation de la FR à partir des signaux ECG de la base de donnée CAPNOBASE, comparé avec les méthodes de la littérature, pour les deux fenêtres 32s and 64s. La médiane (bpm) et les interquartiles (25th-75th) sont présentées. . . . .	68
4.3	Comparaison d'estimation de la FR avec ECG de la base de SHERPAM, entre la sélection des modulations (approche 1), la fusion à deux modulations (approche 2), la fusion à $m$ entrées, la sélection a posteriori et les méthodes de référence de la littérature. Les médianes des erreurs absolues (bpm) et les interquartiles des 10 sujets sont présentées. . . . .	71
5.1	Erreurs d'estimation de la FR avec les signaux PPG dans CAPNOBASE. La médiane de L'erreur absolue (bpm) et l'interquartile (25e-75e) sont présentées. . . . .	86
5.2	Erreurs d'estimation de la FR avec les signaux ECG de la base de données CAPNOBASE. La médiane de L'erreur absolue (bpm) et l'interquartile (25e-75e) sont présentées. . . . .	87



5.3 Performance d'estimation de la FR en appliquant la nouvelle méthode proposée *smart selection*, avec ECG de la base de SHERPAM (fenêtre de 32 s). Sont rapportées les médianes des erreurs absolues et interquartiles en bpm des 10 sujets. . . . . 88

6.1 Les performances d'estimation de la FR en utilisant les signaux ECG de la base de données Néonatale pour une fenêtre de taille 32s. La médiane de L'erreur absolue (bpm) et l'interquartile (25e-75e), sont présentées. . . . . 96





---

**Titre : Fusion par le Lisseur de Kalman pour l'Estimation de la Fréquence Respiratoire à partir de l'Electrocardiogramme ou Photoplethysmogramme**

**Mots clés :** fusion, lisseur de kalman, signal respiratoire, indice de qualité

**Résumé :** Ce mémoire de thèse vise à proposer de nouvelles méthodes robustes pour l'estimation de la fréquence respiratoire (FR) à partir des signaux physiologiques souvent utilisés dans la clinique comme l'électrocardiogramme (ECG) ou le photoplethysmogramme (PPG), tout en évitant de porter des capteurs encombrants et inconfortables. En effet, la respiration influence les signaux ECG et/ou PPG. Plusieurs modulations qui décrivent la respiration sont extraites basée principalement sur l'amplitude, la fréquence et la ligne de base. Il est toutefois difficile de déterminer la combinaison optimale des modulations pour obtenir une estimation précise de la FR en raison du bruit, la spécificité de chaque patient et de l'activité. Après une revue de la littérature, il ressort que peu de travaux ont étudié la qualité de ces modulations. Nous proposons donc de quantifier la qualité des modulations à l'aide d'indices de qualité respiratoire (IQR), un nouvel indice basé sur une modulation sinusoïdale est introduit.

à l'aide d'indices de qualité respiratoire (IQR), un nouvel indice basé sur une modulation sinusoïdale est introduit. Puis, deux méthodes sont proposées: la première sélectionne automatiquement la modulation avec l'IQR le plus élevé pour une estimation de la FR, la seconde combine les deux meilleurs modulations avec le lisseur de Kalman (LK). Une nouvelle approche de fusion de modulations basée sur un modèle multimodale est également explorée. Ces méthodes sont évaluées sur trois bases de données de différents contextes cliniques: la surveillance dans les soins postopératoires (où les patients sont immobiles), le suivi pendant les activités physiques quotidiennes et la surveillance néonatale. Les résultats expérimentaux montrent que les IQRs associés à un algorithme de fusion augmentent la précision de l'estimation de la FR à partir des modulations dérivées et montrent des résultats supérieurs aux travaux issus de la littérature.

---

**Title : Kalman Smoother Data Fusion for Estimating Breathing Rate From the Electrocardiogram or Photoplethysmogram**

**Keywords :** fusion, kalman smoother, Respiratory signal, respiratory quality indice

**Abstract :** The presented work in this dissertation concerns the development of approaches to estimate the breathing rate (BR) accurately from the electrocardiogram (ECG) and photoplethysmogram (PPG), to avoid wearing cumbersome and uncomfortable sensors for direct measurements. In fact, the respiration influences ECG and PPG signals. Several modulations are extracted to describe breathing cycles based on amplitude, frequency and baseline. However, it is difficult to determine the optimal combination to estimate the BR due to the noise and patient-dependency. Since few works have studied the quality of these modulations, we propose to study the quality of modulations using respiratory quality indices (RQI).

To do so, we present two methods: the first automatically selects the modulations with the highest RQI for BR estimation, the second tracks the respiration signal using Kalman smoother. The obtained results show superior performance comparing to the methods in the literature. In addition, an extension of fusion approach is presented based on a multi-mode model. These proposed methods are tested on several datasets with different clinical contexts: monitoring post-operative care (where patients are immobile), daily physical activities and neonatal monitoring. The experimental results show that the RQIs coupled with a fusion algorithm increase the accuracy of the BR estimation from the derived modulations.