

Détection de la somnolence en situation de conduite, à l'aide du rythme respiratoire détecté par capteurs textiles inductifs

par

Victor BELLEMIN

MÉMOIRE PRÉSENTÉ À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
COMME EXIGENCE PARTIELLE À L'OBTENTION DE LA MAÎTRISE
AVEC MÉMOIRE EN GÉNIE
M. Sc. A.

MONTREAL, LE 12, DÉCEMBRE, 2024

ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
UNIVERSITÉ DU QUÉBEC



Victor BELLEMIN, 2024



Cette licence Creative Commons signifie qu'il est permis de diffuser, d'imprimer ou de sauvegarder sur un autre support une partie ou la totalité de cette oeuvre à condition de mentionner l'auteur, que ces utilisations soient faites à des fins non commerciales et que le contenu de l'oeuvre n'ait pas été modifié.

PRÉSENTATION DU JURY

CE MÉMOIRE A ÉTÉ ÉVALUÉ

PAR UN JURY COMPOSÉ DE:

M. Ghyslain Gagnon, directeur de mémoire
Département de génie électrique à l'École de Technologie Supérieure

M. Fabrice Vaussenat, co-directeur
Département de génie électrique à l'École de Technologie Supérieure

M. Eric Wagnac, président du jury
Département de génie mécanique à l'École de Technologie Supérieure

M. Mohamad Forouzanfar, membre du jury
Département de génie électrique à l'École de Technologie Supérieure

IL A FAIT L'OBJET D'UNE SOUTENANCE DEVANT JURY ET PUBLIC

LE 4, DÉCEMBRE, 2024

À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE

REMERCIEMENTS

J'aimerais tout d'abord remercier ma copine Jeanne alias BB, qui m'a soutenu lors des moments de doute et m'a motivé lorsque c'était nécessaire. Merci d'être patiente avec moi et d'attendre la fin de mes interminables études, je t'aime. Un grand merci à ma mère sans qui je n'aurais pas poursuivi cette maîtrise. Grâce à toi, je continue de donner le meilleur de moi-même. Je suis fière de la personne que je suis aujourd'hui et c'est à toi que je le dois, je t'aime maman. Merci à toi aussi papa de m'avoir toujours encouragé à faire des études et du sport, les valeurs acquises dans le sport continuent de me pousser aujourd'hui à être une meilleure personne, j'espère que tu es fière de moi là où tu es. Merci à toute ma famille et particulièrement Olivier et Anne-Roberte pour m'avoir raconté vos expériences de recherche, je partage à présent votre fierté d'avoir terminé un mémoire.

Merci à Geordi mon jumeau de recherche, sans qui mon projet n'aurait pas pu aller aussi loin. Tu as été présent à toutes les étapes de doutes ou de réussites. Ne change pas, tu seras un très bon chercheur ou ingénieur (peu importe ce que tu choisis).

Je voudrais également remercier tous mes amis qui ont contribué de près ou de loin à ce mémoire, en particulier Julo et Pierre et tous ceux ayant participé aux essais.

Un grand merci à Ghyslain Gagnon mon directeur de recherche, pour m'avoir fait confiance, et poussé à fournir un travail de qualité au-delà de mes espérances, tu as toujours réussi à trouver les solutions pour me permettre d'avancer plus loin, tant d'un point vu opérationnel que technique.

Un immense merci à tous les partenaires de recherche, impliqués ou non dans le projet, qui ont donné de leur temps : Fabrice Vaussenat, Mathieu Gratuze, James Elber Duverger, Alireza Saidi, Patricia Forcier, Luiz Melo et enfin Mohktar Liamini. Et plus largement, j'aimerais remercier le groupe CTT de sainte hyacinthe et l'IRSST pour leur soutien tout au long du projet.

Détection de la somnolence en situation de conduite, à l'aide du rythme respiratoire détecté par capteurs textiles inductifs

Victor BELLEMIN

RÉSUMÉ

Depuis quelques décennies, de nombreux rapports mettent en avant le rôle des conducteurs somnolents dans les accidents mortels. Les institutions cherchent donc de nouveaux moyens pour limiter l'impact de la somnolence sur la sécurité routière. Cet intérêt pour réduire la mortalité au volant a poussé les chercheurs à trouver de nouvelles méthodes non-invasives de surveillance des conducteurs dans le but de détecter la somnolence.

Le principal objectif de ce mémoire est de proposer un nouveau système d'acquisition cardio-respiratoire non-invasif basé sur des électrodes inductives textiles dans le but de détecter la somnolence et d'améliorer la précision de ce type de système. Ce mémoire se concentre sur le signal de respiration. Pour ce faire, une méthode novatrice utilisant quatre électrodes réparties le long de la ceinture de sécurité et une fusion par filtre de Kalman permettant d'estimer l'état futur d'un système en réduisant l'incertitude des données a été développée. Pour évaluer le système, différentes positions et tailles d'électrodes ont été testées. Leur performance en situation de conduite simulée a ensuite été mesurée.

Les résultats démontrent que la position des électrodes impacte significativement la précision, avec les électrodes situées sur la ceinture obtenant de meilleures performances que celles situées dans le dos. Il a été relevé que les électrodes de plus grande taille maximisent la précision, et plus généralement, pour obtenir les meilleurs signaux, les mouvements relatifs des électrodes par rapport au sujet doivent être optimisés. Sur les 50 sessions de 1h30, l'utilisation du filtre de Kalman a permis de faire passer de 28% à 44% le taux d'enregistrements avec une erreur absolue moyenne d'estimation du rythme respiratoire inférieure à 2 respirations par minute. La précision de classification de la somnolence obtenue avec ce système textile est comparable à celle obtenue avec les données de référence.

En conclusion, les électrodes inductives textiles sans contact sont une option prometteuse pour la surveillance de la respiration et la détection de la somnolence en situation de conduite. Cependant, des améliorations doivent encore être apportées, comme par exemple une matrice d'électrodes textiles brodée directement sur la ceinture pour limiter leur déplacement. Les prochaines études devraient se concentrer sur l'amélioration des indices de qualité pour détecter les signaux de mauvaise qualité afin d'améliorer la précision de la détection de la somnolence en limitant l'impact du bruit. L'acquisition de nouvelles données permettrait d'améliorer les performances de détection de la somnolence en améliorant la généralisation des modèles.

Mots-clés: somnolence, endormissement, respiration, conduite somnolente, textile

Drowsiness detection in driving situations using respiratory rate monitored by inductive textile sensors

Victor BELLEMIN

ABSTRACT

For several decades, numerous reports have highlighted the role of drowsy drivers in fatal accidents. Institutions are therefore seeking new ways to limit the impact of drowsiness on road safety. This interest in reducing driving-related fatalities has prompted researchers to develop new, non-invasive methods for monitoring drivers to detect drowsiness.

The main objective of this thesis is to propose a new non-invasive cardio-respiratory acquisition system based on textile inductive electrodes to detect drowsiness and improve the accuracy of this type of system. This thesis focuses on the respiratory signal. To achieve this, an innovative method using four electrodes distributed along the seat belt and fusion through a Kalman filter, which estimates the future state of a system by reducing data uncertainty, was developed. To evaluate the system, different electrode positions and sizes were tested, and their performance was measured in a simulated driving situation.

The results demonstrate that electrode position significantly impacts accuracy, with electrodes positioned on the seat belt achieving better performance than those on the back. Larger electrodes were found to maximize accuracy, and generally, for optimal signal quality, the relative movement of electrodes with respect to the subject should be minimized. Over the 50 sessions of 1.5 hours, using the Kalman filter increased the rate of recordings with a mean absolute respiratory rate estimation error of less than 2 breaths per minute from 28% to 44%. The drowsiness classification accuracy achieved with this textile system is comparable to that obtained with reference data.

In conclusion, contactless textile inductive electrodes are a promising option for respiratory monitoring and drowsiness detection in driving conditions. However, improvements are still needed, such as a matrix of textile electrodes directly embroidered onto the seat belt to limit their movement. Future studies should focus on improving quality indices to detect poor-quality signals and enhance drowsiness detection accuracy by minimizing the impact of noise. Acquiring new data would improve drowsiness detection performance by enhancing model generalization.

Keywords: drowsiness, sleepiness, respiration, drowsy driving, textile

TABLE DES MATIÈRES

	Page
INTRODUCTION	1
0.1 Contexte de l'étude et problématique	1
0.2 Objectifs de recherche	5
0.3 Structure de la thèse	6
 CHAPITRE 1 REVUE DE LITTÉRATURE	 9
1.1 La somnolence	9
1.1.1 Le système nerveux autonome, le sommeil, la somnolence et la respiration	 11
1.2 Détection de la somnolence en situation de conduite	17
1.2.1 Notation de la Somnolence	18
1.2.2 Le Perclos, une mesure très répandue	20
1.2.3 Protocole expérimental	21
1.2.4 Les systèmes de détection de la somnolence	22
1.2.4.1 Détection par images	24
1.2.4.2 Détection par mesures véhiculaires	25
1.2.4.3 Détection par mesures physiologiques	26
1.2.4.4 Détection par mesures hybrides	30
1.2.4.5 Remarques générales	31
1.3 Détection de la respiration	33
1.3.1 Les méthodes existantes	33
1.3.1.1 Spirométrie	33
1.3.1.2 La ceinture respiratoire	34
1.3.1.3 Électrodes de contact	34
1.3.1.4 Appareils portables (en anglais "wearables")	35
1.3.1.5 Microphones	36
1.3.1.6 Radars	36
1.3.1.7 Caméra thermique	37
1.3.1.8 Électrodes sans contact	37
1.3.2 La détection inductive	37
1.3.2.1 Détection de la respiration par courants de Foucault induits	 38
1.3.2.2 Méthodes d'acquisition	41
1.3.2.3 Performances et défis associés à la détection de la respiration inductives	 43
1.4 Le Signal de Respiration	48
1.4.1 Généralités	48
1.4.2 Traitement de signal	50
1.4.2.1 Extraction et pré-traitement du signal respiratoire	50
1.4.2.2 Fusion des signaux respiratoires	51

1.4.2.3	Estimation du rythme respiratoire (RR)	53
1.4.2.4	La fusion des rythmes respiratoires	54
1.4.2.5	Indices de qualité	55
1.4.2.6	Remarques générales	58
1.5	Perspectives	58
CHAPITRE 2 MÉTHODOLOGIE ET ARCHITECTURE DU SYSTÈME		61
2.1	Architecture	62
2.1.1	Électrodes inductives textiles	65
2.1.1.1	Méthode de fabrication	66
2.1.2	La carte d'acquisition	70
2.1.2.1	Le numériseur d'inductance LDC1612	72
2.1.3	Plateforme Embarquée STM32H743	76
2.1.3.1	Implémentation Logiciel matériel	78
2.1.4	Logiciels d'acquisition PC python	81
2.1.5	Extraction Perclos	86
2.1.6	Référence Biopac	87
2.1.7	Synchronisation des données (Lab Streaming Layer)	89
2.2	Méthodologie de traitement de signal	90
2.2.1	Prétraitement du signal	91
2.2.1.1	Rééchantillonnage	91
2.2.1.2	Filtrage	91
2.2.1.3	Standardisation	92
2.2.2	Algorithme d'estimation du rythme respiratoire	93
2.2.3	Amélioration de l'estimation du rythme respiratoire	94
2.2.3.1	Choix par vote	94
2.2.3.2	Fusion par filtre de Kalman	96
2.3	Expériences	100
2.3.1	Simulateur de conduite	100
2.3.2	Étude des positions et des formes d'électrodes textiles	100
2.3.3	Étude de la somnolence en situation de conduite simulée	102
2.3.4	Critère de sélection et consignes	103
2.3.5	Déroulement de l'expérience	104
2.3.6	Scénario de conduite	106
2.4	Méthodologie pour l'analyse des données de somnolence	108
2.4.1	Segmentation des données somnolentes	108
2.4.2	Études de la séparabilité des données	110
2.4.3	Classification des données	110
CHAPITRE 3 RÉSULTATS ET DISCUSSIONS		113
3.1	Résultats	113
3.1.1	Performances d'estimation du rythme respiratoire des électrodes textiles	114

3.1.2	Relation entre les indices de qualité et la performance d'estimation du rythme respiratoire	117
3.1.3	Résultats des tests de position et de taille	118
3.1.4	Statistiques des données de somnolence	122
3.1.5	Artefact de mouvements, placement des électrodes	123
3.1.6	Résultats de corrélation entre les caractéristiques du rythme respiratoire expérimental textile et la référence	125
3.1.7	Distribution des données somnolentes/non-somnolentes	127
3.1.8	Classification de la somnolence	132
3.1.8.1	Résultats des données de référence	133
3.1.8.2	Résultats données expérimentales textiles	134
3.2	Discussions	136
3.2.1	Influence de la position des électrodes sur la performance	137
3.2.2	Précision de la détection de la respiration à l'aide d'électrodes textiles sans contact	138
3.2.3	Impact de la fusion de signaux et de l'utilisation des indices de qualité	139
3.2.4	Corrélation entre les caractéristiques du rythme respiratoire et les données de référence	140
3.2.5	Différenciation entre données somnolentes et non-somnolentes	141
3.2.6	Distribution temporelle des événements somnolents	142
3.2.7	Détection de la somnolence à partir des données textiles	142
3.2.8	Remarques générales	143
CONCLUSION ET RECOMMANDATIONS		147
LISTE DE RÉFÉRENCES BIBLIOGRAPHIQUES		149

LISTE DES TABLEAUX

	Page
Tableau 1.1	Description des différents états de sommeil et éveil 14
Tableau 1.2	Statistiques de RSP en état d'éveil et de somnolence 17
Tableau 1.3	Résumé des études sur la détection de la somnolence 32
Tableau 2.1	Caractéristiques du fil métallique (Tinsel) 68
Tableau 2.2	Liste des prototypes produits 71
Tableau 2.3	Consommation d'énergie du capteur 74
Tableau 2.4	STM32H747 Spécifications du CPU, GPIO, DMA et ADC 77
Tableau 2.5	Tableau des tests des positions et tailles des électrodes textiles 102
Tableau 2.6	Tableau des morphologies des sujets de l'étude de positions et tailles 102
Tableau 2.7	Rayon des segments en mètres 107
Tableau 3.1	Résultats des MAE par type et taille d'électrode, position et moyenne des sujets 120
Tableau 3.2	Distribution des temps d'accidents majeur (en minutes) 122
Tableau 3.3	Résultats de classification de référence 133
Tableau 3.4	Résultats de classification de données de référence augmentées 133
Tableau 3.5	Résultats de classification expérimentaux 134
Tableau 3.6	Résultats de classification de données expérimentales augmentées 134

LISTE DES FIGURES

	Page
Figure 0.1	Prévision du revenu des entreprises liées à l'IOT entre 2019 et 2029 2
Figure 0.2	Étude comparative de la détection de la somnolence 3
Figure 0.3	Schéma du système à quatre points de mesure 4
Figure 1.1	Karolinska sleep scale 10
Figure 1.2	Schéma des rythmes circadiens 12
Figure 1.3	Exemple d'un hypnogramme 13
Figure 1.4	Distribution théorique des états de somnolence 15
Figure 1.5	Différences entre la respiration somnolente et alerte 16
Figure 1.6	Échelle de notation de la somnolence de Ellsworth 19
Figure 1.7	Ratio d'ouverture des yeux 20
Figure 1.8	Famille des systèmes de détection de la somnolence 23
Figure 1.9	Schéma fonctionnel des systèmes de détection de la somnolence 24
Figure 1.10	Méthode de détection par la respiration et ECG de Zhou 29
Figure 1.11	Modulation de l'ECG et du PPG par la respiration 35
Figure 1.12	Induction des courants de Foucault dans les tissus biologiques 39
Figure 1.13	Modèle électrique de l'interaction entre le corps et le circuit L-C 40
Figure 1.14	Schéma fonctionnel des circuits d'acquisition inductifs 42
Figure 1.15	Placement de la bobine, siège de conduite intelligent de Walter 44
Figure 1.16	Électrode brodée dans ceinture de sécurité Physiobelt 45
Figure 1.17	Position des Électrodes dans l'études de Cho 46
Figure 1.18	Intégration des capteurs Leicht 47
Figure 1.19	Système respiratoire 49

Figure 1.20	Étapes du traitement de signal de respiration	50
Figure 1.21	Méthode de fusion de signaux respiratoires	52
Figure 1.22	Schéma des étapes d'estimation du filtre de Kalman.....	52
Figure 1.23	Détection temporelle des pics	54
Figure 1.24	Exemple de corrélation avec patron de respiration moyen	56
Figure 2.1	Schéma architecture système	64
Figure 2.2	Système d'acquisition complet	65
Figure 2.3	Brodeuse Tajima TMLX-1201	66
Figure 2.4	Processus de brodage	67
Figure 2.5	Première version électrodes textiles.....	69
Figure 2.6	Version finale électrodes textiles circulaires	70
Figure 2.7	Version finale électrodes textiles rectangulaires	71
Figure 2.8	Carte d'acquisition avec LDC1612	73
Figure 2.9	Séquence de lecture multi-canaux LDC1612	74
Figure 2.10	Courbe fréquence capteur VS inductance.....	74
Figure 2.11	Étapes de calibration LDC1612	75
Figure 2.12	Photo setup stm32.....	77
Figure 2.13	Séquence générale module de communication LDC1612	79
Figure 2.14	Diagramme général de l'application python.....	82
Figure 2.15	Interface signaux de référence.....	84
Figure 2.16	Interface signaux expérimentaux	84
Figure 2.17	Interface signaux de référence.....	85
Figure 2.18	Rapport hauteur/largeur des yeux	86
Figure 2.19	Système de référence Biopac	87

Figure 2.20	Capteurs de référence Biopac	88
Figure 2.21	Lab streaming layer et Lab Recorder	89
Figure 2.22	Normalisation par Z-score	93
Figure 2.23	Évolution des indices de qualité avant et après filtrage	95
Figure 2.24	Schéma de la reconstruction du signal	96
Figure 2.25	Fusion des signaux de respiration par le filtre de Kalman	99
Figure 2.26	Vue globale du simulateur	101
Figure 2.27	Schéma étude de positions et tailles.....	103
Figure 2.28	Probabilité comparative des accidents reliés à la somnolence	105
Figure 2.29	Vue générale de la carte et vue rapprochée de la route.....	106
Figure 2.30	Panneaux de signalisation alertant le conducteur d'un virage serré	107
Figure 2.31	Labellisation des données de rythmes respiratoires	109
Figure 3.1	Performance des canaux pour l'estimation du rythme respiratoire à travers toute les sessions de conduite	114
Figure 3.2	MAE entre la référence et les signaux expérimentaux et fusionnées	115
Figure 3.3	Évolution moyenne de l'erreur d'estimation de la respiration des électrodes textiles fusionnées	116
Figure 3.4	Performance de l'estimation du rythme respiratoire en fonction des sources de la fusion.....	117
Figure 3.5	Indices de qualité VS la MAE	118
Figure 3.6	Indices de qualité par ordre décroissant.....	119
Figure 3.7	Performances des petites électrodes circulaires sur le dossier	120
Figure 3.8	Performances des électrodes au milieu du dossier	121
Figure 3.9	Performances des électrodes rectangulaires sur la ceinture de sécurité	122
Figure 3.10	Évolutions des indices de qualité moyens durant les enregistrements	124

Figure 3.11	Déplacement des électrodes au cours de l'enregistrement	125
Figure 3.12	Corrélation des caractéristiques du rythme respiratoire textiles et de références tout au long des enregistrements	126
Figure 3.13	Corrélation des caractéristiques du rythme respiratoire textiles et de références proches des accidents somnolents	127
Figure 3.14	Évolution moyenne des caractéristiques du rythme respiratoire textiles et références proches des accidents somnolents	128
Figure 3.15	Distribution des caractéristiques du rythme respiratoire non-somnolente/somnolente	129
Figure 3.16	Moyenne et déviation standard du rythme respiratoire pour les sujets somnolents	130
Figure 3.17	Signaux de mauvaise qualité du sujet 17 session 2.....	131
Figure 3.18	Projection UMAP des données non-somnolentes/somnolentes.....	132
Figure 3.19	Matrice de confusion modèle SVM	135
Figure 3.20	Matrice de confusion modèle RDF	135
Figure 3.21	Matrice de confusion modèle SVM données augmentées	136
Figure 3.22	Matrice de confusion modèle RDF données augmentées	136

LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES

DAC	(anglais, Digital to Analog Converter)
ADC	(anglais, Analog to digital Converter)
ETS	École de Technologie Supérieure
SNA	Système nerveux autonome
SNS	Système nerveux sympathique
SNP	Système nerveux parasympathique
KSS	(anglais, Karolinska Sleepiness Scale)
SSS	(anglais, Stanford Sleepiness Scale)
ECG	Électrocardiogram
EEG	Électroencéphalogramme
PPG	(anglais, Photoplethysmogram)
REM	(anglais, Rapid eye movement)
LF	(anglais, Low frequency)
HF	(anglais, High frequency)
RSQI	(anglais, Respiration signal quality index)
RSP	Respiration
LSTM	(anglais, Long-Short-Term-Memory)
CNN	(anglais, Convolutional neural network)
KNN	(anglais, k-nearest neighbors)
ASR	Arythmie sinusoïdale respiratoire
MAE	(anglais, mean absolute error)
RDF	(anglais, Random Forest Classifier)
SVM	(anglais, Support Vector Machine)
RQI	(anglais, Respiration Quality Index)
RR	Rythme respiratoire

SPI	(anglais, Spectral Purity Index)
SDR	(anglais, Spectral Density Ratio)
LSL	(anglais, Lab Streaming Layer)
DMA	(anglais, Direct Memory Access)
CRC	(anglais, Cyclic Redundancy Check)

LISTE DES SYMBOLES ET UNITÉS DE MESURE

ρ	Densité
Ω	Ohm
E	Module d'élasticité
F	Farad
Hz	Hertz
m	Mètre
Q	Facteur de qualité
s	Seconde
V	Volt
W	Watt
I	Courant
∇	Opérateur rotationnel
σ	Conductivité
μ_0	Perméabilité du vide

INTRODUCTION

0.1 Contexte de l'étude et problématique

Ce projet de recherche se concentre sur l'élaboration d'un système d'acquisition de bio-signaux minimalement invasif en situation de conduite. L'objectif est de permettre la détection de la somnolence à l'aide des signaux cardiorespiratoires. Depuis plusieurs années, la somnolence est reconnue comme un facteur majeur de la dégradation de la sécurité routière. D'après des études antérieures (Tefft, 2024,1), elle contribue fortement à la mortalité sur les routes. En 2010, on estime à 7,0% la proportion d'accidents où un conducteur somnolent était impliqué. Ce chiffre augmente à 21,0% pour les accidents mortels. Ces résultats pourraient cependant être sous-estimés, car selon des questionnaires de cette même étude, plus d'un conducteur américain sur quatre admet avoir conduit dans un état de somnolence avancé au cours du dernier mois. Les travaux canadiens de Vanlaar, Simpson, Mayhew & Robertson (2008) corroborent les données américaines avec des cas de somnolence similaires en Ontario. De plus, les réponses des conducteurs suggèrent que les méthodes les plus populaires pour contrer la somnolence sont souvent les moins efficaces. Il est donc vital d'apporter de nouvelles mesures permettant la prévention de la somnolence.

Lors d'un sommet en 2005, (Drobnich, 2005), impliquant différentes agences gouvernementales américaines, les chercheurs estimaient les pertes économiques liées à la somnolence à plus de 12,5 milliards de dollars. Ces pertes se traduisent sur la figure 0.1 par un marché de la détection de la somnolence en expansion, cette évolution montre que le secteur privé a déjà saisi l'ampleur du problème avec un marché actuel estimé à 8 milliards USD et une prévision à 24,4 milliards USD pour 2033 d'après ce rapport de Market.us (2024).

Face à l'importance de la mortalité et au coût qu'elle engendre pour les institutions, l'Union européenne a décidé de mettre à jour, à partir du 7 juillet 2024, sa réglementation Générale

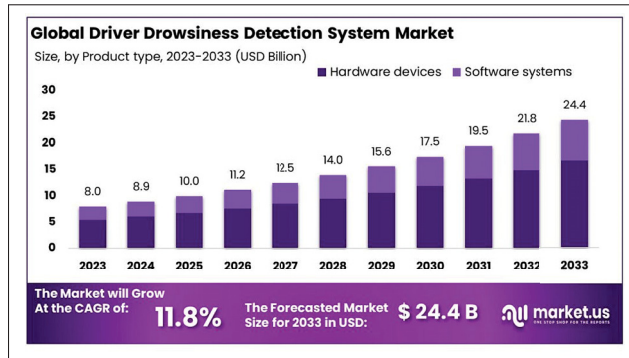


FIGURE 0.1 Pr vision de la valeur du
march  de 2023   2033
Tir e de Market.us (2024)

Safety Regulation 2 (GSR2). Elle oblige les constructeurs automobiles   proposer un syst me de d tection pr coce de l'attention ou de la somnolence dans tous les nouveaux v hicules introduits dans l'Union europ enne   partir de cette date.

Pour r soudre ce probl me, la communaut  scientifique propose diff rentes approches. Il existe trois familles de syst mes de d tection : comportementale, physiologique et v hiculaire. Les plus populaires et pr conis s par la r glementation GSR2 sont celles bas es sur le comportement (taux d'ouverture des yeux, signes de fatigue, etc.) ou les mesures v hiculaires (variation de direction, vitesse, distance avec le v hicule pr c dent, etc.). Les r sultats de d tection de ces deux familles de m thodes soul vent n anmoins certaines limitations. Dans sa revue, Albadawi, Takruri & Awad (2022) aborde les diff rents d fis associ s aux m thodes de d tection. Le principal probl me pour les mesures par image  tant la pr cision de d tection de la somnolence en condition r elle ; la plupart des travaux montrent des r sultats encourageants en situation simul e, mais pr sentent une baisse significative de la pr cision lors de situations non contr l es. Plusieurs facteurs expliquent cela, notamment la difficult    d tecter les visages de mani re stable (luminosit , port de lunettes, couleur de peau, distance de la cam ra). Les cam ras posent aussi un probl me pour la vie priv e des conducteurs, pouvant mener   un rejet de la part de certains utilisateurs.

Les détections basées sur les mesures véhiculaires montrent, elles aussi, des limites. Des événements extérieurs influencent les mesures, par exemple la météo (pluie, neige, vent) (Volvo Car USA, 2007). Mais on peut aussi douter des mesures lorsque la route présente des caractéristiques pouvant impacter la conduite, telles qu'une chaussée déformée induisant des vibrations dans le volant. L'étude de Ramzan, Khan, Awan, Ismail, Ilyas & Mahmood (2019) confirme les remarques de Albadawi *et al.* (2022), tout en fournissant une compilation de la précision de détection de la somnolence par les travaux antérieurs. La figure 0.2, tirée des travaux de Ramzan *et al.* (2019), montre que les méthodes physiologiques ont tendance à obtenir une meilleure précision de détection. On peut donc logiquement espérer obtenir de meilleurs résultats avec une approche physiologique de la détection de la somnolence.




FIGURE 0.2 Étude comparative de la précision de détection de la somnolence
Tirée de (Ramzan *et al.*, 2019, p. 13)

Malgré les résultats de la figure 0.2 les méthodes physiologiques sont pour la plupart trop invasives pour être utilisées en situation réelle, face à ce problème ce mémoire propose un nouveau **système d'acquisition de signaux cardiorespiratoires non invasifs**. Pour cela, une nouvelle approche a été développée utilisant des **capteurs respiratoires textiles inductifs** pouvant être intégrés directement dans la ceinture de sécurité du véhicule. Une méthode illustrée par la figure 0.3 à quatre électrodes permet d'obtenir quatre signaux de respiration, puis deux nouvelles méthodes de fusion de signaux sont proposées pour améliorer les signaux : le choix de signal

par indice de qualité et la fusion par filtre de Kalman, dont l'objectif est de minimiser l'erreur de mesure à l'aide des informations des quatre capteurs.




FIGURE 0.3 Schéma du système à quatre points de mesure

Pour valider le système, une expérience suivant un protocole validé par le comité d'éthique de l'École de technologie supérieure, incluant 25 participants totalisant 75 heures de données de conduite, a été réalisée. Cela nous a permis de créer une base de données comportant les signaux ECG et respiratoires, une vidéo des participants, et les données véhiculaires du simulateur. Sur un ensemble de 50 enregistrements d'une durée de 1h30, la méthode de fusion par filtre de Kalman a amélioré la précision de l'estimation du rythme respiratoire par rapport à la référence. Cette approche a permis de réduire les erreurs de mesure et d'augmenter la proportion de sessions présentant une faible erreur par rapport aux données de référence. Par ailleurs, Les données obtenues permettront de combler le manque de base de données physiologiques en situation de conduite et de somnolence observé lors de nos recherches préliminaires. En effet, seuls les travaux de Massoz, Langohr, François & Verly (2016), mettant à disposition une base de données contenant les données physiologiques et vidéos de personnes somnolentes en situation de conduite, sont en libre accès à notre connaissance. Pour finir, une classification des épisodes de somnolence a été réalisée en utilisant les données du rythme respiratoire collectées à

partir des électrodes textiles ainsi que celles issues des capteurs de référence. Les performances obtenues montrent que les deux types de données fournissent des résultats comparables pour la détection de la somnolence, indiquant un potentiel prometteur pour une méthode non invasive de surveillance basée sur la respiration.

0.2 Objectifs de recherche

La recherche effectuée au cours des deux dernières années dans ce mémoire intitulé "Détection de la somnolence en situation de conduite, à l'aide du rythme respiratoire détecté par capteurs textiles inductifs" s'inscrit dans un projet sur la somnolence de plus grande ampleur impliquant plusieurs partenaires tels que l'Institut de recherche Robert-Sauvé en santé et en sécurité du travail (IRSST) et le Groupe CTT un centre de transfert technologique spécialisé dans les technologies textiles.

Le projet s'articule autour de quatre questions de recherche :

- Peut-on mesurer de manière minimalement invasive et fiable le signal respiratoire à l'aide d'électrodes inductives ?
- Quel est le meilleur emplacement pour placer les électrodes ?
- Existe-t-il un lien entre des caractéristiques fréquentielles ou temporelles du rythme respiratoire et la détérioration des capacités de conduite ?
- Peut-on détecter la somnolence avec des capteurs textiles inductifs ?

Principales contributions de ce mémoire :

1. Système d'acquisition de signaux cardiorespiratoires avec électrodes textiles inductives.
2. Étude comparative de la taille, de la position et de la forme de l'électrode inductive.
3. Nouvelle approche multi-capteurs intégrés à une ceinture de conduite.
4. Sélection automatique du meilleur capteur pour l'estimation du rythme respiratoire.

5. Fusion des signaux de respiration pour l'amélioration de la précision de l'estimation du rythme respiratoire.
6. Base de données de signaux cardiorespiratoires, avec données comportementales et véhiculaires. Les données ont été récoltées en situation de conduite, et plusieurs épisodes de somnolence ont été répertoriés.
7. Travail préliminaire de détection de la somnolence avec la respiration acquise par électrodes inductives.

0.3 Structure de la thèse

L'état de l'art concernant la somnolence au volant et les travaux réalisés au cours de cette maîtrise seront présentés dans les chapitres suivants :

- Le CHAPITRE 1 donne les bases de la compréhension et des définitions autour de la somnolence et du sommeil, en mettant en lumière leur relation avec la respiration. Il propose ensuite un aperçu global des différentes méthodes de détection de la somnolence. Enfin, ce chapitre présente les méthodes de traitement et d'acquisition des signaux respiratoires disponibles dans la littérature.
- Le CHAPITRE 2 explique la méthodologie utilisée pour le projet : conception matérielle et logicielle, conception des électrodes inductives et du circuit d'acquisition, estimation du rythme respiratoire et méthode de sélection de capteurs, et enfin, présentation du système de simulation utilisé.
- Le CHAPITRE 3 expose les résultats des deux expérimentations présentées dans le CHAPITRE 2, une discussion permettant de conclure sur le meilleur type de système et d'électrodes, ainsi qu'une interprétation des résultats obtenus lors de l'expérience de somnolence en situation de conduite.

La conclusion de ce travail offre une vue d'ensemble des activités réalisées et des perspectives futures pour les prochains travaux.

CHAPITRE 1

REVUE DE LITTÉRATURE

1.1 La somnolence

La somnolence, en particulier la somnolence diurne, est définie médicalement comme un besoin non désiré et parfois incontrôlable de dormir pendant la journée. Elle survient généralement lorsque le rythme circadien, qui régule l'alternance entre l'éveil et le sommeil, est perturbé. Le rythme circadien est un cycle biologique de 24 heures qui régule les périodes d'éveil et de sommeil chez les êtres humains. Ce cycle est influencé par des facteurs internes tels que les hormones et par des stimuli externes comme la lumière naturelle (Reddy, Reddy & Sharma, 2024). L'état de somnolence est déclenché par un besoin accru de sommeil de la part du sujet, comme expliqué par Roehrs, Carskadon, Dement & Roth (2017). Le terme le plus souvent utilisé est somnolence, mais la littérature alterne entre les termes anglophones tels que "Drowsiness", "Sleepiness" ou encore "Fatigue", qui sont souvent interchangeables. Cependant, ils présentent certaines différences, comme expliqué dans ce rapport Beirness, 1955, Desmond, 1949, Simpson, 1940 & Traffic Injury Research Foundation (Canada) (2005). En effet, la fatigue est définie par (Beirness *et al.*, 2005, p. 6) comme : "la réticence à poursuivre une tâche en raison d'un effort physique ou mental, ou d'une période prolongée de réalisation de la même tâche"[Traduction libre]. Plus généralement, elle fait référence à l'état précédant le sommeil et, d'après les travaux de Bereshpolova, Stoelzel, Zhuang, Amitai, Alonso & Swadlow (2011), elle inclut vraisemblablement la transition d'un état alerte à non alerte. La littérature n'ayant pas statué sur des marqueurs physiologiques clairs, la présence et l'intensité de la somnolence sont le plus souvent mesurées par des marqueurs comportementaux visibles tels que le taux de fermeture des yeux (Perclos introduit par Knippling & Wierwille (1994)), le bâillement et la fréquence des assoupissements. D'autres travaux, comme Akerstedt & Gillberg (1990), ont cherché à quantifier ces observations à l'aide d'échelles objectives permettant une estimation linéaire de la somnolence.

Karolinska Sleepiness Scale (KSS)	
Extremely alert	1
Very alert	2
Alert	3
Rather alert	4
Neither alert nor sleepy	5
Some signs of sleepiness	6
Sleepy, but no effort to keep awake	7
Sleepy, but some effort to keep awake	8
Very sleepy, great effort to keep awake, fighting sleep	9
Extremely sleepy, can't keep awake	10

FIGURE 1.1 Karolinska sleep scale (KSS)
Tirée de (Shahid *et al.*, 2011a, p. 2)

Cette échelle a été validée par d'autres recherches ultérieures Shahid *et al.* (2011a) qui ont mis en évidence le lien entre **la Karolinska sleep scale (KSS)** présentée sur la figure 1.1 et **les mesures d'électroencéphalogramme (EEG)**, reconnues pour être les plus efficaces pour estimer l'état de fatigue mentale d'un patient à l'aide des ondes alpha 8–12 Hz (éveil) et les ondes thêta 4–8 Hz (premier stade de sommeil) (Gharagozlou, Nasl Saraji, Mazloumi, Nahvi, Motie Nasrabadi, Rahimi Foroushani, Arab Kheradmand, Ashouri & Samavati (2015); Lin, Wu, Liang, Chao, Chen & Jung (2005)). Une autre étude plus contemporaine vient confirmer le statut des mesures EEG comme mesure de référence dans la détection de la somnolence.

Outre l'EEG, d'autres mesures physiologiques, comme l'électrocardiogramme (ECG) et la respiration, se révèlent prometteuses. Par exemple, grâce au rythme cardiaque et à sa variabilité, Fujiwara, Abe, Kamata, Nakayama, Suzuki, Yamakawa, Hiraoka, Kano, Sumi, Masuda, Matsuo & Kadotani (2019) affirment détecter 12 épisodes de somnolence sur 13. De plus, ils valident leurs résultats avec des mesures EEG analysées par un expert. Koh, Cho, Lee, Kwon, Lee, Beom Lim, Lee & Kweon (2017) proposent une technique permettant la détection à l'aide des composantes fréquentielles, basses et hautes fréquences, ainsi que le ratio entre les bandes, et obtiennent 88,8% de précision. Guede-Fernández, Fernández-Chimeno, Ramos-Castro & García-González (2019) réussissent à détecter la somnolence avec une spécificité de 96,6% avec 3 capteurs respiratoires de type ceinture ventrale.

À la vue des résultats cités plus haut, on peut légitimement penser que la somnolence a un effet sur un ensemble élargi de mesures physiologiques. La cause est une fonctionnalité bien connue du corps humain, le système nerveux autonome (Waxenbaum, Reddy & Varacallo (2024)).

Dans le chapitre suivant, le lien de cette technique avec le sommeil et la somnolence sera expliqué.

1.1.1 Le système nerveux autonome, le sommeil, la somnolence et la respiration

C'est le **système nerveux autonome (SNA)** qui contrôle le cycle circadien et le système cardio-respiratoire. Le SNA fait partie d'un ensemble plus large, le système nerveux périphérique. Ce dernier est composé des nerfs et glandes situés en dehors du système nerveux central (l'encéphale et la moelle épinière). Le système nerveux autonome est responsable des fonctions biologiques sur lesquelles les organismes n'ont pas de contrôle, telles que la respiration, le rythme cardiaque, la digestion, la température du corps ou la pression sanguine. Il est composé de deux parties distinctes, le SNS (Système Nerveux Sympathique) et le SNP (Système Nerveux Parasympathique). Il alterne entre une activité accrue de l'un ou de l'autre selon la situation (Waxenbaum *et al.* (2024)).

Le système nerveux sympathique est responsable de la réponse du type "lutte-ou-fuite". Il répond à un stimulus extérieur nécessitant une réponse à un danger ou une situation stressante. Pour préparer le corps à cela, le SNS augmente le rythme cardiaque, stimule la dilatation des bronches et des pupilles, et augmente le rythme respiratoire (Gordan, Gwathmey & Xie, 2015).

Le système nerveux parasympathique, en opposition au SNS, prépare le corps à une réponse de type "repos-ou-digestion". Il ramène le corps vers un état de repos. Comme le SNS, il opère un changement sur diverses fonctions biologiques. Il réduit le rythme cardiaque et le maintient entre 60 et 100 battements par minute, stimule le système digestif, et les bronches se contractent. On retrouve généralement ce type de réponse pendant la digestion ou lors du sommeil (Gordan *et al.*, 2015).

Le SNA occupe une place prépondérante dans la transition d'un état d'éveil vers un état de sommeil. Cette transition est marquée par une augmentation de l'activité du SNS et une baisse de celle du SNP. De plus, lors des différentes phases du sommeil, on note une forte hétérogénéité dans l'activité des deux systèmes (Benarroch, 2019). Cela se traduit donc par des changements physiologiques pour le système cardio-respiratoire qu'il contrôle.

Le rythme circadien travaille avec l'homéostasie pour réguler le sommeil d'un individu. Ces deux systèmes contrôlent l'horloge biologique de l'organisme, ce sont des ensembles de systèmes biologiques rythmiques basés sur des cycles de 24 heures, présentés par la figure 1.2. La pression homéostatique devient de plus en plus forte à mesure qu'une personne reste éveillée, elle fonctionne comme un rappel pour le corps que le sommeil devient nécessaire.




FIGURE 1.2 Schéma des rythmes circadiens
Tirée de National institute of neurological disorders and stroke (2024)

Avant de détailler les stades du sommeil, il est essentiel de comprendre leur fonction. Comme l'explique Patel, Reddy, Shumway & Araujo (2024), les stades du sommeil s'enchaînent jusqu'à atteindre le sommeil profond. Une nuit de sommeil typique comprend 4 à 5 cycles de sommeil, où les différents stades décrits dans le tableau 1.1 apparaissent selon la figure 1.3 dans l'ordre suivant : N1, N2, N3, N2, puis REM (mouvements oculaires rapides). Les phases de sommeil sans mouvements oculaires rapides (NREM) occupe 75% du temps de sommeil total, la majeure partie se passant en phase N2 (Patel *et al.*, 2024). La figure 1.3 illustre un cycle de sommeil

complet, qui dure en moyenne de 90 à 110 minutes (Patel *et al.*, 2024). Les stades du sommeil sont reconnus par divers facteurs biologiques, le plus populaire étant les ondes cérébrales enregistrées lors d'un EEG, comme montré par Nayak & Anilkumar (2024).




FIGURE 1.3 Exemple d'un hypnogramme
Tirée de https://en.wikipedia.org/wiki/Sleep_cycle

De l'éveil jusqu'au stade le plus profond du sommeil (REM), le système nerveux autonome (SNA) est impliqué. Comme l'explique Benarroch (2019), le système cardio-respiratoire est soumis à des modifications au cours de l'évolution du sommeil. Lors des phases de sommeil NREM, on observe : une activité respiratoire réduite et une activité accrue du système nerveux parasympathique (SNP). Contrairement à la phase REM, qui est caractérisé par : une activation sporadique de la respiration liée à l'activité cérébrale, des respirations irrégulières et une activité accrue du système nerveux sympathique (SNS).

Pour résumer, à l'état d'éveil et en situation de stress, l'activation du SNS est très forte. Puis, à mesure que l'individu se calme pour devenir somnolent et enfin s'endormir, le SNP prend le relais pour effectuer la transition du corps vers un état de repos avec un rythme respiratoire et cardiaque plus lents. Cette activation dure pendant les phases de sommeil N1, N2 et N3 jusqu'à atteindre la phase la plus profonde, le REM, où le SNS s'active. Ce faisant, le rythme cardiaque retourne à des valeurs similaires à celles de l'éveil (Benarroch, 2019).

TABLEAU 1.1 Description des différents états de sommeil et éveil, avec caractéristiques des ondes EEG et impact sur le patient
Tiré de Patel *et al.* (2024)

État	Caractéristiques des ondes	Impact sur le patient
Éveil	Ondes bêta (12–35 Hz) et alpha (8-12 Hz)	Activité du SNS, augmentation des ondes alpha à l’approche du stade N1 et transition vers une activité accrue du SNP.
N1	Ondes thêta (4–8 Hz), Transition des ondes alpha vers des fréquences mixtes de faible amplitude (LAMF)	Début du sommeil, dure généralement de 1 à 5 minutes. Transition vers un sommeil plus profond.
N2	Présence de "sleep spindles" et de complexes K	Associé à la consolidation de la mémoire. Cet état dure environ 25 minutes.
N3	Ondes delta (0.5–4 Hz) de faible fréquence et grande amplitude	Phase la plus profonde du sommeil, où le réveil est difficile. Régénération du corps, réparation des tissus, renforcement des os et des muscles, amélioration du système immunitaire.
REM	Ondes bêta similaires à l’éveil	Rêves fréquents, paralysie des muscles squelettiques, activité des yeux, respiration irrégulière, activation du système nerveux sympathique et accélération du rythme cardiaque (Benarroch, 2019).

