

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



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

## MÉMOIRE DE MASTER PROFESSIONNEL

En  
Informatique  
  
Option  
*Génie Logiciel*  
  
Thème

---

Proposition d'un protocole de détection de  
somnolence au volant pour une conduite sûre

---

Présenté par : M. MOKRANI Juba  
M. MOUHOUBI Abdenour

Devant le jury composé de :

Examinatrice	Dr. L. HAMZA	Maître de Conf. A	U. A/Mira Béjaïa.
Examinatrice	Dr. K. OUAZINE	Maître Assist. B	U. A/Mira Béjaïa.
Rapporteur	Dr. M. MOHAMMEDI	Maître de Conf. B	U. A/Mira Béjaïa.

Béjaïa, Octobre 2020.

## ※ *Remerciements* ※

Nous remercions Dieu le tout Puissant qui nous a donné la force et la volonté d'accomplir ce travail.

Nous tenons tout d'abord à remercier docteur Mohamed MOHAMMEDI, pour l'honneur qu'il nous a fait en acceptant de nous encadrer. Ses conseils précieux nous ont permis une bonne orientation dans la réalisation de ce travail.

Nos vifs remerciements vont également au président et aux membres de jury d'avoir accepté d'évaluer notre travail.

Nous remercions tous ceux qui ont contribué de près ou de loin à la réalisation de ce travail.

Nos très sincères remerciements vont aussi à tous les enseignants et enseignantes qui ont contribué à notre formation durant notre cursus.

Merci à nos parents et grands-parents qui nous ont toujours soutenus tout au long de notre cursus.

※ *Dédicaces* ※

Je dédie ce modeste travail :

À mes chers parents pour leur soutien inconditionnel,  
leur tolérance durant toutes mes années d'études,

À notre encadreur Docteur MOHAMMEDI Mohamed qui nous a vraiment motivé  
et guidé tout au long de notre travail,

À ma fiancée qui ma vraiment motivé, poussé à travailler et donner de mon meilleur

À mes frères, ma sœur et belles-seours.

À mes neveux,

À tous mes amis, surtout Omar et Amine avec qui j'ai eu de nombreuses et enrichissantes conversations  
qui m'ont permis d'élargir l'horizon de cette recherche,

À tous ceux qui m'ont aidé de près ou de loin.

À tous mes ami(e)s et toute la promotion Génie Logiciel.

À tous ceux qui travaillent pour que cette nation soit meilleure.

M. *MOKRANI Juba*

※ *Dédicaces* ※

Je dédie ce modeste travail :

À mes très chers parents qui m'ont soutenu durant toutes mes études, qui ont fait de moi ce que je suis  
aujourd'hui je leurs serais éternellement reconnaissant,

À notre encadreur Docteur MOHAMMEDI Mohamed qui nous a vraiment motivé  
et guider tout au long de notre travail,

À mes sœurs, mon frère, mon beau frère et ma belle-soeur,

À mon neveu ;

À tous mes ami(e)s, surtout Amine et Adel avec qui j'ai eu de nombreuses et enrichissantes  
conversations qui m'ont permis d'élargir l'horizon de cette recherche,

À tous ceux qui m'ont aidé de près ou de loin,

À tous mes ami(e)s et toute la promotion Génie Logiciel.

ℳ. *MOUHOUBI Abdenour*

# TABLE DES MATIÈRES

Table des Matières	i
Liste des tableaux	iv
Liste des figures	v
Liste des acronymes	vi
Introduction générale	1
<b>1 Pré-requis théoriques</b>	<b>4</b>
1.1 Introduction	4
1.2 Qu'est-ce que la somnolence au volant	4
1.2.1 Les signes précurseurs de la somnolence au volant	4
1.2.2 Les facteurs de risque de somnolence	5
1.3 Techniques de détection de somnolence	5
1.3.1 Techniques basées sur le traitement d'images	5
1.3.2 Technique basée sur le signal EEG	6
1.3.3 Technique basée sur les réseaux de neurones artificiels	6
1.4 L'électroencéphalogramme (EEG)	6
1.5 Définition d'artefact	7
1.6 Types d'artefact	7
1.6.1 Les clignements oculaires	7
1.6.2 Les mouvements oculaires	7
1.6.3 Les artefacts musculaires	7
1.6.4 Les artefacts d'électrode	7
1.7 Avantages et inconvénients du signal EEG en tant que technique biométrique	8
1.8 Les régions du cerveau humain	8
1.9 Électrodes et système de placement	9
1.9.1 Les électrodes	9
1.9.2 Système 10-20	11

1.10	Les principales bandes de fréquences d'activité cérébrale . . . . .	11
1.10.1	Les ondes delta . . . . .	12
1.10.2	Les ondes thêta . . . . .	12
1.10.3	Les ondes alpha . . . . .	12
1.10.4	Les ondes bêta . . . . .	12
1.10.5	Les ondes gamma . . . . .	12
1.11	Structure générale d'un système de détection de somnolence basée sur le signal EEG . . .	13
1.11.1	Acquisition du signal . . . . .	13
1.11.2	Pré-traitement du signal . . . . .	13
1.11.3	Extraction de caractéristiques . . . . .	14
1.11.4	Classification . . . . .	14
1.12	Traitement du signal . . . . .	14
1.12.1	Définition d'un signal . . . . .	14
1.12.2	Échantillonnage d'un signal . . . . .	15
1.12.3	Spectre d'un signal . . . . .	15
1.12.4	Fréquence de coupure (Cutofffrequency) . . . . .	15
1.12.5	Distance de Hamming . . . . .	15
1.13	Conclusion . . . . .	15
<b>2</b>	<b>État de l'art sur les protocoles de détection de somnolence au volant</b>	<b>16</b>
2.1	Introduction . . . . .	16
2.2	Critères d'évaluation des solutions existantes . . . . .	16
2.2.1	Taux d'exactitude . . . . .	16
2.2.2	Temps de détection du somnolence . . . . .	16
2.2.3	Coût de calcul . . . . .	17
2.2.4	Consommation énergétique . . . . .	17
2.2.5	Applicabilité . . . . .	17
2.3	Classification des travaux étudiés . . . . .	17
2.4	Étude critique des travaux antérieurs . . . . .	18
2.4.1	Solutions basées sur les mesures physiologiques . . . . .	18
2.4.2	Solutions basées sur les caractéristiques faciales . . . . .	19
2.4.3	Solutions basées sur les réseaux de neurones artificielles . . . . .	20
2.5	Synthèse . . . . .	22
2.6	Conclusion . . . . .	24
<b>3</b>	<b>Real-time EEG-based system for detecting drowsy driving state</b>	<b>25</b>
3.1	Introduction . . . . .	25
3.2	Motivation . . . . .	25
3.3	Modèle du système . . . . .	26
3.4	Notre protocole . . . . .	27
3.4.1	Acquisition des signaux EEG du conducteur . . . . .	29
3.4.2	Pré-traitement et segmentation du signal enregistré . . . . .	29
3.4.3	Extraction du signal EEG . . . . .	31

3.4.4	Modèle de détection de somnolence . . . . .	32
3.5	Conclusion . . . . .	33
<b>4</b>	<b>Simulation et évaluation de performances</b>	<b>34</b>
4.1	Introduction . . . . .	34
4.2	Collecte de données . . . . .	34
4.3	Préparation de données . . . . .	35
4.4	Environnement de simulation . . . . .	35
4.4.1	Paramètre de simulation . . . . .	36
4.4.2	Matrice de confusion . . . . .	36
4.4.3	La courbe ROC . . . . .	37
4.4.4	Métriques de simulation . . . . .	37
4.5	Résultats et discussion . . . . .	38
4.5.1	Résultats obtenus par notre protocole . . . . .	38
4.5.2	Discussion . . . . .	41
4.6	Conclusion . . . . .	43
	<b>Conclusion générale et perspectives</b>	<b>44</b>
	<b>Bibliographie</b>	<b>45</b>

## LISTE DES TABLEAUX

1.1	Les différents rythmes physiologiques de base en EEG [52]. . . . .	12
2.1	Étude comparative des différents protocoles analysés. . . . .	23
4.1	Informations des sujets sélectionnées pour validé notre système. . . . .	36
4.2	Matrice de confusion à deux classes. . . . .	36
4.3	Métriques d'évaluation calculées à partir de la matrice de confusion. . . . .	38
4.4	Métriques d'évaluation calculées à partir de la matrice de confusion. . . . .	39
4.5	Comparaison des études de (détection de somnolence du conducteur) basées sur le signal EEG et les modèles probabilistes. . . . .	42
4.6	Comparaison des trois classificateurs SVM, KNN et TREE. . . . .	43

## TABLE DES FIGURES

1.1	Les différentes techniques de détection de somnolences. . . . .	5
1.2	Les lobes cérébraux de vue latérale droite et vue supérieure [3]. . . . .	9
1.3	Montage uni-polaire (référentielle) [44] . . . . .	10
1.4	Montage bipolaire [44]. . . . .	10
1.5	Système d'emplacements des électrodes 10/20 [39]. . . . .	11
1.6	Le signal des différentes ondes [20]. . . . .	13
1.7	Méthodologies d'acquisition du signal. . . . .	13
1.8	Échantillonnage d'un signal. . . . .	15
2.1	Classification des protocoles étudiés pour la détection de somnolence au volant. . . . .	17
3.1	Modèle système. . . . .	26
3.2	Organigramme de protocole proposé. . . . .	28
3.3	Ondelette de Daubechies 4 [1]. . . . .	31
3.4	Décomposition en multiple-niveau [1]. . . . .	31
4.1	Position du canal (C3-O1). . . . .	35
4.2	Interprétation de la courbe ROC [48]. . . . .	37
4.3	La matrice de confusion avec le classificateur SVM. . . . .	39
4.4	La courbe ROC avec le classificateur SVM. . . . .	40
4.5	Nuages de points avec le classificateur SVM. . . . .	41

## LISTE DES ACRONYMES

<b>A</b>	AAR	Adaptatifs Auto-régressifs.
	ANN	Artificial Neural Networks.
<b>B</b>	BCI	Brain Computer Interface.
<b>C</b>	CAR	Commun Average Référencement.
	CNN	Convolutional Neuron Networks.
	CSP	Common Spatial schemes.
	CSSD	Sous-espace Spatial Commun Décomposition.
	CSSP	Common Space-Space models.
<b>D</b>	DB4	Daubechies 4.
	DMS	Driver Monitoring System.
	DWT	Discrete Wavelet Transform.
<b>E</b>	ECG	Electrocardiogramme.
	EEG	Electroencéphalogramme.
	EOG	Electro-oculographie.
<b>F</b>	FAR	False Rejection rate.
	FFT	Fast Fourier Transformations.
	Freq-Norm	Frequency Normalization.
	FRR	False Acceptance Rate.
<b>G</b>	GA	Genetic Algorithms.
<b>H</b>	HDMS	Hierarchical to Monitor Driving Behaviors.
	HRV	Heart Rate Variability.
	Hz	Hertz.

<b>I</b>	ICA	Independent Component Analysis.
	IRMF	Imagerie par Résonance Magnétique Fonctionnelle.
<b>L</b>	LAT	Local Average Technique.
	LDWS	Lane Departure Warning System.
	LSTM	Long Short-Term Memory.
<b>M</b>	MEG	Magnéto-encéphalographie.
	MSPC	Multivariate Statistics Control Process.
<b>N</b>	NHTSA	National Highway Traffic Safety Administration.
	NIRS	Near Infrared Spectroscopie.
<b>P</b>	PC	Personal Computer.
	PCA	Principal Component Analysis.
	PCB	Polychlorobiphényle.
	PW	Signal strength.
<b>Q</b>	QRS	The Normal Rest electrocardiogram.
<b>R</b>	RPR	Relative Power.
	RRI	Intermediate Cooling Circui.
	RRV	Respiratory Rate Variability.
<b>S</b>	SL	Surface Laplacien.
	SVD	Single Value Decomposition.
<b>T</b>	TEP	Position Emission Tomography.
	TQWT	Tapered Quarter Wave Tube.
	TWSVM	Twin Support Vector Machine.
<b>V</b>	V	Volt.
	VGG16	Convolutional Network for Classification and Detection.
	VRC	Heart rate variability.
<b>W</b>	WPD	Decomposition of Wavelet Packets.
	WT	Wavelet Transformations.

## *INTRODUCTION GÉNÉRALE*

Le problème de la sécurité routière est un problème important dont l'enjeu est la diminution du nombre d'accidents, et par là même du nombre de morts et de blessés sur les routes. L'administration nationale de la sécurité routière (NHTSA) a signalé qu'il y avait environ 100000 accidents dans les États-unis causés par la somnolence au volant chaque année, ce qui entraîne plus de 1 500 morts et 71 000 blessés [17].

Les causes de ses accidents de la route peuvent être variées et multiples, cependant la majorité des accidents sont dus à la vitesse excessive, la conduite en état d'ébriété ou sous l'influence de substances psychoactives, la distraction au volant [17]. De ce fait de nombreux efforts ont permis de réduire le nombre d'accidents lié à ses causes par le respect des lois portant sur les principaux risques et la sensibilisation du public et l'implication de multiples compagnes de prévention et de contrôles routiers.

En revanche, la prévention concernant la vigilance et la sensation de fatigue du conducteur reste un défi industriel pour les constructeurs automobiles et académiques pour les chercheurs. La baisse du niveau de veille, appelée somnolence, engendrée par la transition involontaire de l'état de veille vers le sommeil, ou la capacité d'observation et d'analyse sont fortement réduits [43] est responsable du tiers des accidents mortels sur l'autoroute d'après un rapport d'accidentologie de la sécurité routière [43]. Ce problème est d'autant plus sérieux avec l'augmentation du travail de nuit et des cadences de travail dans une société du "24h sur 24 " où les gens favorisent souvent le gain et le plaisir que le sommeil, et surtout la conduite sûre de longs trajets sans repos. Un grand nombre de ces décès pourraient être évités si la somnolence des conducteurs était correctement surveillée et si les conducteurs recevaient des alertes précoces.

Avant toutes choses, il semble important de donner une définition aussi précise que possible du phénomène qui nous intéresse. Si l'on regarde la définition du terme somnolence dans un dictionnaire, on peut lire :

Somnolence : est un intermédiaire entre la veille et le sommeil durant lequel l'organisme a ses facultés d'observation et d'analyse très réduites [45]. Il faut faire cependant attention à différencier la somnolence de la fatigue. Le terme de fatigue correspond à un épuisement du corps après une activité soutenue trop longue. Elle existe sous deux formes : physique et mentale. La fatigue nécessite du repos, ce qui n'est pas forcément synonyme de sommeil.

Depuis une trentaine d'années, des recherches ont été menées afin de mieux comprendre cet état à risque et de mettre en œuvre des systèmes permettant sa détection automatique. Deux types d'approches ont été proposés afin d'étudier ce phénomène. La première approche, la plus ancienne, est orientée sur le comportement du véhicule. Son but est de détecter les comportements anormaux du véhicule sur la

route engendrés par la somnolence. Pour cela, dans l'industrie automobile, Volvo a développé le Driver Alert Control qui avertit les conducteurs soupçonnés de somnolence au volant en utilisant une caméra embarquée connectée à son système d'alerte de sortie de voie. Suivant une veine similaire, un système d'assistance à l'intention a été développé et introduit par Mercedes-Benz qui recueille des données tirées des habitudes de conduite d'un conducteur vérifie sans cesse si les informations obtenues sont en corrélation avec le mouvement de direction et les circonstances de conduite à portée de main [28]. Notamment, l'utilisation de ces systèmes de sécurité qui détectent la somnolence n'est pas répandue et est rare chez les conducteurs car ils sont généralement disponibles dans les véhicules de luxe.

La seconde approche est orientée sur le comportement du conducteur. Dans ce cas, le but est de détecter les signes comportementaux et physiologiques de la somnolence chez le conducteur. Plus récemment, la première classe est l'utilisation de caméras embarquées dans le véhicule a permis de développer des systèmes de détection basés sur les indices visuels de la baisse de vigilance tels que les clignements des yeux, les bâillements ou la direction du regard du conducteur. Cependant, aucun système ne s'est révélé suffisamment efficace à l'heure actuelle pour être commercialisé et l'approche physiologique reste aujourd'hui la plus efficace pour caractériser la somnolence [43].

La deuxième classe de techniques utilise des données acquises à partir de capteurs physiologiques, comme l'électro-oculographie (EOG), l'électrocardiogramme (ECG) et l'électroencéphalogramme (EEG) [46] [14]. Les signaux EEG fournissent des informations sur l'activité du cerveau. Les trois signaux principaux pour mesurer la somnolence du conducteur sont les signaux thêta, delta et alpha. Les signaux thêta et delta augmentent quand un conducteur est somnolent, tandis que les signaux alpha augmentent légèrement. Selon le travail décrit dans [54], cette technique est la méthode la plus précise, avec un taux de précision de plus de 90%.

Nous proposons ici une approche résolument orientée sur l'étude du conducteur afin de détecter la somnolence à partir d'informations physiologiques (liées à l'activité cérébrale). Le but de ce travail consiste à développer un système de détection de somnolence à temps réel chez le conducteur à partir de données électroencéphalographiques (décrivant l'activité cérébrale). Cette approche est motivée par le fait que les médecins spécialistes de la somnolence et du sommeil travaillent essentiellement à partir des données cérébrales pour détecter la somnolence. Notre système consiste à utiliser un casque avec un seul capteur (C3-O1) afin de collecter les signaux cérébraux tout en gardons un maximum de confort au conducteur, et les deux sous-bandes alpha sont bêta pour réduire le coût de calcul afin de minimiser le temps de réponse.

Le reste de ce document présentera le travail effectué afin d'élaborer un système de détection automatique de somnolence chez le conducteur à partir des données électroencéphalographiques. Il est organisé en quatre chapitres comme suite :

Chapitre 1 "**Pré-requis théoriques**" : Nous nous intéressons dans ce chapitre au problème délicat et complexe de la définition de la somnolence à partir des signaux électroencéphalographiques, et les signes de la somnolence présents dans l'électroencéphalogramme (EEG) ainsi que les techniques de sa détection. Ensuite nous donneront les différentes bande d'un signal encéphalographie, les zone du cerveau lié à la somnolence ainsi que la structure générale d'un système de détection de somnolence basé sur l'EEG.

Chapitre 2 "**État de l'art sur les protocoles de détection de somnolence au volant**" : nous discuterons certains travaux de recherche concernant la détection de somnolence au volant, une comparaison de différentes approches par rapport à leur techniques de détections est ensuite présentée pour

mettre en évidence leurs points forts et points faibles en termes d'efficacité, de coût du calcul de taux d'exactitude, de faux rejet et fausse acceptation. Puis, nous donnerons une classification des travaux déjà proposés.

Chapitre 3 "**EEG Based Driver Drowsiness Detection System Using Edge Computing for Safe Driving**" : dans ce chapitre nous présentons notre contribution pour la détection de la somnolence à partir des signaux EEG, en détaillant les différentes phases par lesquelles notre protocole passe pour assurer une détection de somnolence efficace.

Chapitre 4 "**Simulation et évaluation de performances**" :

Nous achèverons cette réflexion par une conclusion générale sur le travail réalisé ainsi que par une présentation des différentes perspectives de recherche que nous souhaiterons accomplir prochainement.

# CHAPITRE 1

## PRÉ-REQUIS THÉORIQUES

### 1.1 Introduction

Dans la conduite, la somnolence est considéré comme l'un des facteurs de risque les plus important des accidents de la route (30% des accidents), le conducteur aura des difficultés de traitement des informations, une réaction lente et une vigilance réduite. Pour diminuer ce taux d'accidents routière, plusieurs études ont été signalées sur la détection de la somnolence du conducteur en utilisons plusieurs techniques comme la techniques basées sur le traitement d'images, la techniques basées sur les réseaux de neurones artificiels et la techniques basées sur l'EEG (électroencéphalographe). Dans ce premier chapitre nous décriront la somnolence au volant et les techniques de la détection, ensuite nous présenterons l'électroencéphalogramme (EEG) ainsi que les artefacts qui le contamine, ensuite nous décriront les régions du cerveau humain. Puis, nous présentons les électrodes et le système de leur placement, nous donneront les principales bandes de fréquences d'activité cérébrale. Enfin, nous décriront c'est quoi le traitement du signal ainsi que la structure générale d'un système de détection de somnolence basée sur le signal EEG.

### 1.2 Qu'est-ce que la somnolence au volant

La somnolence (ou hypovigilance) correspond à un stade altéré de la vigilance. Elle se traduit à la difficulté de rester éveillé. Comme la fatigue, le phénomène est tout d'abord cyclique, la vigilance oscillant entre éveil et somnolence. Mais, tandis que la fatigue laisse le conducteur en état de réagir à des stimulés d'alerte, en cas de somnolence tous les stimulés sont perçus comme atténués. Elle représente un danger majeur au volant : elle entraîne des périodes de "micro-sommeils" (de 1 à 4 secondes) et un risque d'endormissement important quelle que soit la longueur du trajet.

#### 1.2.1 Les signes précurseurs de la somnolence au volant

La somnolence au volant est toujours précéder par des signe qui montre que ce conducteur est somnolent, parmi ces signes on trouve :

- Sensation de paupières lourdes ;

- Envie de se frotter les yeux ;
- Nécessité de bouger ou de changer de position fréquemment ;
- Gêne visuelle ;
- Sensation d'avoir froid.

### 1.2.2 Les facteurs de risque de somnolence

Les facteurs qui provoquent la somnolence au volant sont beaucoup, parmi ces facteurs on cite :

- Être éveillé depuis plus de 17 heures ;
- Une dette de sommeil : l'accumulation d'heures de sommeil en retard ;
- Conduire entre 2 et 5 heures du matin et entre 13 et 15 heures, périodes pendant lesquelles la propension à somnoler est importante ;
- Des troubles du sommeil non traités, comme l'apnée du sommeil ;
- La consommation de drogue, d'alcool ou de médicaments, dont beaucoup ont un effet sédatif, ou diminuent la résistance à la fatigue ;
- Conduire au-dessus des limitations de vitesse. Une vitesse élevée implique un traitement des informations et une adaptation de la vision plus rapides. Ce stress entraîne une plus grande fatigue, à l'origine d'une baisse de vigilance.

## 1.3 Techniques de détection de somnolence

La recherche sur les techniques de détection de somnolence au volant est importante pour améliorer la sécurité routière. Comme le montre la figure 1.1 il existe trois techniques différentes utilisées par les chercheurs pour détecter la somnolence, il y a les techniques basées sur le traitement d'images, les techniques basées sur les réseaux de neurones artificiels et les techniques basées sur l'EEG (électroencéphalographe).

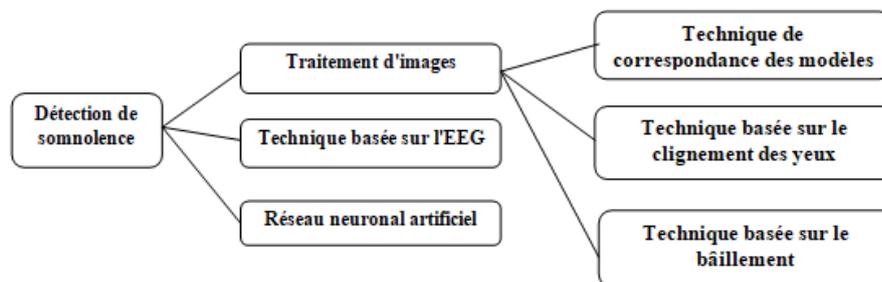


FIGURE 1.1 – Les différentes techniques de détection de somnolences.

### 1.3.1 Techniques basées sur le traitement d'images

Dans les systèmes de surveillance du visage du conducteur, les symptômes utiles pour la détection de la fatigue et de la distraction peuvent être divisés en trois catégories générales :

### Technique de correspondance des modèles

Cette technique a été construite en utilisant une technologie d'amélioration, ce qui fait que le système contient différents modules fonctionnant simultanément. Comme l'œil est la zone la plus importante du visage où apparaissent les symptômes de fatigue. Donc, on peut utiliser ces états, c'est-à-dire que si le conducteur ferme les yeux pendant un certain temps, le système générera une alarme. Parce que dans ce système, il a à la fois les yeux fermés et les modèles ouverts du conducteur. Ce système peut également être formé pour obtenir des modèles d'œil ouverts et fermés de conducteur [29].

### Technique basée sur le clignement des yeux

Cette technique est basée sur les symptômes liés aux régions du visage et des yeux. Dans ce taux de clignement des yeux et la durée de fermeture des yeux est mesurée pour détecter la somnolence du conducteur. Parce que lorsque le conducteur se sentait somnolent à ce moment-là, ses yeux clignent et son regard entre les paupières sont différents à des situations normales, ils détectent donc facilement la somnolence [36] [40].

### Technique basée sur le bâillement

C'est une technique non intrusive en temps réel pour détecter la somnolence du conducteur en utilisant les bâillements ce système comporte plusieurs étapes y compris la détection et le suivi du visage, le bâillement est supposé être modélisé avec une grande ouverture verticale de la bouche. Ils détectent le bâillement en fonction du taux d'ouverture de la bouche et des changements de quantité dans la zone du contour de la bouche [26].

### 1.3.2 Technique basée sur le signal EEG

C'est une technique qui sert à mesurer l'activité électrique du cerveau par des électrodes placées sur le cuir chevelu, ces électrodes seront capturées à travers d'un casque que le conducteur doit porter pendant la conduite. Cette méthode est basée sur l'analyse du spectre de puissance et l'algorithme FastICA [30] a été proposée pour déterminer le degré de fatigue [37].

### 1.3.3 Technique basée sur les réseaux de neurones artificiels

Dans cette technique, On utilise des neurones pour détecter la somnolence du conducteur. Certains chercheurs mènent des recherches dans le domaine de l'optimisation de la détection de la somnolence du conducteur à l'aide d'un réseau neuronal artificiel. Les personnes en fatigue présentent certains comportements visuels qui sont facilement observables à partir de changements dans les traits du visage tels que les yeux, la tête et le visage. Pour utiliser ces signaux visuels, ils ont créé un réseau neuronal artificiel pour détecter la somnolence [51].

## 1.4 L'électroencéphalogramme (EEG)

**Electro :** on étudie les signaux électrique produit par l'organisme. Les messages nerveux sont de nature électrique.

**Encéphalo** : l'encéphale et le cerveau sont à peu près synonymes.

**Gramme** : en grec, signifie "dessin".

L'électroencéphalogramme (EEG) est l'enregistrement de différences de potentiels électrique effectués sur la surface de la tête. Il mesure l'activité électrique du cerveau par des électrodes placées sur le cuir chevelu souvent représenté sous la forme d'un tracé appelé électroencéphalogramme. L'EEG est un examen indolore et non invasif qui renseigne sur l'activité neurophysiologie du cerveau au cours du temps et en particulier du cortex cérébral soit dans un diagnostique en neurologie. Il a une très faible amplitude, de l'ordre du micro-volt. Il se presente différemment selon l'âge, selon l'état de vigilance [27].

## 1.5 Définition d'artefact

Un artefact correspond à tout phénomène perturbateur gênant la transmission ou l'interprétation d'un signal numérique d'origine non cérébrale. Ils peuvent avoir principalement trois origines comme des mouvements et des clignements oculaires, des activités musculaires, des activités cardiaques.

## 1.6 Types d'artefact

Les principales artefacts qui perturbe un signal sont :

### 1.6.1 Les clignements oculaires

Les clignements des yeux forment un signal lent ( $< 4\text{Hz}$ ) qui correspond à un potentiel électrique généré par le mouvement de l'œil et de la paupière. Le signal apparaît principalement dans la zone frontale (Fp1 et Fp2) et s'atténue rapidement lorsque l'on s'éloigne des yeux. Le signal des yeux est symétrique entre les deux hémisphères.

### 1.6.2 Les mouvements oculaires

Les mouvements des yeux forment également un signal lent ( $< 4\text{Hz}$ ) qui correspond au mouvement mécanique des yeux. Les yeux forment un dipôle et lorsque les yeux bougent, ils se rapprochent ou s'éloignent d'un électrode ce qui crée le signal. Le signal apparaît principalement dans la zone frontale et la zone temporale. Il est plus propagé que les clignements, mais il est souvent moins ample. Le signal des yeux est en opposition entre les deux hémisphères.

### 1.6.3 Les artefacts musculaires

L'activité musculaire donne des signaux hautes fréquences ( $> 13\text{Hz}$ ), en grande partie supérieur à l'activité EEG mesurable. Le principal muscle du visage est la mâchoire qui peut créer un signal important dans la région temporale (Secondes 0 à 5). Les muscles frontaux peuvent également apparaître puisqu'ils sont situés juste sous les électrodes (secondes 5 à 10).

### 1.6.4 Les artefacts d'électrode

Il arrive que des mouvements d'un fil ou d'une électrode crée un artefact basse fréquence ( $< 2\text{Hz}$ ) sur une électrode. On les reconnaît en générale à leur amplitude et au fait qu'ils n'apparaissent que sur une

seule électrode. Il se peut également que les électrodes se déplacent suite à un mouvement de la tête et dans ce cas un signal apparaît sur plusieurs électrodes.

## 1.7 Avantages et inconvénients du signal EEG en tant que technique biométrique

Un des avantages de EEG est son excellente résolution temporelle ( $\approx 1$  ms), qui permet d'explorer l'activité du cerveau en ligne, il est indolore et non invasif, un autre avantage de EEG est que cette technique est silencieuse. De plus, il n'est pas contaminé par les mouvements corporels des participants. Donc, l'EEG peut-être utilisé relativement facilement chez les très jeunes enfants. Sur le plan pratique, les coûts d'acquisition et d'opération de EEG ne sont pas élevés [27].

Toutefois, la résolution spatiale de EEG est relativement limitée, car les signaux électriques sont atténués par le cuir chevelu et ne sont mesurés que lorsqu'ils émanent du cuir chevelu. De plus, l'EEG contrairement à l'IRMf et la TEP n'offre pas une image tridimensionnelle du cerveau. Pour les majeurs inconvénients du EEG on a l'emplacement des électrodes qui doivent respecter les distances entre eux en suivant le système 10/20, et aussi le signal EEG est souvent perturbé par des artefacts [27].

**Considérations de sécurité :** Il n'y a aucun risque associé avec les enregistrements EEG, il peut être utilisé avec des participants de tous les âges, des nouveau-nés aux personnes âgées, ainsi que chez des populations cliniques. Il peut être utilisé durant les états de veille, de sommeil ou d'inconscience (par exemple : coma) pour étudier les processus en cours. Toutefois, le port du casque EEG peut entraîner un léger inconfort [27].

## 1.8 Les régions du cerveau humain

Le cerveau proprement dit est formé de deux hémisphères cérébraux, d'aspect plissé dont la substance blanche, interne, est recouverte d'un cortex cérébral gris, d'épaisseur variable. Trois sillons plus accentués (scissure de Sylvius, sillon de Rolando, sillon perpendiculaire) divisent chaque hémisphère en quatre lobes (lobe frontal, lobe temporal, lobe pariétal et lobe occipital) comprenant chacun un certain nombre de circonvolutions (voir la figure 1.2). Le cerveau est disposé au-dessus du tronc cérébral lui-même faisant suite à la moelle épinière. Il repose également sur le dessus du cervelet et est séparé de celui-ci par la tente du cervelet.

Chaque hémisphère abrite un système ventriculaire de forme complexe : c'est une cavité remplie de liquide céphalo-rachidien dont l'excès (par obstacle à son écoulement) entraînera une dilatation ventriculaire appelée hydrocéphalie qui progressivement comprimera les structures cérébrales. Les hémisphères sont unis l'un à l'autre par deux ponts de substance blanche : le corps calleux et le trigone. Entre ces deux ponts, les ventricules latéraux ne sont séparés que par une fine cloison transparente. La substance blanche et la substance grise sont les deux catégories de tissus du système nerveux. Elle forme la partie interne du cerveau et la partie superficielle de la moelle épinière. La substance blanche est composée de fibres nerveuses, les axones et les dendrites, qui relient les différentes parties du cerveau et transmettent les impulsions nerveuses vers les neurones. La substance grise est constituée du corps cellulaire des neurones. Généralement, la substance blanche peut être considérée comme la partie du cerveau responsable de la transmission des informations, alors que la substance grise est responsable du traitement des informations

(car elle est composée des corps cellulaires des neurones) [11].

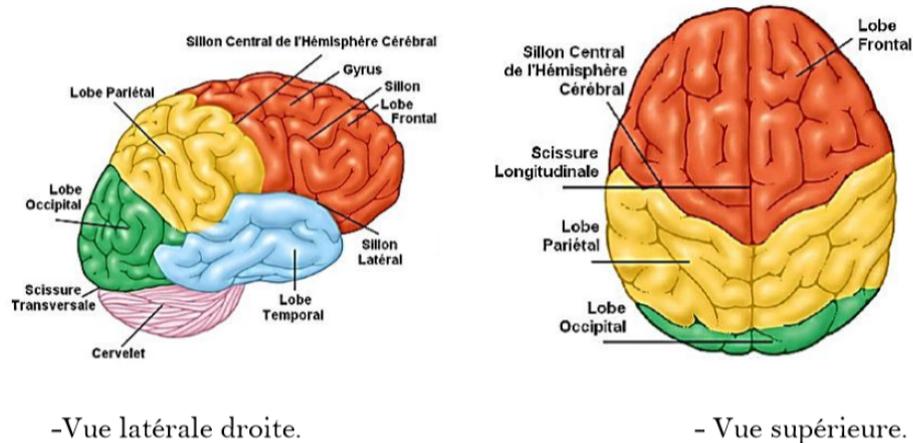


FIGURE 1.2 – Les lobes cérébraux de vue latérale droite et vue supérieure [3].

## 1.9 Électrodes et système de placement

### 1.9.1 Les électrodes

Les électrodes ont pour rôle d'assurer un contact étroit et stable avec la peau pour mesurer les rythmes cérébraux et les potentiels évoqués. Il existe plusieurs types d'électrodes (actives, passives). Les électrodes actives possèdent un système de pré-amplification à l'intérieur même de l'électrode contrairement aux électrodes passives. Les électrodes actives ne requièrent aucune préparation de la peau (p. ex. gel conducteur) contrairement aux électrodes passives. Leur conception et leur réalisation se heurtent à de nombreux problèmes :

- Problème électrique** : fidélité et stabilité quelle que soit la durée de l'examen ; résistance peau électrodes aussi faible ; surface de contact réduite au minimum pour ne pas augmenter la diffusion physiologique.
- Problème pratique** : l'électrode doit être rapidement placée et aisément supportée par le malade.
- Problème mécaniques** : mise en place et fixation.

### 1. Montage d'électrodes

Les montages représentent une combinaison de paires d'électrodes.