La somnolence, comme expliqué précédemment, n’est pas un stade du sommeil à proprement parler, mais fait partie intégrante de l’état d’éveil et est située juste avant le sommeil (N1). D’ailleurs, selon l’étude de Okogbaa, Shell & Filipusic (1994), la somnolence est caractérisée par le moment où la transition entre les ondes alpha 8–12 Hz (éveil) et les ondes thêta 4–8 Hz (N1) survient. Selon les travaux de Benarroch (2019), cette transition est accompagnée d’un changement de mode de fonctionnement du SNA, passant d’une activation du SNS au SNP. On pourrait donc détecter les changements du SNA à travers les métriques physiologiques qu’il contrôle, telles que la respiration ou encore le rythme cardiaque, et donc la transition vers un état de sommeil (la somnolence). L’étude de Vicente, Laguna, Bartra & Bailón (2016) propose d’étudier l’activité du SNS et SNP en utilisant la variabilité cardiaque, la composante basse-fréquence (LF) dans la bande 0.04–0.15 Hz représentant l’activité du SNS et la composante haute-fréquence (HF) dans la bande 0.15 à 0.4 Hz celle du SNP, le ratio entre les deux

bandes représentant la balance d'activités entre les deux systèmes. La figure 1.4 expose la répartition théorique des états de somnolence selon ces composantes proposées par Vicente *et al.* (2016). Une augmentation de la puissance HF combinée à une baisse de la puissance LF est caractéristique d'un état de somnolence. Lors du développement de leur système de détection, les chercheurs ont noté une augmentation de l'instabilité respiratoire corroborant les résultats de cette autre étude (Rodriguez-Ibanez, Garcia-Gonzalez, Fernandez-Chimeno & Ramos-Castro, 2011). Electrophysiology (1996) mentionne que les composantes LF-HF peuvent être contrôlées avec des exercices de respiration, et que dans certains cas, la composante HF influencée par la respiration est caractéristique d'une activité accrue du SNP.




FIGURE 1.4 Distribution théorique des états de somnolence selon les composantes LF et HF
Tirée de (Vicente *et al.*, 2016, p. 2)

Sachant que la respiration est un indicateur avéré de l'activité du SNA, plusieurs travaux ont essayé de caractériser les changements respiratoires lors de la somnolence (Douglas, White, Pickett, Weil & Zvillich, 1982; Trinder, Whitworth, Kay & Wilkin, 1992). Rodriguez-Ibanez *et al.* (2011) proposent déjà en 2011 des éléments de réponse en analysant la variabilité respiratoire. Les travaux de Tateno, Guan, Cao & Qu (2018) tentent de caractériser la pente de la respiration pour détecter la somnolence. Malgré une approche assez simpliste et peu de données dans leurs essais, cette recherche renforce la position de la respiration en tant que caractéristique

pour la détection de la somnolence. L'étude plus contemporaine de Kiashari, Nahvi, Bakhoda, Homayounfard & Tashakori (2020) propose des résultats sérieux avec des tests comportant 30 participants en situation de conduite simulée. En estimant le rythme respiratoire du patient à l'aide d'une caméra thermique, ils détectent la somnolence avec une précision de 90%. Il

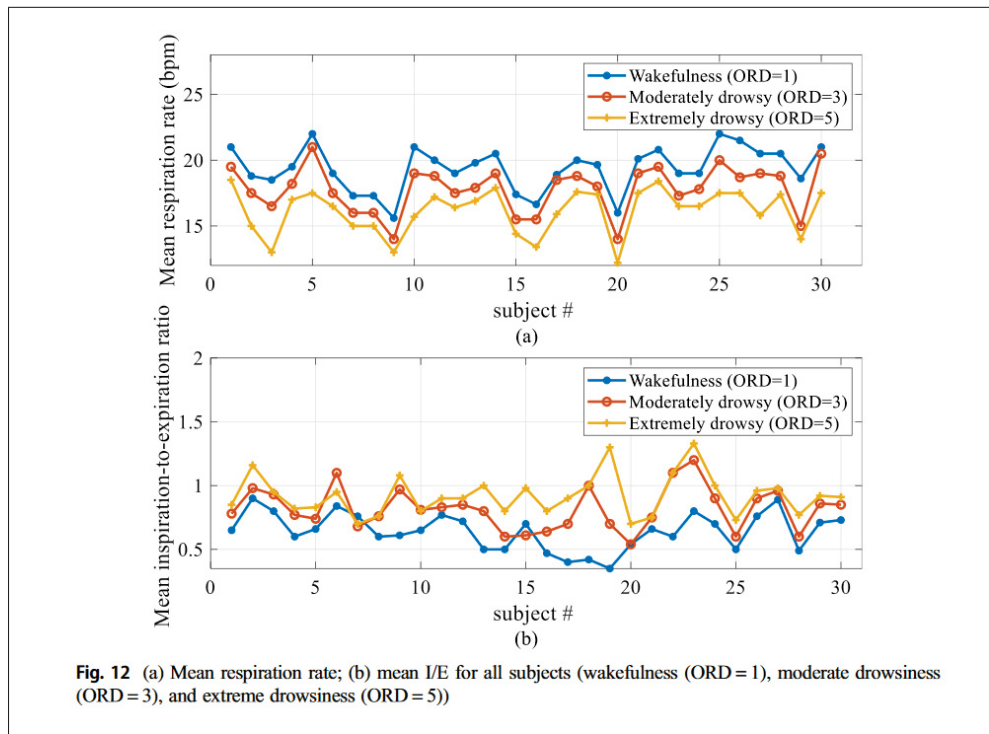


FIGURE 1.5 Graphique du rythme respiratoire moyen et du ratio inspiration-à-expiration entre différents stades de somnolence
Tirée de (Kiashari *et al.*, 2020, p. 13)

effectue aussi une étude de deux caractéristiques de la respiration, le rythme respiratoire et le ratio inspiration-expiration. Sur la figure 1.5, on remarque des différences entre l'état alerte et l'état somnolent. Le rythme respiratoire moyen varie de 19,6 respirations par minute (RPM) (alerte) à 16,5 rpm pour la somnolence extrême. Cette différence est par ailleurs constante à travers tous les patients de l'étude, ce qui est encourageant pour l'utilisation de la respiration.

Le tableau 1.2 présente la variabilité inter-états trouvée dans la littérature, où des études statistiques étaient disponibles. Les résultats concordent entre les différentes recherches : le

rythme respiratoire semble baisser en état de somnolence ou de méditation (Soni & Muniyandi, 2019), tandis que la variabilité respiratoire augmente. Malgré les résultats résumés dans le tableau 1.2, on trouve assez peu d'études effectuant des analyses statistiques des états de somnolence. La plupart publient uniquement des résultats de détection. Il pourrait donc être intéressant de publier nos statistiques concernant cet aspect lors de notre recherche.

TABLEAU 1.2 Statistiques de RSP en état d'éveil et de somnolence et leur différence

Référence	Statistique RSP Éveil	Statistique RSP Somnolence	Différence Éveil à Somnolent
(Soni & Muniyandi, 2019) Étude de la méditation	Mean breathing time, Median time, SDBB, SDABB, RMSSD increased	Mean BR decreased HF band increased VLF band increased	Mean breathing time +17.5% Median time +16.8% SDBB +24% SDABB +29% RMSSD +26% Mean BR -21% HF power +75% LFHF ratio +33%
(Kiashari, Nahvi, Homayounfard & Bakhoda, 2018)	Median RR SD 1.8 RPM Median mean RR 19 RPM	Median RR SD 2.5 RPM Median mean RR 15.5 RPM	0.7 RPM -3.5 RPM
(Kiashari <i>et al.</i> , 2020)	Median RR Mean 19.6 RPM Inspiration/expiration ratio 0.65	Median RR Mean 16.5 RPM Inspiration/expiration ratio 0.90	+0.25 RPM -3.1 RPM
(Perrotte, Bougard, Portron & Vercher, 2024)	N/A	N/A	-1.94 Mean RPM Temps expiration -144.38 ms Temps inspiration -245.28 ms SDBB +581.71 ms

Dans cette section, les caractéristiques du sommeil ont été abordées, et le lien entre le sommeil, la somnolence et le système cardio-respiratoire a été détaillé. La respiration semble être un bon indicateur de la somnolence et de l'activité du SNA. Les études ont montré que la variabilité respiratoire augmente et que le rythme respiratoire baisse lors de l'apparition d'états de somnolence.

Après avoir présenté la somnolence et ses effets, la prochaine section exposera les différentes techniques utilisées dans la littérature pour détecter la somnolence.

1.2 Détection de la somnolence en situation de conduite

La détection de la somnolence est un domaine de recherche très dynamique. Comme présenté en introduction, la somnolence au volant est responsable de milliards de dollars de dommages chaque année et constitue un facteur majeur de mortalité sur les routes. Dans cette section, une vue d'ensemble des approches discutées dans la littérature est proposée. Avant de détailler les

différentes méthodes de détection, il est essentiel de comprendre comment la somnolence est caractérisée par les chercheurs et quelles métriques sont utilisées pour classer ses différents niveaux.

1.2.1 Notation de la Somnolence

Comme expliqué précédemment, la somnolence est un état entre l'éveil et le stade N1 du sommeil. Lors de la transition, certains symptômes de la somnolence apparaissent plus fréquemment et sont visibles d'un point de vue extérieur (Albadawi *et al.*, 2022 ; El-Nabi, El-Shafai, El-Rabaie, Ramadan, Abd El-Samie & Mohsen, 2024 ; Suni & Rehman, 2022 ; Wierwille & Ellsworth, 1994) :

- Difficulté à maintenir une vitesse constante
- Fatigue oculaire
- Clignements
- Tendance à dériver de la voie
- Basculement de la tête
- Proximité excessive avec les véhicules précédents
- Besoin d'ouvrir la fenêtre
- Oublier de prendre un embranchement
- Sensation de fatigue et d'endormissement
- Bâillements répétés

Pour mesurer ces symptômes, plusieurs méthodes ont été développées. Une des plus populaires (Ebrahim Shaik, 2023) est la "Stanford Sleepiness Scale (SSS)" (Shahid, Wilkinson, Marcu & Shapiro, 2011b) c'est une échelle à sept niveaux utilisée pour l'autoévaluation de la somnolence. Une autre métrique est présentée par les travaux de Wierwille & Ellsworth (1994), c'est un système de notation à cinq niveaux destiné à des évaluateurs extérieurs. La figure 1.6 expose cette échelle telle que proposée initialement, cette dernière montre une importante

corrélation avec les variables comme le PERCLOS, et les notes sont constantes à travers les différents observateurs.

Pour finir, le **KSS** est la mesure la plus populaire et est cité dans la majorité des études et des revues scientifiques (Albadawi *et al.*, 2022 ; Ebrahim Shaik, 2023). Présentée par la figure 1.1 elle propose une mesure en 9 niveaux de la somnolence allant de 1 pour extrêmement alerte à 10 pour extrêmement somnolent. Cette mesure a l'avantage de donner une grande linéarité et d'être subjective, ce qui facilite sa mise en place. On verra que sa subjectivité peut aussi être un défaut, car elle dépend de chaque observateur et nécessite donc d'avoir plusieurs observateurs pour maximiser les sources de notation et améliorer la fiabilité.

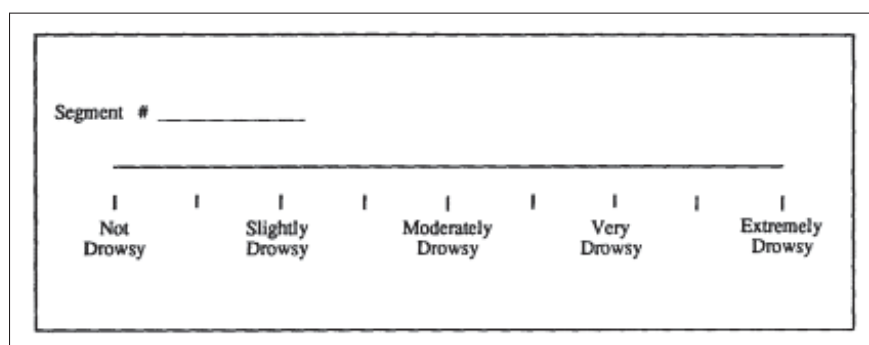


FIGURE 1.6 Échelle de notation de la somnolence de Ellsworth

Tirée de (Wierwille & Ellsworth, 1994, p. 3)

Outre ces échelles, les études utilisent parfois des barèmes plus simples, adaptées à leurs besoins. Certaines décident de diviser la somnolence en 3 états par exemple Kiashari *et al.* (2018), d'autres réduisent même cette notation à 2 niveaux binaires : éveil ou somnolence. Mais on pourrait imaginer une notation différente, par exemple, une mesure d'intensité de la transition vers la somnolence sans pour autant qualifier la personne de somnolente. On pourrait ainsi caractériser la tendance à devenir somnolent plutôt que la somnolence, car il est généralement trop tard pour les conducteurs lorsque la somnolence est détectée.

1.2.2 Le Perclos, une mesure très répandue

Le PERCLOS est défini comme le pourcentage de temps pendant lequel les yeux sont fermés à plus de 80 % sur une fenêtre de temps donnée (Walter W. Wierwille & L. A. Ellsworth, 1994). Plusieurs travaux ont prouvé qu'il a une forte corrélation avec les notations subjectives de la somnolence telles que le KSS (Albadawi *et al.*, 2022 ; Wierwille & Ellsworth, 1994 ; Zhou, Alsaid, Blommer, Curry, Swaminathan, Kochhar, Talamonti, Tijerina & Lei, 2020). Il fournit une indication de l'un des symptômes de la somnolence mentionnés plus haut : la fatigue des yeux ou la fréquence des clignements. C'est aujourd'hui une des mesures les plus répandues, pour plusieurs raisons. Premièrement, on trouve beaucoup de bases de données vidéos incluant le PERCLOS pour la détection de la somnolence (Ghoddosian, Galib & Athitsos, 2019 ; Massoz *et al.*, 2016 ; Nasri, Karrouchi, Snoussi, Kassmi & Messaoudi, 2022), et il est aussi très facilement mesurable à l'aide d'une caméra. Cela favorise donc fortement la recherche sur ce type de données.




FIGURE 1.7 Ratio d'ouverture des yeux
Tirée de (Mehta *et al.*, 2019, p. 3)

Il est possible de le détecter en utilisant le rapport d'ouverture de l'œil (Mehta *et al.*, 2019), qui est défini par le ratio de la hauteur sur la largeur des yeux par l'équation 1.1,

$$EAR = \frac{(|p_2 - p_6| + |p_3 - p_5|)}{2 * |p_1 - p_4|} \quad (1.1)$$

Où $p_1, p_2, p_3, p_4, p_5, p_6$ sont les positions de la figure 1.7. En utilisant un seuil, on peut ensuite définir si l'oeil est fermé ou non.

1.2.3 Protocole expérimental

Bien que les façons de qualifier la somnolence soient diverses et qu'elles ne convergent pas totalement, il semble y avoir un consensus concernant les autres paramètres expérimentaux. D'abord, les critères de sélection des participants seront abordés. Ensuite, cette section poursuivra avec une description des scénarios de conduite et des conditions expérimentales typiquement retrouvées dans la littérature.

Critères de sélection

L'âge n'est pas un paramètre qui est normalement contrôlé, ou bien très peu d'attention y est portée pour la majorité des travaux de la littérature sur la détection de la somnolence. Pourtant, il est connu que le rythme basal ainsi que d'autres caractéristiques des signaux physiologiques peuvent varier en fonction de l'âge (Ansari, Qaraqe, Charafeddine, Serpedin, Righetti & Qaraqe, 2023 ; Kaur, Kumar, Roy & Singh, 2017).

Typiquement, la parité des sexes est visée, mais il semble y avoir un léger biais envers le sexe masculin. Le nombre de participants peut varier d'aussi peu que 4 (Li & Chung, 2013) jusqu'à plus de 90 (Arefnezhad, Hamet, Eichberger, Frühwirth, Ischebeck, Koglbauer, Moser & Yousefi, 2022 ; Jacobé de Naurois, Bourdin, Stratulat, Diaz & Vercher, 2019). Dans l'ensemble des articles cités dans cette revue, la moyenne du nombre de participants se situe aux environs de 25. Généralement, les drogues, l'alcool et le café sont prohibés et il est demandé aux participants d'avoir une bonne santé et aucun problème de sommeil. Ceci ne s'applique évidemment pas aux travaux visant à évaluer la conduite en état d'ébriété ou bien ceux étudiant les troubles du sommeil (Das, Zhou & Lee, 2012 ; Fairclough & Graham, 1999). Il est connu depuis longtemps que la qualité de la conduite varie grandement d'un individu à l'autre et ceci peut rendre difficile la tâche de dissocier la somnolence de la conduite (Ingre, Akerstedt, Peters, Anund & Kecklund,

2006). C'est pour cette raison qu'il est communément exigé que les participants aient au moins un permis de conduire.

Il est courant que les chercheurs collectent des données qualitatives sur les habitudes de sommeil des participants. Par exemple, le Pittsburgh Sleep Quality Index (Buysse, Reynolds, Monk, Berman & Kupfer, 1989) est un questionnaire vastement utilisé dans la littérature du sommeil. C'est un outil intéressant pour valider l'éligibilité d'un participant pour l'expérience (Johns, 1991).

Scénario de conduite

Il semble y avoir un consensus général concernant la nécessité que le scénario de conduite soit monotone et régulier. Ceci peut être expliqué par les travaux de (Larue, Rakotonirainy & Pettitt, 2011), qui ont démontré à l'aide de l'EEG que la faible variabilité de la géométrie de la route et de l'environnement (voitures, arbres et bâtiments) augmentait considérablement l'hypovigilance du conducteur. Des résultats similaires ont été reproduits par (Körber, Cingel, Zimmermann & Bengler, 2015), qui a noté une augmentation du temps de réaction, de la fatigue et de l'errance mentale avec le temps. En vue de reproduire cette monotonie, les chercheurs optent souvent pour un scénario de conduite sur autoroute ou sur un circuit circulaire fermé (Fujiwara *et al.*, 2019; Vicente *et al.*, 2016).

1.2.4 Les systèmes de détection de la somnolence

Le domaine de la détection de la fatigue ou de la somnolence a connu une forte croissance ces dernières années (Albadawi *et al.*, 2022; Ramzan *et al.*, 2019). Avec la nouvelle norme européenne GSR2, on peut s'attendre à ce que cette tendance continue dans les années qui viennent. Cette tendance pourrait même traverser l'Atlantique avec de nouvelles législations possibles au Canada ou aux États-Unis.

Différentes études ont exploré différentes techniques pour détecter la somnolence; la figure 1.8 expose les différents types de mesures, telles que l'étude des mesures véhiculaires, comporte-

mentales ou encore physiologiques comme définis par Ramzan *et al.* (2019). Mais dans sa revue plus contemporaine, Albadawi *et al.* (2022) préfère diviser les types de mesure en 4 familles de manière plus exhaustive : par l'image, physiologique, véhiculaires et les hybrides (mélange des 3 précédentes).

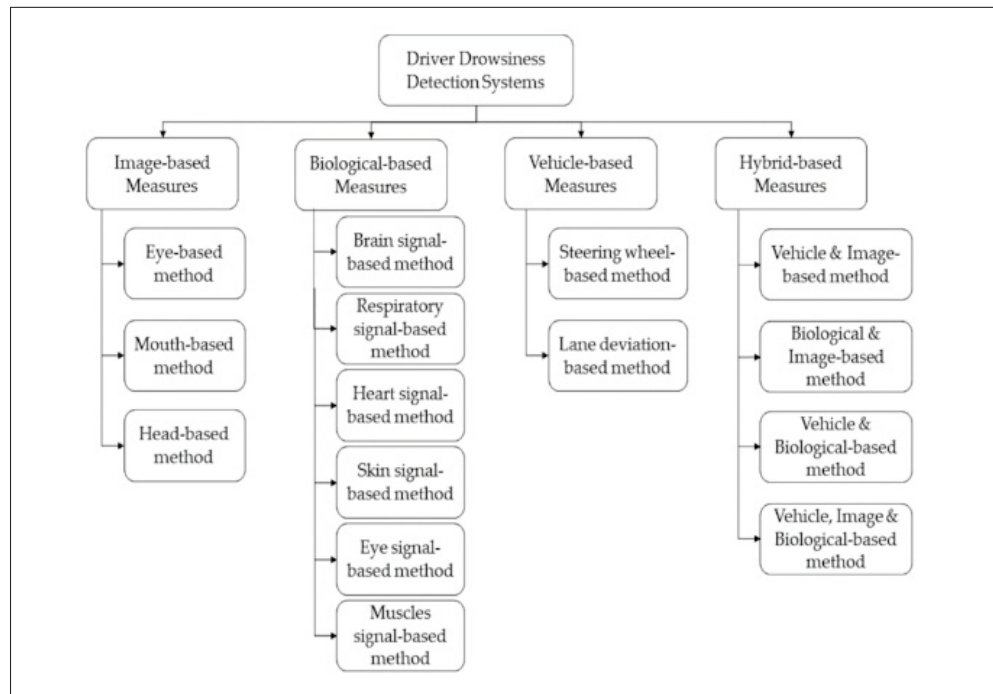


FIGURE 1.8 Famille des systèmes de détection de la somnolence
Tirée de (Albadawi *et al.*, 2022, p. 4)

La figure 1.9 récapitule les schémas fonctionnels de chaque système, ils commencent par collecter des données provenant de diverses sources, telles que des images, des signaux physiologiques, des signaux véhiculaires et des signaux hybrides. Ces données sont ensuite traitées pour extraire les caractéristiques pertinentes.

Après l'extraction des caractéristiques, le système procède à une transformation ou une réduction de la dimension pour simplifier l'ensemble de données, tout en conservant les informations essentielles. Les caractéristiques les plus pertinentes sont ensuite sélectionnées pour estimer le niveau de somnolence (Albadawi *et al.*, 2022).

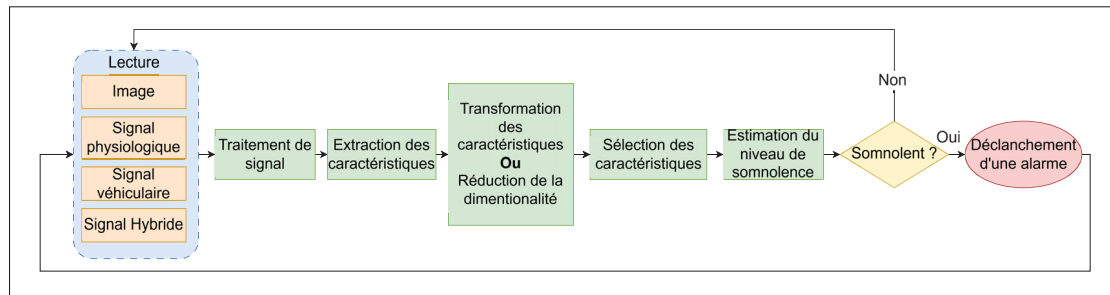


FIGURE 1.9 Schéma fonctionnel des systèmes de détection de la somnolence
Adaptée de (Albadawi *et al.*, 2022, p. 4)

En premier lieu, les familles de technologies déjà en fonction dans les voitures seront étudiées.

1.2.4.1 Détection par images

La détection par images, correspondant aux mesures comportementales, consiste à filmer le conducteur afin de détecter les différents symptômes visibles de la somnolence mentionnés plus haut.

Taux d'ouverture et clignements des yeux, bâillements

Les travaux de Nguyen, Chew & Demidenko (2015) proposent un algorithme mesurant la somnolence en observant l'état des yeux au cours du temps, et allume une alarme en fonction des limites définies pour l'algorithme. Cette étude met en évidence la baisse de leurs performances avec la baisse de la luminosité. Face au problème de luminosité Wijnands, Thompson, Nice, Aschwanden & Stevenson (2020) proposent, une méthode utilisant un CNN. L'algorithme choisit automatiquement les caractéristiques les plus importantes pour détecter la somnolence, ce qui le rend plus résistant à des événements extérieurs comme la luminosité ou le port de lunettes du conducteur. De leur côté, Albadawi, AlRedhaei & Takruri (2023) ont obtenu une performance impressionnante de 99 % avec un classificateur de type Random Forest sur la base de données NTHUDDD. Cette dernière propose un nombre conséquent de sujets (36) et 9 h de vidéo. Pour atteindre ces résultats, les auteurs ont exploité des caractéristiques extraites des yeux, de la

bouche et de la position de la tête afin de constituer leur vecteur d'entrée et une alarme est déclenché si un état de somnolence est détecté pendant assez longtemps.

Comme discuté dans différentes études comparatives Albadawi *et al.* (2022); Ramzan *et al.* (2019); S, M & S (2022), les mesures par l'image offrent l'avantage d'une intégration facile et peu coûteuse dans les véhicules; elles ne requièrent pas de mise en place spécifique concernant le conducteur. Cependant, ces mêmes études (Albadawi *et al.*, 2022; Ramzan *et al.*, 2019; S *et al.*, 2022) ont montré que les performances en situation réelle sont moins bonnes que celles en laboratoire pour différentes raisons, telles que la luminosité ambiante changeante, les erreurs de suivi facial ou encore le port de lunettes par les conducteurs.

1.2.4.2 Détection par mesures véhiculaires

La détection de la somnolence par mesure véhiculaire repose sur l'analyse des paramètres dynamiques du véhicule. Ces paramètres incluent :

- Angle du volant
- Déviation par rapport à la ligne de la route
- Distance avec le véhicule précédent
- Vitesse du véhicule

Ces mesures offrent des indices précieux sur l'état du conducteur, car les comportements de conduite ont tendance à changer lorsque la somnolence s'installe. Par exemple, un conducteur somnolent pourrait montrer des variations plus fréquentes et imprévisibles de l'angle du volant ou une déviation accrue par rapport à sa trajectoire normale.

La littérature indique que l'analyse de ces caractéristiques véhiculaires peut être utilisée avec succès pour identifier les états de somnolence. Forsman, Vila, Short, Mott & Van Dongen (2013) ont démontré que les variations dans ces mesures peuvent refléter les changements dans le

niveau de vigilance du conducteur, offrant ainsi un moyen prometteur de détection précoce de la somnolence.

Angle du volant et vitesse

Dans leurs travaux, Arefnezhad, Samiee, Eichberger & Nahvi (2019) proposent une méthode qui extrait des caractéristiques temporelles et fréquentielles de l'angle du volant et de la vitesse. Ils utilisent ensuite la logique floue pour sélectionner les caractéristiques les plus importantes, et enfin, effectuent la classification des états du conducteur à l'aide d'une machine à vecteurs de support (SVM). Ils parviennent à obtenir de très bons résultats avec une précision de 98,12 % sur leur propre base de données.

1.2.4.3 Détection par mesures physiologiques

Cette famille de détection englobe toutes les méthodes utilisant des signaux biologiques provenant du conducteur. Les méthodes peuvent être invasives, nécessitant une mise en place préalable des capteurs sur le patient, ou non-invasives, ne nécessitant pas de mise en place préalable. La littérature sur ce sujet est vaste et, avec le développement de nouveaux capteurs non-invasifs, elle continue d'être un sujet de recherche très populaire (Albadawi *et al.*, 2022 ; Němcová, Svozilová, Bucuházy, Smíšek, Mézl, Hesko, Belák, Bilík, Maxera, Seitzl, Dominik, Semela, Šucha & Kolář, 2021 ; Ramzan *et al.*, 2019 ; Sikander & Anwar, 2019). Les méthodes basées sur des données physiologiques sont par ailleurs reconnues pour offrir de meilleures performances que les autres familles (Ramzan *et al.*, 2019).

Détection par mesure EEG

Ces méthodes sont réputées pour offrir les meilleures performances (Nayak & Anilkumar, 2024), l'EEG étant la référence pour la plupart des travaux sur la somnolence. L'étude de Akbar & Igasaki (2019) propose une méthode de détection à 9 niveaux de somnolence (KSS) avec un casque EEG à 19 canaux. En extrayant des caractéristiques fréquentielles et temporelles, puis en les passant à un modèle de type "Recurrent Support Vector Regression", ils parviennent à obtenir une RMSE

de 0,15 sur l'estimation du niveau de somnolence KSS. Dans une recherche antérieure, Li, Lee & Chung (2015) ont développé un système avec un bandeau EEG connecté à une montre intelligente, puis, en utilisant un "support vector machine-based posterior probabilistic model" (SVMPPM), ils sont capables de détecter 91,92 % des épisodes de somnolence. Une étude plus récente, influente dans le domaine (Budak, Bajaj, Akbulut, Atila & Sengur, 2019), utilise un réseau de modèle "long-short-term-memory" (LSTM) auquel les chercheurs donnent les caractéristiques extraites du spectrogramme du signal EEG ainsi que la moyenne et déviation standard des sous-bandes de fréquence d'une décomposition en ondelettes. Leur système obtient une précision moyenne de 94,31 %, ce qui est supérieur à la majorité de la littérature. Une dernière étude (Fouad, 2023) propose de comparer de simples algorithmes d'apprentissage machine tel que le SVM, un "Random forest analysis" (RFA) et un "K-Nearest Neighbor". Avec une labellisation binaire basée sur une notation subjective, ils parviennent à obtenir un score impressionnant de 100 % de détection avec un simple KNN, ces études confirment le statut de l'EEG comme mesure la plus précise pour la détection de la somnolence.

Les mesures EEG permettent une détection avec une grande granularité des niveaux de somnolence et obtiennent de meilleures performances que n'importe quelle autre méthode dans la littérature. Cependant, ces techniques nécessitent l'utilisation d'électrodes EEG invasives, on imagine difficilement un conducteur utiliser un casque EEG pour ses trajets quotidiens.

Détection par mesure ECG

La variabilité cardiaque est reconnue depuis longtemps comme un marqueur important de l'activité du système nerveux autonome, qui est lui-même en lien avec la somnolence et le sommeil (Electrophysiology, 1996). C'est donc tout naturellement que la littérature s'est essayée à détecter la somnolence à l'aide des signaux ECG. Fujiwara *et al.* (2019) propose un algorithme basé sur la détection des anomalies pour détecter la somnolence à l'aide des caractéristiques extraites de la variabilité cardiaque, leurs résultats sont validés à l'aide des signaux EEG annotés par un expert. Cette autre étude de Kunder, Sofra & Riener (2020) expose une nouvelle méthode utilisant un bracelet PPG et un capteur ECG pour extraire différentes données du

domaine fréquentiel et temporel, ils utilisent des fenêtres de 5 minutes pour établir les vecteurs de données. Ils définissent ensuite la labellisation des données selon la notation d'observateurs extérieurs pour entraîner leur algorithme de détection.

La littérature utilisant le signal ECG pour détecter le sommeil ou la somnolence est nombreuse et les performances sont bonnes, cependant les méthodes d'acquisition sont pour la plupart sensibles au bruit et voit donc leurs performances réduites pour un usage en situation réelle.

Détection par mesure de la respiration

La respiration peut, comme l'ECG, refléter l'activité du système autonome. De plus, l'ECG et la respiration sont liés par certains phénomènes tels que l'arythmie respiratoire sinusoïdale (ASR) (Berntson, Cacioppo & Quigley, 1993).

Dans cette série d'études (Kiashari *et al.*, 2018,2), les chercheurs proposent une approche très intéressante. Ils parviennent à extraire le rythme respiratoire à partir d'une caméra thermique pour ensuite détecter la somnolence à l'aide d'un classificateur SVM. Ils atteignent de très bonnes performances (90%) en utilisant uniquement quatre caractéristiques du signal respiratoire : le RR moyen, la déviation standard du RR, le ratio moyen de l'inspiration/expiration, et enfin sa déviation standard.

L'étude de Guede-Fernández *et al.* (2019) développe une méthode différente en utilisant des ceintures respiratoires pour capter la respiration. Elle caractérise ensuite la résistance au sommeil des conducteurs à l'aide d'un indice basé sur la variabilité inter-respiratoire ; cette dernière semble augmenter lors des phases de résistance. Cependant, les auteurs rapportent que cette métrique, étant influencée par les mouvements ou par la parole, ne peut fonctionner que pendant l'absence de ces deux phénomènes.

Ici (Tateno *et al.*, 2018), les auteurs proposent d'extraire la respiration du signal ECG pour détecter la respiration. Lors de leurs tests, les auteurs remarquent que le rythme respiratoire tend à baisser lors des moments de somnolence. Ils développent donc un indice de somnolence basé sur la pente de descente de la respiration. Ces résultats sont intéressants car ils confirment ceux

d'autres études (Igasaki, Nagasawa, Murayama & Hu, 2015 ; Kiashari *et al.*, 2018,2) concernant la tendance du rythme respiratoire à baisser lors des épisodes de somnolence. Cependant, les résultats de détection sont à relativiser car l'étude manque de participants et de données. Une autre étude mélange les données EEG et respiratoires (Lee, Lee & Chung, 2014). Les chercheurs dérivent des caractéristiques des données respiratoires et EEG, et gardent les 16 plus importantes en utilisant la méthode d'information mutuelle. Une métrique respiratoire figure parmi celles-ci : la régularité respiratoire. Ils relèvent que la régularité chute considérablement lors des épisodes de somnolence, ce qui rejoint encore une fois les résultats de Guede-Fernández *et al.* (2019). Siddiqui, Saleem, Brown, Bademci, Lee, Rustam & Dudley (2021) utilise une approche moins invasive que Lee *et al.* (2014). En utilisant un radar pour détecter la respiration, ils atteignent néanmoins une précision de 87% à l'aide d'un classificateur SVM. Pour répondre

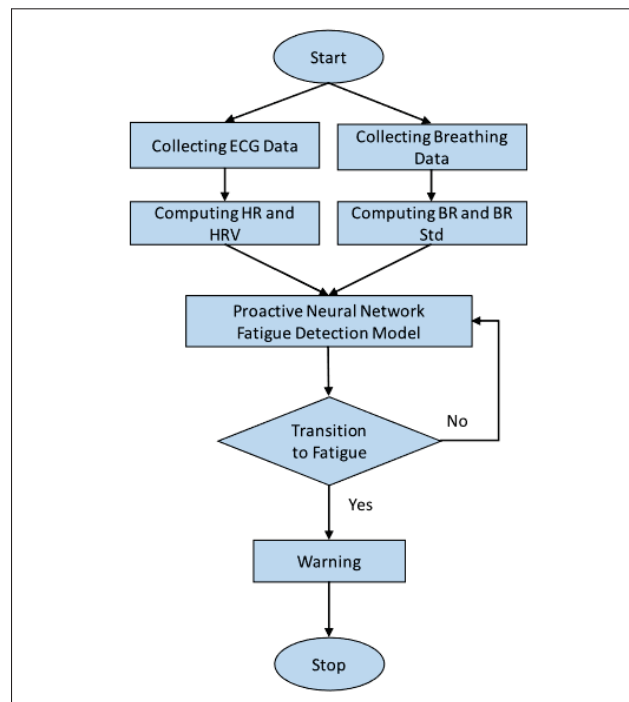


FIGURE 1.10 Méthode de détection par la respiration et ECG

Tirée de (Zhou *et al.*, 2020, p. 4)

à la subjectivité de la mesure KSS, certains chercheurs ont exploré une autre approche. La figure 1.10 est un extrait d'un article de recherche Zhou *et al.* (2020) illustrant leur méthode

pour détecter la somnolence en utilisant le PERCLOS comme base de vérité pour entraîner leur modèle. Pour simplifier, ils entraînent leur modèle à estimer le PERCLOS à partir de leurs données cardiaques et respiratoires et définissent une variation drastique du PERCLOS comme étant un marqueur de changement physiologique vers la somnolence.

Pour résumer, la respiration est une mesure physiologique populaire dans la littérature pour plusieurs raisons. Il existe de nombreuses méthodes non invasives pour la détecter Kiashari *et al.* (2018,2) ; Siddiqui *et al.* (2021). Elle est également considérée comme une caractéristique importante pour la détection de la somnolence Lee *et al.* (2014), même en comparaison avec la référence dans le domaine, l'EEG. De plus, certaines caractéristiques comme le RR moyen et sa déviation standard, le ratio inspiration/expiration moyen et sa déviation standard, ainsi que la régularité respiratoire montrent une grande variabilité entre les états d'éveil et de somnolence. La variabilité inter-patients des mesures semble importante dans les travaux de Kiashari *et al.* (2018,2) et est liée à certains facteurs comportementaux, tels que le PERCLOS (Zhou *et al.*, 2020).

En examinant les différentes revues (Albadawi *et al.*, 2022 ; Němcová *et al.*, 2021 ; Ramzan *et al.*, 2019) sur la détection de la somnolence, on constate une sous-représentation des méthodes utilisant le signal respiratoire comparé aux autres signaux physiologiques. L'adoption d'une nouvelle méthode dans ce domaine pourrait être bénéfique et renforcer la crédibilité de cette mesure pour la détection de la somnolence.

1.2.4.4 Détection par mesures hybrides

Certaines études proposent d'utiliser les différentes méthodes mentionnées précédemment en les combinant dans le but d'améliorer la performance de l'estimation de la somnolence.

Les trois familles de mesures

L'une des études les plus influentes dans le domaine est celle de Jacobé de Naurois *et al.* (2019). Les trois familles de mesures (HR, respiration, comportementale, véhiculaire) sont utilisées pour

prédire la somnolence à l'avance et parviennent à obtenir une performance de prédiction de $4,18 \pm 1,17$ min. Les auteurs notent que le modèle était moins efficace lorsqu'il utilisait uniquement des mesures véhiculaires. Cette étude confirme deux choses : la somnolence peut être prédite et les mesures physiologiques et comportementales semblent être de meilleurs prédicteurs.

Mesures physiologiques et posturales du conducteur

Ces travaux très récents de Perrotte *et al.* (2024) essaient de détecter la somnolence dans les voitures semi-autonomes en utilisant les données cardiaques, respiratoires, et posturales. Ils proposent une étude statistique des valeurs lors des différents états d'éveil. La variabilité respiratoire semble être encore fortement impactée par la somnolence et particulièrement le temps d'inspiration.

L'approche par mesures hybrides pour la détection de la somnolence montre un potentiel prometteur en combinant plusieurs types de données pour améliorer la précision des prédictions. Les études présentées illustrent l'efficacité accrue de l'utilisation conjointe des mesures physiologiques, comportementales et véhiculaires. La recherche de Jacobé de Naurois *et al.* (2019) démontre que les mesures physiologiques et comportementales surpassent les données véhiculaires seules, suggérant que la somnolence est mieux prédite lorsque les indicateurs physiologiques sont utilisés. De plus, l'étude récente de Perrotte *et al.* (2024) sur les voitures semi-autonomes met en évidence l'importance des données respiratoires et posturales pour détecter la somnolence, avec une attention particulière portée à la variabilité respiratoire.

1.2.4.5 Remarques générales

Cette revue, bien que non exhaustive, mais néanmoins instructive, a permis de donner un aperçu des possibilités de détection de la somnolence. Dans le tableau 1.3, on remarque que les modèles de classification classiques, tels que le SVM, sont très populaires dans la littérature, en raison du manque de bases de données physiologiques pour la détection de la somnolence. La respiration semble être une mesure populaire pour les systèmes hybrides (Lee *et al.*, 2014 ; Perrotte *et al.*, 2024 ; Zhou *et al.*, 2020), car elle permet d'améliorer leurs performances avec une mesure

potentiellement peu invasive. On imagine facilement un système multimodal impliquant des mesures physiologiques, véhiculaires et comportementales, dans lequel chacun des types de mesure pourrait assurer une certaine précision de détection lorsque les autres sont inutilisables. Avec l'essor de l'apprentissage profond, on constate une augmentation significative des méthodes de détection utilisant cette technologie. Malgré, cela Ebrahim Shaik (2023) relève que la plupart des études disposent de trop peu de données pour correctement généraliser à de nouveaux sujets. Il sera donc important à l'avenir de créer des bases de données permettant la généralisation inter-sujets de ces techniques, qui pourraient s'avérer plus précises.

Plus largement, les mesures ECG et respiratoires occupent une place prépondérante dans la littérature, souvent combinées entre elles ou avec d'autres mesures telles que le PERCLOS, la posture ou encore les données véhiculaires pour améliorer la précision. Ces mesures continueront vraisemblablement d'être au centre des études futures visant à détecter la somnolence. De plus, l'amélioration des techniques semble pousser les chercheurs vers la prédiction de la somnolence plutôt que sa simple détection.

TABLEAU 1.3 Résumé des études sur la détection de la somnolence

Famille de détection	Mesures utilisées	Caractéristiques utilisées	Méthode de classification	Référence
Images	Comportementales	État des yeux	N/A	(Nguyen <i>et al.</i> , 2015)
		Features automatiques	CNN	(Wijnands <i>et al.</i> , 2020)
		Ouverture de la bouche et des yeux, position de la tête	Random Forest	(Albadawi <i>et al.</i> , 2023)
Véhiculaire	Véhiculaire	Paramètres dynamiques du véhicule	N/A	(Forsman <i>et al.</i> , 2013)
		Déviations de la ligne	SVM, Réseau de neurones	(Ma, Murphey & Zhao, 2015)
		Angle du volant, vitesse	SVM	(Arefnezhad <i>et al.</i> , 2019)
Physiologiques	EEG	N/A	SVMPPM	(Li <i>et al.</i> , 2015)
		Fréquentielles et temporelles	Recurrent Support Vector Regression	(Akbar & Iqbal, 2019)
		Spectrogramme, moyenne et déviation standard	LSTM	(Budak <i>et al.</i> , 2019)
	ECG, PPG	Entropie	SVM, KNN, Random Forest	(Fouad, 2023)
		Variabilité cardiaque	Détection d'anomalies	(Fujiwara <i>et al.</i> , 2019)
		Fréquentielles et temporelles	Random Forest, KNN, SVM	(Kundinger <i>et al.</i> , 2020)
	EEG, Respiration	Régularité respiratoire	Logique floue, SVM	(Lee <i>et al.</i> , 2014)
		RR moyen, déviation standard	SVM	(Kiasari <i>et al.</i> , 2018)
		Pente de descente de la respiration	Indice + seuil	(Tateno <i>et al.</i> , 2018)
	ECG, Respiration	Variabilité et rythme cardio-respiratoire	NN estimant le PERCLOS	(Zhou <i>et al.</i> , 2020)
		Variabilité inter-respiratoire	Indice + seuil	(Guede-Fernández <i>et al.</i> , 2019)
		RR moyen, déviation standard	SVM	(Kiasari <i>et al.</i> , 2020)
Hybrides	HR, Respiration, Comportementales, Véhiculaire	N/A	SVM	(Siddiqui <i>et al.</i> , 2021)
		RR, ECG (fréquentielles, temporelles), déviation de ligne, angle du volant	Réseaux de neurones	(Jacobs de Naurois <i>et al.</i> , 2019)
		Variabilité respiratoire, ECG (fréquentielles, temporelles), surface de contact du siège	N/A	(Perrotte <i>et al.</i> , 2024)

1.3 Détection de la respiration

La détection de la respiration consiste à numériser un signal généré par le mouvement de respiration du corps. Il existe de nombreuses méthodes pour cela, mais on peut les classer en deux catégories distinctes : invasives et non invasives. Les méthodes non invasives sont définies par Cousins, Blencowe & Blazeby (2019) comme étant : "Une procédure invasive consiste à accéder délibérément au corps humain par une incision, une ponction percutanée ou via un orifice naturel, en utilisant des instruments tels que des endoscopes, cathéters, scalpels, ciseaux, dispositifs et tubes." Pour adapter cette définition à notre contexte, les méthodes de captation invasives seront définies comme suit : « Méthodes nécessitant un contact direct avec la peau ou une intervention préalable de la part du patient pour la mise en place des capteurs. »

Une vue d'ensemble des techniques de la littérature pour acquérir la respiration sera présentée, ensuite les méthodes inductives seront étudiées pour en avoir une compréhension détaillée.