**a. Montage uni-polaire (référentiel)** : Dans un montage uni-polaire citer dans la figure 1.3, il y a une électrode de référence et une électrode active. On mesure la différence de potentiel entre l'électrode active et l'électrode de référence [44]. .

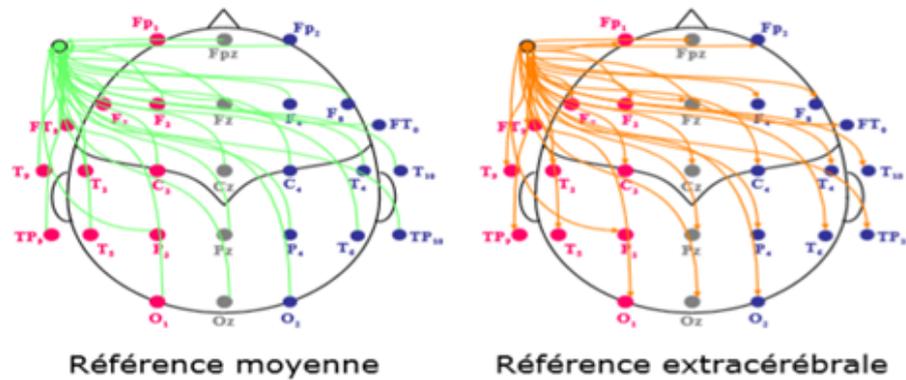


FIGURE 1.3 – Montage uni-polaire (référentielle) [44]

**b. Montage bipolaire :** Dans un montage bipolaire représenté dans la figure 1.4, les deux électrodes sont actives. La différence de potentiel est mesurée entre ces deux électrodes. L'électrode de terre est placée de préférence à distance du scalp, mais lorsqu'il se trouve au niveau du poignet, les enregistrements obtenus sont fréquemment parasités par des activités électrocardiographiques, ce qui rend parfois nécessaire l'utilisation d'une terre collée sur le front. Cette dernière solution devrait cependant être évitée car elle présente l'inconvénient d'imposer un potentiel à proximité de la source d'activités électrique cérébrales. Une bonne solution est la mise en place d'une terre sur l'épaule [44].

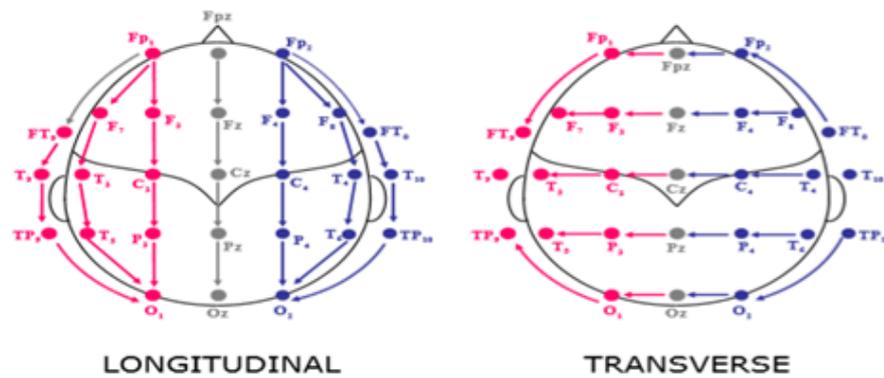


FIGURE 1.4 – Montage bipolaire [44].

## 2. Les différentes électrodes

La plupart des électrodes actuellement utilisées sont en argent recouvert d'une mince couche de chlorure d'argent afin d'éviter les phénomènes de polarisation. La surface en contact avec la peau ne doit pas dépasser un demi-centimètre carré.

### a. Électrodes cupules (électrodes fixées directement sur le cuir chevelu)

C'est un électrode en forme de disque ou de cupule, on peut l'emplir de pâte conductrice avant sa mise en place, ou injecter un gel conducteur après la mise en place.

### b.Électrodes tampon (Électrode maintenue a l'aide d'un casque)

Le tampon est formé de mousse synthétique entourée de tissu, en utilisant un casque pour maintenir facilement la symétrie de leur mise en place, ses tampons doivent être imbibés en permanence par un liquide électrolytique qui assure la continuité de la transmission électrique.

### c.Électrodes aiguilles

Le contact se fait avec le derme sousjacent, ses électrodes sont en alliage de platine, leur utilisation ne pose pas de problème particulier.

## 1.9.2 Système 10-20

Le système international 10/20 de placement des électrodes cité dans la figure 1.5 est le système le plus couramment utilisé. Les chiffres 10 et 20 dénotent le fait que la distance entre deux électrodes adjacentes est de 10 % à 20 % de la distance totale soit entre le devant et le derrière de la tête ou entre le côté gauche et le côté droit du crâne. Au total, 21 électrodes sont posées sur le cuir chevelu selon des règles strictes. Il existe également d'autre système de placement des électrodes tel que le système 10/10 [8]. Les lettres et les chiffres sont utilisés afin de caractériser l'emplacement des électrodes. Les chiffres dénotent l'emplacement des électrodes en fonction de l'hémisphère dans lequel ils se retrouvent. Les chiffres impairs représentent les électrodes localisées sur l'hémisphère gauche et les chiffres pairs représentent celles de l'hémisphère droit. La lettre « Z » est utilisée afin d'identifier les électrodes positionnées sur la ligne médiane. Les lettres quant à elles servent à identifier l'emplacement des électrodes en fonction des lobes du cerveau. La lettre A est utilisée pour identifier les oreilles. Fp = Fronto-polaire; A = Auriculaire; F = Frontale; T = Temporale; C = Centrale; P = Pariétale; O = Occipitale [8].

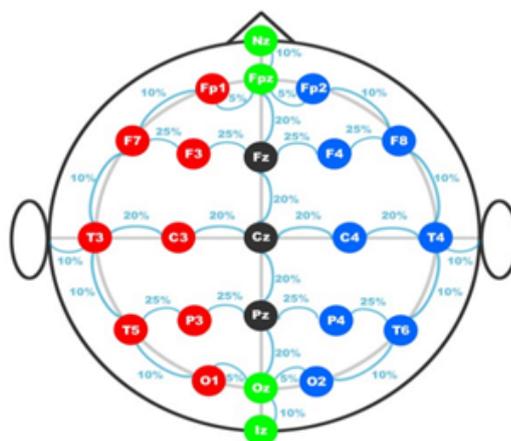


FIGURE 1.5 – Système d'emplacements des électrodes 10/20 [39].

## 1.10 Les principales bandes de fréquences d'activité cérébrale

C'est les rythmes caractérisant l'état cérébral sur des périodes temporelles variables allant de quelques secondes à quelques minutes voire une heure. Dans les zones du cerveau, l'influx nerveux fonctionne en relative cohérence et de façon rythmique. Les neurones s'activent ensemble comme une pulsation, puis se

calment, puis s'activent de nouveau. Grâce à de petites électrodes placées sur le cuir chevelu et reliées à un appareil appelé électroencéphalographie. Le rythme de ces pulsations peut se traduire en forme d'onde [52].

Rythme	<b>Delta</b>	<b>thêta</b>	<b>alpha</b>	<b>Bêta</b>	<b>Gamma</b>
Bande passante	0-4 Hz	4-8 Hz	8-14 Hz	14-30 Hz	>30 Hz
Localisation	Diffus	Centrotemporal	Amplitude maximale postérieure	Antérieur et moyen	Antérieur et moyen
Amplitude	>30 V	20 V	25-75 V	<20 V	<20 V
Corrélat comportementaux	Sommeil profond	Veille sommeil (sommolence)	Veille calme (relaxation)	veille active sommeil paradoxal	veille active sommeil paradoxal

TABLE 1.1 – Les différents rythmes physiologiques de base en EEG [52].

### 1.10.1 Les ondes delta

Ce sont les plus lentes des ondes cérébrales, elles apparaissent sur un tracé EEG d'un patient en état de sommeil lent [52].

### 1.10.2 Les ondes thêta

Les ondes thêta sont produites lors de la première phase du sommeil lent. Elles ouvrent l'esprit au monde subconscient, à une compréhension soudaine, à des intuitions et à plus de créativité [52].

### 1.10.3 Les ondes alpha

Les ondes alpha jettent un pont entre conscient et subconscient, c'est le rythme principal de la détection chez les adultes, elles sont plus en activité dans la région occipitale, dans le cortex et dans sa bande périphérique [52].

### 1.10.4 Les ondes bêta

C'est un rythme qui est dominant quand nous avons les yeux ouverts, écoutons et pensons au cours de la résolution de problèmes analytiques, prise de décision, et traitement des informations relatives au monde qui nous entoure [52].

### 1.10.5 Les ondes gamma

Les ondes gamma est le seul groupe de fréquence présent dans chaque partie du cerveau. Quand le cerveau doit traiter simultanément l'information de différents secteurs, l'activation d'une fréquence de

40Hz favorise l'information entre les secteurs exigés pour un traitement simultané. Une bonne mémoire est associée à l'activité de 40Hz, tandis qu'une insuffisance d'onde de 40Hz crée des incapacités d'étude [52].

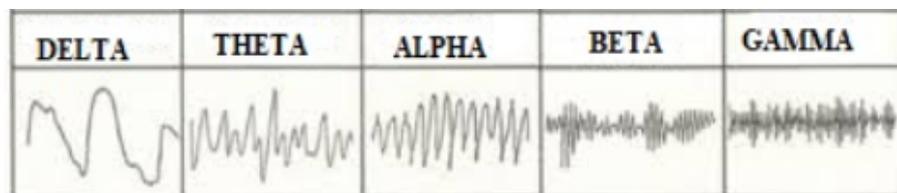


FIGURE 1.6 – Le signal des différentes ondes [20].

## 1.11 Structure générale d'un système de détection de somnolence basée sur le signal EEG

Il existe essentiellement deux types de systèmes BCI. Il s'agit des BCI invasives et des BCI non invasives. La plupart des pays asiatiques préfèrent l'essence des systèmes BCI non invasives en raison de leur prix abordable et la flexibilité dans la capture des signaux du cerveau [2]. Un système BCI est composé de quatre phases. Qui sont Acquisition du signal, pré-traitement du signal, classification du signal et interaction avec l'ordinateur.

### 1.11.1 Acquisition du signal

L'acquisition des signaux cérébraux est réalisée en utilisant diverses méthodes non invasives comme Electroencéphalographie (EEG), imagerie par résonance magnétique fonctionnelle (IRMf), spectroscopie proche infrarouge (NIRS) et, Magnéto-encéphalographie (MEG) (voir la figure 1.7 ).

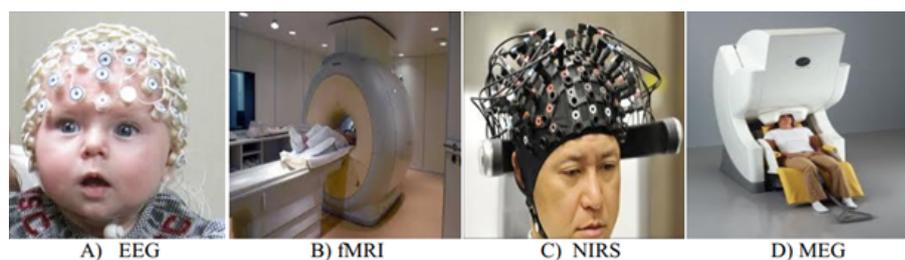


FIGURE 1.7 – Méthodologies d'acquisition du signal.

### 1.11.2 Pré-traitement du signal

Après la phase d'acquisition, les signaux doivent être pré-traités et améliorés. En général, les signaux cérébraux acquis sont contaminés par le bruit et les artefacts. Donc, l'élimination de ces derniers peut se faire en utilisant le référencement moyen en commun (CAR), la Surface Laplacien (SL), Analyse en composantes indépendantes (ICA), Schémas spatiaux communs (CSP), Composante principale Analyse

(PCA), Décomposition à Valeur Unique (SVD), Modèles Spatio-Spatiaux Communs (CSSP), Normalisation de Fréquence (Freq-Norm), Technique de Moyenne Locale (LAT), Filtrage Kalman Robuste, Sous-espace Spatial Commun Décomposition (CSSD), etc. Les méthodes les plus fréquemment utilisées sont l'ICA, le CAR, le SL, le PCA, le CSP et le filtrage adaptatif [4].

### 1.11.3 Extraction de caractéristiques

Après avoir obtenu les signaux sans bruit de la phase d'amélioration du signal, les caractéristiques essentielles des signaux du cerveau ont été extraits. Pour l'extraction des caractéristiques des signaux EEG, On peut utiliser des méthodes telles que les paramètres auto-régressifs adaptatifs (AAR), AAR bilinéaire, AAR multi variée, Transformations de Fourier rapides (FFT), PCA, ICA, Algorithmes génétiques (GA), ondelettes Transformations (WT), Décomposition de paquets d'ondelettes (WPD) ,Parmi celles-ci, ICA, PCA, WT, AR, WPD, Les FFT sont les plus utilisés [34].

### 1.11.4 Classification

Après l'extraction des caractéristiques, les signaux sont classés en différentes classes à l'aide de divers classificateurs. Les différents types de classificateurs comprennent les classificateurs linéaires, les classificateurs basés sur les réseaux neuronaux artificiels (ANN), les classificateurs bayé-siens non linéaires et les classificateurs du plus proche voisin. Parmi ces classificateurs, les classificateurs linéaires et les classificateurs bayé-siens non linéaires sont les plus utilisés dans la conception de la BCI [38]. Cette étape représente la partie décisionnelle de l'ensemble du processus de détection de somnolence. Elle vise à étiqueter des objets suivant la classe auxquels ils appartiennent. Les systèmes de classification comportent trois étapes :

- L'apprentissage, qui va s'efforcer de trouver la description de l'espace des observations qui traduit le mieux l'association avec les classes correspondantes.
- Le test, qui permet d'évaluer les performances du système de classification.
- Validation, est un processus couramment utilisé pour estimer les performances du classifieur.

## 1.12 Traitement du signal

Le traitement du signale est une discipline indispensable de nos jours. Il a pour objet l'élaboration ou l'interprétation des signaux porteurs d'informations. Son but est donc de réussir à extraire un maximum d'informations utiles sur un signal perturbé par du bruit en s'appuyant sur les ressources de l'électronique et de l'informatique.

### 1.12.1 Définition d'un signal

Un signal est la représentation physique de l'information, qu'il convoie de sa source à son destinataire. La description mathématique des signaux est l'objectif de la théorie du signal. Elle offre les moyens d'analyser, de concevoir et de caractériser des systèmes de traitement de l'information.

### 1.12.2 Échantillonnage d'un signal

L'échantillonnage d'un signal continu est l'opération qui consiste à prélever des échantillons du signal pour obtenir un signal discret (voir la figure 1.8), c'est-à-dire une suite de nombres représentant le signal, dans le but de mémoriser, transmettre, ou traiter le signal.

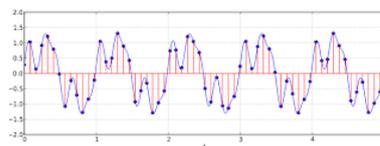


FIGURE 1.8 – Échantillonnage d'un signal.

### 1.12.3 Spectre d'un signal

Le spectre d'un signal est une représentation en fonction de la fréquence, des amplitudes, et éventuellement des phases, des composantes sinusoïdales d'une grandeur physique en fonction du temps.

### 1.12.4 Fréquence de coupure (Cutofffrequency)

La fréquence de coupure d'un circuit électronique est la fréquence limite de fonctionnement utile d'un circuit électronique. La pulsation de coupure est la pulsation correspondante. Les fréquences de coupure basse et haute définissent la bande passante.

### 1.12.5 Distance de Hamming

La distance de Hamming est une notion mathématique, définie par Richard Hamming, et utilisée en informatique, en traitement du signal et dans les télécommunications. Elle joue un rôle important en théorie algébrique des codes correcteurs. Elle permet de quantifier la différence entre deux séquences de symboles. C'est une distance au sens mathématique du terme. À deux suites de symboles de même longueur, elle associe le nombre de positions où les deux suites diffèrent. Le poids de Hamming correspond au nombre d'éléments différents de zéro dans une chaîne d'éléments.

## 1.13 Conclusion

Au cours de ce premier chapitre, un aperçu sur la somnolence au volant et ses techniques de détection ont été d'abord présenté, suivi d'une définition de l'électroencéphalogramme ainsi que les artefacts qui le perturbe, puis on a présenté les différents électrodes ainsi que leur systèmes de placement sur le cuir chevelu, après on a présenté les principales bandes de fréquences d'activité cérébrale, ensuite nous avons vu la structure générale d'un système de détection de somnolence basée sur l'EEG et nous avons terminé avec le traitement de signal ainsi que la définition de ce dernier. Le chapitre suivant sera consacré à un état de l'art sur les protocoles de détections de somnolences au volant.

## CHAPITRE 2

# ÉTAT DE L'ART SUR LES PROTOCOLES DE DÉTECTION DE SOMNOLENCE AU VOLANT

### 2.1 Introduction

Les défis auxquels est confrontée la sécurité du conducteur automobile sont multiples et les solutions proposées n'en sont pas moins nombreuses. Le problème de somnolence au volant est considéré comme un défi très important puisque à cet état sur une autoroute sa causera certainement un accident mortel.

De ce fait, le développement de nouveaux protocoles de détection de somnolence au volant s'avère indispensable. Ces protocoles doivent tenir compte des bénéfices sur le plan d'efficacité et un coût de calcul minimal pour assurer une détection rapide et en temps réel. Ainsi qu'à la contrainte des ressources et matérielles limitées dans les systèmes des smart-phones.

Ce chapitre sera consacré à la présentation et l'étude critique de quelques solutions récemment proposées sur l'axe de détection de somnolence au volant. Pour cela, nous définirons les critères d'évaluation sur lesquels nous nous baserons pour évaluer les protocoles étudiés. Suivie par notre propre classification des solutions étudiées en montrant les principales différences et similarités entre eux. Enfin, nous terminerons par une synthèse résumant les points forts et les points faibles des protocoles étudiés.

### 2.2 Critères d'évaluation des solutions existantes

#### 2.2.1 Taux d'exactitude

Le taux d'exactitude peut être calculée à base de plusieurs informations, il représente le taux des décision prise par le système afin d'accepter ou de refuser un état de somnolence. De ce fait, il faut minimiser au maximum le taux de fausses acceptations et le taux de faux rejets.

#### 2.2.2 Temps de détection du somnolence

La somnolence au volant est un phénomène qui se produit en fraction de seconde de ce fait sa détection doit être réalisé en temps réel.

### 2.2.3 Coût de calcul

Un algorithme très coûteux en calculs provoquera une lenteur au niveau de son exécution. Cela peut mener à des conséquences graves lors des cas de somnolence et de ne pas répondre en temps réel et influence directement sur l'énergie consommée par le dispositif d'alerte.

### 2.2.4 Consommation énergétique

Les batteries des véhicules et des smart phones ont une durée de vie très limitée, il faut donc minimiser la consommation d'énergie.

### 2.2.5 Applicabilité

La proposition des systèmes de détection de somnolence doit être réalisé avec des moyens moins coûteux et réalisables en temps réel sur des véhicules tout en gardon le confort du conducteur.

## 2.3 Classification des travaux étudiés

Nous proposons une classification des travaux que nous avons analysés en une structure composée de trois catégorie. La première catégorie représente les solutions basées sur les mesures physiologiques (EEG, ECG, Signal respiratoire). La deuxième catégorie représente les solutions basées sur les caractéristiques faciales. Enfin, la troisième catégorie représente les solutions basées sur les réseaux de neurones artificiels. La figure 2.1 montre notre classification.

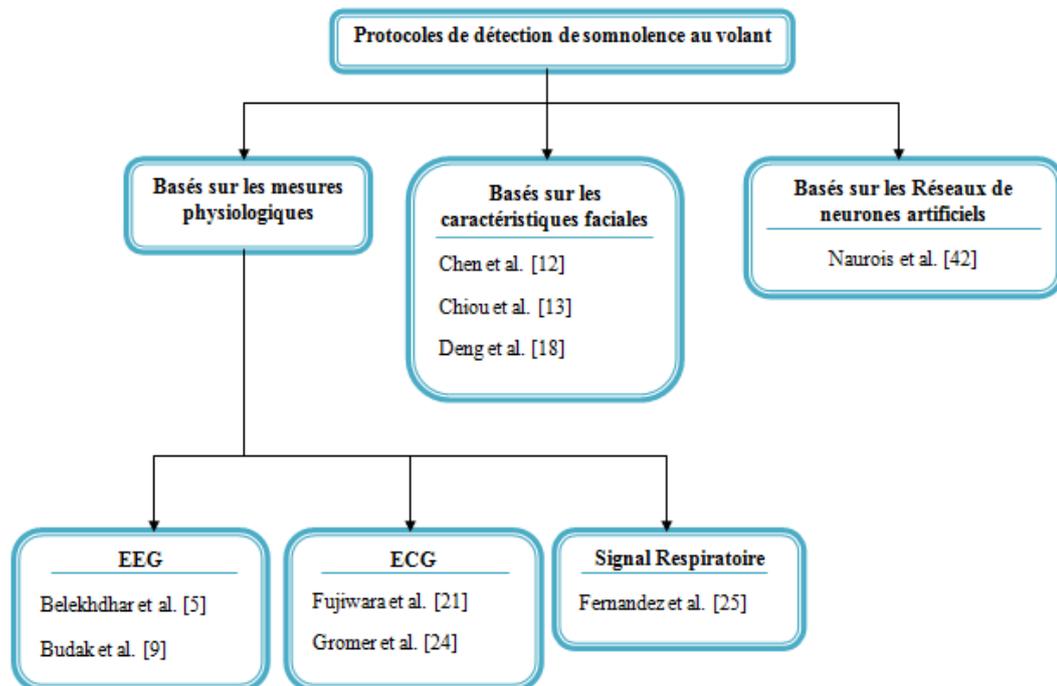


FIGURE 2.1 – Classification des protocoles étudiés pour la détection de somnolence au volant.

## 2.4 Étude critique des travaux antérieurs

### 2.4.1 Solutions basées sur les mesures physiologiques

#### A. Solutions basées sur le signal EEG

— **Single-channel-based automatic drowsiness detection architecture with a reduced number of EEG features**

Belakhdar et al. [5], ont proposé un système de détection de somnolence au volant basé sur les signaux physiologiques EEG. Cette approche est basée sur l'analyse spectrale de la sous-bande alpha, en utilisant le différentiel donné des électrodes C3-O1. Dans ce protocole cinq caractéristiques ont été extraites à partir du signal EEG afin de les utiliser comme entrées pour le classificateur. Le protocole de Belakhdar et al. assure la détection de somnolence au volant grâce au signal physiologique EEG enregistré à partir du canal C3-O1, avec un taux de vraies réponses de 84,29%. Mais, le calcul des cinq caractéristiques extraites du signal EEG affecte sur le coût de calcul du protocole.

— **An effective hybrid model for EEG-Based drowsiness detection**

Budak et al. [9], ont proposé un système de détection de somnolence au volant basé sur les signaux physiologiques EEG. Cette approche emploie trois mécanismes d'extraction des caractéristiques des signaux EEG correspondant à la somnolence. Le premier mécanisme d'extraction de fonction est la distribution d'énergie et de passage par zéro, entropie spectrale et les caractéristiques de fréquence instantanée. La deuxième extraction de fonctionnalités du mécanisme extrait des fonctionnalités profondes d'Alex Net préformé et modèles VGG16 (Convolutional Network for Classification and Detection). Enfin, les caractéristiques statistiques de la fréquence instantanée des signaux EEG décomposées par TQWT (Tapered Quarter Wave Tube) extrait dans le troisième mécanisme d'extraction de fonction. Ensuite ses fonctionnalités sont classées individuellement avec les réseaux LSTM (Long Short-Term Memory) où les sorties de tous les réseaux LSTM sont combinées sur un mécanisme de vote majoritaire.

Le protocole de Budak et al. assure la détection de la somnolence au volant grâce au signal physiologique EEG, avec un taux de vraies réponses de 94,31%. Mais le passage du protocole proposé par trois phases d'extraction de fonctionnalité là où chaque phase du protocole extrait deux à trois fonctionnalités qui affectent sur le coût du calcul et peut ralentir la détection en temps réel avec une consommation d'énergie élevée vue que sa mise en place sera sur un véhicule.

#### B. Solutions basées sur le signal ECG

— **Heart Rate Variability-based Driver Drowsiness detection and its Validation with EEG**

Fujiwara et al. [21], ont proposé un système de détection de somnolence au volant basé sur les signaux physiologiques ECG. Cette approche est basée sur la VRC en utilisant le cadre de prédiction des crises d'épilepsie basée sur la VRC. Les anomalies dans les données de la VRC des conducteurs sont surveillées par le processus de contrôle des statistiques multi variées (MSPC), cet algorithme est basé sur l'utilisation de huit fonctionnalités HRV et MSPC qui est une méthode linéaire.

Le protocole de Fujiwara et al. assure la détection de la somnolence au volant grâce au signal

physiologique ECG, mais sa mise en œuvre reste difficile car un capteur RRI précis est nécessaire pour réaliser un tel système de détection de la somnolence à base de HRV.

— **ECG sensor for detection of driver's drowsiness**

Gromer et al. [24], ont proposé un système de détection de somnolence au volant basé sur la combinaison des signaux physiologiques ECG et l'analyse du visage. Le protocole de Gromer et al décrit le développement des composants matériels et logiciels du capteur. Le matériel se compose d'un PCB (Polychlorobiphényle) pour l'amplification et le filtrage, conçu comme un blindage pour l'Arduino. La combinaison du PCB et de l'Arduino fournit un signal ECG au PC embarqué qui est responsable du filtrage du signal, extraction QRS, calcul de la VRC et génération de sorties. Cet appareil sera ultérieurement combiné avec la partie reconnaissance faciale.

Le protocole de Gromer et al. assure la détection de somnolence grâce à la, combinaison du signal physiologique ECG et l'analyse des caractéristiques du visage. Mais la nécessité d'utilisation d'un PC embarqué reste un inconvénient major, car la détection de somnolence se fait en temps réel et la combinaison du signal physiologique ECG et l'analyse des caractéristiques du visage affecte sur le coût du calcul et le temps de réponse à temps lors de détection de somnolence.

### C. Solutions basées sur le signal respiratoire

#### **Driver drowsiness detection based on respiratory signal analysis**

Fernandez et al. [25], ont proposé un système de détection de somnolence au volant basé sur les modifications du signal respiratoire obtenu à l'aide d'une ceinture de pléthysmographie inductive. L'algorithme proposé est basé sur l'analyse de la variabilité de la fréquence respiratoire (RRV) pour l'état de vigilance du conducteur suivi par l'identification de la lutte contre l'endormissement.

Le protocole de Fernandez et al. assure la détection de la somnolence au volant grâce aux modifications du signal respiratoire. Mais, le port de la ceinture abdominale reste inconfortable pour les conducteurs au volant sur des longs trajets.

#### **2.4.2 Solutions basées sur les caractéristiques faciales**

— **EDDD : event-based drowsiness driving detection through facial motion analysis with neuromorphic vision sensor**

Chen et al. [12], ont proposé un système de détection de somnolence au volant (EDDD) basé sur les caractéristiques faciales en utilisant le capteur de vision neuromorphique. Ce système propose une méthode pour reconnaître et localiser les mouvements oculaires et buccaux du conducteur à partir des flux d'événements. Les caractéristiques extraites liées à la somnolence sont directement liées aux événements à partir des flux d'événements provoqués par les mouvements des yeux et de la bouche.

Le protocole de Chen et al. assure la détection de la somnolence au volant grâce au capteur de vision neuromorphique dans les scénarios de visage tels que la conduite avec lunettes de soleil ou conduire la nuit, ce qui est très difficile pour capteurs de vision traditionnelle basés sur le cadre. Mais, une telle solution ne met pas le conducteur en état de confort car il se sentira toujours mal à l'aise d'être sur des longs trajets face à une caméra et sa mise en œuvre reste toujours chère.

— **Driver monitoring using sparse representation with part-based temporal face descriptors**

Chiou et al. [13], ont proposé un système de surveillance des conducteurs (DMS) hiérarchique (HDMS) pour surveiller leurs comportements de conduite, afin de détecter la somnolence au volant, basé sur les caractéristiques faciales en utilisant des représentations des pièces descriptives du visage temporel. Ce système repose sur deux couches hiérarchiques, pendant la conduite, la première couche du HDMS détecte le comportement de conduite normale et anormale basé sur des modèles de conduite personnelle représentés par des représentations clairsemées. Quand le comportement de conduite anormale est détecté, la deuxième couche du HDMS détermine en outre si le comportement est de la somnolence au volant ou comportement de conduite distrait.

Le protocole de Chiou et al. assure la détection de la somnolence au volant grâce au système de surveillance des comportements des conducteurs hiérarchiques (HDMS), qui permet de modéliser le comportement normal de chaque individu afin de détecter leur comportement anormal, ce qui permet de réduire le nombre de classificateur pour réduire le coût de calcul. Mais, le système proposé est implémenté sur des PC. Cependant, la puissance de calcul et la mémoire de la plupart des systèmes embarqués dans les véhicules sont plutôt très limitées.

— **Real-time driver-drowsiness detection system using facial features**

Deng et al. [18], ont proposé un système de détection de somnolence au volant appelé DriCare. Ce système détecte la somnolence des conducteurs grâce aux bâillements, le clignotement et la durée de la fermeture des yeux en utilisant des images vidéo sans équiper leur corps par des appareils. En utilisant CNN pour évaluer l'état de l'œil, DriCare mesure l'angle d'un œil qui s'ouvre pour déterminer si l'œil est fermé. Pour détecter les bâillements, DriCare évalue la durée de l'ouverture de la bouche. Par ailleurs, DriCare propose trois différents critères pour évaluer le degré de somnolence : la fréquence des clignotements, la durée de fermetures des yeux et le bâillement. Si les résultats dépassent le seuil ancien, DriCare alertera le conducteur somnolent.

Le protocole de Deng et al. Assure la détection de la somnolence au volant grâce au système DriCare, avec un taux de vraies réponses de 92% il est basée sur une caméra installée sur le véhicule qui utilise chaque image de cadre pour analyser et détecter l'état du conducteur. Mais, la combinaison des trois caractéristiques différents affectés directement sur le taux de calcul et la consommation d'énergie, ainsi que l'installation d'une caméra en face du conducteur peut le rendre inconfortable.

### 2.4.3 Solutions basées sur les réseaux de neurones artificielles

— **Detection and prediction of driver drowsiness using artificial neural net work models**

Naurois et al. [42], ont proposé un système de détection de somnolence basé sur les réseaux de neurones artificiels. Le processus de modélisation de ce protocole peut être divisé en deux phases. Phase 01 : Artificial Neural Network (ANN) détecte le niveau de somnolence d'un ensemble prédéterminé de fonctionnalités. Cette ANN est utilisée pour détecter le niveau de somnolence. Phase 02 : si la somnolence est sous le seuil, un deuxième ANN prédit quand il atteindra le seuil et donne ce temps comme sortie, sinon, sa sortie est 0.

Le protocole de Naurois et al. assure la détection de somnolence au volant et prédit quand l'état d'un conducteur est altéré grâce aux modifications du signal respiratoire. Le meilleur modèle dans

cet article utilise des informations sur la fermeture des paupières, le regard et le mouvement de la tête et le temps de conduite. Mais, un tel protocole ne peut être réalisé qu'en utilisant des PC performants et puissants vu que le nombre de calculs à effectuer en temps réel.

## 2.5 Synthèse

Plusieurs protocoles ont été proposés pour la détection automatique de la somnolence au volant pour les conducteurs tout en exploitant les caractéristiques des signaux physiologiques (EEG, ECG, Signal respiratoire), les caractéristiques faciales et les caractéristiques des réseaux de neurones artificiels.

Les protocoles étudiés permettant d'assurer la détection de la somnolence au volant et certains d'entre eux permettent, en plus, de minimiser les ressources.

Nous avons remarqué que certains protocoles étudiés sont plus performants que d'autres, mais requièrent plus de ressources. Afin de mieux comprendre la diversité des protocoles étudiés dans ce chapitre et traitant le problème de la détection de la somnolence au volant.

La table 2.1 illustre une étude comparative que nous avons menée sur les différents protocoles analysés précédemment selon les critères d'évaluation discutés en section 2.2.

Solution basée sur	Protocoles	Taux d'exactitude	Temps de détection	Coût de calcul	Énergie consommée	Applicabilité
<b>EEG</b>	Belakhdar et al. [5]	84.29%	Moyen	Moyen	Moyen	Oui
	Budak et al. [9]	94.31%	Élevé	Élevé	Élevé	Oui
<b>EKG</b>	Fujiwara et al. [21]	Non renseigné	Moyen	Élevé	Élevé	Non
	Gromer et al. [24]	Non renseigné	Élevé	Très élevé	Très élevé	Non
<b>Signal Respiratoire</b>	Fernandez et al. [25]	Non renseigné	Moyen	Moyen	Moyen	Oui
	Chen et al. [12]	Non renseigné	Moyen	Élevé	Élevé	Oui
<b>Caractéristique facial</b>	Chiou et al. [13]	Non renseigné	Moyen	Très élevé	Très élevé	Non
	Deng et al. [18]	92%	Moyen	Élevé	Élevé	Oui
<b>Réseaux de Neurones</b>	Naurois et al. [42]	Non renseigné	Élevé	Très élevé	Très élevé	Non

TABLE 2.1 – Étude comparative des différents protocoles analysés.

Dans certaines protocoles [5] [9], les signaux physiologiques basées sur EEG sont des solution les moins coûteuse pour la détection de la somnolence en terme du coût de calcul, la consommation d'énergies et bien sûr l'applicabilité tout en gardons le confort assuré au conducteur. Ces signaux physiologique sont les meilleur a exploiter pour la détection de la somnolence car la phase de somnolence sont relire directement a la tête.

Pour les solutions [21][24][42] basées sur les signaux physiologiques ECG et les réseaux de neurones, le problème de l'applicabilité de ses système reste à améliorés car leur charge de calcul nécessite l'utilisation des PC, se qui reste inapplicable sur un véhicule pour la détection de somnolence en temps réel.

Dans les solution [13][14][18][25] basées sur les caractéristique faciales et le signal respiratoire, ces deux méthodes sont applicables pour la détection de la somnolence au volant. Mais, elles nécessitent l'utilisation des moyens et matériels extrêmement performants vue que la charge des calcul à résoudre au temps réel, se qui demande des améliorations au niveau de leur algorithme afin de pouvoir l'appliquer sur des véhicules. L'avantage de notre méthode, en plus d'un bon taux de détection des états d'hypovigilance, est qu'elle n'a pas besoin d'être adaptée ou entraînée. Le seuil utilisé pour la détection reste le même pour chaque conducteur. Notre méthode a le grand avantage de fonctionner à partir d'un seul canal EEG. Le détecteur d'artéfacts permet de déterminer la qualité du canal afin d'éviter les fausses détections dues à des perturbations.