1.3.1 Les méthodes existantes

Cette section présente une vue d'ensemble des techniques d'acquisition de la respiration. Les méthodes peuvent être plus moins invasives. En général, l'invasivité permet d'améliorer la précisions et la fiabilité des données au détriments du confort de l'utilisateur. Les méthodes non-invasives répondent au problèmes suivant : comment détecter la respiration sans nécessiter d'action de la part de l'utilisateur final ? Ces dernières années, la littérature semble s'intéresser davantage aux techniques de détection permettant une intégration facile dans les usages quotidiens.

1.3.1.1 Spirométrie

La spirométrie est la méthode la plus courante dans le milieu médical pour effectuer des tests respiratoires (Lamb, Theodore & Bhutta, 2024). Elle est reconnue comme la référence pour étudier l'activité pulmonaire d'un patient. Cependant, c'est aussi l'une des plus invasives, car elle nécessite généralement de porter un masque sur la bouche. Alors que la spirométrie est

couramment utilisée en milieu médical, des méthodes moins invasives, comme les ceintures respiratoires, offrent des alternatives pratiques pour la détection de la respiration

1.3.1.2 La ceinture respiratoire

Les ceintures respiratoires, bien qu'invasives, offrent une méthode largement adoptée dans le domaine commercial en raison de leur facilité d'utilisation et de leur précision. Les plus simples utilisent un capteur basé sur une jauge de déformation reliée à la ceinture. Les jauges de déformation sont des capteurs qui mesurent la force exercée sur un matériau, permettant ainsi de détecter les variations de respiration. Lors du mouvement de respiration, l'effort thoracique étire la sangle, générant une force sur le capteur. Cette force est ensuite numérisée grâce au changement de résistance de la jauge de déformation. C'est par exemple ce qu'utilise la compagnie Biopac pour leur capteur de respiration, et c'est d'ailleurs cette ceinture qui est utilisée comme référence pour nos tests de somnolence. Les jauges de déformation peuvent utiliser différentes technologies, comme la fibre optique (Babchenko, Khanokh, Shomer & Nitzan, 1999), mais le principe de fonctionnement reste le même. De la même manière, un accéléromètre peut être attaché à une ceinture respiratoire pour détecter les mouvements thoraciques. Cette solution est facilement accessible et utilise des composants commerciaux faciles d'accès. Dans leurs recherches (Yoon, Noh, Kwon, Kim & Yoon, 2014), les données d'un accéléromètre et d'un gyroscope attachés à une ceinture autour du torse sont fusionnées avec un filtre de Kalman pour obtenir le rythme respiratoire. En 2014, des chercheurs proposaient d'utiliser des accéléromètres pour détecter la respiration dans le but de réduire les artefacts de mouvement en imagerie nucléaire (Jafari Tadi, Koivisto, Pänkäälä & Paasio, 2014).

1.3.1.3 Électrodes de contact

Les électrodes de contact englobent plusieurs types d'électrodes ; les principales sont celles ECG. La littérature explore depuis longtemps la possibilité d'estimer la respiration à partir des signaux ECG. Il est reconnu depuis longtemps que les signaux ECG sont modulés par la respiration (Charlton, Birrenkott, Bonnici, Pimentel, Johnson, Alastruey, Tarassenko, Watkinson,

Beale & Clifton, 2018), comme montré sur la figure 1.11. De nombreuses études ont obtenu avec précision le signal de respiration, comme rapporté dans la revue de Charlton *et al.* (2018).

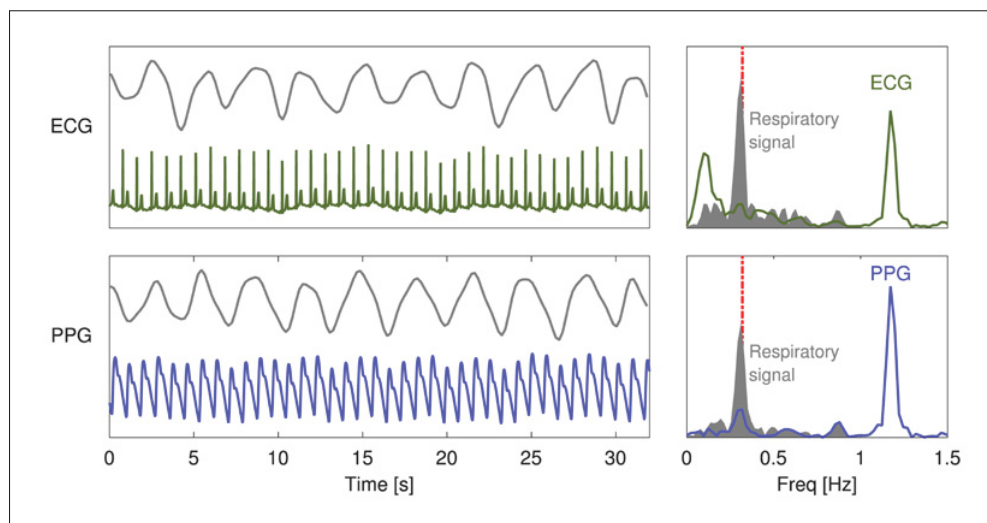


FIGURE 1.11 Modulation de l'ECG et du PPG par la respiration
Tirée de (Charlton *et al.*, 2018, p. 34)

1.3.1.4 Appareils portables (en anglais "wearables")

Les méthodes utilisant des accéléromètres peuvent être non-invasives. C'est l'objectif des nouvelles technologies de la famille des "wearables" : proposer une technologie intégrée dans un objet du quotidien, portable pour l'utilisateur. Wicaksono, Tucker, Sun, Guerrero, Liu, Woo, Pence & Dagdeviren (2020) développe un accéléromètre intégré dans un tissu inclus dans un t-shirt intelligent. Concernant l'estimation de la respiration en situation de conduite, Warnecke, Lasenby & Deserno (2023) ont développé un système utilisant des accéléromètres intégrés à la ceinture. En fusionnant leurs données avec celles d'un capteur piézoélectrique et d'une caméra, ils parviennent à détecter la respiration 60 % du temps lors de leurs essais. Les capteurs PPG peuvent eux aussi être considérés comme des dispositifs portables, comme les montres connectées par exemple. Le signal de respiration peut ensuite être démodulé du signal PPG (Charlton *et al.*, 2018). Le principal problème associé à ces technologies provient des artefacts

de mouvement qui détériorent la qualité des signaux, les rendant parfois inutilisables lorsque les routes sont trop accidentées ou que le conducteur est trop agité, par exemple.

1.3.1.5 Microphones

Toujours dans la lignée des technologies "wearables", les chercheurs Martin & Voix (2018) proposent une méthode de détection de la respiration par microphone intra-auriculaire. L'étude rapporte une erreur absolue de 2,7 cycles respiratoires par minute (CPM). Bien que plus contraignant qu'un simple accéléromètre sur la ceinture, cette technologie offre un avantage potentiel en réduisant l'impact des artefacts de mouvement, ce qui est crucial pour les applications en milieu mobile. Xu, Yu, Chen, Zhu, Kong & Li (2019) ont réduit l'intrusivité du microphone en utilisant simplement le micro d'un téléphone intelligent, couplé à un modèle d'intelligence artificielle de type Réseaux Antagonistes Génératifs (GAN) pour générer une estimation du signal respiratoire. Cette méthode présente l'avantage d'être totalement non intrusive. Cependant, elle est affectée par des facteurs tels que l'emplacement du téléphone, les conditions de bruit ambiant et les vibrations de la route.

1.3.1.6 Radars

Comme le microphone d'un téléphone (Xu *et al.*, 2019), les radars sont des approches non invasives facilement intégrables dans les voitures, comme les caméras. Hong, Zhang, Gu, Li, Zhou & Zhu (2018) sont capables d'extraire la respiration ainsi que d'autres mesures physiologiques à l'aide d'un radar Doppler. Ils parviennent ensuite à effectuer une classification des stades du sommeil lors de tests polysomnographiques. Les travaux les plus récents permettent même de détecter la respiration à travers les murs à l'aide de radars à bande ultralarge Uzunidis, Kasnesis, Papadopoulos, Paliodimos, Patrikakis & Mitilineos (2024). Ces méthodes permettent une intégration non invasive ; cependant, elles sont dépendantes de la position du conducteur et, encore une fois, des vibrations induites par la route.

1.3.1.7 Caméra thermique

Tout aussi facile à intégrer dans une voiture, la caméra thermique peut être utilisée pour détecter la respiration. Kiashari *et al.* (2020) proposent même de détecter la somnolence en utilisant le signal de respiration extrait des images thermiques.

1.3.1.8 Électrodes sans contact

Les électrodes sans contact sont caractérisées par leur capacité à détecter des signaux sans contact direct avec la peau du conducteur. Ces dernières années, plusieurs études (Lessard-Tremblay, Weeks, Morelli, Cowan, Gagnon & Zednik, 2020; Serateyn, Vullings, Meftah & Bergmans, 2015) ont développé de nouvelles électrodes ECG capacitatives sans contact. Comme mentionné précédemment, il est possible d'estimer la respiration à partir de cet ECG (Charlton *et al.*, 2018). Une autre méthode non invasive, mais qui mérite une attention particulière en raison de son potentiel élevé et de son utilisation dans notre projet, est la détection inductive. Cette technique sera explorée en détail dans la section suivante, où son fonctionnement, ses avantages et ses applications spécifiques dans le cadre de ce projet seront discutés.

1.3.2 La détection inductive

La détection inductive représente une méthode prometteuse et non invasive pour surveiller le rythme respiratoire. Contrairement aux techniques invasives telles que la spirométrie ou les ceintures, la détection inductive repose sur la mesure des changements dans les champs électromagnétiques autour du corps, ce qui en fait une solution moins contraignante et plus confortable pour l'utilisateur.

Cette technique utilise généralement des capteurs inductifs qui détectent les variations causées par les mouvements respiratoires sans nécessiter de contact direct avec la peau. En raison de sa sensibilité et de sa capacité à fonctionner sans contact physique, la détection inductive est particulièrement adaptée aux applications de surveillance continue, telles que les systèmes de sécurité des conducteurs dans les véhicules ou les dispositifs de santé connectée. Les

études récentes ont montré que les systèmes de détection inductive peuvent offrir une précision comparable à celle des méthodes traditionnelles tout en minimisant les perturbations pour l'utilisateur (Leicht, Walter, Mathissen, Antink, Teichmann & Leonhardt, 2022). Néanmoins, étant portable, elle n'en reste pas moins affectée par les artefacts de mouvements et les mouvements relatifs de la cible par rapport aux capteurs (Leicht, Vetter, Leonhardt & Teichmann, 2017 ; Leicht *et al.*, 2022 ; Walter, Eilebrecht, Wartzek & Leonhardt, 2011).

Dans les sections suivantes, le principe de fonctionnement de la méthode inductive sera présenté, ainsi que les différentes options dans sa réalisation.

1.3.2.1 Détection de la respiration par courants de Foucault induits

Plusieurs études ont démontré la possibilité d'utiliser les courants de Foucault pour mesurer l'activité respiratoire sans contact (Cho, Yang, Lee, Lee & Lee, 2022 ; Richer & Adler, 2005). Un premier champ magnétique est généré lorsqu'un courant alternatif traverse une bobine, comme illustré dans l'équation 1.2. Si cette bobine est placée près d'un objet conducteur (comme le corps humain), elle génère un champ électrique à l'intérieur de celui-ci (Cho *et al.*, 2022).

$$\nabla \times E = -\frac{\partial B}{\partial t} \quad (1.2)$$

Dans cette équation, B représente le champ magnétique généré par l'inductance, E est le champ électrique, et ∇ est l'opérateur rotationnel, qui décrit la rotation du champ électrique.

Les courants de Foucault sont définis par la conductivité du milieu et l'intensité du champ électrique dans l'objet, comme le montre l'équation 1.3 (Cho *et al.*, 2022).

$$\mathbf{J} = \sigma \mathbf{E} \quad (1.3)$$

Dans cette équation, J représente la densité de courant de Foucault, σ est la conductivité électrique du matériau (dans ce cas, les tissus biologiques), et E est le champ électrique. La densité de courant est directement proportionnelle à la conductivité du matériau et à l'intensité du champ électrique. Ces courants génèrent à leur tour un champ magnétique secondaire, comme illustré par l'équation 1.4 (Cho *et al.*, 2022), et montré sur la figure 1.12.

$$\nabla \times \mathbf{H} = \mathbf{J} + \frac{\partial}{\partial t} \sigma \mathbf{E} \quad (1.4)$$

Dans cette équation, H est le champ magnétique secondaire, J est la densité de courant de Foucault circulant dans les tissus biologiques, et σ représente la conductivité des tissus biologiques. Sachant que la conductivité des tissus biologiques change en fonction de la respiration au cours du temps, elle crée des perturbations dans le champ magnétique secondaire H , modélisées par $\frac{\partial}{\partial t} \sigma \mathbf{E}$ (Cho *et al.*, 2022). Les perturbations du champ secondaire s'opposent au champ

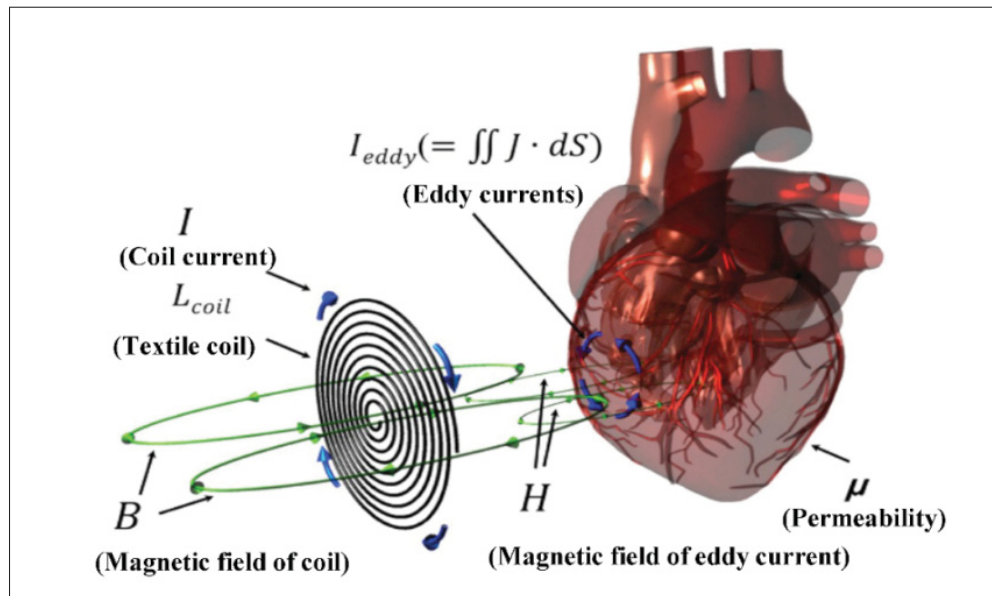


FIGURE 1.12 Induction de courants de Foucault dans les tissus biologiques pour détecter la respiration
Tirée de (Cho *et al.*, 2022, p. 5)

primaire, ce qui se traduit par un changement dans l'induction du circuit oscillant, provoquant

une variation de fréquence. On peut résumer cette interaction décrite par Cho *et al.* (2022) comme celle de deux inductances interagissant l'une avec l'autre, comme illustré dans la figure 1.13. L'équation de l'inductance mutuelle est donnée par :

$$v_1 = L_{\text{oscillateur}} \frac{di_1}{dt} - M \frac{di_2}{dt} \quad (1.5)$$

où $L_{\text{oscillateur}}$ représente l'inductance de l'oscillateur, M est l'inductance mutuelle entre les deux circuits, et $\frac{di_1}{dt}$ et $\frac{di_2}{dt}$ sont les taux de changement des courants dans les bobines respectives.

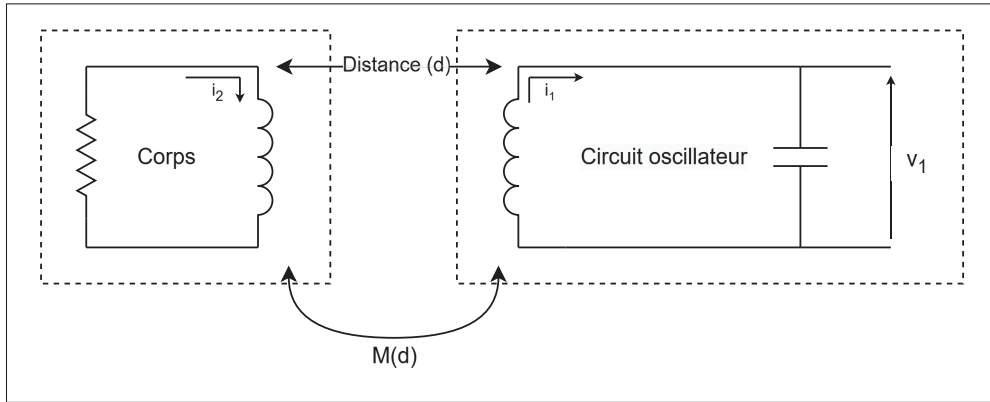


FIGURE 1.13 Modèle électrique de l'interaction entre le corps et le circuit L-C

Lorsque connectée à un condensateur en parallèle pour créer un circuit oscillant, la variation d'inductance causée par les variations de distance modifie la fréquence du circuit, comme modélisé par l'équation 1.6 adaptée de la documentation (Texas Instruments, 2024) du LDC1612 :

$$L(d) = L_{\text{oscillateur}} - M(d) = \frac{1}{(2\pi \cdot f_{\text{capteur}})^2 \cdot C} \quad (1.6)$$

où $L(d)$ est l'inductance en fonction de la distance d , $L_{\text{oscillateur}}$ est l'inductance initiale sans influence externe, $M(d)$ est l'inductance mutuelle qui varie avec la distance, f_{capteur} est la fréquence du capteur, et C est la capacité du condensateur.

Plus généralement, selon l'étude concernant la déformation de bobine imprimée sur papier de Zhu, Jia, Li, Zhou, Chen, Liu & Yang (2022), toutes modifications physiques sur la bobine se

répercuteront sur sa valeur d'inductance, notamment les légères courbures provoquées par les mouvements thoraciques du conducteur. La fréquence d'oscillation du circuit est définie par l'équation 1.7.

$$f_{\text{capteur}} = \frac{1}{2\pi\sqrt{LC}} \quad (1.7)$$

La valeur de l'inductance étant influencée par les perturbations du champ secondaire, les mouvements respiratoires, et dans une moindre mesure les mouvements cardiaques (Cho *et al.*, 2022), se reflètent dans les variations de fréquence du capteur. Le principe de détection ayant été décrit, la section suivante présentera comment la littérature met en application ce dernier.

1.3.2.2 Méthodes d'acquisition

Plusieurs études ont développé des circuits d'acquisition inductifs (Brezulianu, Geman, Zbancioc, Hagan, Aghion, Hemanth & Son, 2019 ; Cho *et al.*, 2022 ; Gi, Lee, Koo, Khang, Kim, Kang, Lee & Lee, 2015 ; Koo, Lee, Gi, Khang, Lee, Lee, Lim, Park & Lee, 2014 ; Leicht *et al.*, 2017,2 ; Richer & Adler, 2005 ; Walter *et al.*, 2011) dans le but de détecter la respiration ou le rythme cardiaque.

On trouve deux approches pour le circuit dans la littérature :

- Conversion de la fréquence d'oscillation du circuit oscillateur en tension avec un Phase-Locked Loop (PLL) (Cho *et al.*, 2022), suivie de la numérisation avec un convertisseur analogique-numérique (ADC).
- Détection de la fréquence de l'oscillateur à l'aide d'un compteur de fréquence numérique (Brezulianu *et al.*, 2019 ; Gi *et al.*, 2015 ; Leicht *et al.*, 2017,2 ; Richer & Adler, 2005 ; Walter *et al.*, 2011).

Sur la figure 1.14, les deux méthodes présentent les mêmes principaux blocs fonctionnels : une inductance intégrée à un circuit oscillateur génère les champs alternatifs décrits dans la section précédente. Ensuite, un composant mesure les variations de fréquence du circuit, ce qui peut

être accompli par un compteur de fréquence ou un PLL. Enfin, la mesure est numérisée pour extraire le signal de respiration.

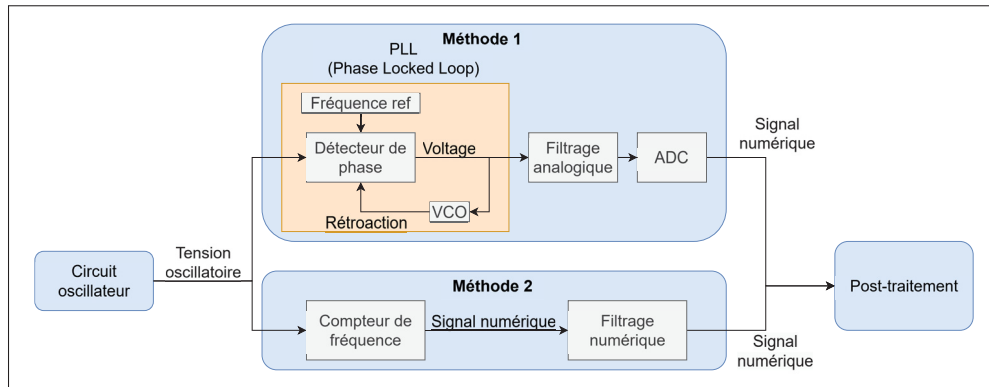


FIGURE 1.14 Schéma fonctionnel des circuits d'acquisition inductifs, présentant les deux méthodes proposées dans la littérature
Adaptée de (Cho *et al.*, 2022, p. 7)

Les circuits intégrant un PLL ont l'avantage de produire un signal analogique permettant un filtrage avant le post-traitement, ce qui permet d'obtenir une fréquence d'échantillonnage beaucoup plus élevée, contrairement aux circuits utilisant un compteur de fréquence.

Il existe des composants commerciaux pour les différentes parties du circuit. Pour le PLL, (Koo *et al.*, 2014) utilisent le PLL CD74HC7046A de Texas Instruments, pour suivre la fréquence générée par un oscillateur de Colpitts. Concernant le compteur de fréquence, il peut être réalisé avec un simple microcontrôleur (MCU) (Walter *et al.*, 2011).

L'étude de Brezulianu *et al.* (2019) utilise le circuit intégré LDC1614, qui est un numériseur d'inductance. Ce composant a l'avantage de pouvoir s'adapter à des plages de fréquence allant de 1 kHz à 10 MHz, il est donc capable de gérer différentes valeurs d'inductance sans besoin de créer un nouveau circuit oscillateur. Malgré sa fréquence d'échantillonnage plus basse qu'un ADC, il offre une résolution de 28 bits, ce qui le rend apte à détecter de très petites variations de fréquence. De plus, l'une des versions propose des acquisitions en parallèle sur 4 canaux, faisant de ce circuit une option viable pour le développement d'un système multicanaux.

Remarques

Toutes les méthodes sont viables pour détecter la respiration, comme les différentes études le prouvent. Cependant, certaines options peuvent être plus intéressantes selon l'application désirée. Le PLL est la solution à privilégier si l'on veut détecter le signal cardiaque en plus de la respiration ; il permet une meilleure précision de mesure et l'application d'un filtrage analogique. Si la simplicité d'implémentation est à privilégier, le compteur de fréquence à l'aide d'un MCU permet de réduire le nombre de composants et est facile à mettre en place.

L'option rassemblant les avantages des deux solutions semble être l'utilisation du LDC1614 de Texas Instruments. Il permet de s'adapter à différentes valeurs d'inductance en modifiant sa configuration logicielle. De plus, il propose une acquisition multicanaux qui serait très utile pour la fusion de capteurs. Enfin, on trouve des **cartes électroniques** de prototypage avec ce circuit, facilitant son implémentation dans des projets d'intégration.

Après avoir présenté le principe de détection et les différentes approches techniques de ce principe, les résultats des différentes méthodes seront présentés, ainsi que les principaux défis associés à cette méthode de détection.

1.3.2.3 Performances et défis associés à la détection de la respiration inductives

L'invasivité est un défi commun à la majorité des technologies permettant l'acquisition de données physiologiques. Ce facteur détermine la possibilité d'intégration dans la plupart des cas d'usage, tels que la surveillance d'un conducteur de véhicule, par exemple. La détection de la respiration par induction permet de répondre à ce problème.

Dès 2005, des chercheurs (Richer & Adler, 2005) ont proposé de surveiller la respiration d'un patient à l'aide de capteurs inductifs placés dans son matelas. Ils ont constaté qu'il était possible de détecter la respiration, mais que les capteurs étaient également fortement affectés par les mouvements du patient.

Sachant qu'il est possible de détecter la respiration à l'aide d'une bobine, Walter *et al.* (2011) ont développé un prototype de siège de voiture intelligent intégrant un détecteur inductif de la respiration. Dans la figure 1.15 la bobine est placée dans le siège du conducteur. Les auteurs reconnaissent que la bobine est située loin du corps du conducteur dans le siège ; la rapprocher permettrait d'améliorer le rapport signal sur bruit. Cependant, comme dans les études précédentes, les artéfacts de mouvements restent un facteur important de détérioration du signal.




FIGURE 1.15 Placement de la bobine siège de conduite intelligent
Tirée de (Walter *et al.*, 2011, p. 6)

Bobines inductives textiles

Pour résoudre le problème de la distance relative de la bobine, la littérature propose de développer des **électrodes textiles** (Gi *et al.*, 2015 ; Koo *et al.*, 2014). L'utilisation de textiles permet une intégration beaucoup plus facile dans les systèmes, et les capteurs peuvent être

intégrés directement dans les vêtements. Sur la figure 1.16 Leicht *et al.* (2017) ont intégré ces bobines textiles directement dans la ceinture de sécurité de la voiture. Les électrodes sont ainsi placées au plus près du corps du conducteur pour améliorer la qualité du signal. Lors de leurs tests ils ont découvert que le signal de respiration de la bobine produisait de meilleurs signaux que celui de référence. Concernant les performances des différentes forme de bobine textiles et




FIGURE 1.16 Électrode brodée dans ceinture de sécurité
Tirée de (Leicht *et al.*, 2017, p. 2)

positions, Cho *et al.* (2022) démontrent dans leur études que la respiration est détectables dans les positions P2, P4 et P6 sur la figure 1.17. De plus, l'études de différentes forme de bobine circulaire montre que la forme à un impact limité sur la qualité du signal de respiration.

Cependant, les **tailles** des électrodes peuvent définitivement avoir un impact sur les mesures. Les travaux de Patiño & Menon (2021) montrent que la taille des électrodes modifie l'inductance et donc l'intensité du champ généré. De plus, la loi de Biot-Savart et l'équation du champ magnétique d'une boucle de courant, données par l'équation suivante :

$$\mathbf{B} = \frac{\mu_0 I R^2}{2(x^2 + R^2)^{3/2}} \hat{x} \quad (1.8)$$

où :

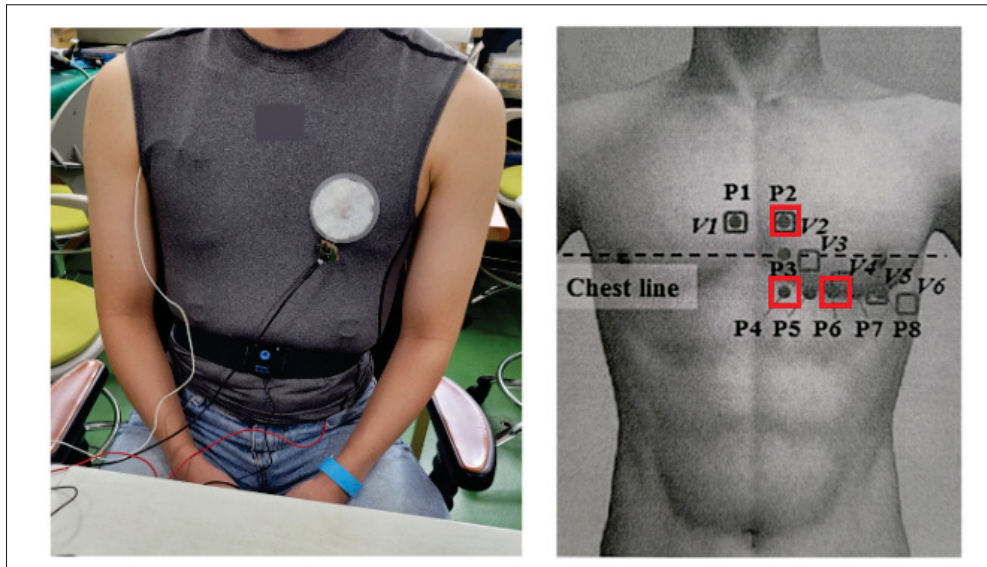


FIGURE 1.17 Position des Électrodes
Tirée de (Cho *et al.*, 2022, p. 8)

- \mathbf{B} est le champ magnétique,
- μ_0 est la perméabilité du vide,
- I est le courant dans la boucle,
- R est le rayon de la boucle,
- x est la distance à l'axe de la boucle,
- \hat{x} est le vecteur unitaire dans la direction x .

montrent que l'intensité du champ magnétique dépend du rayon de la boucle de courant. On peut donc dire que la **taille du champ magnétique** est **liée au diamètre de la bobine**. Il pourrait être intéressant de faire varier ce paramètre pour investiguer d'éventuels changements de performances.

Pour aller plus loin, d'autres études comparent les différences de performances entre des **formes circulaires et rectangulaires**. Luo & Wei (2018) suggèrent que l'inductance mutuelle de deux électrodes rectangulaires serait supérieure à celle des électrodes de forme circulaire et offrirait une tolérance plus grande au non-alignement. Cela suggère des **différences dans la forme et**

l'intensité des champs magnétiques générés, ce qui pourrait influencer les mesures inductives de ce type d'électrodes.

Jusqu'à présent, les études ont proposé des résultats obtenus en laboratoire dans des situations contrôlées. Cependant, dans la dernière étude de la série des travaux de (Leicht *et al.*, 2017,2), les chercheurs ont créé leur système le plus abouti, permettant une intégration dans un véhicule en situation réelle (voir figure 1.18).



FIGURE 1.18 Intégration des capteurs inductifs par les chercheurs
Tirée de (Leicht *et al.*, 2022, p. 5)

Lors des essais, plusieurs tests dans trois scénarios de conduite ont été réalisés : en stationnement, en milieu rural et en milieu urbain. Malgré tous leurs efforts pour améliorer le signal, le scénario urbain présente des performances médiocres. Ils concluent que le système peut être viable sur autoroute, mais pas en milieu urbain, en raison des artefacts de mouvement trop importants.

Cette étude est sérieuse, et le système a été développé de manière itérative depuis 2017 (Leicht *et al.*, 2017). De plus, ce sont les résultats les plus récents concernant la détection inductive de la respiration. Cette référence semble être une bonne base pour comparer les performances de notre système d'acquisition, notamment leurs résultats en position de stationnement, car c'est ce qui se rapproche le plus de la configuration d'un simulateur.

Pour résumer, les méthodes non invasives sont le champ de recherche privilégié ces dernières années. Leur principal intérêt est qu'elles sont pour la plupart facilement intégrables à un système existant. Les électrodes inductives textiles répondent à la majorité des critères de la non-invasivité : elles sont peu chères, simples à fabriquer, flexibles, intégrables dans toutes les surfaces textiles et permettent une détection sans contact.

Les études antérieures ont démontré plusieurs choses :

- Les électrodes textiles permettent de détecter la respiration efficacement.
- Elles offrent de meilleures performances lorsqu'elles sont placées proches du corps.
- Elles peuvent permettre d'observer le rythme cardiaque si placées à la bonne position.
- Les formes d'électrodes circulaires ne créent pas de différence de performances notables.

Cependant, comme toutes les études l'ont montré, le principal défi associé à cette méthode vient des artéfacts de mouvement générés par la voiture, la route ou les mouvements du conducteur. Cet aspect semble être le principal obstacle à une intégration en situation réelle. Il est donc vital d'intégrer des méthodes de traitement de signal, présentées ci-après.

1.4 Le Signal de Respiration

1.4.1 Généralités

La respiration, telle que décrite par Brinkman, Toro & Sharma (2024) a pour fonction principale de faciliter les échanges gazeux entre l'air inspiré et le système circulatoire à l'aide des poumons. En effet, l'organisme a besoin d'échanger du dioxyde de carbone (déchet de l'organisme) avec de l'oxygène pour pouvoir utiliser ses réserves énergétiques. C'est le but principal du système respiratoire décrit par la figure 1.19. Ce système est contrôlé, comme expliqué plus haut, par le SNA, cependant, les individus peuvent néanmoins avoir un certain contrôle sur la respiration. Le rythme respiratoire normal d'un adulte se situe entre 12 et 20 respirations par minute (Chourpiliadis & Bhardwaj, 2024).




FIGURE 1.19 Schéma du système respiratoire
Tirée de Cleveland Clinic (2024)

Chaque cycle respiratoire est composé d'une inspiration et d'une expiration. L'augmentation du volume thoracique est déclenchée lorsque le diaphragme se contracte lors de l'inspiration. Les poumons se dilatent suite à ce changement de volume permettant à l'air d'entrer. L'expiration, quant à elle, est un processus passif qui survient lorsque le diaphragme se relâche, réduisant ainsi le volume thoracique et permettant l'évacuation de l'air (Brinkman *et al.*, 2024).

C'est ce mouvement mécanique que les capteurs des différentes méthodes doivent capter pour être capables d'observer le signal respiratoire.

1.4.2 Traitement de signal

Comme mentionné dans la section précédente, le rythme respiratoire normal chez un adulte se situe entre 12 et 20 respirations par minute (Chourpiliadis & Bhardwaj, 2024), ce qui correspond à une bande de fréquence allant de 0,2 à 0,33 Hz. Afin d'estimer précisément ce rythme, plusieurs étapes sont généralement suivies dans les études dédiées au traitement du signal respiratoire.

Dans cette section, les différentes phases du processus d'estimation du rythme respiratoire, telles que présentées dans la figure 1.20, sont décrites. Ce processus se décompose en cinq étapes principales proposées par Charlton *et al.* (2018) :

1. Extraction des signaux respiratoires.
2. Fusion des signaux respiratoires.
3. Estimation des rythmes respiratoires.
4. Fusion des rythmes respiratoires.
5. Calcul d'indice de qualité.

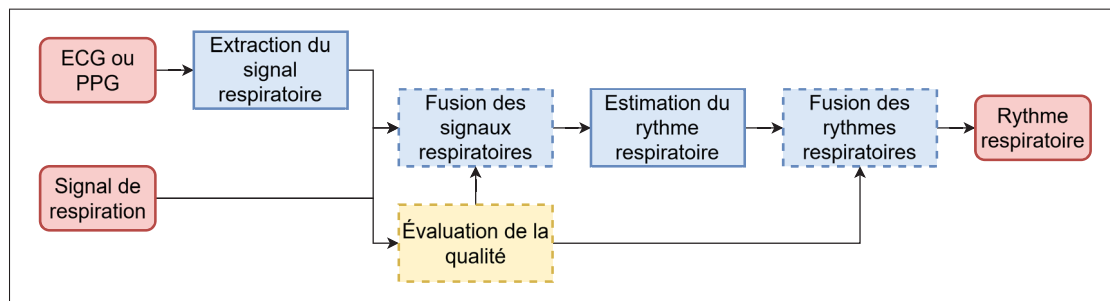


FIGURE 1.20 Étapes du traitement de signal de respiration
Adaptée de Charlton *et al.* (2018)

1.4.2.1 Extraction et pré-traitement du signal respiratoire

Le signal respiratoire peut être acquis de différentes sources, la méthode la plus directe étant d'extraire directement le signal respiratoire avec, par exemple, des ceintures à respiration induite

autour du corps (Guede-Fernández *et al.*, 2019). Mais on peut aussi l'extraire indirectement du signal PPG ou ECG (Pimentel, Charlton & Clifton, 2015). Dans ce mémoire, l'accent sera mis sur les méthodes utilisant directement le signal de respiration, car elles permettent d'extraire des signaux respiratoires de meilleure qualité, plus proches de l'anatomie réelle du signal.

Le pré-traitement : dans la littérature, plusieurs méthodes de traitement de signal sont proposées, mais la méthode la plus souvent utilisée est un filtre passe-bande ou passe-bas avec des fréquences de coupure variables, dépendamment des travaux et des données dont les chercheurs disposent. Warnecke, Wang & Deserno (2019) utilisent un filtre passe-bande autour de la bande de fréquence respiratoire avec une fréquence de coupure de **0.05 Hz et 1 Hz**, tandis que Kiashari *et al.* (2018) utilisent un filtre de Butterworth passe-bas à **0.6 Hz**. Si aucun filtre passe-haut n'est appliqué, on peut s'attendre à ce que le signal présente de lentes variations d'amplitude, auquel cas il faut retirer les tendances basses fréquences.

Une fois le signal de respiration nettoyé, on obtient un signal de bien meilleure qualité. On peut donc procéder à l'estimation du rythme respiratoire.

1.4.2.2 Fusion des signaux respiratoires

Lorsque l'on dispose de plusieurs sources de signaux, il peut être intéressant d'effectuer une fusion de ces dernières dans le but d'améliorer la qualité du signal ou la performance de l'estimation du rythme. La fusion consiste à combiner plusieurs sources contenant des informations redondantes pour augmenter la fiabilité d'une donnée.

Il existe différentes méthodes : on peut, par exemple, fusionner les estimations à l'aide d'une simple moyenne ou médiane, comme dans les travaux de Karlen, Turner, Cooke, Dumont & M.

Pour aller plus loin, Khreis, Ge, Rahman & Carrault (2020) développent deux méthodes : la première sélectionne automatiquement le signal avec le RQI le plus élevé, tandis que la seconde utilise un filtre de Kalman pour fusionner les signaux avec les RQIs les plus élevés. Les résultats obtenus indiquent que les deux méthodes permettent d'améliorer l'estimation

du rythme respiratoire, aussi bien pour les patients immobiles que pour les patients actifs, et montrent que l'on peut appliquer ce type de filtre aux signaux de respiration.

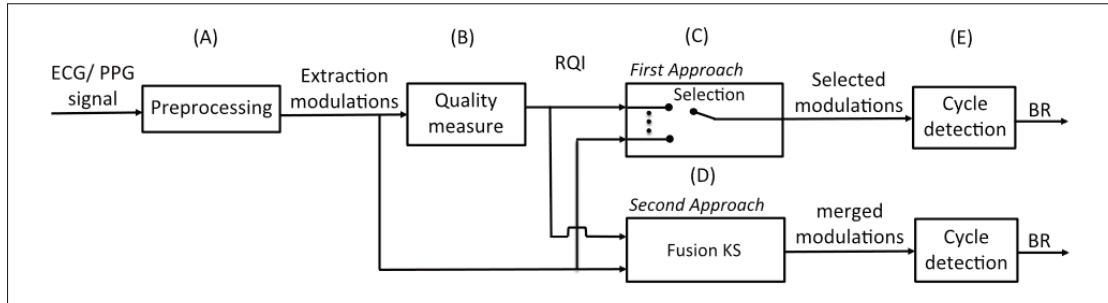


FIGURE 1.21 Méthode de fusion de signaux respiratoires
Tirée de (Khreis *et al.*, 2020, p. 2)

Le filtre de Kalman est utilisé dans de nombreux domaines de l'ingénierie, notamment pour le suivi d'objets en mouvement avec le GPS, le filtrage de bruit, et la fusion de données de nature différente, comme les données inertielles et GPS pour estimer la position. Comme montré par la figure 1.22, il utilise un raisonnement bayésien pour prédire l'état futur d'un système à partir de son état actuel, tout en tenant compte des incertitudes liées aux mesures. (Pei, Biswas, Fussell & Pingali, 2019)




FIGURE 1.22 Schéma des étapes d'estimation du filtre de Kalman
Tirée de Roger R. Labbe Jr (2024b)

Il se décompose selon les étapes suivantes, adaptées du livre "**Kalman and Bayesian Filters in Python**" (Roger R. Labbe Jr, 2024b) :

1. **Prédiction** : Le filtre prédit l'état futur du système en fonction de l'état précédent, en utilisant un modèle de transition défini par le concepteur. Par exemple, dans le cas de la fusion de signaux respiratoires, on peut estimer que l'état sera égal à lui-même, plus l'incertitude du filtre de Kalman.
2. **Observation** : Le filtre prend en entrée les données provenant de capteurs externes, dans notre cas plusieurs sources de signaux.
3. **Fusion** : Le filtre combine la prédiction et les mesures selon la matrice de gain K , calculée grâce aux matrices de covariance, permettant de pondérer chaque source d'information. Si une mesure est plus fiable (avec une variance plus faible dans la matrice de covariance), elle aura un impact plus important dans l'estimation du nouvel état.
4. **Correction** : Le filtre ajuste ensuite l'estimation de l'état en fonction des nouvelles mesures et corrige l'incertitude associée à cette estimation.

Le filtre de kalman permet donc en tout temps de fournir une estimation basée sur les informations communes contenue dans les sources en maximisant l'information.

1.4.2.3 Estimation du rythme respiratoire (RR)

Il existe deux catégories de méthodes : celles qui utilisent le domaine fréquentiel et celles qui se basent sur le domaine temporel. Comme détaillé dans l'étude de Charlton *et al.* (2018), les méthodes temporelles impliquent la détection de chaque pic de respiration, suivie du calcul de l'intervalle instantané ou moyen sur une durée pour estimer le rythme respiratoire. L'avantage est de pouvoir suivre les fluctuations rapides du rythme respiratoire et d'accéder à des mesures variées, comme le RMSSD (Root mean square of successive differences) des intervalles entre respirations (Soni & Muniyandi, 2019). Cependant, ces méthodes sont davantage influencées par les artefacts des signaux respiratoires (Charlton *et al.*, 2018). Les méthodes fréquentielles consistent à estimer la composante fréquentielle dominante sur une fenêtre de temps, le plus

souvent à l'aide d'une analyse spectrale. Elles nécessitent un rythme respiratoire constant et ne permettent pas d'obtenir une analyse pic à pic de la respiration. Cela pourrait se révéler être un problème pour l'étude de la somnolence, car on manquerait alors de caractéristiques pour observer la transition d'éveil à somnolence.