## 2.6 Conclusion

Dans les différents travaux que nous avons passé en revue, plusieurs problèmes ont été soulevés, le principal étant la difficulté de proposer une définition précise de la somnolence et de ses caractéristiques. De plus, la somnolence se manifeste de manière différente chez les différents individus, ce qui augmente la difficulté à définir un référentiel commun pour la détection de ce phénomène. Ces différentes techniques donnent de bons résultats, notamment les réseaux de neurones, mais nécessitent un apprentissage sur un grand nombre de données afin d'élaborer le modèle de détection de la somnolence. En pratique, cela n'est pas toujours réalisable. Enfin, nous avons pu identifier quelques méthodes qui nécessitent pas d'apprentissage et s'adaptent sans réglage aux différents conducteurs. Nous pouvons noter la méthode basée sur l'électroencéphalogramme (ou EEG). Ainsi, nous avons pu soulever précisément les problèmes auxquels nous devons faire face pour obtenir une solution qui répond aux critères cités auparavant. Le chapitre suivant sera consacré à la description détaillée de notre contribution.

## CHAPITRE 3

# REAL-TIME EEG-BASED SYSTEM FOR DETECTING DROWSY DRIVING STATE

### 3.1 Introduction

Nous avons montré à travers l'étude des protocoles de détection de somnolence que la méthode la plus précise est bien celle qui utilise les données acquises à partir des capteurs physiologiques tels que l'électroencéphalogramme(EEG) dont ses signaux fournissent des informations très utiles pour mesurer la somnolence en temps réel. Cette technique est due, d'une part, à réduire le nombre de fausses alarmes et d'autre part, elle est robuste aux différences entre conducteurs et ne nécessite pas de réglage.

Dans ce chapitre nous décrirons en premier lieu notre modèle système sur lequel repose notre contribution. Nous présenterons, par la suite, notre protocole de détection de somnolence qui est basé sur la réduction du nombre de canaux en exploitant seulement le canal C3-O1 et les deux bande de fréquence alpha et bêta.

### 3.2 Motivation

Comme la somnolence au volant est l'une des principales causes d'accidents mortel de véhicules à moteur, d'où le développement des techniques de la détection de cette phase accidentogène est à la fois un défi industriel et académique. En effet l'apprentissage automatique a fait des progrès révolutionnaires ces dernières années, en particulier dans le domaine de l'apprentissage non supervisé. Ainsi, l'utilisation de ces nouvelles techniques et méthodologies peut être un moyen efficace non seulement d'augmenter l'efficacité du système de détection de somnolence du conducteur en temps réel, mais également de fournir un outil qui peut être largement utilisé par les conducteurs.

Notre travail consiste à élaborer un système performant pour la détection automatique de la somnolence chez le conducteur dans le but d'augmenter la précision et d'accélérer la détection de la somnolence. L'étude de la littérature nous a permis de mettre en avant que les signes de la somnolence apparaissent principalement dans la zone occipital et central du cerveau du cerveau, de manière symétrique. Pour cela nous proposons donc d'utiliser un seul canal(C3-O1) pour notre protocole de détection afin de réduire au

minimum le nombre de canaux EEG et ainsi améliorer le confort du conducteur. De plus, la somnolence étant principalement caractérisée par l'évolution des activités alpha et bêta, nous proposons de nous concentrer sur l'évaluation de l'activité dans ses différentes bandes de fréquences afin de concevoir notre protocole.

### 3.3 Modèle du système

Notre protocole de détection repose sur un modèle d'apprentissage automatique, qui s'appuie sur l'utilisation des caractéristiques cérébraux obtenus grâce aux capteurs sans fil. La figure 3.1 montre un résumé de l'approche de formation utilisée dans le protocole de détection de somnolence.

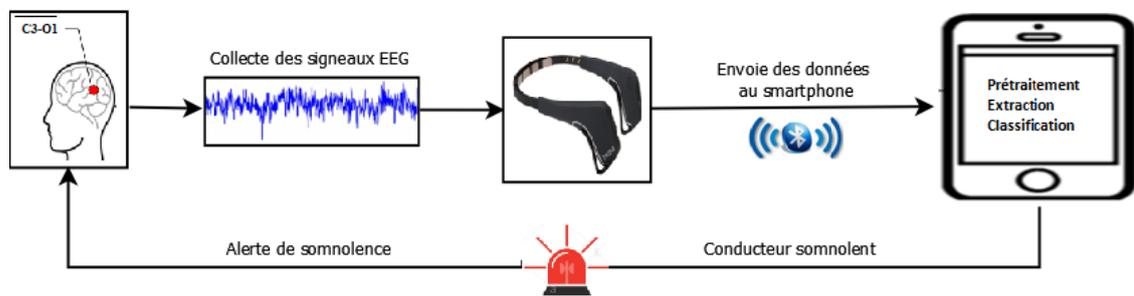


FIGURE 3.1 – Modèle système.

Nous supposons, dans notre protocole, que le casque sans fil est responsable de la collecte et du transfert des données provenant des capteurs. En effet, la connexion Bluetooth ouvre également le canal inverse, permettant au casque d'envoyer le signal EEG mesuré jusqu'au smartphone, offrant ainsi au conducteur un suivi précis de ses séances d'apprentissage grâce à l'application mobile.

Cette application permettra de recevoir des périodes successives de chaque 2s du signal. Ensuite, elle effectuera un prétraitement dont l'objectif est de préparer les données pour être en mesure d'analyser l'activité cérébrale liée à la stimulation, en utilisant les techniques de traitement du signal pour réduire le bruit et atténuer la plupart des artefacts.

Après avoir terminé l'amélioration du signal, nous calculerons la puissance de chaque bande de fréquence qui est la caractéristique essentielle pour notre protocole à fin de pouvoir calculer la puissance relative de chaque bande par rapport au signal.

Une fois que, la caractéristique est extraite, le classificateur linéaire (SVM) estimera la probabilité de conduite somnolente du conducteur. Enfin, une alerte n'est déclenchée que si seulement si la probabilité estimée dépasse un seuil particulier.

### 3.4 Notre protocole

Dans cette section, nous présentons les différentes phases qui constituent notre protocole, qui est basé sur l'utilisation d'un seul canal C3-O1 et la décomposition du signal en sous-bande afin d'exploiter seulement les deux bandes Alpha et Bêta. Puis, nous calculons la puissance relative à chaque bande par rapport au signal qui est notre essentielle caractéristique pour classifier les résultats avec le classificateur linéaire SVM à fin de déclencher une alerte en cas de somnolence. Notre protocole peut être subdivisé en quatre phases essentielles enchaînées comme suit :

- La première phase consiste à collecter les signaux EEG à partir d'un casque et les envoyés par Bluetooth au smart phone.
- La seconde phase consiste à effectuer un prétraitement sur le signal (filtrage, suppression des artefacts) dans le but de réussir à extraire un maximum d'informations utiles sur le signal perturbé.
- La troisième phase consiste à extraire les caractéristiques du signal EEG afin de pouvoir calculer la probabilité de somnolence du conducteur.
- La quatrième phase consiste à classifier les résultats obtenus et déclenché une alerte si seulement si la probabilité estimée dépasse un seuil particulier.

L'organigramme qui montre l'enchaînement des phase de notre protocole proposé représenté par la figure 3.2 .

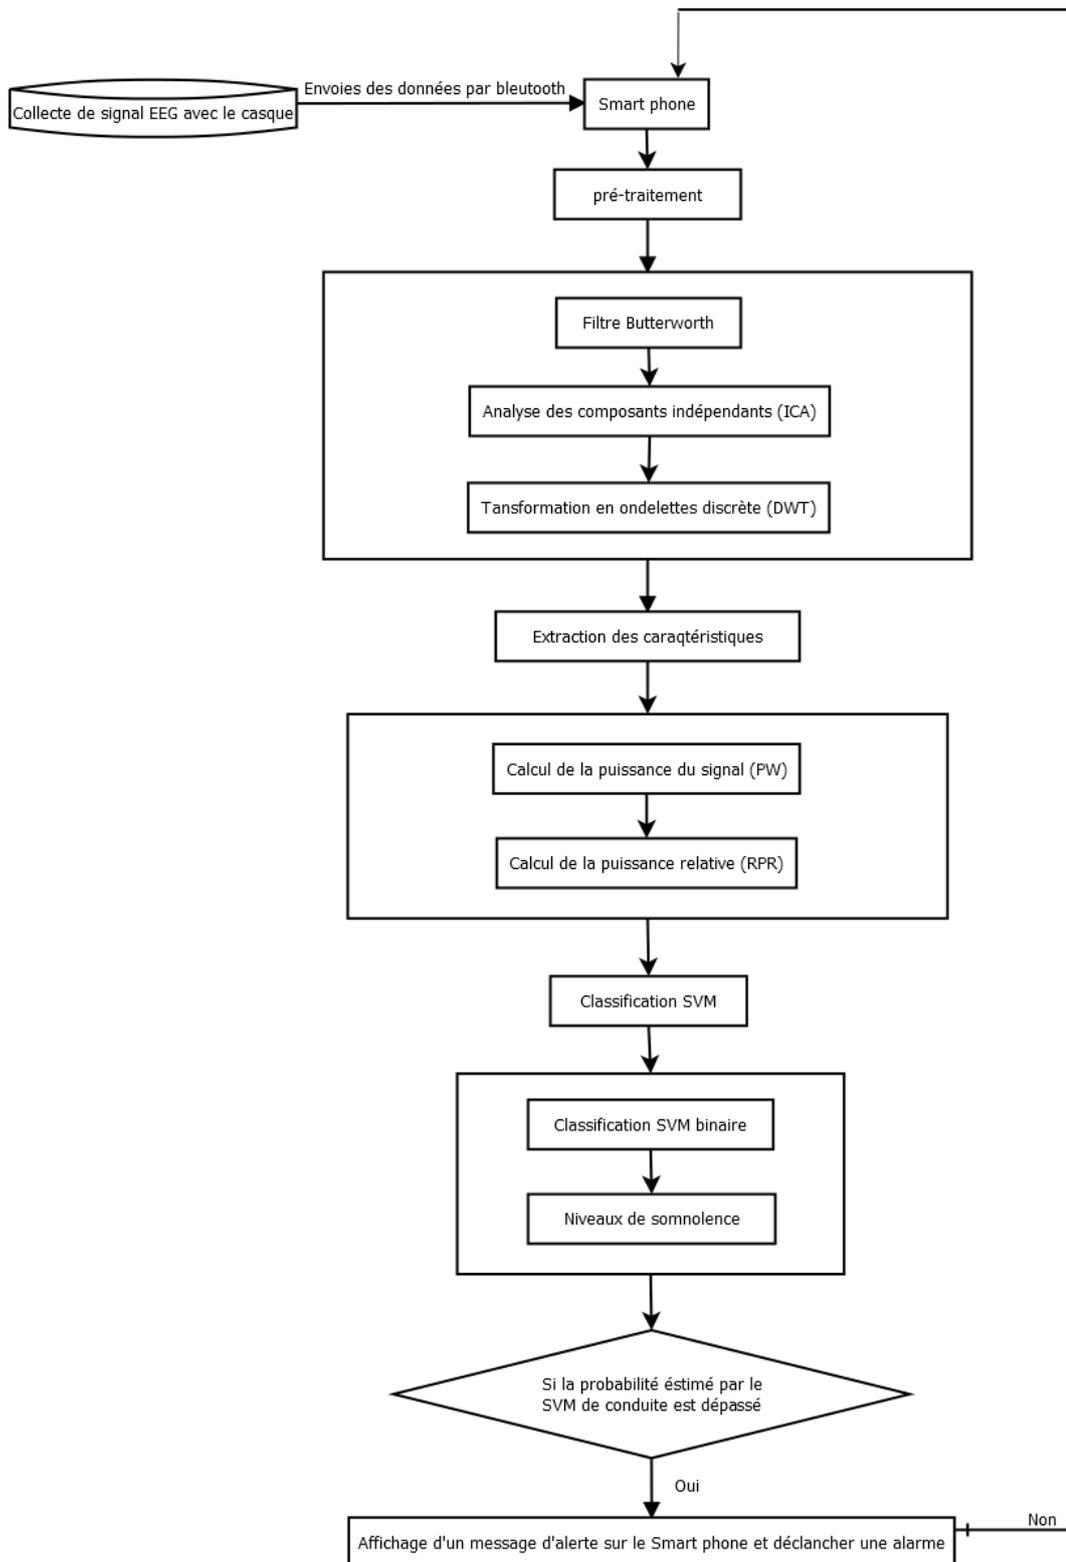


FIGURE 3.2 – Organigramme de protocole proposé.

### 3.4.1 Acquisition des signaux EEG du conducteur

La base de données utilisée pour l'évaluation de notre méthode nous a été fournie par MIT-BIH qu'est une collection d'enregistrements de plusieurs signaux physiologiques pendant le sommeil. Les sujets ont été suivis au laboratoire du sommeil de l'hôpital Beth Israel de Boston pour évaluer les différents états du sommeil [53].

La base de données contient plus de 80 heures d'enregistrements polysomnographiques à quatre, six et sept canaux, chacun avec un signal ECG annoté battement par battement, et des signaux EEG et respiratoires annotés en ce qui concerne les stades de sommeil. L'acquisition des signaux physiologiques (EEG et EOG) a été réalisée à 250Hz [23].

Ce genre de données est très difficile à obtenir. En effet, les campagnes d'acquisition sont très lourdes. L'acquisition EEG nécessite une grande précision dans le placement des électrodes. De plus, il est possible d'effectuer des expérimentations sur le sommeil humain uniquement dans des établissements agréés et spécialisés. Ces campagnes nécessitent parfois de garder les sujets une semaine complète de manière à éviter les perturbations extérieures et à assurer des conditions de sommeil équivalentes pour les différents sujets. Enfin, l'étiquetage des différents niveaux de somnolence est réalisé manuellement par un spécialiste

### 3.4.2 Pré-traitement et segmentation du signal enregistré

Les données qui ont été enregistrées, seront donc pré-traitées pour s'assurer qu'elles sont propres du bruit et des artefacts. Dans cette expérience, un filtre Butterworth passe-haut a été utilisé, l'analyse des composants indépendants (ICA) pour annuler tous les artefacts pendant l'enregistrement et la transformation discrète en ondelettes ont été utilisés pour obtenir une échelle de temps-fréquence des informations avec l'ondelette mère Daubechies4 (db4)[50][16].

#### Filtrage Butterworth :

Le filtre de Butterworth est un type de filtre de traitement de signal conçu pour avoir une réponse en fréquence aussi plat que possible dans la bande passante. Il est également considéré comme un filtre de magnitude au maximum plat.

Un filtre passe-bande de Butterworth de deuxième ordre avec une fréquence de coupure  $\omega_c$  de 0.5 Hz et 30 Hz est appliqué sur les signaux afin de lisser ces signaux et de réduire les artefacts et les tendances linéaire qui sont sélectionné par la fréquence de coupure.

Les polynômes normalisés de Butterworth peuvent être utilisés pour déterminer les fonctions de transfert de filtre passe-bas pour toute fréquence de coupure  $\omega_c$  selon l'équation 3.1 [15] [16] :

$$H(p) = \frac{G_0}{\prod_{k=1}^n (p - p_k) / \omega_c} \quad (3.1)$$

Avec :

$$P = P^2 + 1.4142P + 1 \quad (3.2)$$

(Équation du filtre butterworth de deuxième ordre)[15][50].

Butterworth a montré qu'un filtre passe - bas peut être conçu, la fréquence de coupure à été normalisée à 1 radian par seconde et dont la réponse en fréquence (Gain) était :

$$G(\omega) = \frac{1}{\sqrt{1 + \omega^{2n}}} \quad (3.3)$$

<https://fr.overleaf.com/project/5e84b903e06c07000110ffb7> Où,  $\omega$  est la fréquence angulaire en radians par seconde et  $n$  est le nombre de pôles du filtre égal au nombre d'éléments réactifs dans un filtre passif.

### Analyse des composants indépendants (ICA) :

L'utilisation de l'ICA était destinée à effectuer le processus de retrait des artefacts. L'artefact est un signal de terme qui n'est pas nécessaire, il est enregistré au moment du processus d'acquisition de données. Les artefacts peuvent être générés par le mouvement des muscles du cuir chevelu, le clignement des yeux (clignotant) ou l'environnement bruit. Cela se produit très simplement, car les signaux EEG sont très sensibles et vulnérables avec les bruits. Dans cette recherche, la boîte à outils ICA développée par Brian Moore a été utilisée [7].

### Transformation en ondelettes discrète (DWT) :

Les propriétés des signaux EEG étant des signaux non stationnaires, la transformation en ondelettes discrète est plus adaptée pour analyser le signal à différentes bandes de fréquence avec différentes résolutions en décomposant le signal par une approximation grossière et une information détaillée, car il utilise une technique multi-résolution pour analyser des différentes fréquences avec des différentes résolutions [1].

$$W(n, m; \phi) = \int_{-\infty}^{+\infty} x(s) \phi_{n,m}(s) ds \quad (3.4)$$

Où  $W$  représente le signal en ondelettes dans les paramètres  $n$  et  $m$ , en utilisant la fonction de décalage et de détail de  $\phi$ . Fondamentalement, Wavelet Transform analyse les caractéristiques du signal dans le domaine temporel et fréquentiel en les décomposer en plusieurs fonctions numériques par une seule fonction pour modifier et détailler. Cette fonction appelée fonction mère :

$$\phi_{n,m}(s) = \frac{1}{\sqrt{a_0^m}} \phi\left(\frac{s - nt_0 a_0^m}{a_0^m}\right) \quad (3.5)$$

Dans ce travail, le Daubechies 4 (db4) a été utilisé comme fonction mère (voir la figure 3.3).

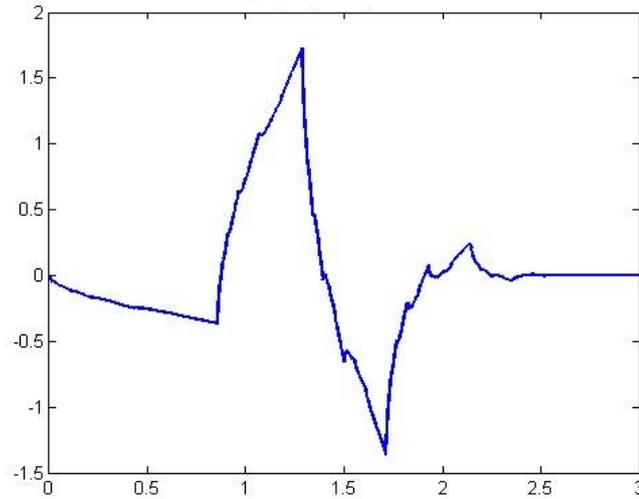


FIGURE 3.3 – Ondelette de Daubechies 4 [1].

Ce type a été choisi en raison de son orthogonalité, donc son approche d'une forme de signaux EEG. Dans la méthode DWT, les filtres passe-bas et passe-haut sont appliqués à plusieurs reprises pour obtenir la représentation du signal numérique en tant que signal d'approximation et coefficients de détail. L'échantillonnage de fréquence est de 128 Hz, de sorte qu'une décomposition à 5 niveaux sera nécessaire, comme suit :

- Niveau 1, est AD1 (0-60 Hz) et CD1 (64-128 Hz) ;
- Niveau 2, est AD2 (0-30 Hz) et CD2 (32-60 Hz) ;
- Niveau 3, est AD3 (0-4 Hz) et CD3 (16-32 Hz) inclus dans la gamme de fréquences bêta ;
- Niveau 4, est AD4 (0-8 Hz) et CD4 (8-16 Hz) inclus dans les gammes de fréquences alpha ;
- niveau 5, est AD5 (0-4 Hz) inclus dans les gammes de fréquences delta et CD5 (4-8 Hz) inclus dans la gamme de fréquences thêta [1].

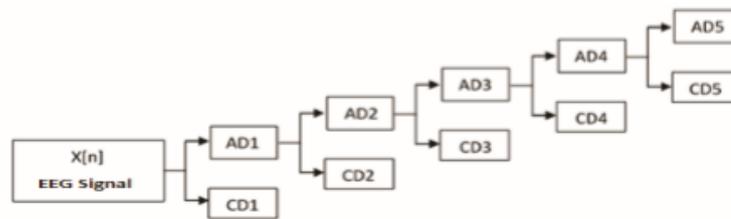


FIGURE 3.4 – Décomposition en multiple-niveau [1].

### 3.4.3 Extraction du signal EEG

Après avoir pré-traiter les données qui ont été enregistrées pour améliorer la qualité du signal EEG en utilisant un filtre Butterworth et l'analyse des composants indépendants (ICA) afin de supprimer tous les artefacts et les bruits, en suite on a décomposé le signal par niveau en utilisant la transformation en ondelettes discrète (DWT) comme le montre la figure (3.4) pour étudier le signal à différentes bandes

de fréquence avec différentes résolutions. Sur la figure (3.4), tous les signaux d'ondelettes représentent chaque fréquence de bande du signal EEG, et qui sont représentés à CD3 (Bêta), CD4 (Alpha), AD5 (Delta) et CD5 (Thêta).

Dans notre protocole nous avons choisi d'étudier les deux bandes alpha et bêta. Cette décomposition représente la forme d'onde qui sera calculée pour obtenir la puissance relative (RPR).

La puissance relative a été choisie comme une caractéristique essentielle afin d'examiner la relation entre le changement de puissance à l'heure du stimulus.

Nous définissons le rapport de puissance relative au signal EEG comme le rapport de la puissance d'une forme d'onde ( $\epsilon$ ) du signal filtré, où  $(\epsilon_i) \in (\alpha, \beta)$  et la somme de la puissance des deux formes d'onde EEG ( $\epsilon$ ).

La puissance du signal EEG est représentée par  $pW$ , qui est estimé par la somme de l'intégrale au carré du signal en utilisant environ 2s du signal EEG pour chaque sujet et la taille Hamming de la fenêtre de 256 points de données. La puissance  $pW$  du signal EEG est calculée comme suit :

$$pW(\epsilon) = \sum_{i=1}^n \int_{-\infty}^{+\infty} |(x(\epsilon_i))|^2 dx \quad (3.6)$$

Où  $n$  est le nombre d'échantillons de signal de bande EEG, et  $X(\epsilon)$  est le carré du signal de bande EEG. Dans notre protocole, il y a deux fonctionnalités de puissance de bande a calculé, comme suit :

— La puissance de la bande alpha :

$$pW(\alpha) = \sum_{i=1}^n \int_{-\infty}^{+\infty} |(x(\alpha_i))|^2 dx \quad (3.7)$$

— La puissance de la bande bêta :

$$pW(\beta) = \sum_{i=1}^n \int_{-\infty}^{+\infty} |(x(\beta_i))|^2 dx \quad (3.8)$$

Le rapport de puissance relative du signal EEG mesuré peut alors être exprimé comme suit :

$$RPR(\epsilon_i) = \frac{pW(\epsilon_i)}{\sum_{i=1}^2 pW(\epsilon_i)} \cdot 100\% \quad (3.9)$$

Après avoir fait le calcul de la valeur de puissance de chaque bande  $\alpha$  et  $\beta$ , le calcul de puissance relative (RPR) serve a former les vecteurs d'entrées pour le classificateur SVM. Sur ce protocole, il y a 2 fonctionnalités, comme suit :

— La puissance relative Alpha ( $RPR_\alpha$ ) :

$$RPR(\alpha) = \frac{pW(\alpha)}{pW(\alpha) + pW(\beta)} \cdot 100\% \quad (3.10)$$

— La puissance relative Bêta ( $RPR_\beta$ ) :

$$RPR(\beta) = \frac{pW(\beta)}{pW(\alpha) + pW(\beta)} \cdot 100\% \quad (3.11)$$

### 3.4.4 Modèle de détection de somnolence

Après l'étape d'extraction de la caractéristique EEG, les signaux doivent être classés. Il existe différents classificateurs pour séparer et classer les ensembles de données dans leur classe appropriée. Au milieu d'eux, les classificateurs linéaires, en particulier, SVM ont été largement utilisés dans la conception des interfaces brain computer (BCI).

### Classification SVM binaire

Le classificateur SVM binaire génère une étiquette de classe désignée par  $y = \pm 1$  pour chaque ensemble de données d'entrée  $v \in \mathbb{R}^n$ . Afin de classer les données d'entrée  $v(\text{RPR}(\alpha), \text{RPR}(\beta))$ , nous les séparons linéairement en utilisant le classificateur SVM linéaire qui est donné par la fonction linéaire indiquée dans l'équation 3.12 :

$$f(v) = \omega^t \cdot v + b \quad (3.12)$$

Par conséquent, pour chaque donnée d'entraînement  $v_i$ , la fonction donne :

$f(v_i) < 0$  pour  $y_i = -1$ , cas où le conducteur est libre.

$f(v_i) \geq 0$  pour  $y_i = +1$ , cas où le conducteur est somnolent.

### TWSVM

Pour distinguer les deux classes «somnolent» ou «alerte», nous avons choisi une approche d'apprentissage automatique efficace appelée TWSVM pour construire deux plans non parallèles pour chaque classe [33]. Par conséquent, en utilisant TWSVM, chaque hyperplan sera éloigné des échantillons de données de l'autre classe et proche de celui du sien [19]. Comme défini par Khemchandani et Chandra dans [33], l'hyperplan donné par l'équation 4 sépare les données d'entraînement de deux classes différentes, donc deux hyperplans  $f_1(v)$  et  $f_2(v)$  sont définis dans l'équation 3.13 comme suit :

$$f(v_i) = \omega_i^t \cdot v + b_i = 0 \quad \forall i \in \{1, 2\} \quad (3.13)$$

Où  $b_i =$  et  $\omega_i$  désignent respectivement le vecteur de biais des hyperplans séparateurs et le vecteur normal à l'hyperplan représentant des exemples d'apprentissage de la classe  $i$ . L'échantillon  $v$  est affecté à la classe  $i$  si et seulement si l'équation 3.14 est satisfaite :

$$\frac{|\omega_i^t \cdot v + b_i|}{|\omega_j^t \cdot v + b_j|} + \frac{\|\omega_j\|}{\|\omega_i\|} < 1 \quad \forall i, j \in \{1, 2\}, \quad i \neq j \quad (3.14)$$

où,  $\|\cdot\|$  désigne la distance euclidienne.

Les modèles de référence de somnolence sont stockés en toute sécurité dans une base de données cloud pour chaque conducteur pour une détection de somnolence d'un futur conducteur pour une conduite en toute sécurité. Ainsi, il est non seulement possible d'économiser de l'espace sur le disque dur, mais aussi et surtout d'assurer la sécurité des valeurs de référence de somnolence et d'y accéder depuis n'importe quel appareil.

## 3.5 Conclusion

Dans ce chapitre, nous avons présenté notre contribution dans la détection de la somnolence au volant. Tout d'abord, nous avons décrit notre modèle système sur lequel nous nous sommes basés pour concevoir notre protocole. Puis, nous avons présenté notre protocole de détection de somnolence basé sur les mesures physiologique EEG en exploitant un seul canal C3-O1 et la puissance relative de bande comme caractéristique afin de les classer par le classificateur SVM. Le chapitre suivant sera consacré à l'évaluation de performances de notre protocole de détection de la somnolence.

# CHAPITRE 4

## SIMULATION ET ÉVALUATION DE PERFORMANCES

### 4.1 Introduction

Après avoir présenté notre contribution pour la détection de la somnolence au volant dans le chapitre précédent, ce chapitre sera consacré à l'évaluation de performances du protocole proposé. Nous présentons en premier lieu les données EEG utilisées pour les simulations. Nous allons décrire par la suite l'environnement et les paramètres de simulation considérés pour l'évaluation de performances du protocole proposé. Ensuite, nous allons décrire les métriques d'évaluation de performances utilisées. Les résultats obtenus à l'issue de ces simulations seront finalement interprétés et comparés avec quelques protocoles concurrent étudiés dans le chapitre état de l'art 2.

### 4.2 Collecte de données

Il existe trois ensembles de données standard d'enregistrement du signal EEG pendant le sommeil. La polysomnographie MIT-BIH dataset [23], l'enregistrement CAP Sleep EEG [49] et la version étendue de Sleep-EDF [32]. Ainsi, le jeu de données MIT-BIH est le plus adapté pour valider notre système proposé car il contient un nombre suffisant d'époques de vigilance (W) et de somnolence (S1) nécessaires pour identifier toutes les transitions entre ces deux états (W, S1).

Même si le jeu de données SLEEP-EDF intègre un grand nombre d'enregistrement EEG (79 sujets), mais nous n'avons trouvé aucune transition entre les états W et S1, ce qui rend cet ensemble de données pas utile pour valider notre travail et de calculer avec précision la puissance de fréquence de chaque bande.

Sachant que nous avons besoin d'au moins 10 époques de 30 s d'état W pour chaque sujet, la base de données de polysomnographie MIT-BIH intégrant plusieurs enregistrements physiologiques (EEG, ECG, EOG, respiration, etc.) de 16 personnes. Les signaux EEG sont enregistrés via trois canaux définis dans le système standard 10-20 comme suite : 11 sujets à partir du canal C3-O1, 5 sujets à partir du canal C4-A1, 11 sujets à partir du canal O2-A1. Dans cette base de données, les signaux EEG ont été échantillonnés avec une fréquence de 250 Hz.

La base de données mentionnée intègre les enregistrements EEG de 11 personnes (slp03, slp04, slp14, slp16, slp45, slp48, slp59, slp60, slp61, slp66, slp67) acquit du canal C3-O1. La position de ce dernier est

représentée sur la figure 4.1 :

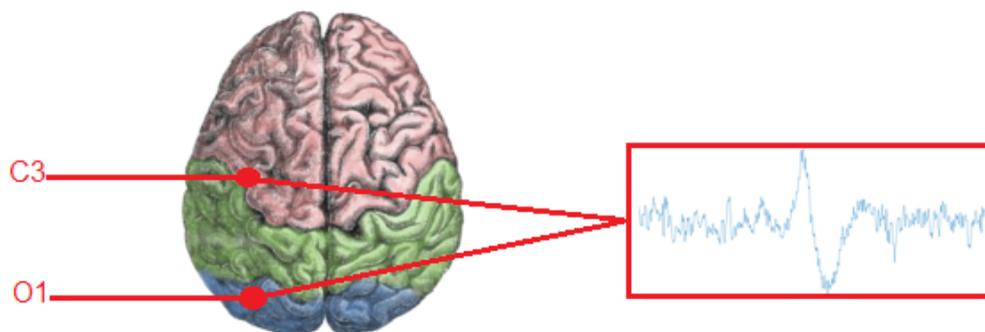


FIGURE 4.1 – Position du canal (C3-O1).

### 4.3 Préparation de données

Tous les enregistrements comprennent un signal ECG, un signal de pression artérielle invasif (mesuré à l'aide d'un cathéter dans l'artère radiale), un signal EEG et un signal de respiration (dans la plupart des cas, à partir d'une thermistance nasale). Les enregistrements à six et sept canaux comprennent également un signal d'effort respiratoire dérivé par pléthysmographie par inductance ; certains incluent un signal EOG et un signal EMG (à partir du menton), et le reste comprend un signal de volume de course cardiaque et un signal d'oxymétrie du lobe de l'oreille [2].

Concernant la base de données utilisée dans ce travail, les stades de sommeil ont été notés visuellement selon la norme traditionnelle proposée par Rechtschaffen et Kales [41], qui consiste en une segmentation des données en époques de 30 s à des fins d'analyse et de classification. En conséquence, l'hypnogramme contient des états de vigilance discrète dont : l'éveil (W), les mouvements oculaires non rapides (NREM) représentés par le stade 1, stade 2, stade 3 et stade 4, mouvement oculaire rapide (REM) et les états du temps de déplacement (MT). L'analyse de ces sept états de vigilance nécessite l'utilisation de toutes les données des canaux EEG.

Dans cette base de données, les 16 sujets étaient des hommes, âgés de 32 à 56 ans (l'âge moyen est 43 ans), avec des poids allant de 89 à 152 kg (le poids moyen est 119 kg). Pour valider notre protocole proposé, seules les données enregistrées auprès de 11 participants (P3, P4, P14, P16, P45, P48, P59, P60, P61, P66 et P67) ont été sélectionnées. De plus, nous avons utilisé l'enregistrement obtenu à partir du canal C3-O1. Nous excluons les époques de vigilance dans la base de données entre les étapes REM, S2, S3 et S4. De plus, nous avons utilisé seules les époques de vigilance précédant immédiatement les époques de somnolence.

Le tableau 4.1 résume les informations de chaque sujet :

### 4.4 Environnement de simulation

Dans cette section, nous présentons au préalable les paramètres de simulation, puis nous décrivons les métriques de simulation utilisés.

TABLE 4.1 – Informations des sujets sélectionnées pour validé notre système.

Participant	Age	Sexe	Poids (Kg)	Durée	Date d'acquisition
P03	51	M	152	6h	17/02/1989
P04	40	M	108	6h	26/02/1989
P14	37	M	152	6h	30/03/1989
P16	35	M	118	6h	11/04/1989
P45	42	M	133	6h20	30/08/1989
P48	56	M	103	6h20	04/09/1989
P59	41	M	111	4h	27/10/1989
P60	49	M	108	5h55	21/11/1989
P61	31	M	91	6h10	19/11/1989
P66	33	M	95	3h40	08/01/1990
P67	/	M	/	1h17	24/01/1990

#### 4.4.1 Paramètre de simulation

Notre protocole de détection de somnolence au volant est simulé sous l'environnement Matlab-R2015b avec un ordinateur ayant un processeur Intel(R) Core (TM) i5-4210U CPU @1.70 GHz 1.70 GHz et mémoire de 8 Go. Nous avons d'abord utilisé les filtres Butterworth avec la boîte à outils Signal Processing de Matlab pour améliorer la qualité du signal. Puis, nous avons séparé chaque bande de fréquence d'époque avec la DWT incluse dans Matlab et on a déterminé la puissance de chaque bande pour calculer la puissance relative de chaque bande de fréquence EEG par rapport a chaque époque du signal. Par la suite, nous avons utilisé le classificateur SVM de la boîte à outils de LibSvm.

#### 4.4.2 Matrice de confusion

La matrice de confusion ou tableau de contingence est un outil permettant de mesurer les performances et la qualité d'un système de classification. Chaque ligne correspond à une classe réelle et chaque colonne correspond à une classe estimée (prédite). Le tableau 4.2 illustre une matrice de confusion à deux classes [48].

		Classe réelle	
		+	-
Classe prédite	+	Vrais positifs	faux négatifs
	-	faux positifs	vrais négatifs

TABLE 4.2 – Matrice de confusion à deux classes.