FIGURE 1.23 Exemple de la détection dans le domaine temporel des pics générée avec la librairie de Makowski *et al.* (2021)

La dernière étape optionnelle proposée dans différents travaux est la fusion de différents rythmes respiratoires.

1.4.2.4 La fusion des rythmes respiratoires

Comme avec les signaux de respiration bruts, il est aussi possible de fusionner les rythmes respiratoires pour augmenter la fiabilité. Dans (Karlen *et al.*), les chercheurs améliorent l'estimation en réduisant l'erreur de 5.8, 6.3 et 3.9 respirations/min (erreur quadratique moyenne notée RMS, Root Mean Square, en anglais) pour les méthodes individuelles à 3.0 respirations/min pour la fusion par moyenne. Ces méthodes peuvent être faillibles ; en effet, si plus de la moitié des sources sont de mauvaise qualité, l'estimation finale sera de mauvaise qualité.

Comme Khreis *et al.* (2020), Lepine, Tajima, Ogasawara, Kasahara & Koizumi (2016) utilisent un filtre de Kalman pour fusionner les estimations et obtenir une meilleure précision, avec une erreur de 2.3 respirations/min sur les patients en position assise. Le filtre de Kalman présente plusieurs avantages, notamment la possibilité de calculer les estimations point à point en temps réel, ainsi que la capacité à mettre à jour le filtre à l'aide d'indices de qualité, par exemple en forçant le filtre à prioriser les sources avec le meilleur indice (Nemati, Malhotra & Clifford, 2010). Une étude plus récente utilise aussi un filtre de Kalman pour fusionner des signaux de respiration acquis par 6 capteurs piézo-électriques pour améliorer leur précision (Chatelais & Gagnon, 2019). Le filtre de Kalman est utilisé dans plusieurs papiers pour l'estimation de la respiration. En effet, il présente plusieurs avantages, comme la prise en compte de l'incertitude associée aux mesures d'entrée à l'aide de la matrice de covariance. Il est également capable d'évoluer dynamiquement en fonction des changements de variabilité des mesures, en mettant à jour sa matrice de covariance, là où une simple moyenne ne le pourrait pas. De plus, comparé à d'autres méthodes telles que les filtres de particules, il offre un bon équilibre entre performances et coûts calculatoires (Stelzer, Kager & Herwig, 2017).

1.4.2.5 Indices de qualité

Les indices de qualité sont des composantes importantes de toute méthode de traitement de signal. Ils permettent de caractériser la qualité des signaux et rendent possible une rétroaction sur les méthodes de traitement de signaux.

1.4.2.5.1 Modèle moyen de respiration

Certaines études proposent de segmenter chaque cycle respiratoire afin de définir un modèle moyen de respiration. Ensuite, une corrélation moyenne est calculée entre chaque cycle respiratoire et ce modèle, comme illustré à la figure 1.24. Cette valeur est ensuite utilisée comme indice de qualité (Orphanidou, Bonnici, Charlton, Clifton, Vallance & Tarassenko, 2014; Romano, Innocenti, Schena, Sacchetti, Nicolò & Massaroni, 2023). Elle donne une indication sur la

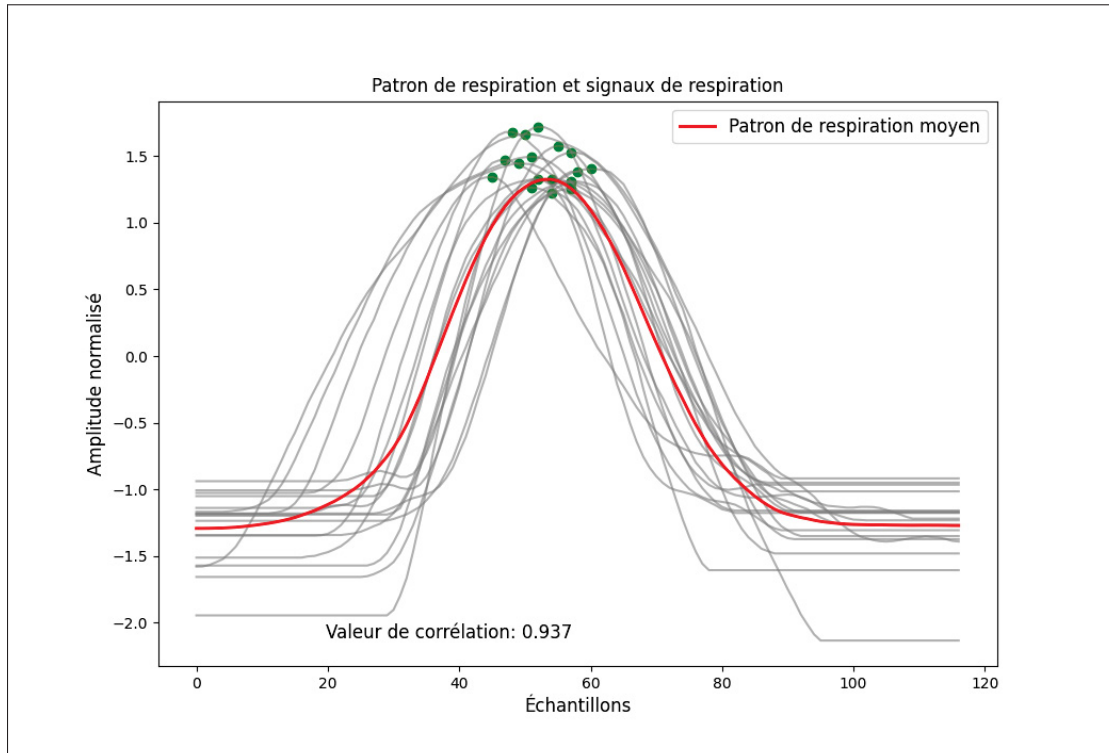


FIGURE 1.24 Exemple de corrélation avec patron de respiration moyen

régularité des formes des vagues de respiration, des vagues avec des perturbations associées à des artefacts de mouvement produiront un moins bon indice.

1.4.2.5.2 Indice de pureté spectrale

D'autres travaux utilisent un indice appelé "Spectral Purity Index" (SPI), introduit par Sörnmo & Laguna (2005). Il permet de mesurer à quel point un signal est représenté par une seule fréquence, un signal sinusoïdal ayant une valeur d'indice égale à 1. Il est calculé à l'aide des moments du spectre de puissance $S_x(e^{j\omega})$, les moments spectraux sont calculés de la manière suivante :

$$\bar{\omega}_n = \int_{-\pi}^{\pi} \omega^n S_x(e^{j\omega}) d\omega. \quad (1.9)$$

Une approximation discrète est proposée par l'équation 1.10 (Sörnmo & Laguna, 2005),

$$\hat{\omega}_i \approx \frac{2\pi}{N} \sum_{n=0}^{N-1} \left(x^{(i/2)}(n) \right)^2, \quad i = 0, 2, 4. \quad (1.10)$$

où $\hat{\omega}_i$ est l'approximation du moment spectral d'ordre i , N est le nombre total d'échantillons, et $x(n)$ est le signal échantillonné.

Cette approximation permet une implémentation sous forme de fenêtres roulantes des moments spectraux.

Le SPI est ensuite défini par le rapport entre le carré du moment d'ordre deux et la puissance totale ainsi que le moment d'ordre quatre,

$$\Gamma_{\text{SPI}}(n) = \frac{\bar{\omega}_2^2(n)}{\bar{\omega}_0(n)\bar{\omega}_4(n)}. \quad (1.11)$$

où $\Gamma_{\text{SPI}}(n)$ est le Spectral Purity Index, $\bar{\omega}_2^2(n)$ est le moment spectral d'ordre deux, $\bar{\omega}_0(n)$ est le moment spectral d'ordre 0 et $\bar{\omega}_4(n)$ le moment spectral d'ordre 4. La recherche de Nemati *et al.* (2010) utilise le SPI pour effectuer une rétroaction sur un filtre de Kalman afin d'estimer un meilleur rythme respiratoire.

1.4.2.5.3 Ratio de puissance relative

Plus simplement, on peut utiliser un simple ratio de puissance relative dans la bande d'intérêt, comme proposé dans les travaux de Elgendi (2016), cet indice donne une indication sur la concentration de puissance des oscillations dans la bande d'intérêt.

$$\text{RSQI} = \frac{\sum_{f=0.2}^{0.33} \text{PSD}}{\sum_{f=0}^{fs/2} \text{PSD}} \quad (1.12)$$

où RSQI est l'indice de qualité du signal respiratoire, f est la fréquence, PSD est la densité spectrale de puissance, et fs est la fréquence d'échantillonnage. Il existe plusieurs types

d'indices de qualité, et la littérature leur porte un intérêt certain. En effet, dans certains cas, ils permettent d'améliorer des algorithmes de fusion, et dans d'autres, avec un système de seuillage, ils permettent de retirer les segments de qualité médiocre des enregistrements. Ces indices améliorent la performance et la fiabilité des systèmes dans lesquels ils ont été utilisés ; ils sont donc une composante importante des algorithmes de traitement de signal.

1.4.2.6 Remarques générales

Dans la section 1.4.2, une revue des différentes méthodes de traitement de signaux a été proposée. On remarque que ce champ de recherche est riche et que certaines méthodes empruntent aux domaines du traitement de signal de l'ECG et du PPG, qui sont encore plus vastes. On observe aussi que les études récentes travaillent à améliorer la fiabilité des estimations du rythme respiratoire à l'aide de nouveaux algorithmes utilisant la fusion de données, ou en proposant des méthodes pour retirer les segments de mauvaise qualité. Notre méthode à 4 points de données pourrait donc avoir un impact positif sur la littérature, en ouvrant la voie à des systèmes d'acquisition à fusion multi-voie pour la détection de la respiration. Après avoir examiné les diverses méthodes de traitement des signaux et leur pertinence dans l'amélioration des estimations du rythme respiratoire, les perspectives possibles pour ce mémoire seront présentées.

1.5 Perspectives

Comme détaillé dans les sections précédentes, la somnolence est une cause majeure d'accidents de la route. Il est donc important de doter le conducteur de tous les outils possibles pour protéger sa vie et celle des autres passagers. Malgré la complexité de reproduire et de détecter la somnolence en laboratoire, de nombreuses études ont réussi à la détecter avec plus ou moins de succès. Différentes techniques ont été utilisées : comportementales (ex. PERCLOS, bâillement, position), véhiculaires (ex. angle du volant, déviation de la ligne) et physiologiques (ex. EEG, ECG, respiration).

Lors de cette revue, il est apparu que les mesures physiologiques obtiennent de meilleurs résultats par rapport aux autres méthodes, notamment l'EEG, qui est, selon la littérature, la mesure de référence pour l'estimation de la somnolence. L'EEG étant trop invasif, les autres mesures physiologiques sont à privilégier.

Le tableau 1.2 met en évidence la séparabilité des métriques respiratoires entre éveil et somnolence. De plus, la respiration offre de bonnes performances de détection dans plusieurs études et peut être acquise grâce à des méthodes non invasives. Elle semble donc être une mesure viable pour la surveillance de l'attention en temps réel des conducteurs. Les méthodes d'acquisition non invasives comme les caméras, les accéléromètres ou les électrodes inductives ont l'avantage d'offrir un confort d'utilisation accru pour l'utilisateur, facilitant leur adoption pour les applications de surveillance des conducteurs. Cependant, les artefacts de mouvement et les événements extérieurs (ex. luminosité, vibrations de la route) restent des défis qui détériorent la fiabilité et la précision de ces systèmes.

Avec l'augmentation du nombre de véhicules autonomes, il deviendra essentiel de surveiller l'état physiologique des occupants. Pour cela, il est crucial d'améliorer la robustesse des techniques d'acquisition non invasives de la respiration, en développant de nouvelles techniques de filtrage ou de fusion de données. La conception de systèmes utilisant la respiration avec d'autres signaux tels que l'ECG pourrait améliorer les performances et la fiabilité.

La détection de la somnolence avec des électrodes textiles représente une nouveauté. En effet, les études présentées dans cette revue n'ont pas effectué d'analyse concernant la possibilité de détecter la somnolence à l'aide des électrodes textiles. Fournir des éléments de réponse sur ce point permettrait d'apporter de la nouveauté dans ce domaine de recherche et pourrait éventuellement ouvrir la voie à de nouveaux travaux dans le futur.

La recherche présentée dans ce mémoire s'appuie sur les références et techniques citées plus haut pour améliorer la précision et la fiabilité de l'acquisition de la respiration inductive. Dans le but d'offrir de nouvelles données à la communauté scientifique, cette recherche propose une nouvelle base de données contenant des épisodes de somnolence. Cette étude contribuera à prouver que

la surveillance des mesures physiologiques en temps réel d'un conducteur avec des électrodes sans contact textiles est possible et permet, dans certains cas, de prévoir la somnolence. Dans la section suivante, le système développé au cours de cette maîtrise sera présenté, l'approche dans sa conception sera expliquée ainsi que les techniques utilisées.

CHAPITRE 2

MÉTHODOLOGIE ET ARCHITECTURE DU SYSTÈME

Après avoir introduit les concepts théoriques liés à l'acquisition inductive et les différentes méthodes proposées par la littérature, ce chapitre présentera la méthode adoptée au cours de cette maîtrise.

L'objectif est de répondre aux requis du projet :

- Acquérir la respiration d'un conducteur de manière non-invasive, de manière fiable et reproductible avec des capteurs textiles.
- Améliorer la performances de détection face au artefacts de mouvements.
- Montrer que les caractéristiques des signaux expérimentaux textiles évoluent de la même manière que celui de référence.

L'approche adoptée comporte deux volets : premièrement, le système d'acquisition expérimental, basé sur un microcontrôleur connecté à un numériseur d'inductance LDC1612 de Texas Instruments permettant l'acquisition des signaux de respiration inductifs. Les données respiratoire sont captées en 4 points 2 en position ventrale et 2 en position thoracique, elles sont ensuite fusionnées à l'aide d'un filtre de kalman pour améliorer la qualité des données. Cette approche utilisant plusieurs capteurs textiles est nouvelle dans la littérature et permet d'améliorer la qualité des signaux de respiration en temps réel. À cela s'ajoute un système d'acquisition de signaux biologique de référence avec possibilité de synchronisation entre les données expérimentales et de référence. Cette approche permettra de démontrer la fiabilité des données recueillies et de prouver que, si l'on peut détecter la somnolence à l'aide des signaux de référence, il sera également possible de le faire avec les signaux expérimentaux textiles.

2.1 Architecture

La figure 2.1 illustre l'architecture complète du système expérimental. Elle comporte les dispositifs d'acquisition des signaux cardio-respiratoires sans contact et de référence, ainsi que les logiciels de simulation de conduite et d'enregistrement des flux de données. Voici une description fonctionnelle de ces différents modules :

1. **Carte d'acquisition ECG** : Elle contient trois circuits intégrés AD8232, des amplificateurs différentiels en mode commun. Chaque circuit est connecté à une paire d'électrodes capacitives textiles, produisant ainsi trois signaux analogiques ECG obtenus sans contact direct avec la peau. Un système de sommation et d'inversion des modes communs produit un signal qui est réinjecté dans le conducteur à l'aide du volant conducteur.
2. **Électrode capacitive** : Chaque électrode capacitive est composée d'un adaptateur d'impédance connecté à une électrode textile conductrice. Ces deux composantes forment un couplage haute impédance, dit « capacitif », avec le linge et la peau du conducteur.
3. **Système d'acquisition de respiration inductive** :
 - **Bobines inductives textiles** : Quatre bobines textiles sont utilisées pour détecter les variations de la respiration en mesurant les changements d'inductance causés par les mouvements thoraciques et ventraux du conducteur. Les bobines sont connectées aux deux cartes d'acquisition pour capturer les données séparément pour les régions ventrale et thoracique.
 - **Cartes d'acquisition inductives** : Chaque carte d'acquisition est équipée d'un numériseur d'inductance LDC1612 de Texas Instruments. Il y a deux cartes : une pour les données ventrales et une autre pour les données thoraciques. Ces cartes convertissent les variations d'inductance, induites par les mouvements de respiration, en signaux numériques via une interface I2C (Inter-Integrated Circuit).
4. **Plateforme STM32** : La plateforme STM32 permet la gestion des données acquises. Elle reçoit les signaux numériques inductifs via l'I2C, puis utilise le **DMA (Direct Memory**

Access) pour transférer efficacement ces données dans **une mémoire tampon de données**. Elle gère aussi l'échantillonnage analogique des trois signaux ECG, qui sont également transmis à une mémoire tampon. Ensuite, ces mémoires sont vidées et les données sont transmises via le **module série** à travers une connexion Serial-USB vers l'ordinateur de recherche.

5. **Biopac (Référence)** : Le système inclut également une référence de mesure, fournie par le **capteur ECG à une dérivation**, une **ceinture respiratoire** ainsi qu'une **pince auriculaire de photopléthysmographie**, tous connectés au système Biopac. Les données de référence sont envoyées via une connexion Ethernet vers l'application Python.
6. **Ordinateur de recherche** : Une **application Python** prend en charge le traitement des données. L'application comprend les modules suivants :
 - **Module caméra** : Ce module traite les images capturées par la caméra.
 - **Interface graphique** : Permet l'affichage en temps réel des données de respiration, des signaux ECG, et des images vidéo.
 - **Module série** : Gère la réception des données expérimentales et les publie vers Lab Streaming Layer (LSL).
 - **Module Biopac** : Gère la réception des données de référence Biopac et les publie vers Lab Streaming Layer (LSL).
 - **Module de conduite** : Gère la synchronisation entre le Lab Streaming Layer (LSL) et le simulateur de conduite.
7. **Logiciel York Driving Simulator** : Génère une simulation de conduite tout en enregistrant les données véhiculaires.
8. **Stream Lab Streaming Layer (LSL)** : Pour synchroniser les données expérimentales et de référence, le système utilise le **Stream LSL**. LSL assure une synchronisation des signaux provenant de différentes sources, facilitant l'analyse combinée des données.
9. **Sauvegarde des données** : Enfin, les données synchronisées sont sauvegardées sous forme de fichiers **Xdf**.

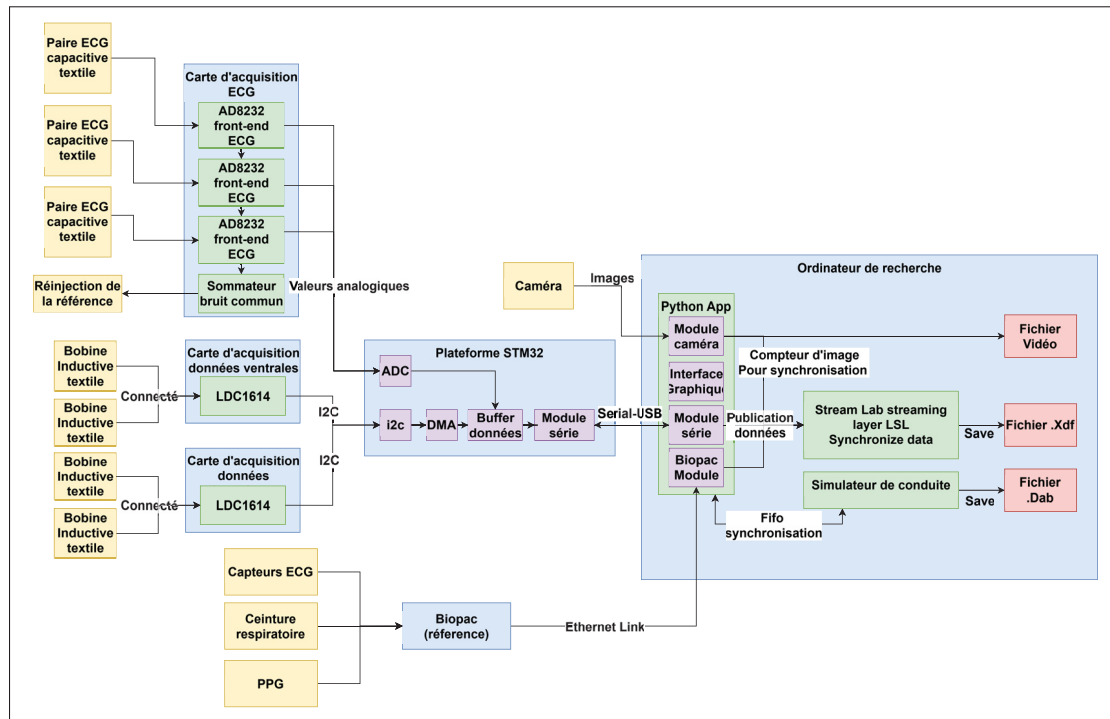


FIGURE 2.1 Architecture du système d'acquisition de la respiration et de référence

Les bobines textiles sont placées selon les positions illustrées en introduction par la figure 0.3 : 2 sont placées sur la partie ventrale de la ceinture et 2 sur la partie thoracique. La figure 2.2 montre sur la première photo le système d'acquisition de respiration inductifs textiles intégré à la ceinture ainsi que les capteurs de références et la seconde présente les capteurs de textiles capacitifs utilisé pour l'acquisition de l'ECG sans contact. Cette architecture modulaire permet une acquisition de données respiratoires avec ou sans système de référence. Grâce à ce système, il est possible de tester différentes électrodes et de les comparer à une référence si nécessaire. L'architecture globale ayant été présentée, les différents modules seront détaillés pour mieux comprendre leur conception.



FIGURE 2.2 Système d'acquisition cardio-respiratoire et capteurs de références

2.1.1 Électrodes inductives textiles

Les électrodes inductives textiles ont été réalisées en partenariat avec **le Groupe CTT de Sainte-Hyacinthe**, spécialisé en textiles intelligents. Comme présenté dans la section 1.3.2, plusieurs études ont démontré qu'en brodant des fils textiles conducteurs selon la forme d'une bobine plane, on reproduit des caractéristiques électriques similaires à celles d'un composant de même forme réalisé avec un câble conducteur classique. Cela apporte **2 avantages** : premièrement, le composant est facilement intégrable sur n'importe quelle surface textile pouvant être brodée, et deuxièmement, il est flexible.

2.1.1.1 Méthode de fabrication

La figure 2.3 présente la brodeuse **Tajima TMLX-1201** utilisée pour broder les électrodes, en suivant le processus "Tailored Fiber Placement" (TFP). Le TFP est une technique de fabrication textile basée sur le principe de la couture, permettant le placement continu de matériaux fibreux sur un substrat textile selon des motifs **curvilignes**. Dans notre cas, le support textile est un tissu noir épais. La figure 2.4 illustre le processus de broderie de plusieurs électrodes. En effet,



FIGURE 2.3 Brodeuse Tajima TMLX-1201

cette brodeuse présente l'avantage de pouvoir définir les formes désirées à l'avance à l'aide d'un logiciel sur ordinateur, puis de lancer la production de plusieurs électrodes de tailles ou formes différentes.




FIGURE 2.4 Processus de brochage en cours des électrodes textiles inductives

2.1.1.1.1 Fils

Le fil textile utilisé pour la fabrication des électrodes inductives est le CE3286YA de la compagnie Meaden, le tableau 2.1 en résume les caractéristiques. Ce fil, avec un diamètre de 1,6 mm, est très robuste, ce qui lui permet de résister aux mouvements thoraciques du conducteur. Il possède également une résistivité plus basse que celle d'autres fils utilisés dans l'industrie, comme ceux de la compagnie **vtechtextiles**, qui propose des fils avec une conductivité bien plus élevée, de l'ordre de plusieurs dizaines de Ω/m . Cela présente l'avantage d'améliorer le facteur de qualité Q de l'inductance, donné par l'équation 2.1, et de réduire les pertes liées à la résistance du fil.

$$Q = \frac{\omega L}{R} \quad (2.1)$$

Le fil de fixation utilisé pour la broderie est un fil 100% polyester de 27 tex (épaisseur du fil).

TABLEAU 2.1 Caractéristiques du fil métallique (Tinsel)

Catégorie	Propriété	Valeur
Matière première	Matériau	Alliage cuivre-étain plaqué argent
	Conductivité	> 55 %
	Tours de couverture	20 ± 2 tours / 10 mm
	Nombre de rubans de cuivre	2
	Sens de l'enroulement	Z
	Textile central	Série K
Produit fini	Construction	2 Wrap X 4 X 4 Strand
	Diamètre du produit fini	1.60 ± 10% mm
	Charge de rupture	> 17 kg
	Résistance du conducteur	< 0.28 Ω /M
	Test de flexion / 270 degrés	> 50,000 cycles

2.1.1.1.2 Schéma d'assemblage

Les électrodes présentent un schéma d'assemblage particulier. La figure 2.5 montre la première version des électrodes, fabriquées en déposant uniquement les fils conducteurs sur le substrat.

Problème : faux contact avec la cible conductrice, cette méthode présentait un problème : elle laissait les fils conducteurs de la bobine à l'air libre. Ainsi, un contact avec la peau, par exemple, modifiait drastiquement l'inductance, créant une discontinuité dans les données. **Solution :** Pour répondre à ce problème, une nouvelle version a été proposée, illustrée à la figure 2.6. La principale nouveauté réside dans l'ajout d'une doublure pour réduire les risques de contact avec la cible conductrice, en utilisant le tissu de support noir comme diélectrique.

Comme expliqué dans le chapitre précédent, la qualité des signaux est accrue lorsque les capteurs inductifs sont proches de leurs cibles. Pour cela, une approche similaire aux travaux de Leicht *et al.* (2017) a été adoptée en **intégrant directement les capteurs dans la ceinture du conducteur**. Afin de s'adapter aux différentes morphologies, les électrodes ont été **intégrées à un passant**, ce qui permet de déplacer les électrodes le long de la ceinture et de les positionner de manière optimale pour chaque sujet. La figure 2.7 illustre la nouvelle électrode rectangulaire intégrée au passant. On remarque que les fils conducteurs sont protégés sur tous les côtés par une doublure en tissu, empêchant tout contact direct avec la cible ou l'extérieur du capteur.



FIGURE 2.5 Première version des électrodes textiles sans doublure

Le tableau 2.2 liste les prototypes produits et testés au cours de cette recherche, les valeurs d'inductances ont été calculées avec un LCR-916 de la marque GwInstek à une fréquence de 100KHz. Deux facteurs ont été modifiés pour les différentes électrodes : la taille et la forme. Pour la taille des électrodes circulaires, la forme définie par (Koo *et al.*, 2014) a été choisie comme base (A.73.12), avant d'expérimenter avec des tailles plus grandes, car 60 mm de diamètre était déjà considéré comme très petit. Concernant les électrodes rectangulaires, n'ayant pas trouvé les dimensions des formes proposées dans les études de Leicht *et al.* (2017,2), deux tailles s'approchant de celles mentionnées dans ces études ont été choisies : une grande et une petite.




FIGURE 2.6 Version finale des électrodes textiles circulaires avec doublure

2.1.2 La carte d'acquisition

Le rôle de cette carte est d'accueillir le circuit oscillateur permettant la mesure de l'inductance.

Pour cela, nous utilisons sur la figure 2.8 celle de Seed Studio disponible à l'adresse :

https://wiki.seeedstudio.com/Grove-2_Channel_Inductive_Sensor-LDC1612/




FIGURE 2.7 Version finale des électrodes textiles rectangulaires avec doublure

TABLEAU 2.2 Liste des prototypes produits

Prototyp	Diamètre extérieur (mm)	Diamètre intérieur (mm)	Nombre de tours	Espace entre les tours (mm)	Diamètre du fil (mm)	Inductance mesurée (µH)	Facteur Q	Forme
A.73.12	60	0	10	1,5	1,5	2.863	5.9	Circulaire
A.73.20	80	5	13	1,5	1,5	5.8	7.37	Circulaire
A.73.15	120	0	20	1,5	1,5	19.788	9.42	Circulaire
A.73.39	Longueur : 150, Largeur : 50	Longueur : 115, Largeur : 10	5	3	1,5	2.518	3.71	Rectangulaire
A.73.40	Longueur : 100, Largeur : 50	Longueur : 60, Largeur : 10	5	3	1,5	1.698	3.69	Rectangulaire

Grâce à cela, nous disposons d'un design déjà éprouvé avec les connecteurs nécessaires. Elle contient plusieurs composants importants :

- Le circuit intégré LDC1612, un numériseur d'inductance à 2 canaux.
- Un condensateur, partie intégrante du circuit oscillant LC.
- Un connecteur pour la bobine textile.
- Un connecteur pour la communication I2C et l'alimentation.
- Un connecteur pour les lignes de contrôle, interruption, et mise en sommeil.

2.1.2.1 Le numériseur d'inductance LDC1612

Le LDC1612 mesure la fréquence d'oscillation de deux circuits oscillateurs. Il fournit ensuite une valeur proportionnelle à la fréquence, avec une résolution maximale de **28 bits**, communiquée via **une interface I2C**. Le principal avantages de ce circuit est qu'il supporte un large éventail de combinaisons d'inductances et de condensateurs avec des oscillations allant **de 1 kHz à 10 MHz**, permettant d'essayer **différentes configurations de bobines textiles**. Et propose une **logique de lecture séquentielle** des bobines.

Il est possible de configurer le temps de conversion ; cependant, plus le temps de conversion est rapide, plus la résolution est réduite. Pour lire l'inductance, comme illustré dans la figure 2.9, le LDC1612 alterne de **manière séquentielle** entre les circuits oscillants afin de ne pas créer de perturbations dans les lectures. Dans un monde idéal, le modèle d'un **circuit oscillateur LC** ne contiendrait pas de résistance et pourrait osciller indéfiniment. Cependant, en réalité, l'inductance possède une résistance en série avec l'inductance créée par le courant alternatif, cela est provoqué par la tendance du courant à circuler en périphérie du conducteur, ce que l'on appelle en anglais le "skin effect". Pour maintenir l'oscillation, le LDC1612 injecte un courant alternatif à la fréquence de résonance du circuit. Pour obtenir des performances optimales, la documentation du LDC1612 recommande de configurer le registre de courant de l'appareil afin de maintenir l'amplitude du capteur entre 1.2V et 1.8V. **Les notes d'application** de Texas Instruments (2024) permettent de choisir correctement le condensateur du circuit LC. La figure 2.10 montre l'évolution de la fréquence du circuit en fonction des valeurs L et C, tirée de la note d'application. D'après les valeurs théoriques des inductances textiles du tableau 2.2, qui varient entre **1.698 μ H** et **19.788 μ H**, on remarque, en observant le graphique, qu'un condensateur de




FIGURE 2.8 Carte d'acquisition avec LDC1612 branchée à deux bobines inductives textiles

1 nF permet de rester dans la plage de fonctionnement du capteur. Selon l'équation 2.2, en choisissant ce condensateur, la fréquence du capteur devrait théoriquement être comprise entre **3.862 MHz** et **1.131 MHz**.

$$f_{\text{SENSOR}}(\text{Hz}) = \frac{1}{2\pi\sqrt{LC}} \quad (2.2)$$

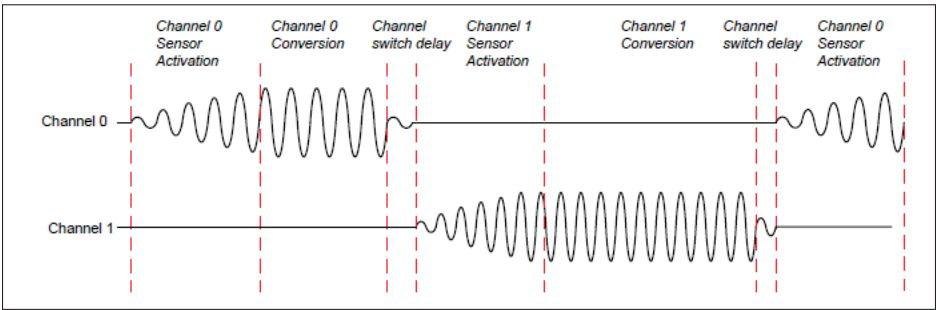


FIGURE 2.9 Séquence de lecture multi-canaux LDC1612
Tirée de (Texas Instruments, 2024)




FIGURE 2.10 Courbe de la fréquence du capteur VS inductance
Tirée de Texas Instruments (2024)

La consommation du LDC1612 est faible comparativement à l’alimentation d’une batterie de voiture. La valeur de cette dernière est présentée dans le tableau 2.3, où l’on observe que la carte peut atteindre une consommation de **0.01296 W**.

TABEAU 2.3 Consommation d’énergie du capteur
Tirée de Texas Instruments (2024)

Paramètre	Min	Typ	Max
V_{DD} (Tension d’alimentation)	2.7 V	3.3 V	3.6 V
I_{DD} (Courant de consommation)	-	2.1 mA	-
$I_{\text{SENSOR MAX}}$ (Courant maximum du capteur)	-	-	1.5 mA

2.1.2.1.1 Configuration du LDC1612

Cette étape permet de définir les paramètres d'acquisition de l'appareil. La première étape, présentée sur la figure 2.11, est de **calibrer l'injection de courant** de l'appareil. Cette étape doit être réalisée avec un sujet proche des électrodes, car l'interaction et donc la valeur de R_p seront minimales, et le courant à injecter sera maximal lorsque la cible conductrice sera la plus proche de la bobine. Le microcontrôleur gérant la communication avec le LDC1612 orchestre cette étape en envoyant les commandes nécessaires.




FIGURE 2.11 Étapes de calibration du LDC1612

Après avoir effectué la calibration, il est nécessaire de configurer les registres du LDC1612 :

1. **Registre : temps de conversion**, il est configuré pour prendre en compte le temps de changement de canal et de mise en oscillation, et est défini à **25 ms** pour une fréquence d'échantillonnage de **40 Hz**.
2. **Registre : valeur du courant d'injection**, configuré selon la valeur obtenue lors de la calibration.
3. **Registre : ligne d'interruption**, on configure le registre d'interruption pour que lorsqu'une conversion complète des canaux se termine, **une ligne est levée** pour indiquer au microcontrôleur que **les données sont prêtes**.
4. **Registre : division de l'horloge**, le LDC1612 contient une horloge de référence de 40 MHz pour la lecture et le respect des temps de conversion. **On ne divise pas** cette horloge, on configure ce registre avec **une valeur de 1**.

Pour résumer, une fois cette étape de configuration effectuée par le microcontrôleur, le LDC1612 attend le message de début pour commencer son acquisition avec les valeurs configurées dans

ses registres.

Elle commencera avec les deux caractéristiques suivantes :

- Fréquence d'échantillonnage de **40 Hz**.
- Interruption levée à la **fin d'une séquence d'acquisition complète**.
- **Circuit oscillateur** :
 - Inductances textiles comprise entre **1.97 μ H** et **15.75 μ H**.
 - Condensateur de **1 nF**.

2.1.3 Plateforme Embarquée STM32H743

La plateforme logicielle embarquée sert d'interface entre les capteurs et l'ordinateur de recherche, qui héberge l'application de post-traitement Python. Elle assure l'échantillonnage des données issues du système d'acquisition des données ECG textiles capacitives, ainsi que celles provenant du système d'acquisition des données respiratoires textiles inductives. Elle gère également la calibration des modules LDC1612. Aucune modification n'est apportée aux données, qui sont transmises telles quelles à l'ordinateur. Le démarrage de chaque communication série vers l'ordinateur est déclenché par la réception des données respiratoires via la communication I2C. Installée à l'arrière du siège du conducteur, comme montré sur la figure 2.12, dans un boîtier de protection imprimé en 3D, la plateforme est directement connectée aux sorties des cartes d'acquisition LDC1612 et AD8232 à l'aide de connecteurs. Par ailleurs, la connexion aux différents ports du microcontrôleur est assurée par une carte mezzanine spécialement conçue pour le projet. Pour cette plateforme, nous utilisons **cette** carte de développement avec un microcontrôleur STM32H747ZI dont les spécifications sont résumées dans le tableau 2.4. Ce dernier possède plusieurs caractéristiques intéressantes, la plus importante étant la grande quantité de "General-Purpose Input/Output" (GPIO) et son convertisseur analogique-numérique (ADC) à 16 bits de résolution, permettant une grande précision pour la mesure ECG. Plus généralement, cette carte a été choisie dans le but de surdimensionner nos besoins et de ne pas être limités par la plateforme matérielle lors du développement. Avec son processeur Cortex-M7



FIGURE 2.12 Photo setup stm32

de 480 MHz, elle est suffisamment rapide pour effectuer toutes les tâches d'acquisition dans les temps impartis.

TABLEAU 2.4 STM32H747 Spécifications du CPU, GPIO, DMA et ADC

Catégorie	Détails
CPU	<ul style="list-style-type: none"> - 32-bit Arm® Cortex®-M7 core avec FPU double précision et cache L1 : 16 Ko de données et 16 Ko d'instructions - Fréquence jusqu'à 480 MHz, 1027 DMIPS/2.14 DMIPS/MHz - 32-bit Arm® Cortex®-M4 core avec FPU, ART Accelerator pour l'accès mémoire interne et instructions DSP - Fréquence jusqu'à 240 MHz, 300 DMIPS/1.25 DMIPS/MHz
GPIO	- Jusqu'à 168 I/O avec support d'interruption
DMA	<ul style="list-style-type: none"> - 1x contrôleur MDMA (Memory Direct Memory Access) - 2x DMA double-port avec FIFO - 1x DMA de base avec capacités de routage de requêtes
ADC	- 3x ADCs 16 bits (jusqu'à 36 canaux, 3.6 MSPS)

2.1.3.1 Implémentation Logiciel matériel

Le logiciel exécuté sur le microcontrôleur est codé en C++. Il est flashé grâce à l'environnement de développement PlatformIO, qui utilise ST-Link pour uploader le programme sur la carte de développement.

Le programme est séparé en trois modules distinct :

- **Module communication PC** : Gère l'envoi des données et la réception des commandes venant du PC de recherche.
- **Module de lecture AD8232** : Effectue la lecture à intervalles réguliers des mesures différentielles analogiques ECG.
- **Module de communication LDC1612** : Envois les commandes d'écriture des registres aux LDC1612s, et lit les données lorsque la ligne d'interruption d'un des LDC1612s est levée.

Chaque module est développé et appelés selon une structure similaire, une fonction d'initialisation configure le module lors du lancement du programme et ensuite la routine de chaque module est appelé dans la boucle principale du programme. Dans le but de pouvoir respecter les temps d'acquisition, le programme ne contient **aucune condition bloquantes** excepté lors de l'initialisation et est uniquement **dirigée par des interruptions**.

2.1.3.1.1 Module d'acquisition (Acq) ECG AD8232

Ce module utilise un **timer** matériel et le **convertisseur analogiques-numérique (ADC)** du STM32. Il est peu complexe et fonctionne de la manière suivantes :

1. Initialisation du timer à une fréquence de 500 Hz.
2. Initialisation de la résolution de l'ADC à 16 bits.
3. Configuration de l'interruption et de la fonction d'interruption de fin de timer.
4. Dans la fonction d'interruption **un drapeau est levé** signifiant que 2 ms se sont écoulés.

5. Dans la routine principale **si le drapeau est levé**, les 3 valeurs analogiques des cartes d'acquisition ECG sont lues et poussées dans le buffer de données de ECG.

2.1.3.1.2 Module d'acquisition (Acq) Respiration (RSP) LDC1612

Comme mentionné précédemment, ce module configure les LDC1612 lors de l'initialisation, en paramétrant les registres selon la procédure décrite dans la section 2.1.2.1. Il configure ensuite les différents composants matériels du processeur nécessaires à l'application. Premièrement, il configure **le périphérique I2C**, utilisé pour communiquer avec **chaque LDC1612** en assignant les valeurs GPIO correspondantes, ainsi que **la ligne d'interruption** qui indique lorsque **les données sont prêtes** pour chaque carte d'acquisition. La figure 2.13 décrit le fonctionnement

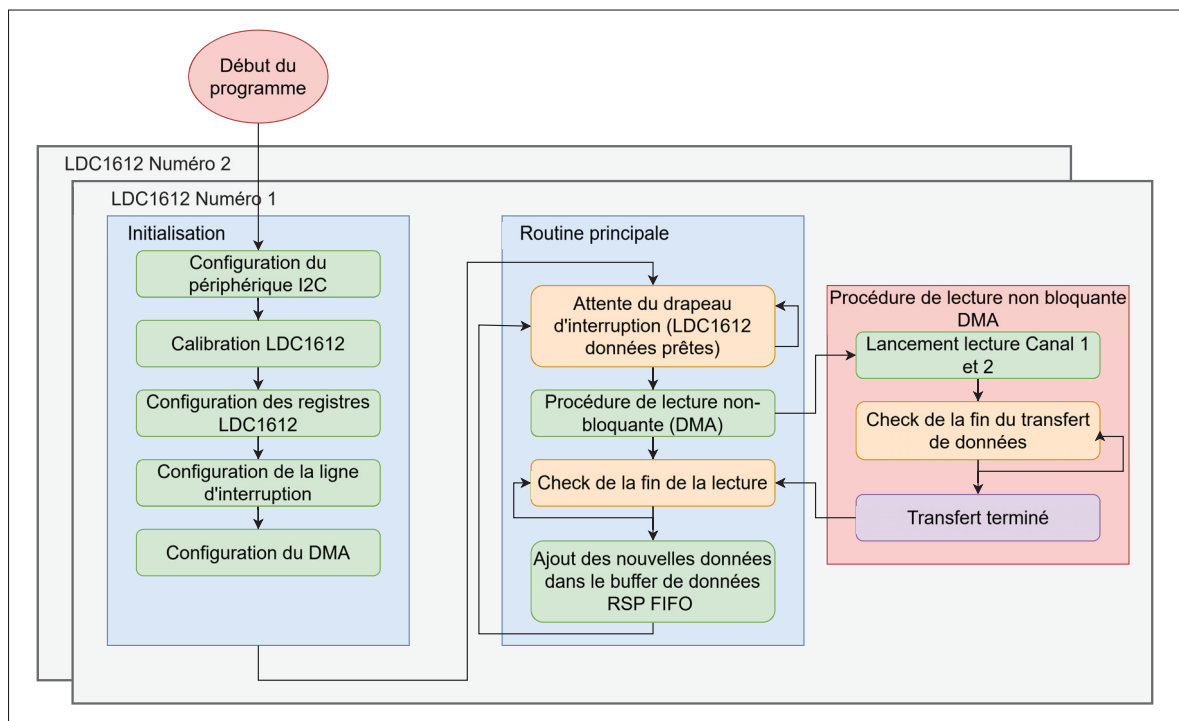


FIGURE 2.13 Diagramme Séquence générale module de communication LDC1612

général du module. **Initialisation :**

- **Configuration du périphérique I2C** : le processeur configure le bus I2C, qui est utilisé pour la communication entre le microcontrôleur et les LDC1612.
- **Calibration LDC1612** : chaque LDC1612 est calibré.
- **Configuration des registres LDC1612** : les registres internes de chaque LDC1612 sont configurés.
- **Configuration de la ligne d'interruption** : une ligne d'interruption est configurée pour signaler lorsque de nouvelles données sont prêtes.
- **Configuration du DMA** : le DMA (Direct Memory Access) est configuré pour permettre le transfert des données sans bloquer le processeur.