- Vrais négatifs (VN) : le nombre d'exemple négatifs que le modèle a correctement classés comme négatifs.
- Faux négatifs (FN) : le nombre d'exemple positifs que le modèle a incorrectement classés comme négatifs.

- Faux positive (FN) : le nombre d'exemple négatifs que le modèle a incorrectement classés comme positifs.
- Vrais positifs (VP) : le nombre d'exemple positifs que le modèle a correctement classés comme positifs.

En particulier, si la matrice de confusion est diagonale (i.e., FN= FP= 0), le classifieur est dit parfait.

### 4.4.3 La courbe ROC

Les courbes ROC (Receiver Operating Characteristic) furent inventées pendant la seconde guerre mondiale pour la mise au point de moyens efficaces de détection des avions japonais, ainsi que la séparation entre les signaux radars et le bruit. Ces courbes mesurent les performances d'un classifieur binaire. Autrement dit, le système vise à diviser les éléments en deux groupes différents en fonction d'une ou plusieurs caractéristiques de chaque élément. La courbe ROC se définit par une représentation du taux des vrais positifs en fonction du taux des faux positifs. Cette représentation met en évidence un autre indicateur d'évaluation pertinent déployé pour mesurer la performance d'un classifieur, appelé l'aire sous la courbe (AUC). Plus cette région se rapproche de 1, plus le classifieur est performant. La figure 4.2 illustre l'interprétation de la courbe ROC [48].

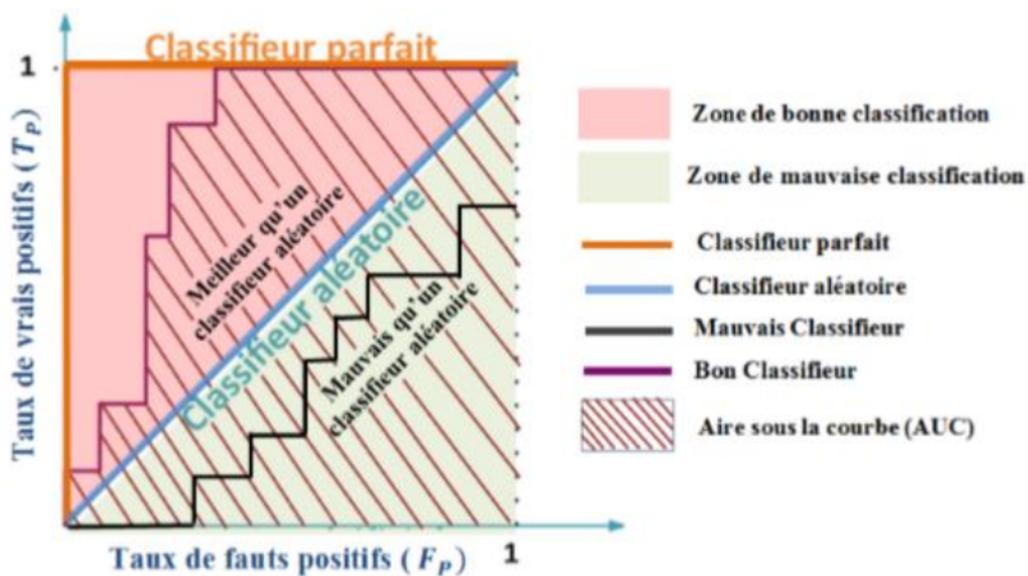


FIGURE 4.2 – Interprétation de la courbe ROC [48].

### 4.4.4 Métriques de simulation

Pour l'évaluation de performance de notre protocole nous sommes intéressés aux métriques de performances suivantes : (1) **Temps de détection de la somnolence** : c'est l'intervalle de temps que le protocole prend pour décider si le conducteur est somnolent ou éveillé, (2) **Taux d'exactitude** : il représente le taux de décision prise par le protocole afin d'accepter ou de rejeter un état de somnolence, (3) **Taux de fausse acceptation (TFA)** : c'est la mesure de la probabilité que le protocole de détection de somnolence au volant accepte à tort une fausse détection de somnolence. Il est indiqué comme le

rapport du nombre de faux rejets divisé par le nombre d’alerte, **(4) Taux de faux rejet (TFR)** : c’est la mesure de la probabilité que le protocole de détection de somnolence au volant rejette à tort une bonne détection de somnolence. Il est exprimé comme le rapport du nombre de fausses acceptations divisée par le nombre d’alerte.

Ces métriques sont calculées en fonction du nombre de caractéristiques qui servent d’entrées à la formation et aux tests SVM de la manière citer dans le tableau 4.3 :

Métriques d’évaluation	Définition
Exactitude ( $e$ )	$(V_p + V_n)/(V_p + F_p + V_n + F_n)$
Rappel ( $\psi$ )	$(V_p)/(V_p + F_n)$
Précision ( $\sigma$ )	$(V_p)/(V_p + F_p)$
Taux du faux négatif	$(F_n)/(V_p + F_n)$
Taux de faux positif	$(F_p)/(V_n + F_p)$
Spécificité ( $\phi$ )	$(V_n)/(V_n + F_p)$

TABLE 4.3 – Métriques d’évaluation calculées à partir de la matrice de confusion.

La mesure globale de performances du protocole proposé peut être obtenue à partir de la métrique  $F_{score4.1}$  :

$$F_{score} = 2 \frac{\Psi\sigma}{\psi + \sigma} \quad (4.1)$$

## 4.5 Résultats et discussion

Cette partie présente les résultats obtenus par le protocole proposé sur une base de données expertisée. Ces résultats sont comparés à ceux de la littérature. Pour commencer, nous devons tout d’abord récupérer les données à classifier. Cependant, les décisions de l’expert ont lieu toutes les 2 s. On compare donc nos décisions aux décisions de l’expert par bloc de 2 s. Le conducteur est alors considéré comme “somnolent” si durant ces 2 s a été classées comme “somnolent” par notre algorithme.

### 4.5.1 Résultats obtenus par notre protocole

L’algorithme de détection a été appliqué sur l’ensemble de la base de données fournie par la polysomnographie MIT-BIH et présentée dans la section 4.3. Nous rappelons que ces données représentent 58 heures de données de conduite provenant de onze participants différents. De plus, les données ont toutes été expertisées par un médecin spécialisé.

#### Matrice de confusion

la figure 4.3 illustre la matrice de confusion du protocole proposé.

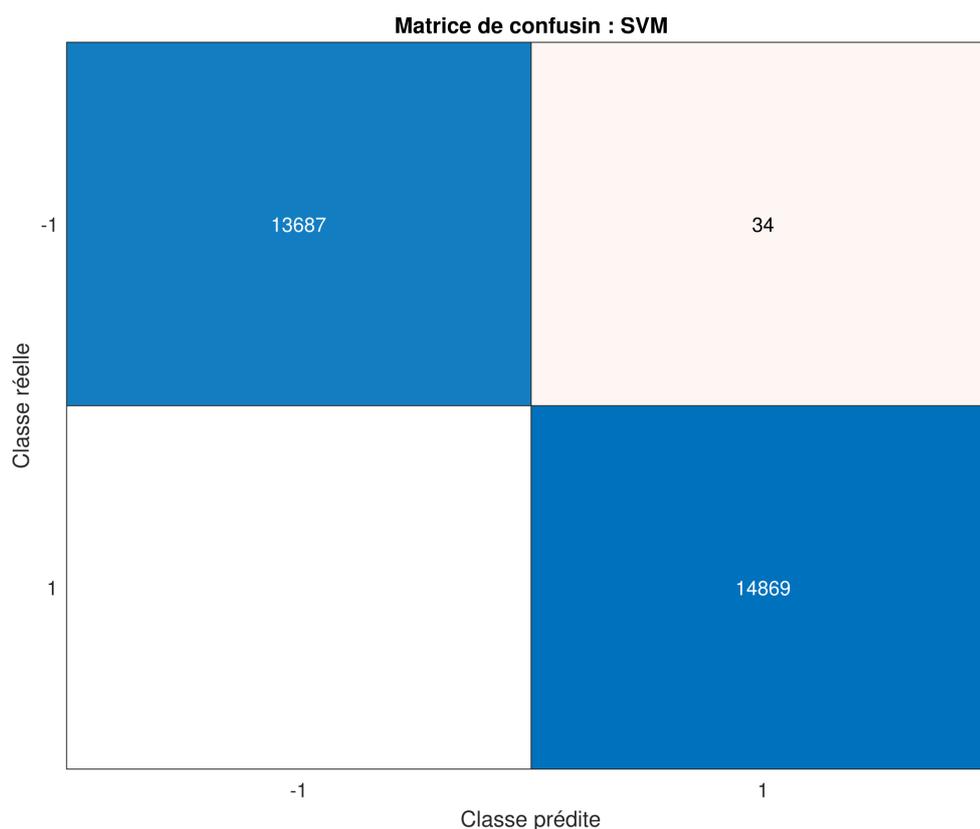


FIGURE 4.3 – La matrice de confusion avec le classificateur SVM.

D'après cette matrice de confusion nous avons un total de 28590 prédicteurs avec 28556 prédicteurs bien classés et 34 mal classés. Pour les métriques de simulation présentées dans la table 4.3 nous aurons :

Métriques d'évaluation	Définition %
Exactitude ( $e$ )	99,87
Rappel ( $\psi$ )	99,77
Précision ( $\sigma$ )	100
Taux du faux négatif	0,22
Taux de faux positif	0,00
Spécificité ( $\phi$ )	100

TABLE 4.4 – Métriques d'évaluation calculées à partir de la matrice de confusion.

La mesure globale de performances du protocole proposé est obtenue à partir de la métrique  $f_{score}$  qui est :

$$f_{score} = 99,88\%$$

### Courbe ROC

Afin d'évaluer les performances du protocole proposé, nous avons représenté la courbe ROC. Pour cela, nous calculons les coefficients ROC de la détection du niveau de "sommolence" par rapport à l'état de "veille". Nous trouvons  $VP = 100\%$  et  $FP = 0\%$ .

la figure 4.4 présente la courbe ROC avec le classificateur SVM.

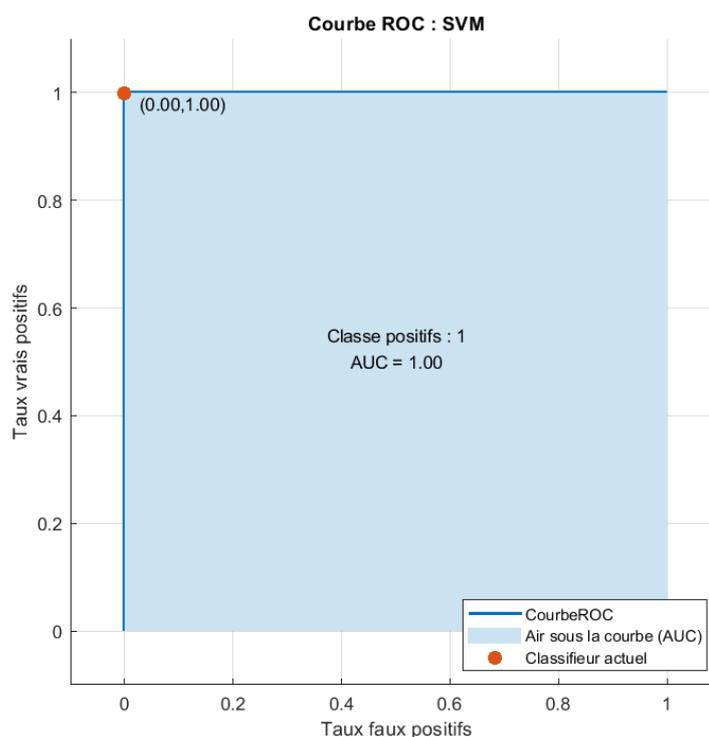


FIGURE 4.4 – La courbe ROC avec le classificateur SVM.

Tandis que la courbe ROC se définit par la présentation des vrais positifs (100%) en fonction des faux positifs on aurait l'indicateur d'évaluation  $AUC=1$  qui est l'aire sous la courbe. D'après la figure 4.2 nous pouvons clairement déduire que classificateur SVM est parfait.

### Nuages de points

Dans la figure 4.5 nous avons une représentation des points de la puissance relative de la bande de fréquence alpha ( $RPR_\alpha$ ) et la puissance relative de la bande de fréquence bêta ( $RPR_\beta$ ) selon le classificateur SVM.

Sur la figure 4.5 on as :

- La classe (-1) représenté avec des points bleu désigne les prédictions correct la ou  $RPR_\alpha$  est dominante par rapport à  $RPR_\beta$  qui veut dire que le conducteur est en état de somnolence.
- La classe (1) représenté avec des points orange désigne les prédictions correct la ou  $RPR_\beta$  est dominante par rapport à la  $RPR_\alpha$  qui veut dire que le conducteur est en état veille.
- La classe (-1) représenté avec des crois bleu désigne les prédiction incorrecte de l'état de somnolence.

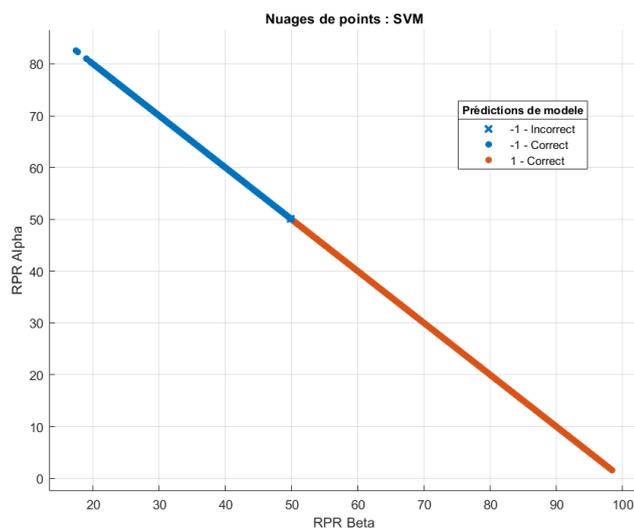


FIGURE 4.5 – Nuages de points avec le classificateur SVM.

### 4.5.2 Discussion

Ces systèmes nécessitent cependant un nombre très important d'indices, ce qui peut rendre délicate leur mise en place. L'avantage du protocole proposé est sa robustesse aux différences interindividuelles. En effet, il a pu être appliqué sur onze participants différents sans avoir à changer les paramètres de l'algorithme. De plus, l'utilisation d'un seul canal EEG et une seule caractéristique de données (RPR) nous permet de réduire le coût du calculs de notre algorithme et le temps de détection de somnolence. De plus, ces performances restent très correctes avec 99,87% de bonnes classifications, 100% taux de vrais positifs et 99,75% taux de vrais négatifs. Enfin, la pertinence de cette comparaison reste relative car toutes ces techniques ont été testées sur des données différentes.

Le tableau 4.5 illustre une comparaison entre le protocole proposé et quelques protocole concurrent présenté dans le chapitre état de l'art 2.

<b>Protocoles</b>	Notre protocole	Belakhdar et al. [5]	Budak et al. [9]	Li et al. [22]
<b>Base de données EEG</b>	MIT-BIH polysomnographic [53]	MIT-BIH polysomnographic [53]	MIT-BIH polysomnographic [53]	MIT-BIH polysomnographic [53]
<b>Nombres de canaux</b>	1	1	6	2
<b>Pré traitement</b>	Butterworth filter ICA DWT	Butterworth filter	Filtre passe-haut Filtre passe-bas	Filtre passe-bas
<b>Extraction</b>	DWT	FFT	Distribution d'énergie Passage par zéro Alex Net préformé Modèles VGG16 TQWT	FFT
<b>Nombre de caractéristiques</b>	1	5	8	1
<b>Classification</b>	TWSVM	ANN	LSTM	SVMPPM
<b>Temps de détection (s)</b>	1	2	Non renseigner	Non renseigner
<b>Exactitude (%)</b>	99,87	82.70	94.31	91.92
<b>TVP (%)</b>	100	79.90	Non renseigner	Non renseigner
<b>TVN (%)</b>	99,75	85.50	Non renseigner	Non renseigner
<b>Sampling rate (Hz)</b>	128	250	250	128

TABLE 4.5 – Comparaison des études de (détection de somnolence du conducteur) basées sur le signal EEG et les modèles probabilistes.

### Comparaison du classificateur SVM par rapport au classificateur KNN et classificateur TREE

Nous allons d'abord évaluer les performances des trois modèles de classificateurs choisis (SVM, TREE, KNN) l'évaluation des classificateurs est basée sur le temps de détection et la probabilité de détection correcte (exactitude), le taux de vrais positifs et le taux de vrais négatifs.

	Temps de détection (ms)	Exactitude (%)	Taux de vrais positifs (%)	Taux de vrais négatifs (%)
<b>SVM</b>	1072,590	99,87 28556/28590	100 14869/14869	99,75 13687/13721
<b>KNN</b>	164,481	99,60 28477/28590	99,54 14802/14869	99,66 13675/13721
<b>TREE</b>	234,790	99,70 (28505/28590)	99,68 (14828/14869)	99,72 (13677/13721)

TABLE 4.6 – Comparaison des trois classificateurs SVM, KNN et TREE.

D'après le tableau 4.6, il ressort que les performances des trois classificateurs sont parfaits en termes de probabilité moyenne de détection, car elles sont évaluées à 99,87% pour le classificateur SVM qui a le plus haut taux d'exactitude suivi par le classificateur TREE avec 99.70% et 99,60% pour le classificateur KNN. Mais, en temps de détection le classificateur KNN est meilleur avec 164ms suivi par le classificateur TREE avec 234 ms et 1072 ms pour le classificateur SVM.