Routine principale :

- Le programme attend un **drapeau d'interruption** indiquant que les données sont prêtes à être lues sur le LDC1612.
- Ensuite, une **procédure de lecture non bloquante** (via DMA) est lancée, permettant de lire les données des canaux 1 et 2 sans bloquer le processeur.
- Lorsque le **transfert des données est terminé**, le programme reprend son cycle pour surveiller les prochaines interruptions.

Ce diagramme montre le fonctionnement asynchrone du module grâce à l'utilisation du DMA, permettant de libérer le processeur pendant la lecture des données, ainsi que la gestion efficace des interruptions pour assurer un traitement en temps réel et respecter les temps d'échantillonnage.

2.1.3.1.3 Module de communication PC

La mission de ce module est de recevoir/envoyer les informations et données depuis/vers le PC. Pour ce faire, une **bibliothèque de sérialisation** est utilisée pour communiquer par liaison série vers le port USB du PC de recherche (PB2, 2024). **La sérialisation utilise un protocole simple**, défini de la manière suivante :

- **Octet de début** : Cet octet marque le début du message.

- **ID du paquet (8 bits)** : Ce champ contient l'identifiant du paquet, codé sur 8 bits, permettant de définir le type de message.
- **Données (0 à 256 octets)** : Contient les données à transmettre, qui peuvent aller de 0 à 256 octets selon la taille des informations.
- **CRC 8 bits** : Un "Cyclic Redundancy Check" (CRC) est ajouté pour vérifier l'intégrité des données et détecter les erreurs lors de la transmission.
- **Octet de fin** : Cet octet indique la fin du message.

L'application Python sur le PC fait usage de la bibliothèque logicielle précédemment mentionnée pour sérialiser et désérialiser ce message. Pour l'envoi des données, le processus est simple. Dans la routine principale, le module vérifie s'il y a de **nouvelles données dans la mémoire tampon circulaire**. Si oui, les données sont envoyées selon **le principe du premier arrivé, premier servi**. Ce module est actif uniquement si de nouvelles données sont disponibles, et son impact sur le temps du processeur est donc très limité. Une fois les données envoyées vers le PC de recherche, c'est l'application python qui prend le relais et reçoit les données.

2.1.4 Logiciels d'acquisition PC python

Le logiciel d'acquisition est une application Python dont la structure principale est présentée sur la figure 2.14. Il est responsable de plusieurs tâches effectuées en parallèle : premièrement, la réception des données provenant de la plateforme STM32 ainsi que du système de référence Biopac. Une fois ces données reçues, elles sont envoyées vers le module d'interface utilisateur pour être affichées en temps réel sur l'ordinateur de recherche, et publiées sur le flux LSL (présenté dans la section 2.1.7) afin de synchroniser les données expérimentales avec celles de référence. Enfin, l'application est également responsable de la lecture des images provenant de la caméra et de la publication de marqueurs temporels dans le flux LSL à chaque image reçue, permettant ainsi une post-synchronisation des signaux et de la vidéo.

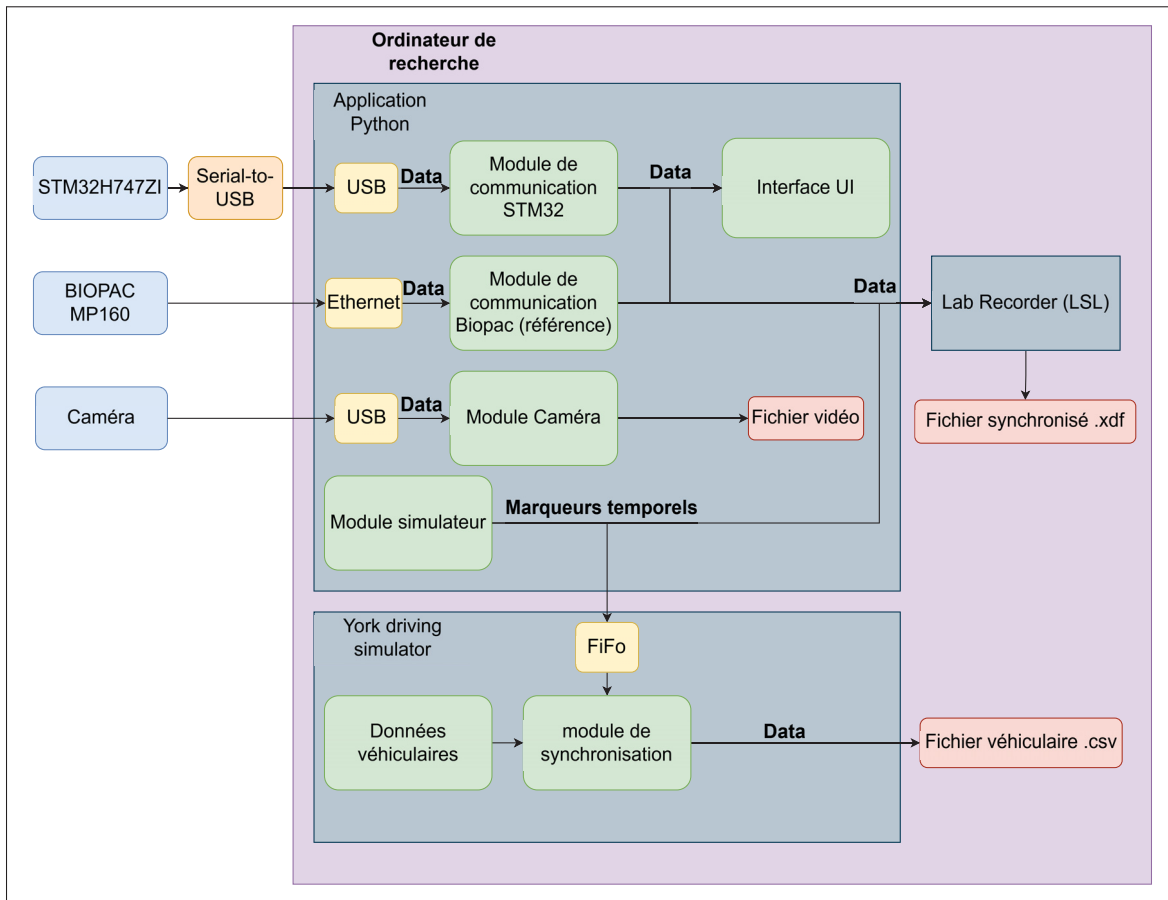


FIGURE 2.14 Diagramme général de l'application python

2.1.4.0.1 Module de communication STM32

Ce module indépendant, utilisant un processus distinct, assure la communication avec la plateforme embarquée. Il s'active uniquement lorsqu'un message est reçu depuis le STM32 ou lorsqu'une commande doit être envoyée vers celui-ci. Voici la manière dont il procède :

1. Attente de nouveaux messages.
2. Désérialisation du message reçu à l'aide de la bibliothèque "Serial Transfer" présentée précédemment.
3. Mise en forme des données selon leur type (RSP ou ECG).
4. Envoi des données vers le module UI.

5. Sauvegarde des données dans un fichier CSV.
6. Publication des données sur le flux LSL pour synchronisation.
7. Envoi des commandes vers le STM32 si nécessaire.

2.1.4.0.2 Interface graphique

L'interface graphique a été codée en Python à l'aide de la bibliothèque PyQt5. Elle est séparée en deux vues principales : une vue pour les données expérimentales et une autre pour les données de référence. Cela permet d'effectuer un diagnostic rapide des données avant le lancement de l'acquisition. La vue des données de référence est montrée par la figure 2.15 et celle des données expérimentales par la figure 2.16.

L'interface dispose aussi de quelques boutons permettant d'envoyer des commandes vers le STM32. Par exemple, elle permet de lancer une calibration automatique des électrodes inductives à n'importe quel moment, ou encore de lancer un redémarrage logiciel de la plateforme embarquée. Elle autorise également le chercheur à activer l'acquisition de la référence ou non, et permet de lancer ou stopper l'acquisition des données expérimentales et de référence simultanément.

2.1.4.0.3 Module de communication Biopac

Ce module permet d'interagir avec le système Biopac grâce à une couche logicielle Python autour des pilotes Windows fournis par la compagnie dans des fichiers .dll. Au début du programme, notre application tente de se connecter au système Biopac via la connexion Ethernet. Si elle y parvient, le programme attend l'instruction pour lancer l'acquisition. Une fois l'acquisition lancée, notre module Python doit lire les données au fur et à mesure qu'elles sont disponibles. Pour ne pas perdre de données, ce module est également contenu dans **un processus séparé** et communique par **file d'attente FIFO** avec le programme principal lorsque de nouvelles données sont reçues. Comme pour les données expérimentales, les données de référence sont publiées



FIGURE 2.15 Interface signaux de référence de l’application python

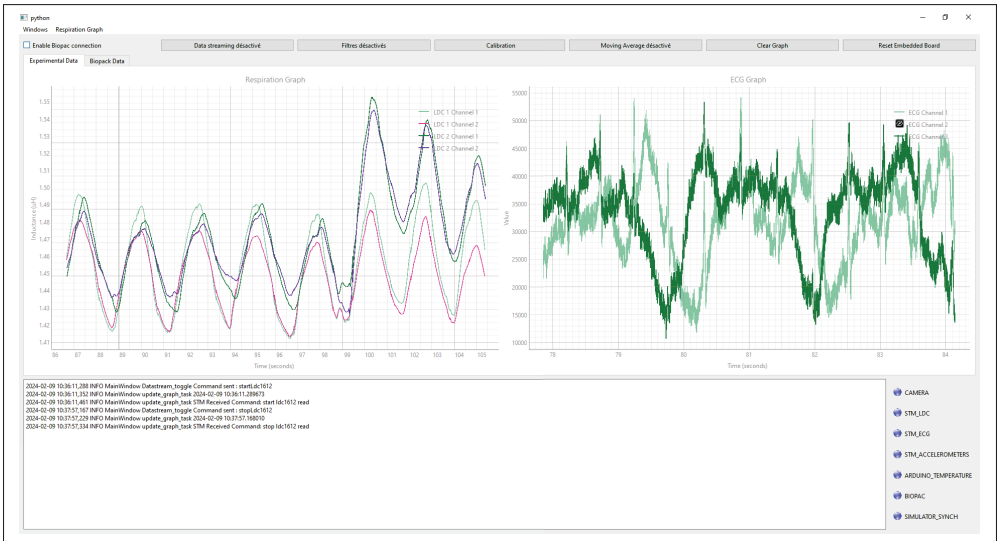


FIGURE 2.16 Interface signaux expérimentaux de l’application python

sur le flux LSL le plus rapidement possible pour effectuer la post-synchronisation dans Lab Recorder.

2.1.4.0.4 Module caméra

La caméra est connectée à un port USB de l'ordinateur de recherche, en utilisant la bibliothèque python opencv2, les images sont lues aussitôt qu'elles sont disponibles. Le module fonctionne comme suit :

1. La caméra est initialisée avec une résolution de 640x480 pixels et une fréquence de 30 images/secondes.
2. Une fois l'acquisition lancée, les images sont lues dès qu'elles sont disponibles. À chaque image :
 - a. L'image est ajoutée au fichier vidéo.
 - b. Le compteur d'images est incrémenté et envoyé sur le flux LSL comme illustré sur la figure 2.17.

Grâce à l'envoi d'un compteur comme marqueur vers LSL, il est possible de réaliser la post-synchronisation des données vidéo par la suite à l'aide du compteur et de leurs coordonnées temporelles dans le flux LSL, et d'associer l'image correspondante.

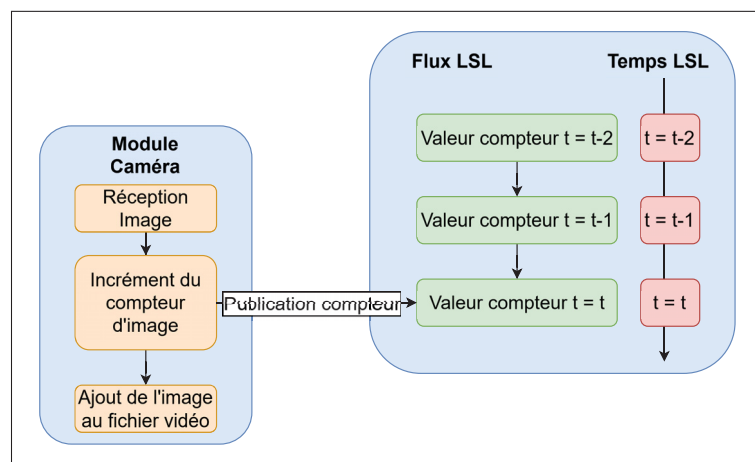


FIGURE 2.17 Interface signaux de référence de l'application python

2.1.4.0.5 Synchronisation Simulateur

Le module de synchronisation du simulateur est effectuée à l'aide d'une communication entre le simulateur et l'application Python. Le module de synchronisation envoie un compte toutes les 2 secondes au logiciel de simulation à l'aide d'une communication de type Fifo. Ce dernier aligne ensuite ce compteur avec la prochaine donnée véhiculaire qu'il enregistre. Au même moment, le module de synchronisation envoie aussi un compte dans le flux LSL pour permettre la post-synchronisation.

2.1.5 Extraction Perclos

Le PERCLOS est extrait en post-traitement à l'aide de la bibliothèque **Mediapipe** de Google. Les marqueurs faciaux sont extraits de chaque image et la figure 2.18 montre l'Eyes-Aspect-Ratio (EAR) qui est calculé. Cette valeur est ensuite sauvegardée pour la post-synchronisation. Le PERCLOS est ensuite déterminé par le pourcentage de temps, sur **1 minute**, durant lequel les valeurs de EAR passent en dessous d'un certain seuil, considérant alors que les yeux sont fermés.

Les sujets ayant des ouvertures différentes pour chacun, il a été nécessaire d'adapter les seuils




FIGURE 2.18 Rapport hauteur/largeur des yeux
Tirée de Borza *et al.* (2018)

de fermeture dans le but d'éviter la saturation ou la non-fermeture des yeux, se fut effectué au cas par cas pour chaque sujet.

2.1.6 Référence Biopac

Le système de référence sur la figure 2.19, le Biopac MP160, est une référence en matière d'acquisition de signaux physiologiques dans un contexte de recherche. Il dispose de plus



FIGURE 2.19 Système de référence Biopac

de 53 000 références sur Google Scholar, la majorité des publications de recherche dans le milieu biomédical utilise ce système pour acquérir leurs signaux de référence. Pour l'étude, nous

disposons du MP160 et de sa version sans fil. La figure 2.20 présente les capteurs de référence utilisés :

- 1 Capteur ECG une dérivation.
- 1 Ceinture de respiration.
- 1 Capteur PPG à l'oreille gauche.




FIGURE 2.20 Capteurs de référence Biopac

Lors de l'acquisition, il est configuré pour effectuer un échantillonnage à **500 Hz** pour tout les canaux.

2.1.7 Synchronisation des données (Lab Streaming Layer)

LSL est une plateforme open-source de middleware en réseau qui facilite la transmission, la réception, la synchronisation et l'enregistrement des flux de données neuronales, physiologiques et comportementales provenant de différents capteurs (Christian Kothe, Medine, Chadwick Boulay, Tristan Stenner & Matthew Grivich, 2024). La bibliothèque contient des interfaces C, C++, Python, Matlab, et permet à tous ces programmes de pouvoir communiquer entre eux.

Le Lab Streaming Layer intègre une fonctionnalité de synchronisation temporelle pour toutes les données enregistrées, conçue pour atteindre une précision inférieure à la milliseconde sur un réseau local d'ordinateurs. Cette fonctionnalité permet une collecte de données synchronisée sans configuration supplémentaire. La synchronisation temporelle intégrée s'inspire du protocole NTP (Network Time Protocol), largement utilisé, et est implémentée dans la bibliothèque LSL.

La figure 2.21 illustre comment le « LSL Lab Recorder » est utilisé dans ce projet. Cette application permet de recevoir les données venant des sources LSL : le module Biopac, le module STM32 et le module de caméra. Ces données sont ensuite sauvegardées.

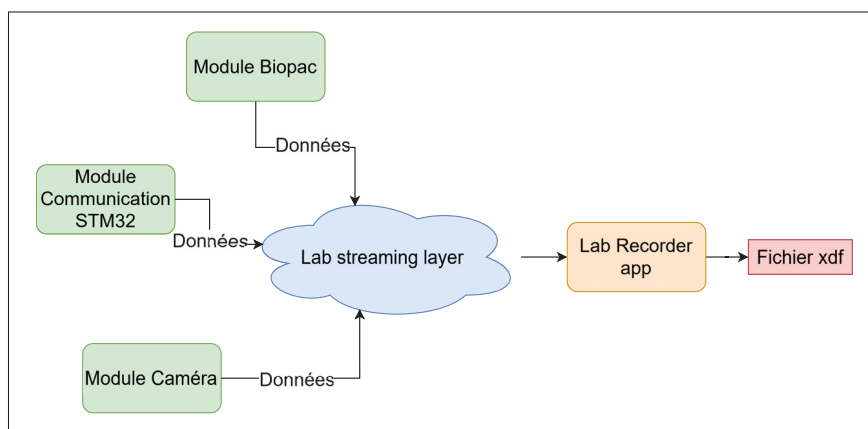


FIGURE 2.21 Lab streaming layer et Lab Recorder

Pour la post-synchronisation, le fichier «.xdf» contenant les données disposant d'une coordonnées temporelles sont lues. Les marqueurs de la caméra et du simulateur sont utilisés pour réaligner

les données de perclos et véhiculaires. Puis les données sont sauvegardés dans des fichiers selon des coordonnées temporelles synchronisées.

La synchronisation pour le PERCLOS est simple ; chaque image dispose d'un marqueur. Les données « EAR » partagent donc les mêmes marqueurs. Ces marqueurs ont tous des coordonnées temporelles dans le fichier « .xdf ».

Voici une brève description de la méthode de synchronisation :

1. Lecture des **marqueurs n et $n+1$** et de leurs coordonnées temporelles dans le fichier « .xdf » LSL.
2. Lecture des données récoltées **entre les deux marqueurs** dans le fichier de données du simulateur.
3. **Réassignement de coordonnées temporelles** aux données basé sur celles des marqueurs dans LSL à l'aide d'un rééchantillonnage basé sur une extrapolation linéaire.
4. **Sauvegarde** des données synchronisées selon le temps de LSL dans un fichier « .csv ».

La synchronisation logicielle est une composante cruciale de l'expérience pour pouvoir comparer les mesures expérimentales et les mesures de référence. Le LSL a permis de gagner un temps précieux lors de l'implémentation, ce qui a permis d'éviter une synchronisation matérielle beaucoup plus ardue.

Après avoir présenté l'architecture, la méthodologie utilisée dans le but d'améliorer les performances de notre système expérimental sera présentée.

2.2 Méthodologie de traitement de signal

Le système présenté précédemment permet l'acquisition de signaux de référence de bonne qualité grâce à l'utilisation d'une ceinture respiratoire invasive. Cependant, les données expérimentales obtenues à l'aide d'électrodes textiles inductives sont de moins bonne qualité et plus sensibles aux artéfacts de mouvement, comme observé dans différentes études, notamment dans le Chapitre 1.

Pour résoudre ce problème, deux méthodes ont été développées et comparées dans ce mémoire :

1. Sélection des signaux selon des indices de qualité.
2. Fusion des signaux par filtre de Kalman.

2.2.1 Prétraitement du signal

Avant d'appliquer les deux méthodes citées plus haut, il est nécessaire d'effectuer quelques étapes de prétraitement. L'objectif de cette étape est de retirer préalablement les composantes indésirables des signaux associées aux artefacts de mouvement ou à l'instrumentation expérimentale.

2.2.1.1 Rééchantillonnage

Après avoir synchronisé les signaux dans leurs fichiers de données respectifs, les données sont **rééchantillonnées** de manière uniforme. Les signaux venant du simulateur, des vidéos, de la référence Biopac et du système inductif textile sont tous **rééchantillonnés à 25 Hz** et filtrés selon la fréquence de Nyquist si l'on effectue un sous-échantillonnage.

2.2.1.2 Filtrage

Pour s'assurer de conserver uniquement les composantes fréquentielles associées à la respiration, un filtrage numérique est appliqué aux données de respiration de référence et expérimentales. Le signal de respiration au repos étant compris entre 12 et 20 respirations par minute (Chourpiliadis & Bhardwaj, 2024), ce qui correspond à 0,2 et 0,33 Hz, il est nécessaire de filtrer le signal autour de ces fréquences. Dans notre étude, ayant des signaux pouvant varier lentement avec le temps en raison des mouvements relatifs de la ceinture et du conducteur, un filtre à réponse impulsionnelle infinie **passe-bande d'ordre 2 de Butterworth** avec une **fréquence de coupure de [0,05-0,8 Hz]** appliqué dans les deux sens est utilisé. Cela permet d'éliminer les composantes basse fréquence, rendant inutile la suppression de tendance. De plus, la fréquence supérieure de 0,8 Hz nous permet de capter des schémas respiratoires anormaux pouvant être

liés à la somnolence jusqu'à **48 respirations/minute** (0,8 Hz), tout en conservant l'intégrité du signal respiratoire.

Ces fréquences de coupure permettent de retirer une partie des artéfacts de mouvement compris entre 0,01 et 10 Hz (Lee, Kim, Park & Kim, 2020).

2.2.1.3 Standardisation

Une fois le signal filtré à l'aide d'un filtre passe-bande d'ordre 2 avec des fréquences de coupure de 0,05-0,8 Hz, nous procédons à une étape de standardisation par **z-score glissant**. Cette méthode permet de rendre le signal plus robuste aux variations locales, et l'amplitude des pics de respiration est normalisée selon l'écart-type des données (Włodarczak, 2019).

Le z-score est une méthode de standardisation qui permet de ramener les valeurs d'une distribution autour d'une moyenne nulle avec un écart-type unitaire. La version glissante de cette méthode consiste à calculer le z-score sur une fenêtre mobile (définie par une durée en secondes). Le calcul se fait via l'équation suivante :

$$Z(n) = \frac{X(n) - \mu_w(n)}{\sigma_w(n)} \quad (2.3)$$

où $X(n)$ est la valeur du signal à l'instant n , $\mu_w(n)$ et $\sigma_w(n)$ sont respectivement la moyenne et l'écart-type du signal dans la fenêtre mobile centrée autour de n .

Sur la figure 2.22, la taille de la fenêtre choisie est de 30 secondes, ce qui permet de mieux réagir aux variations extrêmes qui seraient trop peu minimisées par une fenêtre plus grande. Cependant, une fenêtre trop petite peut amplifier les variations de plus haute fréquence et altérer le signal. Cette approche facilite la comparaison des signaux provenant de différentes sources, comme ceux de la ceinture inductive et du système de référence Biopac, en s'assurant que les différences de magnitude ou de tendance n'influencent pas la détection des pics de respiration.




FIGURE 2.22 Normalisation par Z-score
avec une fenêtre de 30 secondes

2.2.2 Algorithme d'estimation du rythme respiratoire

Si l'estimation du rythme respiratoire est une étape cruciale, le choix de l'algorithme l'est tout autant. Pour détecter le rythme respiratoire, on peut utiliser des techniques fréquentielles ou des techniques temporelles. Dans notre cas, les techniques temporelles sont à privilégier si l'on veut récupérer l'évolution des écarts inter-respiratoires (Charlton *et al.*, 2018) afin de favoriser la détection de la somnolence.

Dans l'évaluation des algorithmes proposée par Charlton, Bonnici, Tarassenko, Clifton, Beale & Watkinson (2016), les meilleurs résultats étaient obtenus à l'aide des algorithmes utilisant la détection dans le domaine temporel des pics. La meilleure performance obtenue était celle de l'algorithme détectant les pics et les vallées, puis définissant un seuil à 0.2 fois le 75^e percentile des valeurs des pics.

Lors de cette étude, une méthode similaire mais plus récente a été utilisée (Khodadad, Nordebo, Müller, Waldmann, Yerworth, Becher, Frerichs, Sophocleous, van Kaam, Miedema, Seifnara-

ghi & Bayford, 2018), basée sur **la détection de croisements avec zéro**. L'algorithme fonctionne comme suit :

1. Recherche d'un croisement avec zéro.
2. Si le croisement avec zéro est montant, l'algorithme attend le prochain croisement descendant.
3. Si une alternance de croisements est confirmée, on recherche le minimum ou le maximum entre les deux croisements.
4. La dernière étape consiste à retirer les pics dont l'écart d'amplitude est inférieur à la valeur médiane de l'écart pics-vallées, multipliée par un facteur de seuil.

Le facteur de seuil est défini à 0.3, mais il peut être modifié pour être plus ou moins permissif. Cet algorithme a été mis en place à l'aide de la librairie python (Makowski *et al.*, 2021) disponible à cette adresse : <https://neuropsychology.github.io/NeuroKit/>.

Pour finir, **une correction des pics** de respiration est appliquée. Si un nouveau pic est supérieur à trois fois la moyenne inter-pics des pics précédents, ce pic est supprimé dans le but de **retirer les valeurs extrêmes**.

2.2.3 Amélioration de l'estimation du rythme respiratoire

Pour réduire l'impact des artefacts de mouvements et améliorer la fiabilité de nos capteurs sans contact, deux méthodes basées sur l'acquisition de plusieurs capteurs textiles inductifs ont été exploré :

1. **Choix du meilleurs signal de respiration**, par indices de qualité.
2. **Fusion de signaux respiratoire** à l'aide d'un filtre de **kalman**.

2.2.3.1 Choix par vote

Pour le choix par vote nous utilisons trois indice de qualité différents présenté lors de la revue de littérature :

1. **Indice de pureté spectrale (SPI)** (Sörnmo & Laguna, 2005), cet indicateur permet de caractériser le fait que la bande de fréquence est concentrée autour d'une seule fréquence. Le SPI d'un sinus pur sera égale à 1, cet indice a l'avantage de pouvoir être calculé échantillon par échantillon si désiré.
2. **Ratio de densité spectrale (SDR)**, c'est un simple ratio de la puissance contenue dans la bande d'intérêt sur la bande de fréquence totale.
3. **Corrélation avec fusion dynamique**, À l'aide d'une fenêtre roulante les vagues de respiration sont segmentés et utilisés pour créer une vague de respiration moyenne, ensuite la corrélation de chaque vague avec celle moyenne est calculé. Et pour finir, la corrélation moyenne est utilisé comme indice. Cet indice donne une indication sur **la stabilité de la morphologie des respirations** et donc sur le bruit qui les affectes.

Ces indices sont calculés avec une fenêtre roulante de 60 secondes avec un pas de 10 secondes. La figure 2.23 donne un exemple de l'évolution des indices avant et après filtrage. On remarque que le SPI est fortement impacté par le signal. Cela est dû à l'utilisation de la dérivée seconde dans la formule ; il est donc nécessaire de filtrer le signal avant d'utiliser cet indice, comme spécifié par Sörnmo & Laguna (2005). Pour reconstruire le signal en utilisant uniquement




FIGURE 2.23 Évolution des indices de qualité avant et après filtrage

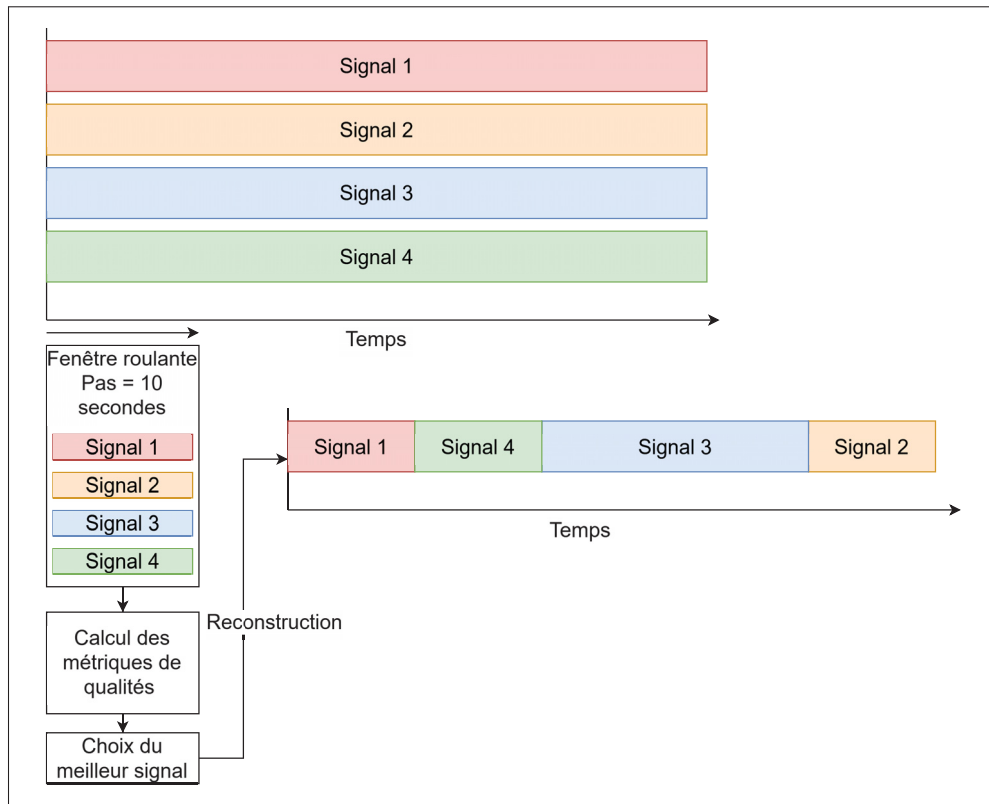


FIGURE 2.24 Schéma de la reconstruction du signal à l'aide des indices de qualité

les signaux de meilleure qualité, la figure 2.24 illustre la méthode utilisée. Lors de l'étape de sélection du meilleur signal, les indices sont additionnés et le signal obtenant le meilleur score est utilisé pour la reconstruction. Cette technique permet d'obtenir un signal dont les performances sont proches de celles du signal source ayant les meilleures performances.

2.2.3.2 Fusion par filtre de Kalman

Pour la fusion avec le filtre de Kalman, un simple filtre de Kalman linéaire est utilisé (Nemati *et al.*, 2010). Le filtre de Kalman est un filtre bayésien qui produit des prédictions d'états futurs basées sur son état actuel et la variance associée aux mesures. Il est utile pour minimiser les incertitudes des mesures et fusionner des signaux à l'aide de sa matrice de covariance.

L'étape de **prédiction** du filtre de Kalman consiste à estimer l'état futur du système basé sur l'état actuel et le modèle du système définis par l'ingénieur. Elle se formule de la manière suivante :

- Soit \mathbf{x} l'état estimé du système.
- \mathbf{P} la matrice de covariance associée à l'estimation de l'état.
- \mathbf{F} la matrice de transition d'état qui décrit comment l'état évolue.
- \mathbf{Q} la matrice de covariance du processus qui représente l'incertitude associée aux différents signaux d'entrée.
- \mathbf{B} la matrice d'entrée qui modélise l'effet des contrôles sur le système (**pas utilisée dans le cas de cette étude**).
- \mathbf{u} le vecteur d'entrée de contrôle (**pas utilisé dans le cas de cette étude**).

L'étape de prédiction se décompose en deux équations :

$$\hat{\mathbf{x}}_{k|k-1} = \mathbf{F}\hat{\mathbf{x}}_{k-1|k-1} + \mathbf{B}\mathbf{u}_k \quad (2.4)$$

$$\mathbf{P}_{k|k-1} = \mathbf{F}\mathbf{P}_{k-1|k-1}\mathbf{F}^\top + \mathbf{Q} \quad (2.5)$$

Dans ces équations :

- $\hat{\mathbf{x}}_{k|k-1}$ est la prédiction de l'état au temps k sachant l'état au temps $k - 1$.
- $\mathbf{P}_{k|k-1}$ est la matrice de covariance prédite, représentant l'incertitude de l'état prédit sachant l'état la covariance aux temps précédent.

L'étape de **mise à jour** du filtre de Kalman permet de corriger l'estimation prédite en fonction des nouvelles observations mesurées.

Les termes utilisés sont les suivants :

- \mathbf{z} est la mesure observée.
- \mathbf{H} est la matrice d'observation qui relie l'état à la mesure.

- \mathbf{R} est la matrice de covariance du bruit de mesure, représentant l'incertitude des mesures.
- \mathbf{I} est la matrice identité.

L'étape de mise à jour se décompose en quatre équations principales :

$$\mathbf{y} = \mathbf{z} - \mathbf{H}\hat{\mathbf{x}}_{k|k-1} \quad (2.6)$$

$$\mathbf{K} = \mathbf{P}_{k|k-1}\mathbf{H}^\top (\mathbf{H}\mathbf{P}_{k|k-1}\mathbf{H}^\top + \mathbf{R})^{-1} \quad (2.7)$$

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}\mathbf{y} \quad (2.8)$$

$$\mathbf{P}_{k|k} = (\mathbf{I} - \mathbf{K}\mathbf{H})\mathbf{P}_{k|k-1} \quad (2.9)$$

Dans ces équations :

- \mathbf{y} est la différence entre la mesure observée et la prédiction.
- \mathbf{K} est le gain de Kalman, qui ajuste le poids donné à la différence \mathbf{y} en fonction de la matrice covariance de la prédiction et de la mesure.
- $\hat{\mathbf{x}}_{k|k}$ est l'estimation mise à jour de l'état après la correction.
- $\mathbf{P}_{k|k}$ est la matrice de covariance mise à jour, représentant l'incertitude corrigée de l'estimation.

Ces équations sont directement tirées du livre (Roger R. Labbe Jr, 2024b). Dans l'étude de ce mémoire, la bibliothèque Python FilterPy (Roger R. Labbe Jr, 2024a) est utilisée pour développer le filtre de Kalman. Le rôle de l'ingénieur pour développer le filtre se limite à quelques étapes. Premièrement, la matrice de transition \mathbf{F} est définie, comme nous ne disposons pas de modèle pour prédire l'état futur. La valeur du signal futur est égale à sa valeur précédente, plus une

incertitude, comme proposé par Nemati *et al.* (2010) $\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_{k-1}$. Ensuite, la matrice de bruit de mesure \mathbf{R} et la matrice de covariance \mathbf{Q} doivent être initialisées :

1. \mathbf{R} est **initialisée à 1** (Nemati *et al.*, 2010).
2. \mathbf{Q} doit être déterminée empiriquement : si sa valeur est trop petite, le filtre ne s'ajustera pas suffisamment aux nouvelles observations, tandis qu'une valeur trop grande fera que le filtre suivra les nouvelles observations de manière excessive, dans le cas de ce mémoire, elle est initialisée à 1.




FIGURE 2.25 Fusion des signaux de respiration par le filtre de Kalman

Une fois le filtre initialisé, il peut être utilisé sur la figure 2.25 pour fusionner les signaux préalablement filtrée ou non. On peut d'ailleurs observer l'avantage de cette fusion sur la figure 2.25, le filtre minimise l'impact des petites variations et maximise celles communes aux signaux.

2.3 Expériences

Après avoir présenté les méthodes utilisées pour acquérir les signaux respiratoires à l'aide des électrodes textiles et celles de référence ainsi que les techniques de traitement de signal proposées pour améliorer la qualité des signaux, il est nécessaire de tester leurs performances à travers des expérimentations. Au cours de ce mémoire, deux expériences ont été réalisées : une expérience en situation de conduite pour explorer les performances de différentes configurations d'électrodes ainsi que leurs positions, et une expérience incluant 75 h de données de conduite sur simulateur ayant pour but de provoquer des épisodes de somnolence.

2.3.1 Simulateur de conduite

Le York driving simulator est un logiciel qui a été utilisé à plusieurs reprises dans la littérature pour divers types d'études psychomotrices. Il permet de concevoir des scénarios de conduite hautement personnalisés. Il enregistre la vitesse, la déviation de la route, l'activité du volant et de nombreuses autres métriques à une fréquence d'échantillonnage de 25 Hz.

Dans le but d'assurer un maximum d'immersion, trois téléviseurs Samsung 1080p de 32 pouces chacun ont été utilisés pour créer une vue panoramique de la route. Le dispositif « Logitech G29 Driving Force Race Wheel » a été utilisé comme volant et pédale d'accélération. Le « GTR driving simulator » sert de support principal et comporte un siège ajustable ainsi que des supports pour les écrans. Un cadre a été installé en vue d'installer une ceinture de sécurité pour l'application des électrodes textiles. Enfin, un coussin recouvert de velcro a été agencé au siège pour améliorer le confort et permettre l'attache des électrodes capacitatives.

2.3.2 Étude des positions et des formes d'électrodes textiles

Dans la littérature, deux positions sont utilisées par les chercheurs pour détecter la respiration : dans le dos (Walter *et al.*, 2011) et à l'avant (Cho *et al.*, 2022 ; Leicht *et al.*, 2017). Dans certains articles, plusieurs formes d'électrodes textiles sont testées (Cho *et al.*, 2022). Cependant, aucune comparaison entre les électrodes situées à l'avant et à l'arrière n'a été effectuée.



FIGURE 2.26 Vue globale du simulateur

Dans cette expérience, nous proposons d'apporter des réponses préliminaires aux questions suivantes :

1. Quelles positions avec les électrodes de petite taille inspirées de (Koo *et al.*, 2014) obtiennent les meilleures performances dans le dos ?
2. Quelles formes et tailles obtiennent les meilleures performances dans le milieu du dos ?
3. Les électrodes intégrées à la ceinture obtiennent-elles de meilleures performances que celles dans le dos ?

Pour cela, un essai en situation de conduite a été effectué sur 3 sujets, référencés par le tableau 2.6 de morphologie très différente. Huit tests, résumés dans le tableau 2.5 de 10 minutes, ont été réalisés par chaque sujet aux positions de la figure 2.27.

Lors de chaque test, les sujets étaient installés dans le simulateur en suivant le même scénario de conduite, alternant des courbes lentes à gauche et à droite, parfois entrecoupées d'une courbe plus intense. De plus, il leur était demandé de ne pas effectuer de mouvements anormaux afin de conserver une homogénéité dans les tests effectués.

TABLEAU 2.5 Tableau des tests des positions et tailles des électrodes textiles

Type d'Électrode	Position	Position Verticale	Taille de l'Électrode	Modèle d'Électrode
Circulaire	Dos	Haut (3)	Petite	A.73.12
Circulaire	Dos	Milieu (2)	Petite	A.73.12
Circulaire	Dos	Bas (1)	Petite	A.73.12
Circulaire	Dos	Milieu (2)	Moyenne	A.73.20
Circulaire	Dos	Milieu (2)	Grande	A.73.15
Rectangulaire	Dos	Milieu (2)	Petite	A.73.40
Rectangulaire	Avant	4 positions simultanée	Grande	A.73.39
Rectangulaire	Avant	4 positions simultanée	Petite	A.73.40

Pour **quantifier la qualité des signaux expérimentaux**, les indices de qualité présentés précédemment, le **SDR**, **SPI** et la **corrélation avec le schéma de respiration**, seront utilisés, ainsi que **l'erreur absolue moyenne** avec le rythme respiratoire de **référence**.

Pour quantifier la morphologie des patients, une mesure a été effectuée afin de calculer une aire approximative du torse. La mesure d'épaule à épaule ainsi que la distance entre la base du cou et le nombril sont prises. Ces deux mesures sont ensuite multipliées entre elles et divisées par deux, suivant la formule 2.10 pour l'aire d'un triangle. Les résultats sont présentés dans le tableau 2.6.

$$A = \frac{1}{2} \times L_{\text{épaule}} \times D_{\text{cou-nombril}} \quad (2.10)$$

TABLEAU 2.6 Tableau des morphologies des sujets de l'étude de positions et tailles

Sujet	Épaule (cm)	Taille Torse (cm)	Aire Torse (cm ²)
1	55	52	1430
2	44	40	840
3	36	38	684

2.3.3 Étude de la somnolence en situation de conduite simulée

Ici, l'expérience principale de ce mémoire est présentée. Cette étude permet l'évaluation de l'efficacité du système d'acquisition avec des électrodes textiles inductives. Elle propose aussi

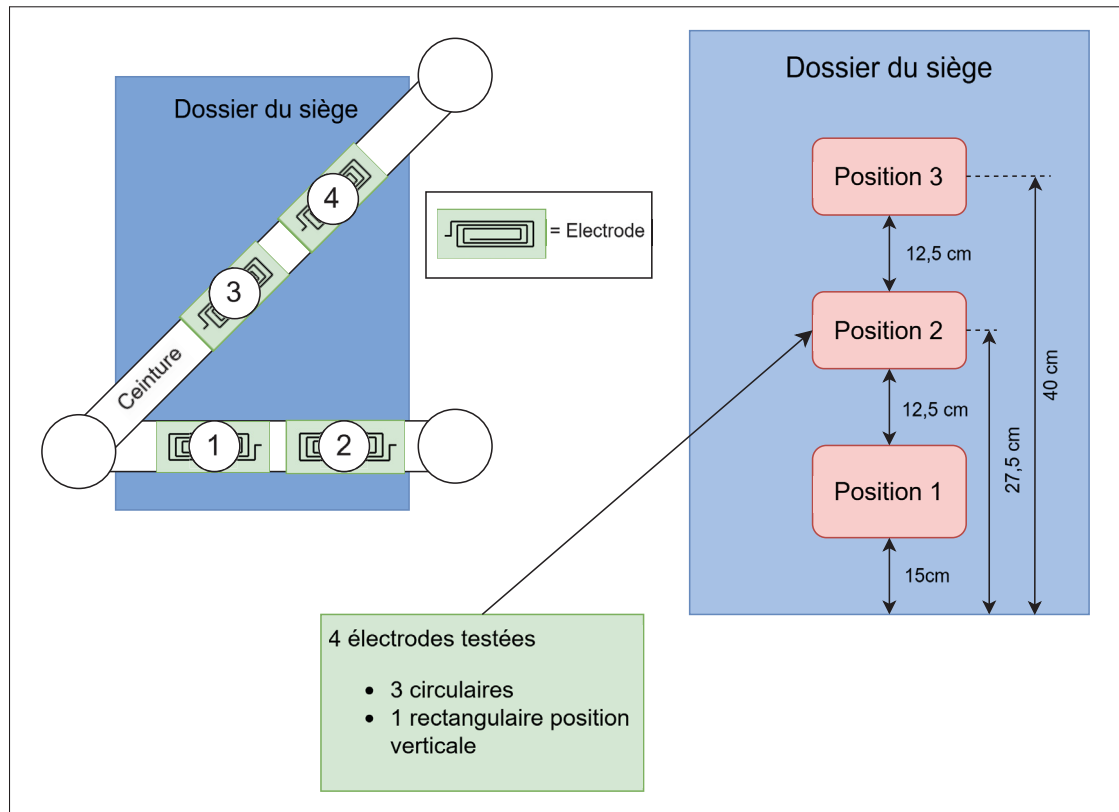


FIGURE 2.27 Schéma étude de positions et tailles

un premier pas vers la détection de la somnolence à l'aide de la respiration, en utilisant des électrodes inductives textiles.

2.3.4 Critère de sélection et consignes

Un total de 25 participants ont été choisis, totalisant 11 sujets féminins et 14 masculins. L'âge moyen était de 26,7 ($\pm 2,7$) ans. Le faible écart type en âge s'explique par le fait que le recrutement a été principalement réalisé auprès des étudiants de l'École de Technologie Supérieure. Chaque participant devait répondre à des critères de sélection spécifiques :

- Être en bonne santé générale.
- Avoir un permis de conduire et conduire au moins une fois par mois.
- Aucune consommation de drogues, café, stimulants ou alcool 48 heures avant l'expérience.

- Ne prendre aucun médicament sur ordonnance pouvant causer la somnolence.
- Avoir dormi entre 7 et 9 heures la nuit précédente.
- Ne pas avoir d'allergies connues au matériel médical.
- Ne pas avoir de problèmes de dos.
- Ne pas souffrir de problèmes de sommeil graves tels que la narcolepsie ou une insomnie sévère.

Chaque participant a reçu une compensation de 100 \$ pour sa participation.

2.3.5 Déroulement de l'expérience

L'expérience était séparée en deux parties. Pour la première, il était demandé aux sujets de se présenter pour 9 heures le matin. Voici un aperçu du déroulement de la session :

1. Explication de la procédure au participant (9h00-9h15).
2. Remplissage du questionnaire d'éligibilité (9h15-9h20).
3. Remplissage des questionnaires à des fins statistiques (9h20-9h35) :
 - a. Epworth Sleepiness Scale (ESS).
 - b. Pittsburgh Sleep Quality Index (PSQI).
 - c. Karolinska Sleepiness Scale (KSS).
 - d. Mensurations corporelles.
4. Familiarisation avec le simulateur selon un scénario de conduite active (9h20-9h35).
5. Test PVT (Psychomotor Vigilance Task) pour le temps de réaction (9h35-9h45).
6. Ajustement des capteurs pour l'individu et configuration du simulateur (9h45-10h00).
7. Expérimentation (10h00-11h30).
8. Désinstallation des systèmes d'acquisitions (capteurs) (11h30-11h45).
9. Tests et questionnaires post-expérience (PVT et KSS) (11h45-12h00).

Pour la deuxième partie, les étapes étaient les mêmes que pour la première partie, à l'exception du remplissage des questionnaires suivants : éligibilité, ESS, PSQI, ainsi que la prise des mensurations corporelles. La seconde expérience débutait à 21h00 (la conduite commençait à 22h00). Le protocole expérimental de la deuxième partie fut changé après 7 participants, car il a été observé qu'aucun participant ne semblait présenter des signes apparents de somnolence lors de cette conduite en fin de soirée. Il aurait été désirable que cette dernière commence plus tard, puisqu'il est connu depuis longtemps que le pic du nombre d'accidents liés à la somnolence se situe généralement entre 2h00 et 3h00 du matin (Horne & Reyner, 1995). Cependant, la logistique résultant d'une expérience se déroulant la nuit était prohibitive et sortait du cadre du projet, qui visait à examiner la somnolence lors de situations de conduite typiques (tard en soirée et tôt le matin). C'est pour cette raison que la deuxième séance a été placée à 13h30 (pour que l'expérience commence à environ 14h00), juste avant le pic d'après-midi de la probabilité des accidents liés à la somnolence. Grâce à ce changement, une augmentation des signes apparents de somnolence fut observée et l'expérience a pu se dérouler adéquatement.




FIGURE 2.28 Probabilité comparative des accidents liés à la somnolence en fonction du temps de la journée
Tirée de (Horne & Reyner, 1995)

2.3.6 Scénario de conduite

Le scénario de conduite a été conçu de façon à maximiser la monotonie de la géométrie de la route ainsi que de l'environnement. Pour ce faire, aucun bâtiment n'a été utilisé. Des arbres ont été parsemés de façon répétitive aux abords de la route afin de maintenir une certaine immersion. La route possède deux voies en sens inverse, séparées par une ligne pointillée de dépassement. Initialement, il était prévu que des véhicules circulent en sens inverse, mais il a été décidé de ne pas continuer dans cette voie pour éviter des arrêts de simulation trop fréquents (collisions frontales). Lors de la séance, il a été demandé aux participants de suivre à vitesse constante et à une distance raisonnable un véhicule de tête se déplaçant à une vitesse de 100 km/h tout en restant dans la voie de droite.




FIGURE 2.29 Vue générale de la carte et vue rapprochée de la route

Pour imiter les conditions variables de la conduite réelle et pour augmenter les chances que des dépassements de lignes se produisent, différentes courbes ont été incorporées dans la route. Il est possible de voir la forme générale sinueuse de la route dans l'image de droite de la figure 2.29. La largeur de la route était de 3,962 m et la largeur du véhicule était de 1,676 m. Une tolérance de 5 m pour la conduite hors route a été définie pour éviter que la simulation soit constamment arrêtée au moindre écart. Le chemin était séparé en 20 segments selon trois différents rayons de courbure. L'ordonnancement de ces segments a été réalisé de façon symétrique, tel qu'illustré

dans le tableau 2.7. Des indicateurs de courbes ont été placés juste avant chaque segment avec un rayon de 400 m pour prévenir les conducteurs d'un virage serré, tel qu'à l'image de 2.30.

TABLEAU 2.7 Rayon des segments en mètres

Segment	1	2	3	4	5	6	7	8	9	10
Rayon(m)	2000	2000	400	400	850	400	400	850	400	400
Segment	11	12	13	14	15	16	17	18	19	20
Rayon(m)	2000	2000	400	400	850	400	400	850	400	450



FIGURE 2.30 Panneaux de signalisation alertant le conducteur d'un virage serré

À une vitesse constante de 100 km/h, le participant met environ neuf minutes et demie pour faire un tour complet du circuit, pour un total minimum de neuf tours au cours des 90 minutes de l'expérience.

2.4 Méthodologie pour l'analyse des données de somnolence

Dans la section précédente, l'étude de la somnolence en situation de conduite incluant 25 sujets a été présentée. Ici, la démarche pour l'analyse de ces données sera présentée. L'objectif de cette analyse est de montrer si oui ou non les données de respiration de référence et idéalement textiles peuvent permettre la détection de la somnolence.

2.4.1 Segmentation des données somnolentes

La première chose nécessaire pour analyser les données est d'identifier les points d'intérêts. Comme mentionné, le PERCLOS est une donnée très répandue pour la détection de la somnolence (Albadawi *et al.*, 2022). Cependant, les valeurs de seuils associées à la somnolence peuvent varier en fonction des sujets et certaines études semblent montrer que le PERCLOS n'est pas une mesure absolue de la somnolence (Trutschel, Sirois, Sommer, Golz & Edwards, 2011). Pour répondre à ce problème lors de ce mémoire, la sélection des points d'intérêts associés à la somnolence a été effectuée à l'aide des accidents détectés dans le simulateur et une double vérification à l'aide des vidéos et du PERCLOS. Les accidents somnolents sont définis selon les conditions suivantes :

1. **Accidents** : les quatre roues du véhicule sont sorties de la route.
2. **Perclos** : Une augmentation significative du PERCLOS est observable cinq minutes avant l'accident et jusqu'à deux minutes après.
3. **Vidéo** : Une vérification vidéo confirme que le sujet présentait des symptômes avant ou lors du crash.

La figure 2.31 illustre la segmentation appliquée à un signal de rythme respiratoire d'un des sujets. On observe l'augmentation du PERCLOS avant l'accident symbolisée par la ligne verticale verte. Pour la segmentation, on utilise une fenêtre glissante de **5 minutes** avec un pas de 15 secondes, si le centre de la fenêtre est situé entre $t = -5\text{minutes}$ et $t = +2\text{minutes}$ par rapport à l'accident alors cette fenêtre est considérée comme contenant des données de somnolence. Pour les données non-somnolentes, celles situées **au moins 10 minutes avant un accident**

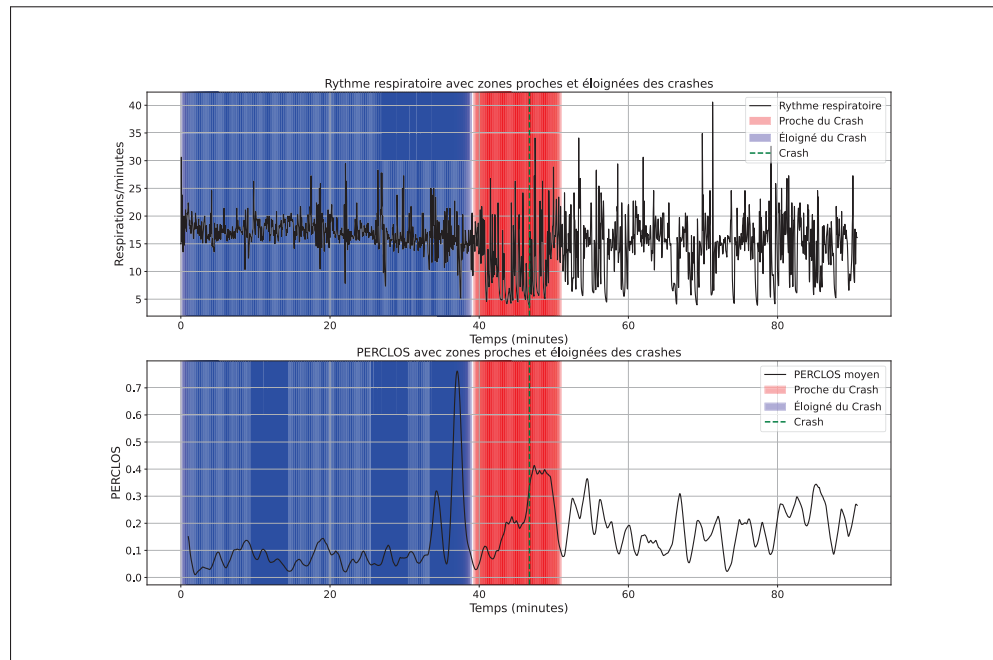


FIGURE 2.31 Segmentation des données de rythmes respiratoires en fonction des accidents

somnolent sont considérées comme étant des données associées à **un état alerte**. Ici, on utilise le rythme respiratoire, mais on pourrait tout aussi bien utiliser le signal de respiration brut. Dans cette étude, uniquement les premiers accidents seront considérés, cela pour deux raisons ; Premièrement, nous n'avons aucune certitude sur la fin des événements de somnolence après un accident et deuxièmement, la figure 3.10 indique que les indices de qualité baissent tout au long de l'enregistrement ce qui induit une augmentation du bruit la plupart du temps à cause des sujets devenant de plus en plus impatients et créant plus d'artéfacts de mouvements. De plus, **uniquement les sessions ou un accident s'est produit seront utilisés**. Cela est nécessaire, car **les sessions du matin et de l'après-midi d'un même patient** peuvent présenter des **profils respiratoires très différents**. Pour finir, les **données obtenues sont normalisées par sessions** pour la raison mentionnée précédemment.

2.4.2 Études de la séparabilité des données

Une fois les données segmentées en deux catégories distinctes, somnolente et non somnolente, il devient possible d'étudier la distribution des caractéristiques des données. Pour calculer ces dernières, nous utilisons la librairie Python introduite par Barandas, Folgado, Fernandes, Santos, Abreu, Bota, Liu, Schultz & Gamboa (2020). Elle permet d'extraire jusqu'à 65 caractéristiques du domaine temporel, spectral, statistique et fractal, fournissant une analyse détaillée et diversifiée des signaux.

Puis, deux études sont effectuées :

1. **Étude des distributions** des données somnolentes.
2. Étude de la séparabilité des données à l'aide de la technique **d'Approximation et Projection Uniforme de Variétés (UMAP)** (McInnes, Healy & Melville, 2020) en anglais. UMAP est une méthode de réduction de dimensionnalité qui préserve la structure globale tout en mettant en évidence les patterns locaux, ce qui est crucial pour visualiser la séparabilité des classes.

La méthode UMAP, introduite par McInnes *et al.* (2020), effectue une réduction de la dimension des données dans le but de faciliter leur représentation et de fournir une représentation visuelle permettant d'observer si les données sont séparables ou non.

2.4.3 Classification des données

Une fois la séparabilité des données explorée, une tentative de classification des données est effectuée. Cela n'étant pas le sujet principal de ce mémoire, l'objectif est de montrer que des résultats satisfaisants peuvent être obtenus assez rapidement avec les données de référence et expérimentales.

Le principal problème de notre distribution de données est le déséquilibre entre les classes somnolentes et non somnolentes :

- **532** données **somnolentes**.
- **1655** données **non somnolentes**.

Pour pallier cela, la méthode ADASYN (He, Bai, Garcia & Li, 2008) est utilisée pour augmenter le nombre de données somnolentes en générant des échantillons synthétiques **sur les données d'entraînement uniquement**, améliorant ainsi l'équilibre des classes et les performances des modèles de classification.

Ensuite, une validation croisée est utilisée pour l'entraînement et la validation. les sessions de conduite sont regroupées afin de prendre en compte **la variabilité inter-sessions et inter-sujets**. Afin d'évaluer la capacité **du modèle à généraliser** sur des **données non vues**. Plus précisément, les sessions sont considérées comme des groupes, et chaque session représente un sous-ensemble unique de données. Les sessions sont **réparties aléatoirement dans cinq groupes**, à chaque cycle **4 groupes sont utilisé pour entraîner le modèle** et le **groupe restant** est utilisé pour **tester le modèle**. De cette manière, les performances sont mesurées sur les données de session qu'il n'a jamais vues, on mesure donc sa capacité à généraliser. Pour mesurer ces performances, La moyenne des métriques est calculée à travers les cycles d'entraînements.

Concernant la classification, deux classificateurs sont utilisés :

1. **Classificateur à vecteurs de support (SVM)** (Cervantes, Garcia-Lamont, Rodríguez-Mazahua & Lopez, 2020), le SVM est un modèle puissant pour traiter des données à plusieurs dimensions. L'algorithme cherche la meilleure façon de séparer les données à l'aide d'une fonction linéaire ou non, formant un "hyperplan" dans l'espace des données permettant de les séparer.
2. **Classificateur par forêts aléatoires** (Breiman, 2001), composé de plusieurs arbres de décision, chaque arbre dispose uniquement d'une partie des données, et l'estimation finale est donnée comme étant la moyenne des décisions de l'ensemble des arbres le composant. Il a pour avantage d'avoir une très grande capacité de généralisation.

Pour trouver les meilleurs paramètres pour chaque modèle, **une recherche par grille** est effectuée avant la validation croisée, lors de la recherche chaque combinaison de paramètres est testée, selon les mêmes règles de validation croisée mentionnée précédemment. **Le meilleur modèle est choisi selon la métrique de performance F1**, qui donne une mesure de la performance tenant compte de la précision et du rappel.

Les résultats de ces deux classificateurs sont présentés dans la partie résultats. L'objectif ici n'est pas de trouver le meilleur classificateur, mais plutôt de montrer qu'il est possible d'atteindre des résultats similaires avec les données textiles et de référence.

Dans cette section, la méthodologie pour la conception du système d'acquisition de la respiration sans contact avec des électrodes textiles a été présentée. La méthode d'analyse de données pour valider le système et prouver que ce dernier est viable pour détecter la somnolence de manière non invasive a été détaillée. Dans la section suivante, les résultats seront discutés ainsi que leurs implications concernant les hypothèses de recherche.

CHAPITRE 3

RÉSULTATS ET DISCUSSIONS

Après avoir présenté le système et les expériences réalisées, les résultats obtenus sont présentés et discutés dans ce chapitre. Ces derniers répondent à plusieurs questions :

1. Est-il possible d'obtenir la respiration avec précisions à l'aide d'électrodes textiles sans contact ?
2. Les électrodes obtiennent-elles de meilleures performances lorsqu'elles sont positionnées sur la ceinture du conducteur ?
3. La fusion ou le choix de signal par indice de qualité améliore-t-il la précision de l'estimation du rythme respiratoire ?
4. Les caractéristiques du rythme respiratoire des électrodes textiles et de la ceinture de référence sont-elles corrélées ?
5. Les caractéristiques du rythme respiratoire des données somnolentes et non-somnolentes ont-elles des distributions séparables ?
6. Est-il possible d'effectuer une détection de la somnolence avec les données textiles ?

3.1 Résultats

Ici, les résultats de performances des électrodes textiles sur l'ensemble des enregistrements ainsi que ceux des techniques de traitement de signal sont d'abord présentés. Ensuite, l'évolution des indices de qualité en fonction de la performance de l'estimation du rythme respiratoire démontre qu'ils sont corrélés avec les performances de détection. Les performances des différentes positions et tailles d'électrodes sont évaluées à l'aide de ces indices et du signal de référence. Pour finir, les résultats de l'analyse des données de somnolence sont présentés.

3.1.1 Performances d’estimation du rythme respiratoire des électrodes textiles

Pour calculer l’erreur absolue moyenne du rythme respiratoire de chaque canal face à la référence, présentée dans la figure 3.1, l’erreur absolue moyenne (**MAE** en anglais) est calculée sur chaque enregistrement de 1h30. Les trois périodes correspondent à trois segments de 30 minutes découpés dans les enregistrements. Les tableaux croisés dynamiques sur la droite des graphiques permettent d’observer les valeurs de *p* des moyennes des enregistrements. On observe que

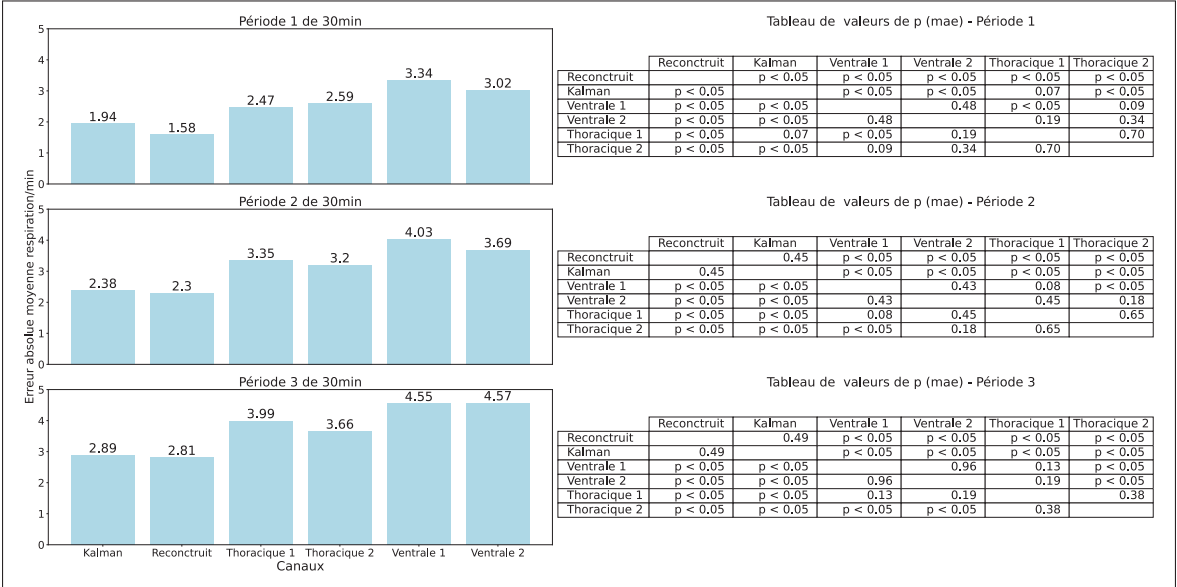


FIGURE 3.1 Performance des canaux pour l’estimation du rythme respiratoire à travers toute les sessions de conduite

l’erreur des canaux utilisant la **fusion de données** ou la reconstruction est **plus faible que celle des signaux originaux**. On note aussi que **les valeurs *p*** du test de Student **sont inférieures à 0.05**, indiquant une différence significative des moyennes. Les deux méthodes d’amélioration (la fusion et la reconstruction) obtiennent des performances similaires. Les électrodes thoraciques ont des performances sensiblement supérieures à celles ventrales, cependant les valeurs de *p* sont parfois supérieures à 0.05.

Pour apporter une vue d’ensemble de la performance d’estimation du rythme respiratoire à travers toute l’expérience de somnolence, les courbes de la figure 3.2 représentent la MAE par

enregistrement entre la référence et les signaux expérimentaux fusionnés par Kalman, ordonnées de la plus petite à la plus grande. On peut y observer que l'estimation du rythme respiratoire est meilleure pour les signaux fusionnés à partir des autres électrodes. De plus, on peut noter que **44%** des enregistrements de 1h30 obtiennent une **MAE inférieure à 2 respirations/minute** là où la meilleure électrode textile n'en as que **28%**.




FIGURE 3.2 MAE par enregistrement entre la référence et les signaux expérimentaux et fusionnés ordonnées de la plus petite à la plus grande

Selon le même principe, mais avec des périodes de signaux plus petites de 18 minutes, la MAE et son écart-type moyen calculés sur l'ensemble des enregistrements sont affichées sur la figure 3.3. La MAE est calculée entre le rythme respiratoire du signal textile fusionné et celui de la référence. L'erreur moyenne **augmente**, passant de **1.84 respirations par minute** pour la première période de 18 minutes à **3.09 respirations par minute** pour la dernière. L'écart-type moyen augmente également, passant de **2.57 respirations par minute** à **3.45 respirations par minute**.




FIGURE 3.3 Évolution moyenne de l'erreur d'estimation de la respiration des électrodes textiles fusionnées avec le filtre de kalman au cours des enregistrements de l'expérience de somnolence

Les performances **en fonction des électrodes utilisées pour la fusion** ont également été étudiées, comme le montre la figure 3.4. Les résultats de la MAE avec la référence pour le signal textile fusionné varient selon la configuration des capteurs : uniquement avec les capteurs textiles ventraux, avec les capteurs textiles thoraciques, ou avec tous les quatre capteurs textiles. On observe que les performances de la fusion sont **meilleures lorsque toutes les électrodes sont utilisées**. Cependant, les valeurs de p du test de Student ne permettent pas de déterminer si les électrodes du haut obtiennent de meilleures performances que celles du bas.




FIGURE 3.4 Performance de l'estimation du rythme respiratoire en fonction des sources utilisées pour la fusion du filtre kalman,
Haut = électrodes thoraciques,
Bas = électrodes ventrales

3.1.2 Relation entre les indices de qualité et la performance d'estimation du rythme respiratoire

Pour valider les indices de qualité, une étude a été effectuée sur les valeurs des indices en fonction de la performance d'estimation du rythme respiratoire par rapport à la référence. Pour cela, tous les enregistrements ont été **découpés en segments de 18 minutes**, puis leur **MAE ainsi que les indices de qualité** ont été calculés pour chaque segment. Pour finir, les indices ont été affichés sur la figure 3.5 en fonction de la MAE. On observe la corrélation entre les indices de qualité et l'erreur d'estimation du rythme respiratoire pour les deux électrodes ventrales et thoraciques, ainsi que celle obtenue avec le signal fusionné. Chaque point de données représente la métrique moyenne obtenue dans un des segments de 18 minutes lors de l'expérience sur la somnolence.




FIGURE 3.5 Indices de qualité VS la MAE

Le ratio de densité spectrale et la corrélation inter-respiratoire obtiennent les meilleures valeurs de corrélation, avec respectivement **0.73** et **0.81**.

Les indices moyens obtenus sur chaque enregistrement de 1h30 de l'expérience de somnolence sont présentés par la figure 3.6 organisés de la meilleure à la moins bonne valeur. La ligne du haut présente les valeurs du signal fusionné à partir des électrodes textiles avec un filtrage préalable, tandis que la ligne du bas montre les résultats où le filtrage est effectué après la fusion.

On observe des différences importantes de qualité pour tous les indices entre la référence et les signaux expérimentaux. La fusion semble améliorer sensiblement la qualité des signaux. Le graphique démontre que le signal est de meilleure qualité lorsque le filtrage est appliqué avant la fusion du filtre Kalman. On notera un SDR plus élevé pour la fusion du signal lorsque le filtrage est appliqué avant ; cela est dû au fait que le signal fusionné est filtré dans la bande de respiration avant de calculer les valeurs de SDR.

3.1.3 Résultats des tests de position et de taille

Dans cette section, les résultats des tests de position et de taille des électrodes détaillés dans la méthodologie sont présentés. Le tableau 3.1 présente les résultats obtenus lors des tests de position avec les valeurs de l'erreur absolue moyenne d'estimation du rythme respiratoire.

Concernant les performances de la petite électrode dans le dos, la position haute obtient les meilleurs résultats avec **5,62 ± 4,80 rsp/min**. De même, **à la position du milieu**, l'électrode

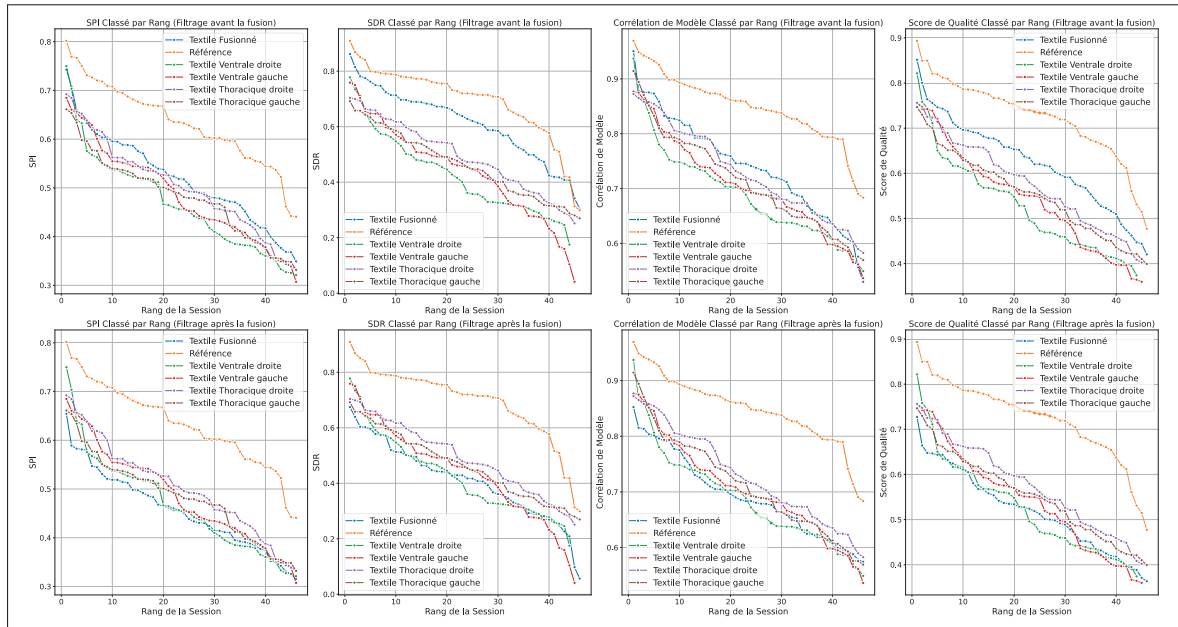


FIGURE 3.6 Indices de qualité pour chaque session par ordre décroissant

circulaire de grande taille obtient des performances supérieures aux autres tailles circulaires, **en particulier pour les sujets 2 et 3** ayant les plus **petites morphologies**. Les performances de la petite électrode rectangulaire au milieu du dos sont également comparables à celles de la grande électrode circulaire, avec respectivement $4,11 \pm 3,60$ rsp/min et $4,20 \pm 3,81$ rsp/min.

Pour terminer, on observe que **l'erreur d'estimation du rythme respiratoire est plus faible** avec les électrodes **rectangulaires placées sur la ceinture de sécurité**. De plus, les électrodes de petite taille obtiennent une meilleure détection à travers les 3 sujets que toutes les autres électrodes ou positions. Un autre résultat remarquable est la performance plus faible dans le dos pour le sujet 1, ayant une morphologie plus imposante que les deux autres sujets.

Le graphique 3.7 présente les résultats des tests avec les petites électrodes circulaires dans le dos. On remarque que les petites électrodes ont de **meilleures performances** avec les morphologies des **sujets 2 et 3**. La position dans **le haut du dos** obtient une **MAE plus faible** que les autres positions. La figure 3.8 présente la MAE du tableau 3.1 des différentes électrodes dans le milieu du dos. Les électrodes circulaires de **plus grande taille** permettent une **meilleure estimation**

TABLEAU 3.1 Résultats des MAE par type et taille d'électrode, position et moyenne des sujets

Type d'Électrode	Position	Taille de l'Électrode	sujet 1 MAE	sujet 2 MAE	sujet 3 MAE	Moyenne des sujets
Circulaire	Bas du dos	Petite	9.16 ± 5.00 rsp/min	5.05 ± 3.64 rsp/min	7.80 ± 5.03 rsp/min	7.33 ± 4.55 rsp/min
Circulaire	Milieu du dos	Petite	12.36 ± 4.68 rsp/min	7.39 ± 4.66 rsp/min	12.92 ± 3.70 rsp/min	10.89 ± 4.35 rsp/min
Circulaire	Haut du dos	Petite	9.24 ± 5.49 rsp/min	4.13 ± 3.92 rsp/min	3.50 ± 5.00 rsp/min	5.62 ± 4.80 rsp/min
Circulaire	Milieu du dos	Moyenne	8.57 ± 4.37 rsp/min	2.91 ± 3.37 rsp/min	7.08 ± 4.09 rsp/min	6.19 ± 3.94 rsp/min
Circulaire	Milieu du dos	Grande	8.79 ± 5.13 rsp/min	1.10 ± 1.97 rsp/min	2.43 ± 3.71 rsp/min	4.11 ± 3.60 rsp/min
Rectangulaire	Milieu du dos	Petite	2.72 ± 3.84 rsp/min	1.34 ± 2.25 rsp/min	8.53 ± 5.35 rsp/min	4.20 ± 3.81 rsp/min
Rectangulaire	1	Grande	1.56 ± 3.03 rsp/min	6.70 ± 4.45 rsp/min	4.83 ± 5.29 rsp/min	4.36 ± 4.26 rsp/min
Rectangulaire	2	Grande	1.77 ± 3.40 rsp/min	6.07 ± 6.21 rsp/min	1.69 ± 2.87 rsp/min	3.17 ± 4.16 rsp/min
Rectangulaire	3	Grande	4.32 ± 4.82 rsp/min	4.06 ± 3.97 rsp/min	2.77 ± 4.18 rsp/min	3.72 ± 4.32 rsp/min
Rectangulaire	4	Grande	4.86 ± 4.50 rsp/min	6.73 ± 6.30 rsp/min	5.83 ± 4.80 rsp/min	5.81 ± 5.20 rsp/min
Rectangulaire	1	Petite	0.49 ± 0.96 rsp/min	1.47 ± 2.87 rsp/min	4.12 ± 4.28 rsp/min	2.03 ± 2.70 rsp/min
Rectangulaire	2	Petite	0.87 ± 2.06 rsp/min	5.27 ± 3.68 rsp/min	1.13 ± 2.52 rsp/min	2.42 ± 2.75 rsp/min
Rectangulaire	3	Petite	0.64 ± 1.61 rsp/min	0.78 ± 1.81 rsp/min	3.49 ± 4.20 rsp/min	1.64 ± 2.54 rsp/min
Rectangulaire	4	Petite	3.21 ± 3.78 rsp/min	1.52 ± 2.69 rsp/min	6.20 ± 4.43 rsp/min	3.64 ± 3.63 rsp/min




FIGURE 3.7 Performances des petites électrodes circulaires sur le dossier de conduite

du rythme respiratoire. L'électrode rectangulaire positionnée de manière verticale obtient de meilleurs résultats que la petite électrode circulaire pour tous les sujets. Cependant, la MAE de cette dernière est plus grande pour le sujet 3 avec la plus petite morphologie.




FIGURE 3.8 Performances des électrodes au milieu du dossier de conduite

La figure 3.9 permet d'observer les performances des électrodes à l'avant. Les petites électrodes **performent moins bien** pour le sujet 3, qui a une petite morphologie, notamment pour les **positions 1, 3 et 4**, mais on observe clairement que les petites électrodes rectangulaires obtiennent une meilleure estimation du rythme respiratoire.

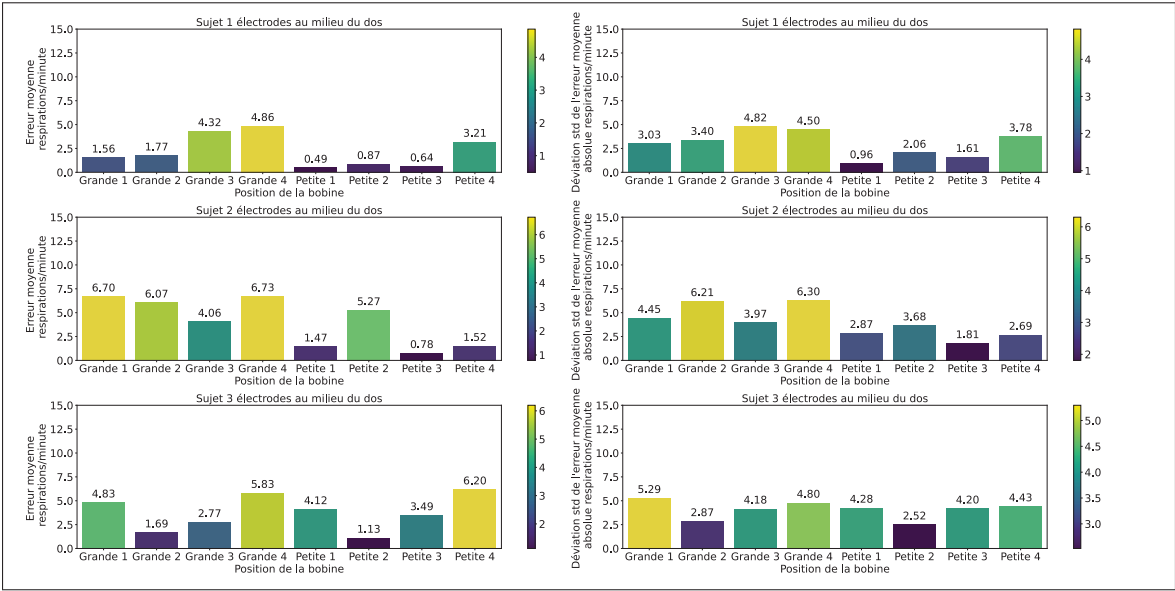


FIGURE 3.9 Performances des électrodes rectangulaires sur la ceinture par sujets

3.1.4 Statistiques des données de somnolence

Le tableau 3.2 présente les statistiques des accidents somnolents définis dans la section méthodologie comme étant le premier accident d’une session, concordant avec des signes de somnolence avérés sur la vidéo et une augmentation significative du PERCLOS. Lors des essais,

TABLEAU 3.2 Distribution des temps d’accidents majeur (en minutes)

Métrique	Accidents Majeurs (Minutes)
Nombre d’occurrences	19
Moyenne	34.15
Écart-Type	16.15
Minimum	11.5
25ème centile	20.91
50ème centile (Médiane)	34.38
75ème centile	44.13
Maximum	76.17

19 accidents somnolents ont été confirmés sur les 50 sessions, rappelons qu’un accident est

détecté lorsque les **quatre roues** de la voiture sortent de la voie de droite. Cela correspond à **38% des sessions enregistrées**. La majorité des accidents survient dans les 45 premières minutes.

3.1.5 Artefact de mouvements, placement des électrodes

Lors de l'expérience sur la somnolence, plusieurs phénomènes ont été observés. Pour étudier l'évolution du bruit au cours des enregistrements, les indices de qualité de tous les canaux ont été calculés pour chaque période de 18 minutes des enregistrements de 1h30. Ensuite, on a calculé la moyenne à travers tous les enregistrements pour les périodes 1, 2, 3, 4, et 5. La figure 3.10 illustre la détérioration des indices de qualité moyens à travers toutes les sessions au cours du temps. On observe très clairement pour tous les canaux une détérioration de la qualité des signaux au cours des enregistrements. Comme le montre la figure 3.11, les mouvements de certains sujets agités ont créé un déplacement des électrodes inductives lors des enregistrements.

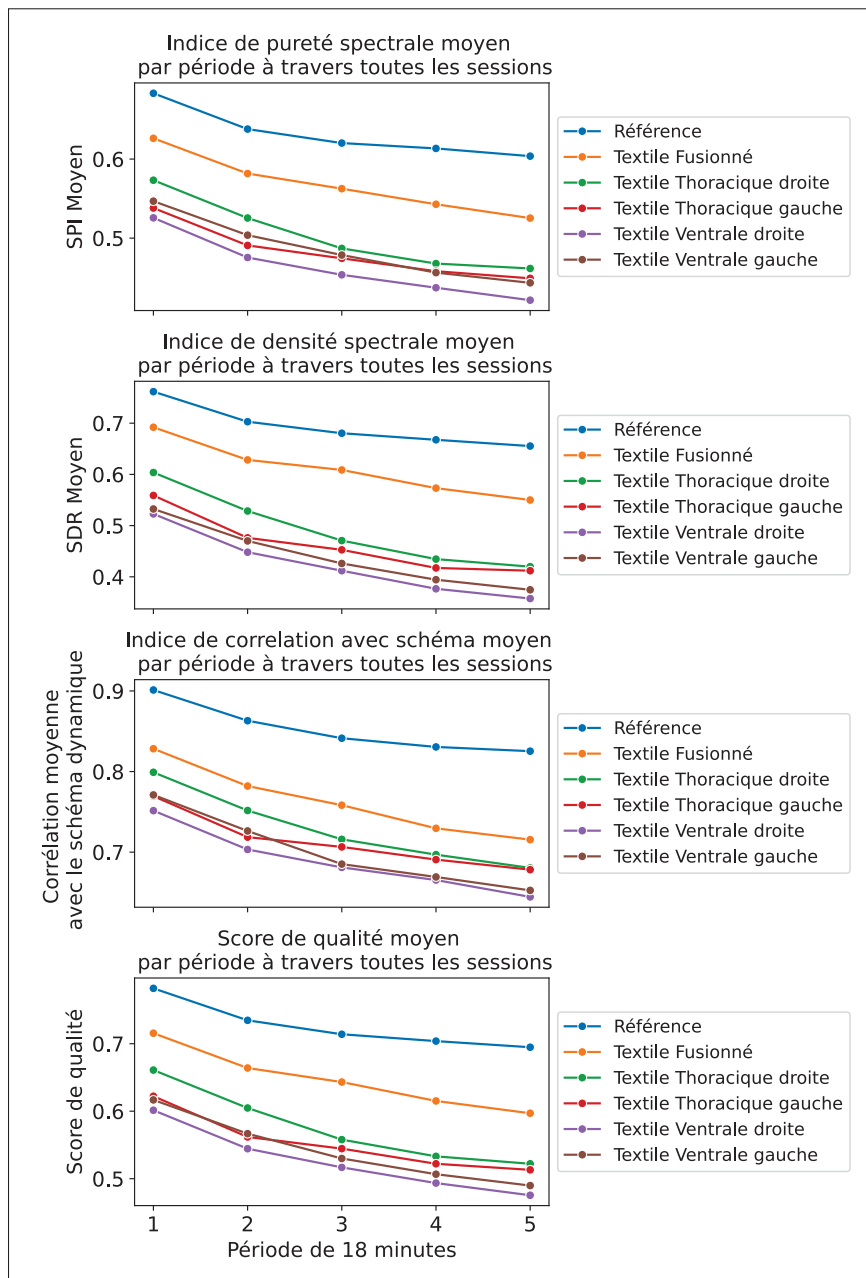


FIGURE 3.10 Évolutions des indices de qualité moyens des signaux filtrés durant les enregistrements




FIGURE 3.11 Déplacement des électrodes au cours de l'enregistrement

3.1.6 Résultats de corrélation entre les caractéristiques du rythme respiratoire expérimental textile et la référence

Pour comparer les performances des électrodes textiles par rapport à la référence, des caractéristiques **statistiques temporelles et spectrales** du **rythme respiratoire** ont été calculées à l'aide d'une fenêtre glissante de 5 minutes, comme expliqué précédemment dans la partie méthodologie.

Les métriques utilisées sont :

1. **Déviati on absolue moyenne** : la moyenne des déviations absolues par rapport à un point central d'une série statistique. C'est une mesure de la dispersion.
2. **Déviati on standard** : la racine carrée de la variance, également une mesure de la dispersion.
3. **Minimum** : la valeur minimale dans la fenêtre de 5 minutes.
4. **Moyenne** : la valeur moyenne de la fenêtre de 5 minutes.
5. **Somme des différences absolues** : donne une mesure de la variabilité du signal.
6. **Points de retournement négatifs** : points de changement de croissance vers décroissance.

Les figures 3.12 et 3.13 exposent respectivement la corrélation de certaines caractéristiques tout au long du signal et uniquement près des accidents. Les valeurs textiles présentent une meilleure corrélation proche des accidents (les accidents choisis sont uniquement les premiers accidents somnolents). Certaines caractéristiques montrent une **moins bonne corrélation** avec la référence, notamment **la somme des différences absolues et les points de retournement négatifs**.