D'après les résultats expérimentaux présentés nous pouvons conclure que : tous les classificateurs présentent globalement de très bonnes performances. Ceci peut être expliqué par le fait que nos données ont été bien pré-traitées et le choix de la puissance relative de bandes de fréquences alpha et bêta pour bien extraire les fonctionnalités qui servent d'entrées au classificateur afin de bien les classifier.

## 4.6 Conclusion

Ce chapitre clôture notre travail avec une étude expérimentale sur la détection de somnolence basée sur le signal EEG, ainsi que des simulations qui ont été réalisées afin de valider notre protocole.

Nous avons conclu que les résultats obtenus sont encourageants. Nous avons obtenu un taux d'exactitude de 99,87% ce qui donne un avantage d'avoir une bonne détection de somnolence. Nous avons également conclu que la durée de détection de somnolence est aussi inférieure pour notre protocole, ce qui rendra le processus d'authentification plus rapide.

## *CONCLUSION GÉNÉRALE ET PERSPECTIVES*

Ce travail nous a permis suite à une réflexion sur la définition et la caractérisation de l'état de somnolence de proposer un système permettant sa détection. Ce système assure une détection automatique de la baisse de vigilance chez le conducteur à l'aide d'un système expert entièrement orienté sur l'étude du conducteur afin de détecter la somnolence à partir d'information physiologique EEG.

Ce système s'avère performant avec environ 99,87 % de bonnes détections des états de somnolence. De plus, ce travail a permis de mettre en avant l'intérêt d'utiliser le signal EEG, grâce à ses bonnes performances et son grand avantage qui est sa robustesse aux différences interindividuelles. En effet, ce système ne nécessite pas de changer les réglages en fonction du conducteur et seul un apprentissage d'une durée de deux secondes et réalisé pour effectuer la détection EEG. Les performances présentées ont d'ailleurs été obtenues sur une base de données MIT-BIH polysomnographique [23] réalisée à partir de 11 conducteurs différents sans avoir eu à changer les paramètres.

Notre protocole de détection s'appuie sur une détection de somnolence à l'aide d'un unique canal (C3-O1). La détection EEG est réalisée par le calcul de la puissance relative de chaque bande par rapport au signal qui seront l'entrée du classificateur SVM afin de distinguer les deux classes «somnolent, alerte». Un filtre Butterworth à été utilisé pour éliminer les artefacts, afin d'utilisée l'information EEG uniquement lorsqu'elle est de bonne qualité pour réduire le nombre de fausses alarmes. De plus, ce protocole utilise la décomposition on ondelette discrète afin de sélection seulement les bande alpha et bêta et éliminer les bruits dans le but de minimiser le coût de calculs et accélérer la détection en temps réel.

L'objectif de ce travail était de proposer une solution optimale tout en minimisant le coût de calcul, dont sa mise en œuvre est réalisable et nécessite pas de véhicule de nouvelles technologies et surtout ce système assure le confort du conducteur.

Enfin, le problème de la somnolence est un problème très sérieux. Même s'il est possible de détecter cet état accidentogène à l'aide de systèmes de détection automatique, les plus performants soient-ils, le meilleur indicateur de somnolence reste encore le conducteur qui doit apprendre à connaître ses limites. C'est pourquoi ces systèmes de détection ne sont utiles que s'ils s'accompagnent d'une sensibilisation et d'une responsabilisation du conducteur.

Pour conclure ce document, nous présentons des perspectives qui feront l'objet de nos futures recherches. À commencer d'abord par la réalisation d'une application mobile pour notre système de détection et le connecter au casques qui sont capable de capter le signal EEG afin de le mettre en œuvre sur des condition réelle pour le conducteur automobile.

## BIBLIOGRAPHIE

- [1] wavelet-transform. <http://gwyddion.net/documentation/user-guide-fr/wavelet-transform.html>, (Consulté le 10 mars 2020).
- [2] physionet. [<https://physionet.org/files/slpdb/1.0.0/slpdb.html>]., (Consulté le 13 08 2020).
- [3] Lobes of the brain. <http://www.amicusvisualsolutions.com/BrainLobes.>, (Consulté le 15 Mars 2020).
- [4] B. Ali, Mehrdad, Fatoureh K. Rabab, E. Gary, and A. Birch. survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals. *Neural Engg.*, 4, 2007.
- [5] I. Belakhdar, W. Kaaniche, R. Djemal, and B. Ouni. Single-channel-based automatic drowsiness detection architecture with a reduced number of eeg features. *Microprocessors and Microsystems*, pages 1–24, 2018.
- [6] S. R. Benbadis. Introduction to sleep electroencephalography, sleep : A comprehensive handbook. pages 989–1024, 2006.
- [7] K. J. Blinowska and J. Zygiereicz. Analyse pratique du signal biomédical utilisant matlab. *Boca Raton, CRC Presse*, 2011.
- [8] C. Briere and R.Lopez, 2019.
- [9] U. Budak, V. Bajaj, Y. Akbulut, O. Atilla, and A. Sengur. An effective hybrid model for eeg-based drowsiness detection. *IEEE sensors journal*, 19 :7624–7631, 2019.
- [10] A. Bustomi, S.K. Wijaya, and Prawito. Analyzing power spectral of electroencephalogramme (eeg) signal to identify motoric arm movement using emotiv epoc +. *AIP Conference proceedings*, 1862(030071) :1–7, 2017.
- [11] J. Cambier and P.Verstichel. le cerveau encyclopédia universalis. *Encyclopédia Universalis*, 2011.
- [12] G. Che, L. Hong, J. Dong, P. Liu, J. Conradt, and A. Knoll. Eddd : Event-based drowsiness driving detection through facial motion analysiswith neuromorphic vision sensor. *IEEE sensors journal*, 20 :6170–6181, 2020.
- [13] C. Chiou, W. Wang, S. Lu, C. Huang, P. Chung, and Y. Lai. Driver monitoring using sparse representation with part-based temporal face des-criptors. *IEEE transactions on intelligent transportation systems*, pages 1–16, 2019.

- [14] K. T. Chui, K. F. Tsang, H. R. Chi, B. W. K. Ling, and C. K. Wu. An accurate eeg based transportation safety drowsiness detection scheme. *IEEE Transactions on Industrial Informatics*, 12(4) :1438–1452, 2017.
- [15] A. G. Correa and E. L. Leber. An automatic detector of drowsiness based on spectral analysis and wavelet decomposition of eeg records. *Engineering in Medicine and Biology Society (EMBC), Annual International Conference of the IEEE*, pages 1405–1408, 2010.
- [16] A.G. Correa, L. Orosco, and E. Laciari. Automatic detection of drowsiness in eeg records based on multimodal analysis. In *Medical engineering physics (36)2*, pages 244–249, 2014.
- [17] Organisation Mondiale de la Santé. Conseils pour la sécurité routière. <https://www.who.int/fr/news-room/feature-stories/detail/tips-to-stay-safe-on-the-road-this-new-year>, (Consulté le 08 juin 2020).
- [18] W. Deng and R. Wu. Real-time driver-drowsiness detection system using facial features. *IEEE Access*, 4 :1–12, 2019.
- [19] S. Ding, J. Yu, and B. Qi. An overview on twin support vector machines. *Artif Intell Rev*, 42(2) :245–252, 2014.
- [20] A. Follet-Maitrel, L. Mammeri, and M. Descamps. qu’est ce que les battements binauraux. <http://tpe-batement-binauraux.webnode.fr/quest-ce-que-les-battements-binauraux/>.
- [21] K. Fujiwara, E. Abe, K. Kamata, C. Nakayama, Y. Suzuki, T. Yamakawa, T. Hiraoka, M. Kano, Y. Sumi, F. Masuda, M. Matsuo, and H. Kadotani. Heart rate variability-based driver drowsiness detection and its validation with eeg. *IEEE transactions on biomedical engineering*, pages 1–10, 2018.
- [22] G.Li, B.L.Lee, and W.Y.Chung. Smartwatch-based wearable eeg system for driver drowsiness detection. *IEEE*, 2473679 :1–12, 2015.
- [23] A. Goldberger, L. Amaral, L. Glass, J. Hausdorff, P. C. Ivanov, R. Mark, J. Mietus, G. Moody, C. Peng, H. Stanley, Physiobank, physiotoolkit, and physionet. Components of a new research resource for complex physiologic signals. *circulation [online]*, 101(23) :215–220, 2000.
- [24] M. Gromera, D. Salba, T. Walzera, N. M. Madrida, and R. Seepold. Ecg sensor for detection of driver’s drowsiness. *23rd International Conference on Knowledge-Based and Intelligent Information Engineering Systems*, 159 :1938–1946, 2019.
- [25] F. Guede-Fernandez, M. Fernandez-Chimeno, J. Ramos-Castro, and M. A. Garcia-Gonzalez. Driver drowsiness detection based on respiratory signal analysis. *IEEE access*, 7 :81826–81838, 2019.
- [26] B. Hariri, S. Abtahi, S. Shirmohammadi, and L. Martel. *Une méthode de mesure bâillante pour détecter Somnolence du conducteur*. PhD thesis, Université d’Ottawa, Ottawa, Canada.
- [27] Centre intégré en neuroimagerie et neurostimulation de Québec. Eeg. <http://www.cinq.ulaval.ca/EEG>, (Consulté le 03 Mars 2020).
- [28] R. Jabbara, K. Al-Khalifaa, M. Kharbechea, W. Alhajyaseena, M. Jafarib, and S. Jiang. Real-time driver drowsiness detection for android application using deep neural networks techniques. *Science Direct*, 7 :1–8, 2018.
- [29] D. Jayanthi and M. Bommy. Conducteur en temps réel basé sur la vision système de détection de la fatigue pour un contrôle efficace des véhicules. *International Journal of Engineering and Advanced Technology (IJEAT)*, 2 :2249 – 8958, October 2012.

- [30] T.P. Jung, S. Makeig, and C. Humphries. Extended ica removes artefacts from electroencephalographic recording, advances in neural inf. *Processing Systems, Cambridge*, 10, 1998.
- [31] V. Kartsch, S. Benatti, P. Schiavone, D. Rossi, and L. Benini. Une approche de fusion de capteurs pour la détection de la somnolence dans les systèmes de faible puissance. *Inf. Fusion*, 44 :66–76, 2018.
- [32] B. Kemp, A. H. Zwinderman, B. Tuk, H. A. Kamphuisen, and J. J. Obery. Analysis of a sleep-dependent neuronal feedback loop : the slow-wave microcontinuity of the eeg. *IEEE Transactions on Biomedical Engineering*, 47(9) :1185–1194, 2000.
- [33] R. Khemchandani and S. Chandra. Twin support vector machines for pattern classification. *IEEE Trans Pattern Anal Mach Intell*, 29(5) :905–910, 2007.
- [34] M. Kołodziej, A. Majkowski, J. Rak, and Remigiusz. Linear discriminant analysis as eeg features reduction technique for brain-computer interfaces. *Przegląd Elektrotechniczny*, 3, 2012.
- [35] M. R. Lakshmi, T. V. Prasad, and V. C. Prakash. Survey on eeg signal processing methods. *International Journal of Advanced Research in Computer Science and Software Engineering*, 2014.
- [36] A. Lenskiy and J. Lee. Driver’s eye blinking detection using novel color and texture segmentation algorithms. *International Journal of Control, Automation, and Systems*, pages 1598–6446, 2012.
- [37] M. Li, C. Zhang, and J. Yang. An eeg-based method for detecting drowsy driving state. In *Systèmes flous et découverte de connaissances (FSKD), Septième Conférence internationale sur le , 5, pp. 2164-2167*, 2010.
- [38] Fabien Lotte. *Brain-Co-mputer Interfaces in Virtual Reality Applications*. PhD thesis, Rennes, 2009.
- [39] Trans Cranial Technologies LTD. 10/20 system positioning manual electrode placement procedure, 2012.
- [40] A. M. Malla, P. R. Davidson, P. J. Bones, R. Green, and R. D. Jones. Automated video-based measurement of eye closure for detecting behavioral microsleep. In *conférence internationale annuelle Conférence de l’IEEE EMBS Buenos Aires, Argentine*, 31 août – 4 septembre 2010.
- [41] D. Moser, P. Anderer, G. Gruber, S. Parapatics, E. Loretz, M. Boeck, G. Kloesch, E. Heller, A. Schmidt, H. Danker-Hopfe, and al. Sleep classification according to aasm and rechtschaffen kales : effects on sleep scoring parameters. *Sleep*, 32(2) :139–149, 2009.
- [42] C. J. Nauroisa, C. Bourdina, A. Stratulatb, E. Diazb, and J. Verchera. Detection and prediction of driver drowsiness using artificial neural network models. *Elsevier ? Science Direct*, 126 :95–104, 2019.
- [43] A. Picot. Détection d’hypovigilance chez le conducteur par fusion d’informations physiologiques et vidéo. traitement du signal et de l’image [eess.sp]. 2009.
- [44] B. Pidoux. Le sommeil et sa pathologie, aout 2007.
- [45] Reverso. [Reverso.com](https://www.reverso.com/), (Consulté le 01 juin 2020).
- [46] A. Sengupta, A. Dasgupta, A. Chaudhuri, A. George, A. Routray, and R. Guha. A multimodal system for assessing alertness levels due to cognitive loading. *IEEE Trans. on Neural Systems and Rehabilitation Engg*, 25(7) :1037–1046, 2017.
- [47] H. Slimani and H. Kheddouci. Eddd : Event-based drowsiness driving detection through facial motion analysis with neuromorphic vision sensor. *IEEE SENSORS JOURNAL*, 185 :192–207, 2020.

- [48] H. Tayakout. Détection itérative par turbo codage combinant différentes techniques à base de systèmes mimo. *Thèse de doctorat en Electronique*, 2019.
- [49] M. G. Terzano, L. Parrino, A. Smerieri, R. Chervin, S. Chokroverty, C. Guilleminault, M. Hirshkowitz, M. Mahowald, H. Moldofsky, A. Rosa, and et al. Atlas, rules, and recording techniques for the scoring of cyclic alternating pattern (cap) in human sleep. *Sleep medicine*, 3(2) :187–199, 2002.
- [50] C. C. Tseng and S. L. Lee. Closed-form designs of digital fractional order butterworth filters using discrete transforms. In *Signal Processing 137*, pages 80–97, 2017.
- [51] M. Vats and A. Garg. Detection and security system for drowsy driver by using artificial neural network technique. *International Journal of Applied Science and Advance Technology*, 2012.
- [52] J. Vion-Dury and F. Blanquet. *Pratique de l'EEG*. Elsevier Masson, 2008.
- [53] Y. Ichimaru and GB. Moody. Développement de la de données polysomnographique su cd-rom. *Psychiatry and Clinical Neurosciences*, 53 :175–177, 1999.
- [54] Z. Mardi, S. Ashtiani, and M. Mikaili. Eeg-based drowsiness detection for safe driving using chaotic features and statistical tests. *Journal of medical signals and sensors*, 1 :130–137, 2011.

## RÉSUMÉ

Au cours de la dernière décennie, la somnolence au volant est une cause fréquente d'accidents de la route. La somnolence est un état intermédiaire entre le sommeil et l'éveil, représentant un état dégradé et donc potentiellement affectant les performances de conduite. Détecter si un conducteur est somnolent ou même prédire à quelle vitesse il est susceptible de devenir somnolent sont des défis importants pour le développement de nouveaux systèmes d'assistance à la conduite. Dans ce document, nous nous sommes intéressés à la proposition d'un nouveau protocole de détection de somnolence basé sur des signaux EEG utilisant la machine à vecteurs de support (SVM). Le protocole proposé repose sur l'utilisation de la puissance relative des bandes de fréquences alpha et bêta en tant que caractéristiques biométriques extraites d'un seul canal C3-O1 du signal EEG avec une haute précision et un bon processus de prétraitement des données. Ensuite, nous avons réalisé un programme de simulation sous Matlab simulink pour valider notre protocole, avec des signaux EEG réels. Les résultats obtenus montrent que le protocole proposé assure une exactitude de 99.87%, un vrai positif de 100% et un vrai négatif de 99,75%. Cette adaptation est une première réponse au problème de la variabilité interindividuelle. Une comparaison avec d'autres protocoles concurrents dans la littérature ont mis en évidence les avantages du protocole proposé en termes de temps de détection de somnolence, et d'exactitude.

**Mots clés :** Accidents de la route ; somnolence ; signal EEG ; classificateur SVM.

## ABSTRACT

In the past decade drowsiness while driving is a common cause of traffic accidents. Drowsiness is an intermediate state between drowsiness and wakefulness, representing a degraded state and therefore potentially affects driving performance. Detecting if a driver is drowsy or even predicting how soon he is likely to become drowsy are significant challenges for the development of new driver assistance systems. In this document, we are interested in the proposal of a new drowsiness detection protocol based on EEG signals by using the support vector machine (SVM). The proposed protocol relies on the use of the relative power of the alpha and beta frequency bands as biometric features extracted from a single C3-O1 channel of EEG signal with high precision and good data pre-processing process. Then, we carried out a simulation program under Matlab simulink to validate the proposed protocol, with real EEG signals. The results obtained show that the proposed protocol ensures an accuracy of 99.87%, a true positive of 100 % and a true negative of 99.75 %. This adaptation is a first response to the problem of interindividual variability. A comparison with other concurrent protocols in the literature highlighted the advantages of the proposed protocol in terms of drowsiness detection time, and accuracy.

**Key words :** Traffic accidents ; drowsiness ; EEG signal ; SVM classifier.