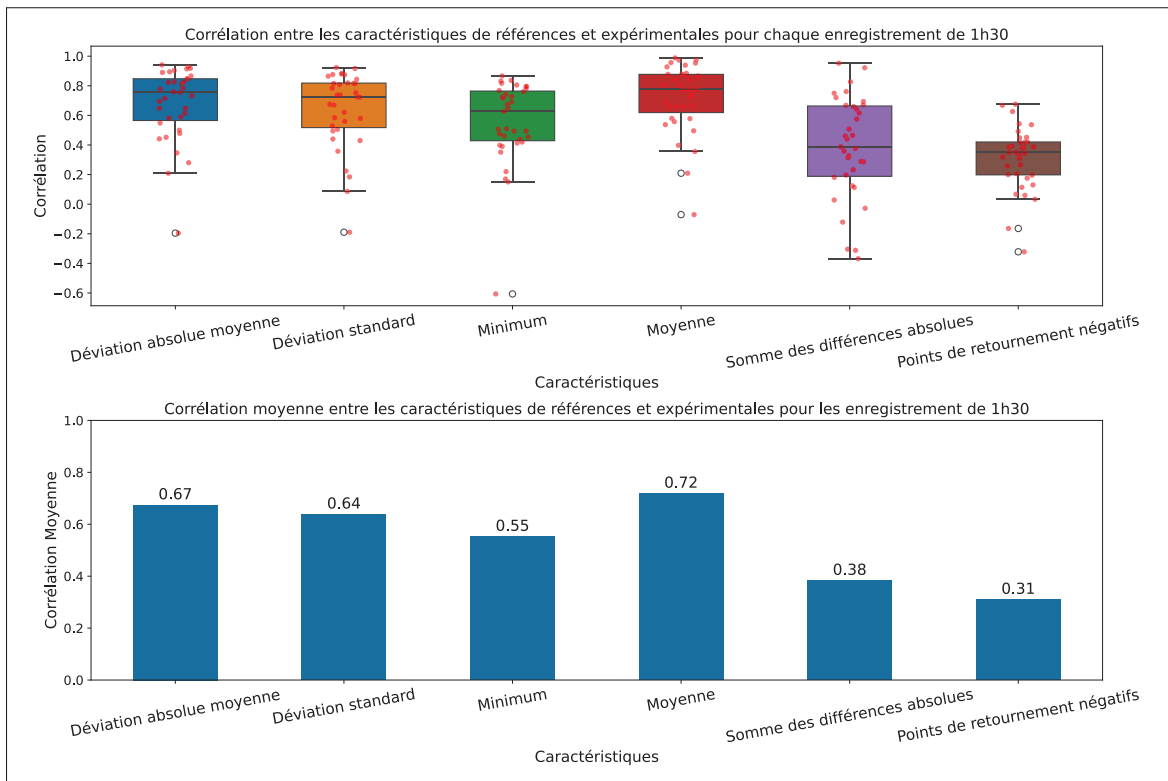


FIGURE 3.12 Corrélation des caractéristiques du rythme respiratoire textile et celui de références tout au long des enregistrements

Pour étudier les tendances d'évolution des caractéristiques du rythme respiratoire présentées ci-dessus autour des accidents somnolents, la moyenne de ces caractéristiques, préalablement normalisée par sujet, a été calculée **de 15 minutes avant à 15 minutes après les accidents**. La figure 3.14 montre l'évolution moyenne des caractéristiques du rythme respiratoire autour des accidents. On remarque que les valeurs extraites du signal de respiration des **électrodes textiles fusionnées sont proches** de celles de **référence** et suivent **la même évolution moyenne**, même lors de variations plus complexes comme avec les points de retournements négatifs.

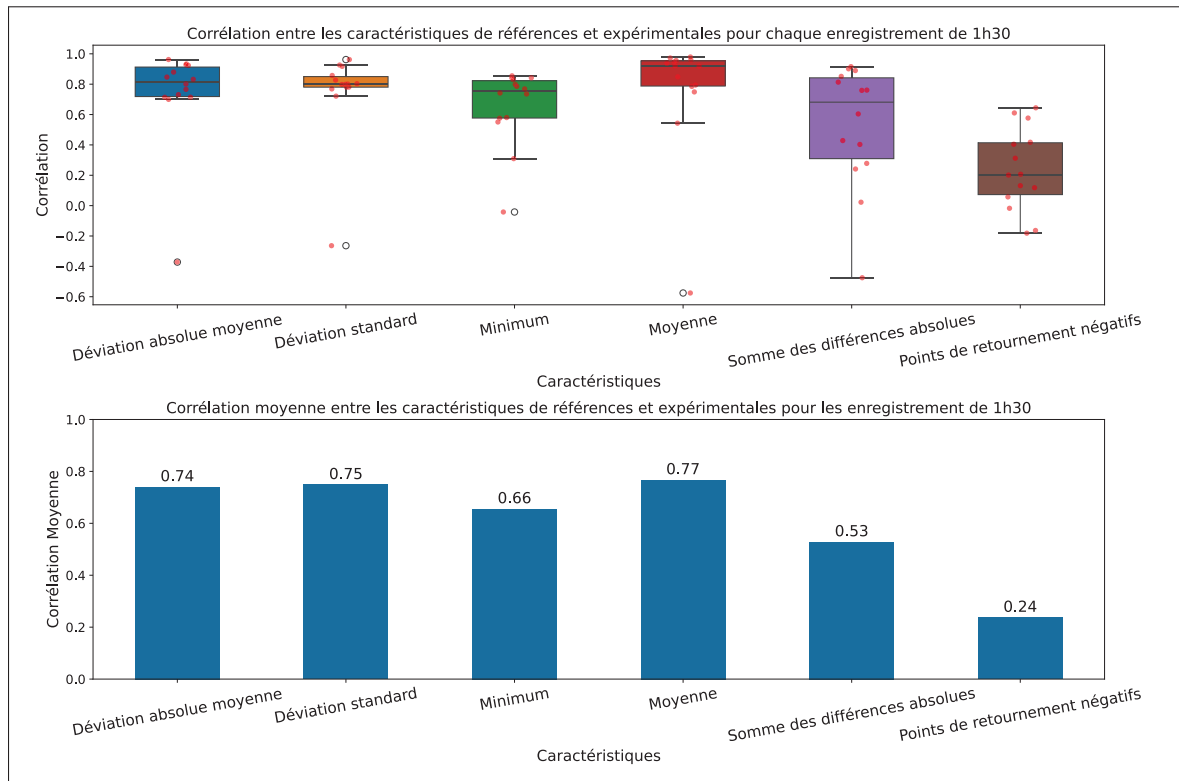


FIGURE 3.13 Corrélation des caractéristiques du rythme respiratoire textile et celui de référence proche des accidents somnolents

Concernant les tendances, on observe une **diminution du rythme respiratoire moyen** ainsi qu'une **augmentation de sa déviation standard et de la somme des différences absolues**, indiquant une **augmentation de l'instabilité du rythme respiratoire**.

3.1.7 Distribution des données somnolentes/non-somnolentes

Une fois les données labellisées selon la règle spécifiée précédemment dans la méthodologie :

1. **Données non-somnolentes** : Au moins 10 minutes avant un accident somnolent.
2. **Données somnolentes** : De -5 minutes à +2 minutes autour de l'accident.

Les enregistrements classés dans les 10% les moins bons selon la valeur de l'indice de densité spectrale ont été retirés des distributions pour limiter l'impact du bruit sur celles-ci.

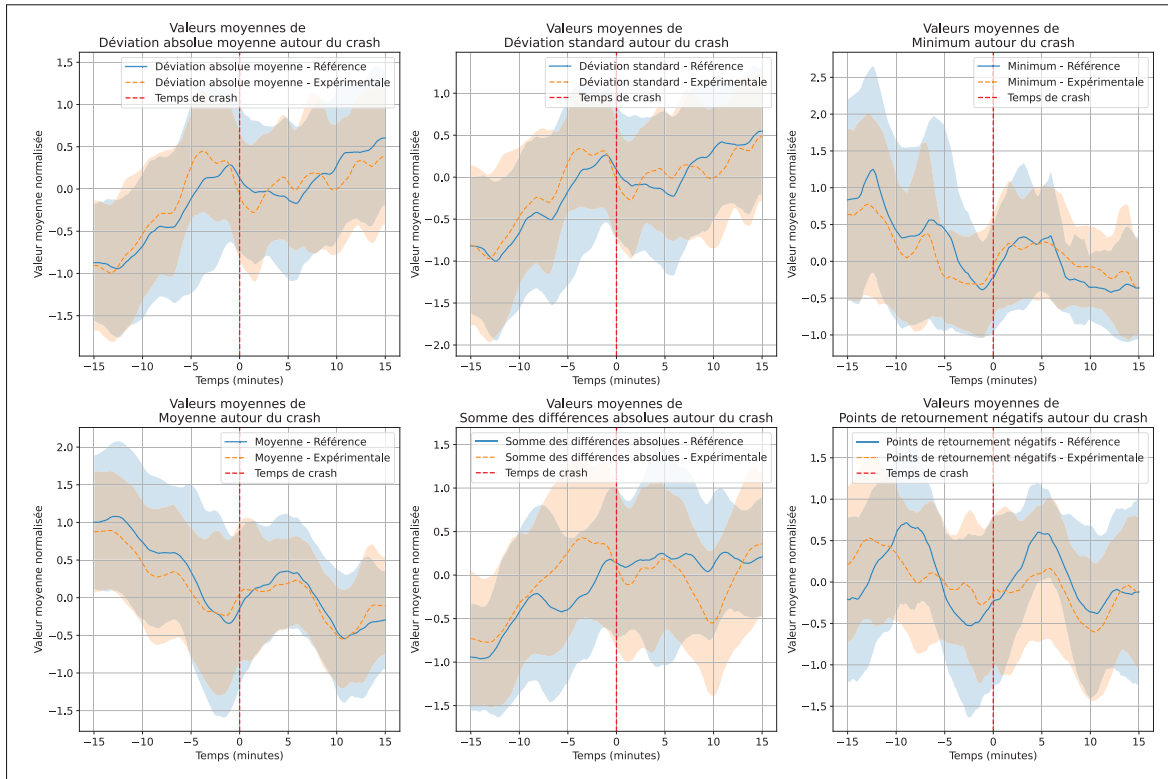


FIGURE 3.14 Évolution moyenne des caractéristiques du rythme respiratoire textiles et référence proche des accidents somnolents

La distribution des caractéristiques extraites du rythme respiratoire est étudiée sur la figure 3.15. On observe des distributions avec des moyennes significativement différentes. Pour les caractéristiques du rythme respiratoire étudiées :

- **Moyenne.**
- **Déviation standard.**
- **Somme des différences absolues.**
- **Points de retournement négatifs.**
- **Diminution spectrale** : modélise la décroissance moyenne de puissance dans les différentes fréquences du signal.

D'autres caractéristiques montrent des distributions intéressantes, mais nous nous limiterons à celles-ci car, en général, ce sont la moyenne et la déviation standard qui sont étudiées dans les revues de littérature.

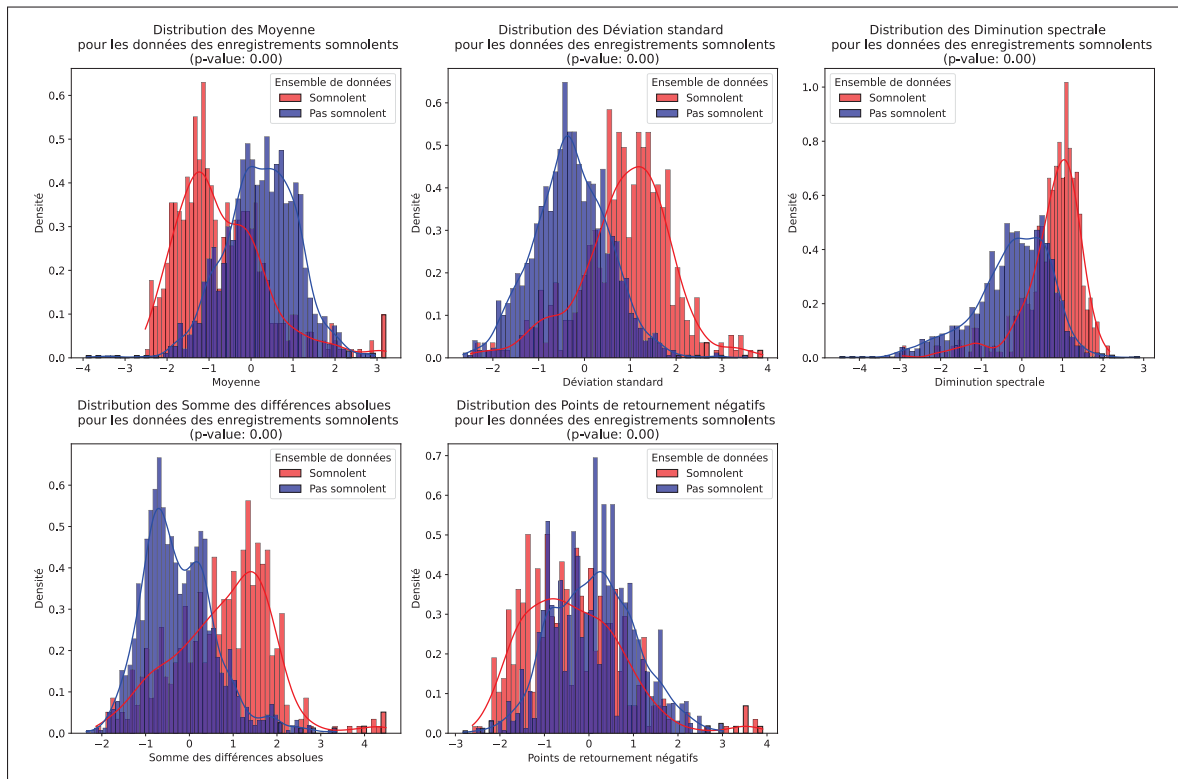


FIGURE 3.15 Distribution des caractéristiques du rythme respiratoire non-somnolentes/somnolentes

Pour explorer la séparabilité du rythme respiratoire moyen et sont instabilités, la figure 3.16 illustre les valeurs moyennes de chaque classe de données (éloigné des accidents, proches des accidents) et chaque sujet du rythme respiratoire moyen et de sa déviation standard pour les données expérimentales textiles. On remarque que le profil du rythme respiratoire de certains sujets diffèrent fortement entre non-somnolent (éloigné de l'accident) et somnolent (proche de l'accident). Cependant, la séparabilité de certaines sessions est discutable, notamment celles de la moyenne du rythme respiratoire des sujets **15, 17, 21**. En revanche, pour le sujet **15**, la déviation standard permet de les différencier plus facilement. On remarque aussi des tendances sont inversée notamment pour la moyenne des sujets **9 et 17 session 1**. De même pour la

déviati on standard, la session 1 du sujet 17 et la session 2 du sujet 21 présente un profil inversé par rapport aux autres métriques. Plus généralement, on observe qu'il y a une grande variabilité inter-sujet et inter-session. On note aussi que la rythme respiratoire somnolent est plus bas contrairement à la variabilité qui semble augmenter proches des accidents. Pour la



FIGURE 3.16 Moyenne et déviation standard du rythme respiratoire pour les sujets somnolents avec les données expérimentale textiles

projection, certaines sessions avec des signaux de mauvaise qualité ont été retirées, comme la session 2 du sujet 17 illustrée sur la figure 3.17, où les signaux résultants de la fusion étaient fortement bruités, perturbant la distribution des données. Elles ont donc été retirées des données.

Plusieurs autres enregistrements ont été retirés, car les sujets étaient beaucoup trop agités ou ne respectaient pas le protocole :




FIGURE 3.17 Signaux textiles de mauvaise qualité du sujet 17 session 2

1. P014, session 1 et 2.
2. P017, session 1.

Pour finir, les résultats de la projection UMAP sont présentés sur la figure 3.18. On peut y observer la séparabilité dans le plan réduit produit par la méthode UMAP, qui est notamment **similaire entre les données de référence et celles textiles**.

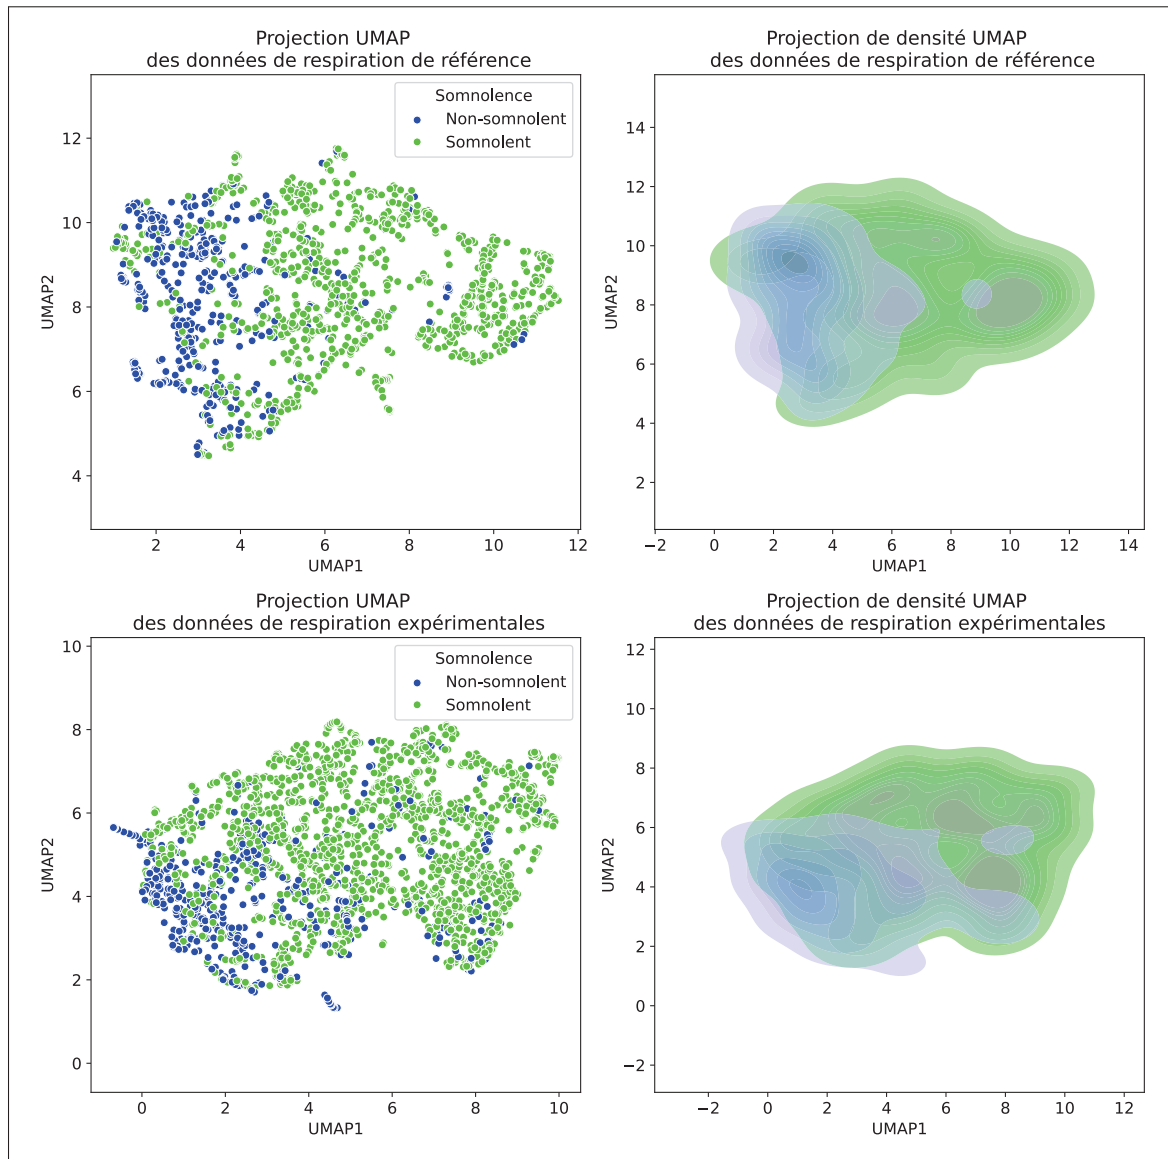


FIGURE 3.18 Projection UMAP des données non-somnolentes/somnolentes

3.1.8 Classification de la somnolence

Dans cette section, les résultats de classification avec les données présentées plus haut seront exposés. Les performances des deux classificateurs seront présentées ainsi que les résultats de la classification des données expérimentales avec un modèle entraîné sur les mêmes données de référence.

3.1.8.1 Résultats des données de référence

Suivant la méthode présentée dans le chapitre précédent, une classification a été effectuée pour tenter de distinguer les données proches et éloignées des accidents somnolents. Les résultats sont présentés dans le tableau 3.3 pour la classification avec les données de référence, et dans le tableau 3.5 pour la classification avec les données obtenues par fusion de capteurs textiles.

TABLEAU 3.3 Résultats de classification pour les modèles SVM et Random Forest (RDF) avec données de références

Métrique	SVM	Random Forest (RDF)
Exactitude moyenne (Average Accuracy)	0.83 ± 0.05	0.81 ± 0.06
Précision moyenne (Average Precision)	0.72 ± 0.15	0.68 ± 0.16
Rappel Somnolent moyen	0.66 ± 0.14	0.64 ± 0.14
Rappel Non-Somnolent moyen	0.90 ± 0.05	0.88 ± 0.06
Score F1 moyen (Average F1 Score)	0.68 ± 0.11	0.66 ± 0.12

TABLEAU 3.4 Résultats de classification pour les modèles SVM et Random Forest (RDF) avec données de référence augmentées

Métrique	SVM	Random Forest (RDF)
Exactitude moyenne (Average Accuracy)	0.76 ± 0.09	0.76 ± 0.10
Exactitude équilibrée moyenne	0.79 ± 0.08	0.77 ± 0.10
Précision moyenne (Average Precision)	0.55 ± 0.16	0.56 ± 0.18
Rappel Somnolent moyen	0.85 ± 0.08	0.81 ± 0.11
Rappel Non-Somnolent moyen	0.72 ± 0.11	0.74 ± 0.12
Score F1 moyen (Average F1 Score)	0.66 ± 0.12	0.65 ± 0.14

On observe de meilleures performances avec le classificateur SVM. Le taux de classification des données somnolentes est meilleur que celui des données non somnolentes. L'augmentation des données permet d'améliorer les performances sur la classe minoritaire (somnolente) au détriment de la classe majoritaire (non-somnolente).

TABLEAU 3.5 Résultats de classification pour les modèles SVM et Random Forest (RDF) avec données expérimentales textiles

Métrique	SVM	Random Forest (RDF)
Exactitude moyenne (Average Accuracy)	0.82 ± 0.03	0.82 ± 0.06
Précision moyenne (Average Precision)	0.72 ± 0.13	0.67 ± 0.16
Rappel Somnolent moyen	0.66 ± 0.10	0.64 ± 0.15
Rappel Non-Somnolent moyen	0.89 ± 0.07	0.88 ± 0.06
Score F1 moyen (Average F1 Score)	0.67 ± 0.04	0.65 ± 0.13

TABLEAU 3.6 Résultats de classification pour les modèles SVM et Random Forest (RDF) avec données d'expérimentales augmentées

Métrique	SVM	Random Forest (RDF)
Exactitude moyenne (Average Accuracy)	0.80 ± 0.04	0.77 ± 0.06
Précision moyenne (Average Precision)	0.59 ± 0.07	0.57 ± 0.13
Rappel Somnolent moyen	0.87 ± 0.08	0.74 ± 0.15
Rappel Non-Somnolent moyen	0.77 ± 0.03	0.79 ± 0.06
Score F1 moyen (Average F1 Score)	0.70 ± 0.07	0.64 ± 0.12

3.1.8.2 Résultats données expérimentales textiles

Le tableau 3.5 démontre que des résultats similaires à ceux des données de référence peuvent être atteints avec les deux classificateurs. On observe néanmoins que les performances de généralisation peuvent être variables avec les écart-types des performances élevés pour les données de référence et expérimentale. Les données sous-représentées de somnolence obtiennent une performance de détection plus faible que les celles éloignées des accidents. On observe aussi une amélioration de la détection des événements somnolent lors de l'augmentation de données dans le tableau 3.6 et 3.4 pour les données de références et expérimentales.

Pour finir, les résultats de prédiction pour les deux modèles ont été accumulés à travers les validations croisées pour obtenir les matrices de confusion des 4 figures 3.19, 3.20, 3.21 et 3.22. On peut observer, des valeurs très similaires pour les classifications des deux modèles. Ainsi qu'une amélioration significative de la détection de la somnolence au détriment de l'augmentation de faux positifs pendant les phases d'éveils, conséquences de l'augmentation de données.




FIGURE 3.19 Matrice de confusion du modèle SVM pour les données de références et expérimentales




FIGURE 3.20 Matrice de confusion du modèle RDF pour les données de références et expérimentales




FIGURE 3.21 Matrice de confusion du modèle SVM pour les données de références et expérimentales avec augmentation




FIGURE 3.22 Matrice de confusion du modèle RDF pour les données de références et expérimentales avec augmentation

3.2 Discussions

Les résultats ayant été présentés dans la section précédente, cette section les discuteras dans le but de répondre aux questions présenté dans l'introduction de ce chapitre.

3.2.1 Influence de la position des électrodes sur la performance

L'une des questions fondamentales de cette étude était de déterminer si la position des électrodes textiles influençait la précision de la détection. Les tests de position ont révélé plusieurs informations, notamment concernant la position des petites électrodes circulaires dans le dos. Il s'est avéré que la position des électrodes dans le dos influence les performances d'estimation du rythme respiratoire ; la position du haut obtient de meilleures performances que celle du milieu et du bas, particulièrement avec les morphologies plus imposantes des sujets 1 et 2. Comme mentionné dans la revue de littérature, deux phénomènes influencent les changements de valeurs d'inductance : la courbure de l'électrode (Zhu *et al.*, 2022) et la distance relative du corps par rapport à la bobine. **Pour les patients plus corpulents**, la bobine au **milieu du dos** est totalement **écrasée**, limitant les variations de distance et aussi de courbure, expliquant la **faible qualité des signaux**.

Un autre point important concerne les résultats obtenus au milieu du dos ; les électrodes circulaires de plus grande taille ainsi que celles rectangulaires obtiennent une MAE du rythme respiratoire plus faible que les petites électrodes, pour les mêmes raisons énoncées précédemment. En ayant une taille d'électrodes plus importante, les déformations et les mouvements relatifs par rapport à la bobine sont maximisés, même pour les sujets avec les plus grandes morphologies.

Comme la littérature le suggérait, **les électrodes les plus proches des mouvements thoraciques** obtiennent les **meilleures performances** lors des tests effectués. On peut donc conclure que les électrodes situées sur la ceinture de sécurité permettent la meilleure précision d'acquisition pour la respiration. Toutefois, il est à noter que les électrodes rectangulaires de grande taille ont une moins bonne précision sur le sujet avec la plus petite morphologie. Cela provient du fait que **le sujet 3** présente une morphologie tellement **petite** que les **mouvements relatifs** à la ceinture de sécurité sont extrêmement **limités**.

Pour terminer, lors de l'expérience de somnolence avec des capteurs sur la ceinture, les électrodes thoraciques obtiennent une meilleure précision ainsi que de meilleurs indices de qualité. En effet, lors de nombreux tests, les sujets finissaient par **conduire à une main par lassitude**, avec

l'autre main posée sur les jambes, ce qui produisait des **artefacts de mouvement** impossibles à contrôler et **réduisant la performance** de ces électrodes.

À l'avenir, il serait judicieux de se tourner vers une matrice d'électrodes sur la ceinture de sécurité de plus petites tailles plutôt que quelques électrodes de grande taille pour maximiser les chances d'obtenir un signal de bonne qualité.

Un dernier point, lors de ces essais, il a été aussi remarqué que dans certains cas (les électrodes sur le torse), les électrodes semblent **détecter des signaux cardiaques**. Pour de travaux futurs, les chercheurs pourraient extraire le rythme cardiaque des signaux obtenus lors des expériences avec des techniques de filtrage plus adaptées. Si cela s'avérait être le cas, le système deviendrait par essence un système multimodal d'acquisition de signaux biologiques pouvant améliorer les résultats de détection de la somnolence.

3.2.2 Précision de la détection de la respiration à l'aide d'électrodes textiles sans contact

L'analyse de la MAE de l'estimation du rythme respiratoire des électrodes textiles inductives par rapport à la ceinture de référence montre que le système textile, avec la méthode de fusion de données par filtre de Kalman, parvient à estimer le rythme respiratoire avec une MAE inférieure à 2.36 respirations/minute sur 50% des enregistrements de 1h30. Ces résultats obtenus en condition de conduite simulée sont comparables à ceux de Leicht *et al.* (2022). Dans leur étude, les enregistrements étaient beaucoup plus courts (10 minutes) que ceux réalisés dans ce mémoire (1h30). Des enregistrements plus longs permettent l'apparition de plus d'artefacts de mouvement de la part des sujets en raison de la lassitude, ce qui explique la baisse de performances pour certains enregistrements, comme expliqué dans le paragraphe suivant. On peut donc conclure que la performance de notre système rivalise avec les études les plus récentes du même domaine.

Lors de l'étude de l'évolution des performances au cours du temps, présentée sur la figure 3.3, **la MAE augmente avec le temps**. Cela s'explique par le fait que les électrodes expérimentales ont pu **se déplacer** lors des **expérimentations**. Un exemple de ce déplacement est visible sur la figure 3.11, où l'électrode est totalement descendue en bas de la ceinture de sécurité. Ce

problème est récurrent chez plusieurs sujets, notamment les plus agités. Pour y remédier, on pourrait envisager un système où, tout **au long de la ceinture, des électrodes inductives textiles seraient brodées**, et celles avec les signaux ayant **les meilleurs indices de qualité** seraient utilisées pour la **fusion**.

3.2.3 Impact de la fusion de signaux et de l'utilisation des indices de qualité

Pour évaluer la pertinence des trois indices de qualité présentés par la méthodologie, ces derniers ont été évalués en fonction de l'erreur d'estimation du rythme respiratoire par rapport à la ceinture respiratoire de référence. Il s'est avéré que la corrélation inter-respiratoire avec modèle dynamique et le ratio de densité spectrale présentent tous deux une corrélation élevée avec la MAE, indiquant que ces deux indices sont de bons candidats pour la caractérisation des signaux respiratoires à l'avenir. L'indice de pureté spectrale présente une corrélation moins importante avec la MAE, ce qui est compréhensible, car cet indice mesure la similarité d'un signal avec un sinus et ne reflète pas nécessairement la quantité d'information contenue dans la bande de fréquence d'intérêt ; par exemple, une oscillation pure d'amplitude faible pourrait avoir un bon SPI mais ne pas être détectée par un algorithme si cette oscillation se situe dans une fréquence non-respiratoire.

Les figures 3.1 et 3.2 démontrent que la fusion de données a un impact significatif sur la précision. Les deux méthodes présentées permettent d'obtenir une MAE plus faible, indiquant que ces méthodes sont viables pour faire face aux artéfacts de mouvement en situation de conduite. Ces deux méthodes présentent néanmoins des différences ; en effet, la reconstruction de signal ne permet pas de reconstruire le signal point par point, car l'algorithme sélectionne le meilleur signal toutes les 10 secondes, contrairement à la fusion par filtre de Kalman qui fusionne en continu les quatre signaux. Cependant, comme indiqué dans la littérature (Khreis *et al.*, 2020), on peut envisager un système mélangeant les deux méthodes en choisissant quels signaux sont utilisés par la fusion pour améliorer la précision. Concernant la fusion, on remarque sur la figure 3.4 que le choix du capteur utilisé a un impact sur la fusion et que, dans l'état actuel, l'utilisation

des quatre électrodes augmente significativement la précision. Un système de choix de capteurs avant fusion pourrait permettre d'améliorer la performance de la fusion.

Il a également été remarqué que le filtrage avant la fusion permet d'améliorer les indices de qualité du signal de sortie. Lors des prochaines itérations, il sera intéressant de filtrer les signaux entrants dans l'étape de fusion dans le but de maximiser l'amélioration du signal par le filtre de Kalman.

L'étude réalisée se concentre sur les résultats globaux du filtre de Kalman, mais il pourrait être intéressant d'étudier son comportement lors de variations rapides du signal pouvant être provoquées par des artefacts de mouvements. Nous pourrions alors caractériser l'impact de ces événements sur les performances du filtre.

Pour conclure, la fusion par filtre de Kalman ou la reconstruction permet d'améliorer significativement la précision d'estimation du rythme respiratoire. En combinant les deux méthodes et en effectuant une rétroaction à l'aide des indices de qualité sur le filtre de Kalman, comme suggéré dans Nemati *et al.* (2010), la résistance aux artefacts de mouvement du système inductif textile pourrait être encore améliorée. Malgré les performances intéressantes observées pour le filtre de Kalman, d'autres méthodes pourraient donner d'excellentes performances face aux comportements non linéaires générés par les artefacts de mouvements, telles que les filtres adaptatifs utilisés avec un accéléromètre pour soustraire le bruit, comme proposé par Zhang, Silva, Wu, Zheng, Wu & Wang (2014). Pour finir, de la fusion par apprentissage machine pourrait aussi proposer de bonnes performances en entraînant un modèle à reconstruire la référence à partir des quatre sources de signal.

3.2.4 Corrélation entre les caractéristiques du rythme respiratoire et les données de référence

Malgré le bruit inhérent aux électrodes inductives textiles sans contact, il a été constaté que certaines des caractéristiques extraites du rythme respiratoire obtenues depuis **les électrodes textiles fusionnées sont corrélées** avec celles extraites des **signaux de référence**. Notamment,

la moyenne, la déviation standard et les valeurs minimales. Cependant, les caractéristiques liées aux valeurs différentielles du signal, comme la somme des différences absolues et les points de retournement négatifs, sont plus affectées par le bruit ce qui réduit leur corrélation avec celles des signaux de références.

Les corrélations élevées (> 0.6) tout au long des signaux, comme l'indique la figure 3.12, montrent que **malgré l'augmentation du bruit, les caractéristiques restent corrélées**. Les corrélations nous indiquent que, malgré le bruit, les signaux textiles inductifs suivent des évolutions similaires à ceux de référence et pourraient donc être utilisés pour **la détection de la somnolence** . Peut-être même que ces différences de bruit abritent des informations que les signaux de référence ne possèdent pas.

3.2.5 Différenciation entre données somnolentes et non-somnolentes

L'analyse des distributions des caractéristiques respiratoires montre des différences entre les phases somnolentes (proches des accidents) et non-somnolentes (éloignées des accidents au début des enregistrements), en particulier pour la déviation standard et la moyenne du rythme respiratoire. La diminution spectrale a également montré des différences intéressantes. Les données obtenues corroborent les observations des différentes études présentées dans la revue de littérature, comme indiqué dans le tableau 1.2, signalant que le rythme respiratoire moyen diminue lors des états de somnolence et que son instabilité augmente, comme le démontrent les tendances en 3.14. En analysant plus en détail par sujet les valeurs de la moyenne et de la déviation standard, il apparaît que ces dernières sont similaires entre les deux classes pour plusieurs sujets, chaque sujet présentant une répartition différente des moyennes et des déviations standard. Cela indique qu'il existe une variabilité inter-sujets, ce qui pourrait impacter l'utilisation future des données pour de l'apprentissage automatique. Enfin, une réduction de toutes les statistiques avec la méthode UMAP permet d'observer des séparations similaires entre les données extraites des signaux fusionnés textiles et les signaux de référence. On peut donc s'attendre à ce que des algorithmes entraînés sur les données de référence fonctionnent également sur les données textiles. Malgré la réduction UMAP la séparabilité n'est toujours pas parfaite, les classes restent

très proches. Une analyse plus approfondie de certaines caractéristiques pourrait permettre de mettre en évidence des différences plus marquées entre les deux états. À l'avenir, il sera crucial d'effectuer plus d'essais avec un bruit contrôlé, pour entraîner les modèles sur ces données en premier lieu, puis observer leur performance sur des données plus bruitées comme celles des données textiles. Un modèle d'intelligence artificielle entraîné sur des bases de données publiques de sommeil pourrait ensuite être testé sur les données textiles en situation de conduite pour pallier le problème de manque de données.

3.2.6 Distribution temporelle des événements somnolents

Les résultats indiquent que la majorité des accidents somnolents se produisent dans les premières 45 minutes des sessions de conduite, avec une moyenne observée autour de 34 minutes. Pour la suite du projet, il serait judicieux de raccourcir les expérimentations à 45 minutes. Cela aurait pour effet de réduire les perturbations des données générées par les mouvements de lassitude (repositionnement, soupir, énervement). Il serait nécessaire de stopper les sujets une fois un accident majeur observé pour éviter toute ambiguïté sur les données suivant un crash somnolent.

3.2.7 Détection de la somnolence à partir des données textiles

Enfin, en ce qui concerne la détection de la somnolence, les résultats montrent que **les données textiles permettent de classer** cet état avec une précision **comparable à celle des données de référence**. Les modèles SVM et SDF se sont montrés relativement efficaces, atteignant des scores F1 intéressant pour la référence et les données expérimentales, avec respectivement de **0.68 et 0.66**. Il est intéressant de noter que le bruit plus important **des électrodes textiles impact peu les performances de détection des modèles**. On remarque des performances de généralisation variables dépendamment des sessions utilisées en test comme indiqué par les écart-types des scores F1. On peut expliquer ses performances variables par plusieurs facteurs. Premièrement, comme on l'a observé, **la variabilité inter-session et sujets est très grande** rendant **la généralisation compliquée** avec peu de données. De plus, les profils des données entre **les deux classes sont inversées pour certaines sessions**. Pour finir, la somnolence étant un

événement ponctuel rare, les bases de données pour ce type de détection sont souvent **dé balancé**, rendant la détection des classes minoritaires plus difficiles, cela est d'ailleurs observable dans nos résultats avec un rappel plus faibles pour la classe de données somnolente (proche des accidents). **L'augmentation de données permet d'empêcher le sur-apprentissage** du modèle sur les données non somnolente, ce qui a pour effet d'augmenter la performance de détection des moments somnolents de **0.66 à 0.87**. Mais cela à aussi pour conséquence d'augmenter le taux de faux positifs, ce qui n'est pas souhaitable dans un produit commercial, car les utilisateurs pourraient être irrités par de fausses alarmes. C'est donc un point qui doit être pris en compte lors de l'entraînement du modèle, et cela dépendra de l'objectif du produit final. Pour empêcher l'augmentation de données de créer trop de faux positifs, nous pourrions, dans de futurs travaux, déclencher une alarme uniquement lorsque la somnolence est détectée pendant 1 à 2 minutes consécutives. Pour toutes ces raisons, il est nécessaire d'acquérir plus de données pour pouvoir améliorer les performances et les capacités de généralisation du modèle, au vu de la variabilité inter-sujet observée dans les résultats. Idéalement, une autre expérience plus petite avec les mêmes paramètres pourrait être effectué, et les données acquises pourrait être utilisé comme données de tests pour le modèle entraîné sur les données de la première expérience.

Ces résultats de détection indiquent que notre système d'acquisition à l'aide d'électrodes inductives textiles est viable pour la détection de la somnolence et qu'il serait intéressant de poursuivre dans cette voie.

3.2.8 Remarques générales

Comme présenté dans la revue de littérature, le principal problème associé à la détection par électrodes textiles inductives provient des artefacts de mouvement. Malheureusement, le système actuel présente quelques lacunes, notamment concernant **le placement des électrodes**, qui ont tendance à **bouger lors d'une utilisation prolongée**. De plus, le placement **ne peut pas être ajusté** pour chaque sujet et leur morphologie. Il est donc impératif de développer **un système de matrices d'électrodes brodées** directement sur la ceinture de sécurité pour pouvoir s'adapter à toutes les morphologies et limiter leurs déplacements.

Néanmoins, lors de cette étude, nous avons prouvé qu'il était possible d'améliorer la précision des électrodes textiles inductives en proposant des techniques novatrices à l'aide de méthodes de choix de signaux ou de fusion **jusqu'alors non utilisées dans ce type de système**. Cependant, la précision est par moments trop faible et ces méthodes ne suffiront pas à améliorer le signal de manière convenable en tout temps. À l'avenir, il sera donc nécessaire de mettre **l'accent sur le développement d'indices de qualité** supplémentaires avec une **très bonne corrélation** avec les **performances d'estimation du rythme respiratoire** dans le but de pouvoir déterminer si un signal est de suffisamment bonne qualité pour être utilisé par un modèle de détection. Une autre piste d'amélioration de l'acquisition et du traitement de signal consisterait à modifier le système d'acquisition pour utiliser un système employant une boucle à verrouillage de phase, comme mentionné dans la revue de littérature. Ce système proposerait un premier filtrage analogique éliminant les fréquences indésirables avant le traitement numérique. Cela permettrait aussi de faire un pas vers des capteurs plus précis pouvant permettre la détection du rythme **respiratoire et cardiaque**. Nous serions alors capables de fusionner les données cardio-respiratoires pour obtenir une meilleure détection de la somnolence comme démontré dans les différentes études utilisant la fusion de données (Jacobé de Naurois *et al.*, 2019 ; Perrotte *et al.*, 2024 ; Zhou *et al.*, 2020).

La labellisation proposée dans ce mémoire permet d'effectuer une classification des moments de somnolence à l'aide des données issues des tests de conduite. Les données du rythme respiratoire extraites des électrodes inductives textiles permettent d'obtenir des **performances similaires à celles des données de référence**. À l'avenir, Il serait intéressant de trouver une autre base de vérité pour la labellisation des données, ce qui permettrait d'utiliser l'intégralité des données collectées. Une future étude pourrait utiliser les vidéos collectées pour évaluer le niveau de somnolence selon l'échelle KSS, afin de labelliser les données. Seulement **six caractéristiques** ont été utilisées pour la classification, et **aucune méthode de sélection de caractéristiques** n'a été tentée, ce qui laisse encore de la place pour l'amélioration dans de futurs travaux. Néanmoins, il sera nécessaire **d'acquérir davantage de données textiles de respiration** en situation de conduite pour tester la performance d'un modèle d'intelligence artificielle. Ce dernier pourrait

être entraîné sur des bases de données polysomnographiques, en labellisant les données précédant le stade de sommeil N1 comme somnolentes ou en utilisant le EEG comme base de vérité. Et finalement il serait testé sur les données expérimentales textiles. La détection de la somnolence proposée dans ce mémoire est un travail préliminaire pour prouver qu'un système utilisant des électrodes textiles pour l'acquisition de la respiration est utilisable pour ces tâches. Uniquement deux modèles simples à mettre en place ont été utilisés, mais la transition vers la somnolence est un évènement progressif, des modèles récurrents pourraient obtenir de meilleures performances que ceux utilisés dans ce mémoire.

CONCLUSION ET RECOMMANDATIONS

L'objectif principal de ce mémoire était de concevoir un système permettant d'évaluer la somnolence au volant à l'aide des signaux cardio-respiratoires acquis par des électrodes inductives et capacitives textiles sans contact. L'utilisation de ce dispositif a révélé que la position et la forme des électrodes avaient un impact sur la précision d'acquisition de la respiration. Les résultats ont démontré que pour obtenir les meilleurs signaux de respiration, il est nécessaire de maximiser les courbures des électrodes et le déplacement relatif des corps des sujets. Les électrodes rectangulaires situées sur la ceinture du conducteur ont montré la meilleure précision d'acquisition. Bien que les résultats d'acquisition aient été satisfaisants, un traitement numérique a été nécessaire afin d'augmenter la précision des mesures. Les méthodes d'amélioration des signaux, telles que la fusion par filtre de Kalman et le choix de signal à l'aide d'indices de qualité, ont toutes deux amélioré significativement la précision en augmentant la proportion d'enregistrements avec une **erreur absolue moyenne inférieure à 2 respirations/minute de 28% à 44%**. La performance de classification de la somnolence, similaire entre les données de référence et les données textiles, avec un **score F1** respectif de **0.68 ± 0.11** et **0.67 ± 0.04** , suggère que les électrodes textiles sont viables pour détecter les états de somnolence.

Au cours de ce de nos travaux de recherche, un nouveau système d'acquisition inductif textile multi-capteurs de la respiration a été proposé. L'utilisation d'une matrice de capteurs sur la ceinture de sécurité associée à la fusion des données ont permis d'améliorer la précision de mesure ainsi que sa stabilité par rapport aux études précédentes. Cette association est, à notre connaissance, la première utilisant des électrodes textiles inductives. Les données recueillies sont ensuite utilisées pour une classification linéaire des incidents somnolents, offrant les premiers résultats de classification de la somnolence à l'aide de capteurs textiles inductifs sans contact.

Néanmoins, les résultats sont perfectibles, les artefacts de mouvement jouent encore un rôle trop important dans la qualité des signaux. Pour corriger cela, il sera nécessaire à l'avenir de concevoir

un système de matrices d'électrodes brodées directement dans la ceinture pour améliorer les signaux. L'ajout de capteurs tels que des accéléromètres pourraient permettre de soustraire le bruit des signaux de respiration et ainsi réduire les artefacts. Pour envisager un système en situation réelle, il sera impératif de développer de solides indices de qualité pour permettre l'exclusion des signaux trop bruités avant toute tentative de détection de la somnolence.

Cette étude propose un système de détection de la somnolence non-invasive de la somnolence avec le premier système par fusion de capteurs textiles respiratoire. Le système expérimental obtient des performances de détection comparables à celle obtenue par les données expérimentales (ceinture respiratoire thoracique). Les résultats proposés dans cette étude poussent à améliorer le système existant et prouvent qu'il est possible de détecter la somnolence de manière non invasive à l'aide de la respiration. Ce projet pourrait donc avoir un impact considérable dans le domaine de la surveillance des conducteurs en permettant la détection de la somnolence sans filmer l'intérieur des habitacles des véhicules ou prendre le relais lorsque les mesures véhiculaires ou comportementales sont inutilisables.

LISTE DE RÉFÉRENCES BIBLIOGRAPHIQUES

- Akbar, I. A. & Igasaki, T. (2019). Drowsiness Estimation Using Electroencephalogram and Recurrent Support Vector Regression. *Information*, 10(6), 217. doi : 10.3390/info10060217.
- Akerstedt, T. & Gillberg, M. (1990). Subjective and objective sleepiness in the active individual. *The International Journal of Neuroscience*, 52(1-2), 29–37. doi : 10.3109/00207459008994241.
- Albadawi, Y., Takruri, M. & Awad, M. (2022). A Review of Recent Developments in Driver Drowsiness Detection Systems. *Sensors (Basel, Switzerland)*, 22(5), 2069. doi : 10.3390/s22052069.
- Albadawi, Y., AlRedhaei, A. & Takruri, M. (2023). Real-Time Machine Learning-Based Driver Drowsiness Detection Using Visual Features. *Journal of Imaging*, 9(5), 91. doi : 10.3390/jimaging9050091. Number : 5 Publisher : Multidisciplinary Digital Publishing Institute.
- Ansari, M. Y., Qaraqe, M., Charafeddine, F., Serpedin, E., Righetti, R. & Qaraqe, K. (2023). Estimating age and gender from electrocardiogram signals : A comprehensive review of the past decade. *Artificial Intelligence in Medicine*, 146, 102690. doi : 10.1016/j.artmed.2023.102690.
- Arefnezhad, S., Samiee, S., Eichberger, A. & Nahvi, A. (2019). Driver Drowsiness Detection Based on Steering Wheel Data Applying Adaptive Neuro-Fuzzy Feature Selection. *Sensors*, 19(4), 943. doi : 10.3390/s19040943. Number : 4 Publisher : Multidisciplinary Digital Publishing Institute.
- Arefnezhad, S., Hamet, J., Eichberger, A., Frühwirth, M., Ischebeck, A., Koglbauer, I. V., Moser, M. & Yousefi, A. (2022). Driver drowsiness estimation using EEG signals with a dynamical encoder–decoder modeling framework. *Scientific Reports*, 12(1), 2650. doi : 10.1038/s41598-022-05810-x. Publisher : Nature Publishing Group.
- Babchenko, A., Khanokh, B., Shomer, Y. & Nitzan, M. (1999). Fiber optic sensor for the measurement of the respiratory chest circumference changes. *Journal of Biomedical Optics*, 4(2), 224–229. doi : 10.1117/1.429909. Publisher : SPIE.
- Barandas, M., Folgado, D., Fernandes, L., Santos, S., Abreu, M., Bota, P., Liu, H., Schultz, T. & Gamboa, H. (2020). TSFEL : Time Series Feature Extraction Library. *SoftwareX*, 11. doi : 10.1016/j.softx.2020.100456. Publisher : Elsevier.

- Beirness, 1955, D. J., Desmond, 1949, K. J., Simpson, 1940, H. M. & Traffic Injury Research Foundation (Canada). (2005). *The road safety monitor 2004 : drowsy driving*. Ottawa : Traffic Injury Research Foundation.
- Benarroch, E. E. (2019). Control of the cardiovascular and respiratory systems during sleep. *Autonomic Neuroscience*, 218, 54–63. doi : 10.1016/j.autneu.2019.01.007.
- Bereshpolova, Y., Stoelzel, C. R., Zhuang, J., Amitai, Y., Alonso, J.-M. & Swadlow, H. A. (2011). Getting Drowsy? Alert/Nonalert Transitions and Visual Thalamo-cortical Network Dynamics. *The Journal of Neuroscience*, 31(48), 17480–17487. doi : 10.1523/JNEUROSCI.2262-11.2011.
- Berntson, G. G., Cacioppo, J. T. & Quigley, K. S. (1993). Respiratory sinus arrhythmia : Autonomic origins, physiological mechanisms, and psychophysiological implications. *Psychophysiology*, 30(2), 183–196. doi : 10.1111/j.1469-8986.1993.tb01731.x. _eprint : <https://onlinelibrary.wiley.com/doi/pdf/10.1111/j.1469-8986.1993.tb01731.x>.
- Borza, D., Itu, R. & Danescu, R. (2018). In the Eye of the Deceiver : Analyzing Eye Movements as a Cue to Deception. *Journal of Imaging*, 4, 120. doi : 10.3390/jimaging4100120.
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32. doi : 10.1023/A:1010933404324.
- Brezulianu, A., Geman, O., Zbancioc, M. D., Hagan, M., Aghion, C., Hemanth, D. J. & Son, L. H. (2019). IoT Based Heart Activity Monitoring Using Inductive Sensors. *Sensors*, 19(15), 3284. doi : 10.3390/s19153284.
- Brinkman, J. E., Toro, F. & Sharma, S. (2024). Physiology, Respiratory Drive. Dans *StatPearls*. Treasure Island (FL) : StatPearls Publishing. Repéré à <http://www.ncbi.nlm.nih.gov/books/NBK482414/>.
- Budak, U., Bajaj, V., Akbulut, Y., Atila, O. & Sengur, A. (2019). An Effective Hybrid Model for EEG-Based Drowsiness Detection. *IEEE Sensors Journal*, 19(17), 7624–7631. doi : 10.1109/JSEN.2019.2917850. Conference Name : IEEE Sensors Journal.
- Buysse, D. J., Reynolds, C. F., Monk, T. H., Berman, S. R. & Kupfer, D. J. (1989). The Pittsburgh Sleep Quality Index : a new instrument for psychiatric practice and research. *Psychiatry Research*, 28(2), 193–213. doi : 10.1016/0165-1781(89)90047-4.
- Cervantes, J., Garcia-Lamont, F., Rodríguez-Mazahua, L. & Lopez, A. (2020). A comprehensive survey on support vector machine classification : Applications, challenges and trends. *Neurocomputing*, 408, 189–215. doi : 10.1016/j.neucom.2019.10.118.

- Charlton, P. H., Bonnici, T., Tarassenko, L., Clifton, D. A., Beale, R. & Watkinson, P. J. (2016). An assessment of algorithms to estimate respiratory rate from the electrocardiogram and photoplethysmogram. *Physiological Measurement*, 37(4), 610–626. doi : 10.1088/0967-3334/37/4/610.
- Charlton, P. H., Birrenkott, D. A., Bonnici, T., Pimentel, M. A. F., Johnson, A. E. W., Alastruey, J., Tarassenko, L., Watkinson, P. J., Beale, R. & Clifton, D. A. (2018). Breathing Rate Estimation From the Electrocardiogram and Photoplethysmogram : A Review. *IEEE reviews in biomedical engineering*, 11, 2–20. doi : 10.1109/RBME.2017.2763681.
- Chatelais, B. & Gagnon, J.-F. (2019). Extracting human breathing rate from the fusion of multiple piezo-resistive membranes. *2019 22th International Conference on Information Fusion (FUSION)*, pp. 1–8. doi : 10.23919/FUSION43075.2019.9011188.
- Cho, H.-S., Yang, J.-H., Lee, S.-Y., Lee, J.-W. & Lee, J.-H. (2022). Wearable Fabric Loop Sensor Based on Magnetic-Field-Induced Conductivity for Simultaneous Detection of Cardiac Activity and Respiration Signals. *Sensors*, 22(24), 9884. doi : 10.3390/s22249884. Number : 24 Publisher : Multidisciplinary Digital Publishing Institute.
- Chourpiliadis, C. & Bhardwaj, A. (2024). Physiology, Respiratory Rate. Dans *StatPearls*. Treasure Island (FL) : StatPearls Publishing. Repéré à <http://www.ncbi.nlm.nih.gov/books/NBK537306/>.
- Christian Kothe, Medine, D., Chadwick Boulay, Tristan Stenner & Matthew Grivich. (2024). *sccn/labstreaminglayer*. Swartz Center for Computational Neuroscience. original-date : 2018-02-28T10 :50 :12Z, Repéré à <https://github.com/sccn/labstreaminglayer>.
- Cleveland Clinic. (2024). Respiratory System. Repéré à <https://my.clevelandclinic.org/health/body/21205-respiratory-system>.
- Cousins, S., Blencowe, N. S. & Blazeby, J. M. (2019). What is an invasive procedure? A definition to inform study design, evidence synthesis and research tracking. *BMJ Open*, 9(7), e028576. doi : 10.1136/bmjopen-2018-028576.
- Das, D., Zhou, S. & Lee, J. D. (2012). Differentiating Alcohol-Induced Driving Behavior Using Steering Wheel Signals. *IEEE Transactions on Intelligent Transportation Systems*, 13(3), 1355–1368. doi : 10.1109/TITS.2012.2188891. Conference Name : IEEE Transactions on Intelligent Transportation Systems.
- Douglas, N. J., White, D. P., Pickett, C. K., Weil, J. V. & Zwillich, C. W. (1982). Respiration during sleep in normal man. *Thorax*, 37(11), 840–844. doi : 10.1136/thx.37.11.840.

- Drobnich, D. (2005). A National Sleep Foundation's Conference Summary : The National Summit to Prevent Drowsy Driving and a New Call to Action. *INDUSTRIAL HEALTH*, 43(1), 197–200. doi : 10.2486/indhealth.43.197.
- Ebrahim Shaik, M. (2023). A systematic review on detection and prediction of driver drowsiness. *Transportation Research Interdisciplinary Perspectives*, 21, 100864. doi : 10.1016/j.trip.2023.100864.
- El-Nabi, S. A., El-Shafai, W., El-Rabaie, E.-S. M., Ramadan, K. F., Abd El-Samie, F. E. & Mohsen, S. (2024). Machine learning and deep learning techniques for driver fatigue and drowsiness detection : a review. *Multimedia Tools and Applications*, 83(3), 9441–9477. doi : 10.1007/s11042-023-15054-0.
- Electrophysiology, T. F. o. t. E. S. o. C. t. N. A. S. o. P. (1996). Heart Rate Variability. *Circulation*, 93(5), 1043–1065. doi : 10.1161/01.CIR.93.5.1043. Publisher : American Heart Association.
- Elgendi, M. (2016). Optimal Signal Quality Index for Photoplethysmogram Signals. *Bioengineering*, 3(4), 21. doi : 10.3390/bioengineering3040021. Number : 4 Publisher : Multidisciplinary Digital Publishing Institute.
- Fairclough, S. H. & Graham, R. (1999). Impairment of driving performance caused by sleep deprivation or alcohol : a comparative study. *Human Factors*, 41(1), 118–128. doi : 10.1518/001872099779577336.
- Forsman, P. M., Vila, B. J., Short, R. A., Mott, C. G. & Van Dongen, H. P. (2013). Efficient driver drowsiness detection at moderate levels of drowsiness. *Accident Analysis & Prevention*, 50, 341–350. doi : 10.1016/j.aap.2012.05.005.
- Fouad, I. A. (2023). A robust and efficient EEG-based drowsiness detection system using different machine learning algorithms. *Ain Shams Engineering Journal*, 14(3), 101895. doi : 10.1016/j.asej.2022.101895.
- Fujiwara, K., Abe, E., Kamata, K., Nakayama, C., Suzuki, Y., Yamakawa, T., Hiraoka, T., Kano, M., Sumi, Y., Masuda, F., Matsuo, M. & Kadotani, H. (2019). Heart Rate Variability-Based Driver Drowsiness Detection and Its Validation With EEG. *IEEE Transactions on Biomedical Engineering*, 66(6), 1769–1778. doi : 10.1109/TBME.2018.2879346. Conference Name : IEEE Transactions on Biomedical Engineering.
- Gharagozlou, F., Nasl Saraji, G., Mazloumi, A., Nahvi, A., Motie Nasrabadi, A., Rahimi Foroushani, A., Arab Kheradmand, A., Ashouri, M. & Samavati, M. (2015). Detecting Driver Mental Fatigue Based on EEG Alpha Power Changes during Simulated Driving. *Iranian Journal of Public Health*, 44(12), 1693–1700.

- Ghoddosian, R., Galib, M. & Athitsos, V. (2019). A Realistic Dataset and Baseline Temporal Model for Early Drowsiness Detection. arXiv. arXiv :1904.07312 [cs], Repéré à <http://arxiv.org/abs/1904.07312>.
- Gi, S. O., Lee, Y. J., Koo, H. R., Khang, S., Kim, K.-N., Kang, S.-J., Lee, J. H. & Lee, J.-W. (2015). Application of a Textile-based Inductive Sensor for the Vital Sign Monitoring. *Journal of Electrical Engineering and Technology*, 10(1), 364–371. doi : 10.5370/JEET.2015.10.1.364.
- Gordan, R., Gwathmey, J. K. & Xie, L.-H. (2015). Autonomic and endocrine control of cardiovascular function. *World Journal of Cardiology*, 7(4), 204–214. doi : 10.4330/wjc.v7.i4.204.
- Guede-Fernández, F., Fernández-Chimeno, M., Ramos-Castro, J. & García-González, M. A. (2019). Driver Drowsiness Detection Based on Respiratory Signal Analysis. *IEEE Access*, 7, 81826–81838. doi : 10.1109/ACCESS.2019.2924481. Conference Name : IEEE Access.
- He, H., Bai, Y., Garcia, E. A. & Li, S. (2008). ADASYN : Adaptive synthetic sampling approach for imbalanced learning. *2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)*, pp. 1322–1328. doi : 10.1109/IJCNN.2008.4633969.
- Hong, H., Zhang, L., Gu, C., Li, Y., Zhou, G. & Zhu, X. (2018). Noncontact Sleep Stage Estimation Using a CW Doppler Radar. *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, 8(2), 260–270. doi : 10.1109/JETCAS.2017.2789278.
- Horne, J. A. & Reyner, L. A. (1995). Driver sleepiness. *Journal of Sleep Research*, 4(s2), 23–29. doi : 10.1111/j.1365-2869.1995.tb00222.x. _eprint : <https://onlinelibrary.wiley.com/doi/pdf/10.1111/j.1365-2869.1995.tb00222.x>.
- Igasaki, T., Nagasawa, K., Murayama, N. & Hu, Z. (2015). Drowsiness estimation under driving environment by heart rate variability and/or breathing rate variability with logistic regression analysis. *2015 8th International Conference on Biomedical Engineering and Informatics (BMEI)*, pp. 189–193. doi : 10.1109/BMEI.2015.7401498.
- Ingre, M., Akerstedt, T., Peters, B., Anund, A. & Kecklund, G. (2006). Subjective sleepiness, simulated driving performance and blink duration : examining individual differences. *Journal of Sleep Research*, 15(1), 47–53. doi : 10.1111/j.1365-2869.2006.00504.x.
- Jacobé de Naurois, C., Bourdin, C., Stratulat, A., Diaz, E. & Vercher, J.-L. (2019). Detection and prediction of driver drowsiness using artificial neural network models. *Accident Analysis & Prevention*, 126, 95–104. doi : 10.1016/j.aap.2017.11.038.

- Jafari Tadi, M., Koivisto, T., Pänkäälä, M. & Paasio, A. (2014). Accelerometer-Based Method for Extracting Respiratory and Cardiac Gating Information for Dual Gating during Nuclear Medicine Imaging. *International Journal of Biomedical Imaging*, 2014(1), 690124. doi : 10.1155/2014/690124. _eprint : <https://onlinelibrary.wiley.com/doi/pdf/10.1155/2014/690124>.
- Johns, M. W. (1991). A new method for measuring daytime sleepiness : the Epworth sleepiness scale. *Sleep*, 14(6), 540–545. doi : 10.1093/sleep/14.6.540.
- Karlen, W., Turner, M., Cooke, E., Dumont, G. & M, J. Ansermino. Place : Capnobase.
- Kaur, B., Kumar, P., Roy, P. P. & Singh, D. (2017). Impact of Ageing on EEG Based Biometric Systems. pp. 459–464. doi : 10.1109/ACPR.2017.33.
- Khodadad, D., Nordebo, S., Müller, B., Waldmann, A., Yerworth, R., Becher, T., Frerichs, I., Sophocleous, L., van Kaam, A., Miedema, M., Seifnaraghi, N. & Bayford, R. (2018). Optimized breath detection algorithm in electrical impedance tomography. *Physiological Measurement*, 39(9), 094001. doi : 10.1088/1361-6579/aad7e6.
- Khreis, S., Ge, D., Rahman, H. A. & Carrault, G. (2020). Breathing Rate Estimation Using Kalman Smoother With Electrocardiogram and Photoplethysmogram. *IEEE Transactions on Biomedical Engineering*, 67(3), 893–904. doi : 10.1109/TBME.2019.2923448. Conference Name : IEEE Transactions on Biomedical Engineering.
- Kiashari, S. E. H., Nahvi, A., Homayounfard, A. & Bakhoda, H. (2018). Monitoring the Variation in Driver Respiration Rate from Wakefulness to Drowsiness : A Non-Intrusive Method for Drowsiness Detection Using Thermal Imaging. 3(1), 10.
- Kiashari, S. E. H., Nahvi, A., Bakhoda, H., Homayounfard, A. & Tashakori, M. (2020). Evaluation of driver drowsiness using respiration analysis by thermal imaging on a driving simulator. *Multimedia Tools and Applications*, 79(25), 17793–17815. doi : 10.1007/s11042-020-08696-x.
- Knipling, R. R. & Wierwille, W. W. (1994). Vehicle-based drowsy driver detection : Current status and future prospects : (526702009-001). Institution : American Psychological Association, doi : 10.1037/e526702009-001.
- Koh, S., Cho, B. R., Lee, J.-i., Kwon, S.-O., Lee, S., Beom Lim, J., Lee, S. B. & Kweon, H.-D. (2017). Driver drowsiness detection via PPG biosignals by using multimodal head support. *2017 4th International Conference on Control, Decision and Information Technologies (CoDIT)*, pp. 0383–0388. doi : 10.1109/CoDIT.2017.8102622.

- Koo, H. R., Lee, Y.-J., Gi, S., Khang, S., Lee, J. H., Lee, J.-H., Lim, M.-G., Park, H.-J. & Lee, J.-W. (2014). The Effect of Textile-Based Inductive Coil Sensor Positions for Heart Rate Monitoring. *Journal of Medical Systems*, 38(2), 2. doi : 10.1007/s10916-013-0002-0.
- Kundinger, T., Sofra, N. & Riener, A. (2020). Assessment of the Potential of Wrist-Worn Wearable Sensors for Driver Drowsiness Detection. *Sensors (Basel, Switzerland)*, 20(4), 1029. doi : 10.3390/s20041029.
- Körber, M., Cingel, A., Zimmermann, M. & Bengler, K. (2015). Vigilance Decrement and Passive Fatigue Caused by Monotony in Automated Driving. *Procedia Manufacturing*, 3, 2403–2409. doi : 10.1016/j.promfg.2015.07.499.
- Lamb, K., Theodore, D. & Bhutta, B. S. (2024). Spirometry. Dans *StatPearls*. Treasure Island (FL) : StatPearls Publishing. Repéré à <http://www.ncbi.nlm.nih.gov/books/NBK560526/>.
- Larue, G. S., Rakotonirainy, A. & Pettitt, A. N. (2011). Driving performance impairments due to hypovigilance on monotonous roads. *Accident Analysis & Prevention*, 43(6), 2037–2046. doi : 10.1016/j.aap.2011.05.023.
- Lee, B.-G., Lee, B.-L. & Chung, W.-Y. (2014). Mobile Healthcare for Automatic Driving Sleep-Onset Detection Using Wavelet-Based EEG and Respiration Signals. *Sensors*, 14(10), 17915–17936. doi : 10.3390/s141017915.
- Lee, J., Kim, M., Park, H.-K. & Kim, I. Y. (2020). Motion Artifact Reduction in Wearable Photoplethysmography Based on Multi-Channel Sensors with Multiple Wavelengths. *Sensors (Basel, Switzerland)*, 20(5), 1493. doi : 10.3390/s20051493.
- Leicht, L., Vetter, P., Leonhardt, S. & Teichmann, D. (2017). The PhysioBelt : A safety belt integrated sensor system for heart activity and respiration. *2017 IEEE International Conference on Vehicular Electronics and Safety (ICVES)*, pp. 191–195. doi : 10.1109/ICVES.2017.7991924.
- Leicht, L., Walter, M., Mathissen, M., Antink, C. H., Teichmann, D. & Leonhardt, S. (2022). Unobtrusive Measurement of Physiological Features Under Simulated and Real Driving Conditions. *IEEE Transactions on Intelligent Transportation Systems*, 23(5), 4767–4777. doi : 10.1109/TITS.2022.3143004. Conference Name : IEEE Transactions on Intelligent Transportation Systems.
- Lepine, N. N., Tajima, T., Ogasawara, T., Kasahara, R. & Koizumi, H. (2016). Robust respiration rate estimation using adaptive Kalman filtering with textile ECG sensor and accelerometer. *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 3797–3800. doi : 10.1109/EMBC.2016.7591555.

- Lessard-Tremblay, M., Weeks, J., Morelli, L., Cowan, G., Gagnon, G. & Zednik, R. J. (2020). Contactless Capacitive Electrocardiography Using Hybrid Flexible Printed Electrodes. *Sensors (Basel, Switzerland)*, 20(18). doi : 10.3390/s20185156. Publisher : Multidisciplinary Digital Publishing Institute (MDPI).
- Li, G. & Chung, W.-Y. (2013). Detection of Driver Drowsiness Using Wavelet Analysis of Heart Rate Variability and a Support Vector Machine Classifier. *Sensors*, 13(12), 16494–16511. doi : 10.3390/s131216494. Number : 12 Publisher : Multidisciplinary Digital Publishing Institute.
- Li, G., Lee, B.-L. & Chung, W.-Y. (2015). Smartwatch-Based Wearable EEG System for Driver Drowsiness Detection. *IEEE Sensors Journal*, 15(12), 7169–7180. doi : 10.1109/JSEN.2015.2473679. Conference Name : IEEE Sensors Journal.
- Lin, C.-T., Wu, R.-C., Liang, S.-F., Chao, W.-H., Chen, Y.-J. & Jung, T.-P. (2005). EEG-based drowsiness estimation for safety driving using independent component analysis. *IEEE Transactions on Circuits and Systems I : Regular Papers*, 52(12), 2726–2738. doi : 10.1109/TCSI.2005.857555. Conference Name : IEEE Transactions on Circuits and Systems I : Regular Papers.
- Luo, Z. & Wei, X. (2018). Theoretical Analysis of Planar Spiral Coils between Two Multilayer Media for Electric Vehicle Wireless Charging. *Energies*, 11(4), 693. doi : 10.3390/en11040693.
- Ma, J., Murphey, Y. L. & Zhao, H. (2015). Real Time Drowsiness Detection Based on Lateral Distance Using Wavelet Transform and Neural Network. *2015 IEEE Symposium Series on Computational Intelligence*, pp. 411–418. doi : 10.1109/SSCI.2015.68.
- Makowski, D., Pham, T., Lau, Z. J., Brammer, J. C., Lespinasse, F., Pham, H., Schölzel, C. & Chen, S. H. A. (2021). NeuroKit2 : A Python toolbox for neurophysiological signal processing. *Behavior Research Methods*, 53(4), 1689–1696. doi : 10.3758/s13428-020-01516-y.
- Market.us. (2024). Driver Drowsiness Detection System Market Size| CAGR of 11.8%. Repéré à <https://market.us/report/driver-drowsiness-detection-system-market/>.
- Martin, A. & Voix, J. (2018). In-Ear Audio Wearable : Measurement of Heart and Breathing Rates for Health and Safety Monitoring. *IEEE Transactions on Biomedical Engineering*, 65(6), 1256–1263. doi : 10.1109/TBME.2017.2720463. Conference Name : IEEE Transactions on Biomedical Engineering.
- Massoz, Q., Langohr, T., François, C. & Verly, J. G. (2016). The ULg multimodality drowsiness database (called DROZY) and examples of use. *2016 IEEE Winter Conference on Applications of Computer Vision (WACV)*, pp. 1–7. doi : 10.1109/WACV.2016.7477715.

- McInnes, L., Healy, J. & Melville, J. (2020). UMAP : Uniform Manifold Approximation and Projection for Dimension Reduction. *arXiv*. arXiv :1802.03426 [cs, stat], doi : 10.48550/arXiv.1802.03426.
- Mehta, S., Dadhich, S., Gumber, S. & Jadhav Bhatt, A. (2019). Real-Time Driver Drowsiness Detection System Using Eye Aspect Ratio and Eye Closure Ratio. *SSRN Electronic Journal*. doi : 10.2139/ssrn.3356401.
- Nasri, I., Karrouchi, M., Snoussi, H., Kassmi, K. & Messaoudi, A. (2022). Detection and Prediction of Driver Drowsiness for the Prevention of Road Accidents Using Deep Neural Networks Techniques. *WITS 2020*, pp. 57–64. doi : 10.1007/978-981-33-6893-4_6.
- National institute of neurological disorders and stroke. (2024). Brain Basics : Understanding Sleep | National Institute of Neurological Disorders and Stroke. Repéré à <https://www.ninds.nih.gov/health-information/public-education/brain-basics/brain-basics-understanding-sleep>.
- Nayak, C. S. & Anilkumar, A. C. (2024). EEG Normal Sleep. Dans *StatPearls*. Treasure Island (FL) : StatPearls Publishing. Repéré à <http://www.ncbi.nlm.nih.gov/books/NBK537023/>.
- Nemati, S., Malhotra, A. & Clifford, G. D. (2010). Data Fusion for Improved Respiration Rate Estimation. *EURASIP Journal on Advances in Signal Processing*, 2010(1), 926305. doi : 10.1155/2010/926305.
- Nguyen, T. P., Chew, M. T. & Demidenko, S. (2015). Eye tracking system to detect driver drowsiness. *2015 6th International Conference on Automation, Robotics and Applications (ICARA)*, pp. 472–477. doi : 10.1109/ICARA.2015.7081194.
- Němcová, A., Svozilová, V., Bucsuházy, K., Smíšek, R., Mézl, M., Hesko, B., Belák, M., Bilík, M., Maxera, P., Seitzl, M., Dominik, T., Semela, M., Šucha, M. & Kolář, R. (2021). Multimodal Features for Detection of Driver Stress and Fatigue : Review. *IEEE Transactions on Intelligent Transportation Systems*, 22(6), 3214–3233. doi : 10.1109/TITS.2020.2977762. Conference Name : IEEE Transactions on Intelligent Transportation Systems.
- Okogbaa, O. G., Shell, R. L. & Filipusic, D. (1994). On the investigation of the neurophysiological correlates of knowledge worker mental fatigue using the EEG signal. *Applied Ergonomics*, 25(6), 355–365. doi : 10.1016/0003-6870(94)90054-X.
- Orphanidou, C., Bonnici, T., Charlton, P., Clifton, D., Vallance, D. & Tarassenko, L. (2014). Signal Quality Indices for the Electrocardiogram and Photoplethysmogram : Derivation and Applications to Wireless Monitoring. *IEEE Journal of Biomedical and Health Informatics*, 1–1. doi : 10.1109/JBHI.2014.2338351.

- Patel, A. K., Reddy, V., Shumway, K. R. & Araujo, J. F. (2024). Physiology, Sleep Stages. Dans *StatPearls*. Treasure Island (FL) : StatPearls Publishing. Repéré à <http://www.ncbi.nlm.nih.gov/books/NBK526132/>.
- Patiño, A. G. & Menon, C. (2021). Inductive Textile Sensor Design and Validation for a Wearable Monitoring Device. *Sensors (Basel, Switzerland)*, 21(1), 225. doi : 10.3390/s21010225.
- PB2. (2024). PowerBroker2/SerialTransfer. original-date : 2019-07-16T21 :50 :05Z, Repéré à <https://github.com/PowerBroker2/SerialTransfer>.
- Pei, Y., Biswas, S., Fussell, D. S. & Pingali, K. (2019). An Elementary Introduction to Kalman Filtering. arXiv. arXiv :1710.04055 [cs, eess], Repéré à <http://arxiv.org/abs/1710.04055>.
- Perrotte, G., Bougard, C., Portron, A. & Vercher, J.-L. (2024). Monitoring driver drowsiness in partially automated vehicles : Added value from combining postural and physiological indicators. *Transportation Research Part F : Traffic Psychology and Behaviour*, 100, 458–474. doi : 10.1016/j.trf.2023.12.010.
- Pimentel, M. A. F., Charlton, P. H. & Clifton, D. A. (2015). Probabilistic Estimation of Respiratory Rate from Wearable Sensors. Dans Mukhopadhyay, S. C. (Éd.), *Wearable Electronics Sensors : For Safe and Healthy Living* (pp. 241–262). Cham : Springer International Publishing. doi : 10.1007/978-3-319-18191-2_10.
- Ramzan, M., Khan, H. U., Awan, S. M., Ismail, A., Ilyas, M. & Mahmood, A. (2019). A Survey on State-of-the-Art Drowsiness Detection Techniques. *IEEE Access*, 7, 61904–61919. doi : 10.1109/ACCESS.2019.2914373. Conference Name : IEEE Access.
- Reddy, S., Reddy, V. & Sharma, S. (2024). Physiology, Circadian Rhythm. Dans *StatPearls*. Treasure Island (FL) : StatPearls Publishing. Repéré à <http://www.ncbi.nlm.nih.gov/books/NBK519507/>.
- Richer, A. & Adler, A. (2005). Eddy Current Based Flexible Sensor for Contactless Measurement of Breathing. *2005 IEEE Instrumentation and Measurement Technology Conference Proceedings*, 1, 257–260. doi : 10.1109/IMTC.2005.1604112.
- Rodriguez-Ibanez, N., Garcia-Gonzalez, M. A., Fernandez-Chimeno, M. & Ramos-Castro, J. (2011). Drowsiness detection by thoracic effort signal analysis in real driving environments. *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 6055–6058. doi : 10.1109/IEMBS.2011.6091496.

- Roehrs, T., Carskadon, M. A., Dement, W. C. & Roth, T. (2017). Chapter 4 - Daytime Sleepiness and Alertness. Dans Kryger, M., Roth, T. & Dement, W. C. (Éds.), *Principles and Practice of Sleep Medicine (Sixth Edition)* (pp. 39–48.e4). Elsevier. doi : 10.1016/B978-0-323-24288-2.00004-0.
- Roger R. Labbe Jr. (2024a). FilterPy. original-date : 2014-07-15T02 :15 :19Z, Repéré à <https://github.com/rlabbe/filterpy>.
- Roger R. Labbe Jr. (2024b). Kalman and Bayesian Filters in Python. Repéré à <https://github.com/rlabbe/Kalman-and-Bayesian-Filters-in-Python/>.
- Romano, C., Innocenti, L., Schena, E., Sacchetti, M., Nicolò, A. & Massaroni, C. (2023). A Signal Quality Index for Improving the Estimation of Breath-by-Breath Respiratory Rate During Sport and Exercise. *IEEE Sensors Journal*, 23(24), 31250–31258. doi : 10.1109/JSEN.2023.3330444.
- S, P., M, M. D. & S, S. (2022). A Review on Drowsiness Prediction System using Deep Learning Approaches. *2022 6th International Conference on Computing Methodologies and Communication (ICCMC)*, pp. 1079–1084. doi : 10.1109/ICCMC53470.2022.9753842.
- Serteyn, A., Vullings, R., Meftah, M. & Bergmans, J. W. M. (2015). Motion Artifacts in Capacitive ECG Measurements : Reducing the Combined Effect of DC Voltages and Capacitance Changes Using an Injection Signal. *IEEE Transactions on Biomedical Engineering*, 62(1), 264–273. doi : 10.1109/TBME.2014.2348178.
- Shahid, A., Wilkinson, K., Marcu, S. & Shapiro, C. M. (2011a). Karolinska Sleepiness Scale (KSS). Dans Shahid, A., Wilkinson, K., Marcu, S. & Shapiro, C. M. (Éds.), *STOP, THAT and One Hundred Other Sleep Scales* (pp. 209–210). New York, NY : Springer New York. doi : 10.1007/978-1-4419-9893-4_47.
- Shahid, A., Wilkinson, K., Marcu, S. & Shapiro, C. M. (2011b). Stanford Sleepiness Scale (SSS). Dans Shahid, A., Wilkinson, K., Marcu, S. & Shapiro, C. M. (Éds.), *STOP, THAT and One Hundred Other Sleep Scales* (pp. 369–370). New York, NY : Springer New York. doi : 10.1007/978-1-4419-9893-4_91.
- Siddiqui, H. U. R., Saleem, A. A., Brown, R., Bademci, B., Lee, E., Rustam, F. & Dudley, S. (2021). Non-Invasive Driver Drowsiness Detection System. *Sensors*, 21(14), 4833. doi : 10.3390/s21144833. Number : 14 Publisher : Multidisciplinary Digital Publishing Institute.

- Sikander, G. & Anwar, S. (2019). Driver Fatigue Detection Systems : A Review. *IEEE Transactions on Intelligent Transportation Systems*, 20(6), 2339–2352. doi : 10.1109/TITS.2018.2868499. Conference Name : IEEE Transactions on Intelligent Transportation Systems.
- Soni, R. & Muniyandi, M. (2019). Breath Rate Variability : A Novel Measure to Study the Meditation Effects. *International Journal of Yoga*, 12(1), 45–54. doi : 10.4103/i-joy.IJOY_27_17.
- Stelzer, I. V., Kager, J. & Herwig, C. (2017). Comparison of Particle Filter and Extended Kalman Filter Algorithms for Monitoring of Bioprocesses. Dans Espuña, A., Graells, M. & Puigjaner, L. (Éds.), *Computer Aided Chemical Engineering* (vol. 40, pp. 1483–1488). Elsevier. doi : 10.1016/B978-0-444-63965-3.50249-X.
- Suni, E. & Rehman, A. (2022). Drowsy Driving. Running Time : 301, Repéré à <https://www.sleepfoundation.org/drowsy-driving>.
- Sörnmo, L. & Laguna, P. (2005). Chapter 3 - EEG Signal Processing. Dans Sörnmo, L. & Laguna, P. (Éds.), *Bioelectrical Signal Processing in Cardiac and Neurological Applications* (pp. 55–179). Burlington : Academic Press. doi : 10.1016/B978-012437552-9/50003-9.
- Tateno, S., Guan, X., Cao, R. & Qu, Z. (2018). Development of Drowsiness Detection System Based on Respiration Changes Using Heart Rate Monitoring. *2018 57th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE)*, pp. 1664–1669. doi : 10.23919/SICE.2018.8492599.
- Tefft, B. C. (2024). Drowsy Driving in Fatal Crashes, United States, 2017–2021 - AAA Foundation for Traffic Safety. Repéré à <https://aaafoundation.org/drowsy-driving-in-fatal-crashes-united-states-2017-2021/>, <https://aaafoundation.org/drowsy-driving-in-fatal-crashes-united-states-2017-2021/>.
- Tefft, B. C. (2014). Prevalence of motor vehicle crashes involving drowsy drivers, United States, 1999–2008. *Accident Analysis & Prevention*, 45, 180–186. doi : 10.1016/j.aap.2011.05.028.
- Texas Instruments. (2024). LDC1612 data sheet, product information and support | TI.com. Repéré à https://www.ti.com/product/LDC1612?utm_source=google&utm_medium=cpc&utm_campaign=asc-null-null-GPN_EN-cpc-pf-google-ww&utm_content=LDC1612&ds_k=LDC1612&DCM=yes&gad_source=1&gclid=Cj0KCQiAoae5BhCNARIsADVLzZcoFP13CYyvq_w7GQmJ0jFc_p6bWwZooomcLWqJp-nVdmE0Rup0I-IaArSCEALw_wcB&gclsrc=aw.ds.

- Trinder, J., Whitworth, F., Kay, A. & Wilkin, P. (1992). Respiratory instability during sleep onset. *Journal of Applied Physiology*, 73(6), 2462–2469. doi : 10.1152/jappl.1992.73.6.2462. Publisher : American Physiological Society.
- Trutschel, U., Sirois, B., Sommer, D., Golz, M. & Edwards, D. (2011). PERCLOS : An Alertness Measure of the Past. *Driving Assessment Conference*, 6(2011). doi : 10.17077/drivingassessment.1394. Number : 2011 Publisher : University of Iowa.
- Uzunidis, D., Kasnesis, P., Papadopoulos, F. G., Paliodimos, E. N., Patrikakis, C. Z. & Mitilineos, S. A. (2024). Breathing Rate Estimation Behind Walls Exploiting a UWB Radar Sensor. *2024 13th International Conference on Modern Circuits and Systems Technologies (MOCAST)*, pp. 1–4. doi : 10.1109/MOCAST61810.2024.10615864.
- Vanlaar, W., Simpson, H., Mayhew, D. & Robertson, R. (2008). Fatigued and drowsy driving : A survey of attitudes, opinions and behaviors. *Journal of Safety Research*, 39(3), 303–309. doi : 10.1016/j.jsr.2007.12.007.
- Vicente, J., Laguna, P., Bartra, A. & Bailón, R. (2016). Drowsiness detection using heart rate variability. *Medical & Biological Engineering & Computing*, 54(6), 927–937. doi : 10.1007/s11517-015-1448-7.
- Volvo Car USA. (2007). Volvo Cars introduces new systems for alerting tired and distracted drivers. Repéré à <https://www.media.volvocars.com/us/en-us/media/pressreleases/12130/>.
- Walter, M., Eilebrecht, B., Wartzek, T. & Leonhardt, S. (2011). The smart car seat : personalized monitoring of vital signs in automotive applications. *Personal and Ubiquitous Computing*, 15(7), 707–715. doi : 10.1007/s00779-010-0350-4.
- Walter W. Wierwille & L. A. Ellsworth. (1994). *Research On Vehicle-Based Driver Status/Performance Monitoring ; Development, Validation, And Refinement Of Algorithms For Detection Of Driver Drowsiness, Final Report*. Repéré à <https://rosap.nhtl.bts.gov/view/dot/2578>.
- Warnecke, J. M., Wang, J. & Deserno, T. M. (2019). Noise Reduction for Efficient In-Vehicle Respiration Monitoring with Accelerometers. *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 3257–3261. doi : 10.1109/EMBC.2019.8857654.
- Warnecke, J. M., Lasenby, J. & Deserno, T. M. (2023). Robust in-vehicle respiratory rate detection using multimodal signal fusion. *Scientific Reports*, 13(1), 20435. doi : 10.1038/s41598-023-47504-y. Publisher : Nature Publishing Group.

- Waxenbaum, J. A., Reddy, V. & Varacallo, M. (2024). Anatomy, Autonomic Nervous System. Dans *StatPearls*. Treasure Island (FL) : StatPearls Publishing. Repéré à <http://www.ncbi.nlm.nih.gov/books/NBK539845/>.
- Wicaksono, I., Tucker, C. I., Sun, T., Guerrero, C. A., Liu, C., Woo, W. M., Pence, E. J. & Dagdeviren, C. (2020). A tailored, electronic textile conformable suit for large-scale spatiotemporal physiological sensing in vivo. *npj Flexible Electronics*, 4(1), 1–13. doi : 10.1038/s41528-020-0068-y. Publisher : Nature Publishing Group.
- Wierwille, W. W. & Ellsworth, L. A. (1994). Evaluation of driver drowsiness by trained raters. *Accident ; Analysis and Prevention*, 26(5), 571–581. doi : 10.1016/0001-4575(94)90019-1.
- Wijnands, J. S., Thompson, J., Nice, K. A., Aschwanden, G. D. P. A. & Stevenson, M. (2020). Real-time monitoring of driver drowsiness on mobile platforms using 3D neural networks. *Neural Computing and Applications*, 32(13), 9731–9743. doi : 10.1007/s00521-019-04506-0.
- Włodarczak, M. (2019). RespInPeace : Toolkit for Processing Respiratory Belt Data.
- Xu, X., Yu, J., Chen, Y., Zhu, Y., Kong, L. & Li, M. (2019). BreathListener : Fine-grained Breathing Monitoring in Driving Environments Utilizing Acoustic Signals. *Proceedings of the 17th Annual International Conference on Mobile Systems, Applications, and Services*, pp. 54–66. doi : 10.1145/3307334.3326074.
- Yoon, J.-W., Noh, Y.-S., Kwon, Y.-S., Kim, W.-K. & Yoon, H.-R. (2014). Improvement of Dynamic Respiration Monitoring Through Sensor Fusion of Accelerometer and Gyro-sensor. *Journal of Electrical Engineering and Technology*, 9(1), 334–343. doi : 10.5370/JEET.2014.9.1.334.
- Zhang, Z., Silva, I., Wu, D., Zheng, J., Wu, H. & Wang, W. (2014). Adaptive motion artefact reduction in respiration and ECG signals for wearable healthcare monitoring systems. *Medical & Biological Engineering & Computing*, 52(12), 1019–1030. doi : 10.1007/s11517-014-1201-7.
- Zhou, F., Alsaid, A., Blommer, M., Curry, R., Swaminathan, R., Kochhar, D., Talamonti, W., Tijerina, L. & Lei, B. (2020). Driver fatigue transition prediction in highly automated driving using physiological features. *Expert Systems with Applications*, 147, 113204. doi : 10.1016/j.eswa.2020.113204.
- Zhu, J., Jia, Y., Li, M., Zhou, Z., Chen, Y., Liu, Q. & Yang, X. (2022). A paper-based self-inductive folding displacement sensor for human respiration and motion signals measurement. *npj Flexible Electronics*, 6(1), 67. doi : 10.1038/s41528-022-00198-0.