

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE
MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITÉ ABDERRAHMANE MIRA DE BÉJAÏA



FACULTÉ DES SCIENCES EXACTES
DÉPARTEMENT D'INFORMATIQUE
MÉMOIRE DE FIN DE CYCLE
EN VUE D'OBTENTION DU DIPLÔME DE MASTER RECHERCHE EN
INFORMATIQUE
OPTION : INTELLIGENCE ARTIFICIELLE

Thème

**Reconnaissance du comportement de
conduite d'un conducteur automobile pour la
sûreté du trafic routier**

Présenté par :

M. BOUAROURI DJALLAL M. BEN AISSA Mohamed Dhia Eddine

Soutenu devant le jury composé de :

Président	M. AISSANI Sofiane	M.C.A	U. A. MIRA BÉJAÏA
Encadrante	Mme ZAMOUCHE Djamila	M.A.B	U. A. MIRA BÉJAÏA
Co-encadrante	Mme OUAZINE Kahina	M.C.B	ESTIN BÉJAÏA
Examineur	M. BOUCHEBBAH Fatah	M.C.B	U. A. MIRA BÉJAÏA
Examinatrice	Mme BOUAFIA Khadoudja	Doctorante	U. A. MIRA BÉJAÏA

Promotion 2022 – 2023

Remerciements

Notre remerciement s'adresse en premier lieu à Allah le tout puissant pour la volonté, la santé et la patience qu'il nous a donnée durant toutes ces longues années

Ce travail n'aurait pas pu être réalisé sans l'aide considérable, le soutien, la compétence et la relecture critique de notre encadrante, **Mme Djamila Zamouche**, ainsi que de **Mme Kahina Ouazine**. Leur précieuse contribution, tant sur le fond que sur la forme de ce mémoire, nous a guidés sur le chemin du savoir.

Nous souhaitons également exprimer notre gratitude envers **Mme Djamila Boulahrouz**, chef du département d'informatique, pour ses remarques et son suivi tout au long de nos études et de notre projet.

Nous tenons également à remercier chaleureusement tous les enseignants qui ont contribué à notre formation.

Nous adressons un grand merci à tous nos proches, amis et collègues pour leur soutien moral et leurs encouragements.

En conclusion, nous souhaitons exprimer notre immense gratitude envers toutes les personnes qui ont participé, de près ou de loin, à l'achèvement de ce mémoire.

Dedicace

A ma chère, douce et tendre mère

Je voudrais dédier ces mots à ma mère chérie, douce et tendre, celle qui a illuminé les moments les plus sombres de ma vie, celle qui a tout sacrifié pour que je réussisse, celle qui a su faire briller un sourire sur mon visage en toute circonstance. Aucune dédicace ne serait suffisante pour exprimer le respect, l'amour inconditionnel et éternel, ainsi que la considération que j'ai pour les sacrifices qu'elle a consentis pour mon éducation et mon bien-être.

A mon cher père, le plus doux de tous

Je tiens à te remercier pour tout le soutien et l'amour que tu m'as accordés depuis mon enfance. J'espère que ta bénédiction me suivra tout au long de ma vie.

A ma chère sœur et mon cher frère

Je vous remercie pour le soutien que vous m'avez apporté toutes ces longues années, vous étiez mon refuge, et l'épaule sur laquelle je me reposais

A mon cher BOULAID

Je voudrais dédier ces mots à Boulaïd, mon cher et unique meilleur ami, la plus belle âme que j'ai jamais rencontrée de toute ma vie. Personne ne pourra jamais prendre ta place dans mon cœur. Ce mémoire est dédié à notre amitié éternelle

A mes chères amis

« AICHA,DYHIA , Dr FAYCAL ,ZAKARIA ,BILAL ,YASSINE , MAMOUNE ,ZAKI ,ISLAM ,TARIK , AZZEDDINE ,DJYMY, LHADI, DJALALE, HAFID , MASSI , MOURAD L'ARTISTE »

À mon cher ami défunt AIMADE

Ta perte mon ami Aimad a créé un vide immense dans ma vie. Tu étais un étudiant brillant et un ami dévoué qui m'a toujours aidé dans mes études. Bien que tu me manque terriblement, je suis reconnaissant d'avoir eu la chance de te connaître et de t'avoir comme ami. Je garde en mémoire les moments passés ensemble et tu resteras à jamais dans mon cœur

Dedicace

À MES CHERS PARENTS

aucune dédicace ne saurait exprimer mon respect, mon amour éternel et ma considération pour les sacrifices que vous avez consenti pour mon instruction et mon bien être. Je vous remercie pour tout le soutien et l'amour que vous me portez depuis mon enfance et j'espère que votre bénédiction m'accompagne toujours. Que ce modeste travail soit l'exaucement de vos vœux tant formulés, le fruit de vos innombrables sacrifices, bien que je ne vous en acquitterai jamais assez.

Et Je remercie mes sœurs et mes frères pour leurs encouragements. Enfin,

je remercie mes amis HAFID, MASSINISA, RAMZI, MAMOUN ,LAMIN ,BOULAID,AZEDDINE , qui ont toujours été là pour moi. Leur soutien inconditionnel et leurs encouragements ont été d'une grande aide

À mon cher ami défunt AIMADE

Ta perte mon ami Aimad a créé un vide immense dans ma vie. Tu étais un étudiant brillant et un ami dévoué qui m'a toujours aidé dans mes études. Bien que tu me manque terriblement, je suis reconnaissant d'avoir eu la chance de te connaître et de t'avoir comme ami. Je garde en mémoire les moments passés ensemble et tu resteras à jamais dans mon cœur

Table des Matières

Table des Matières

Table des Figures

Liste des Tableaux

Introduction générale	2
1 Notions fondamentales	4
1.1 Introduction	5
1.2 Système de Transport Intelligent	5
1.2.1 Définition des STI	5
1.2.2 Evolution des STI	6
1.2.2.1 Les premiers développements des STI (années 1960-1990) .	6
1.2.2.2 L'extension des STI à d'autres modes de transport (années 1990-2000)	6
1.2.2.3 Les développements récents des STI (années 2000-2020) .	7
1.2.2.4 L'avenir des STI (années 2020 et au-delà)	7
1.2.3 Politique des STI dans l'Union Européenne	7
1.2.4 Politique des STI en Algérie	7

1.2.5	Objectifs des STI	8
1.2.6	Technologies des STI	8
1.2.6.1	Technologies de calcul avancées	9
1.2.6.2	Technologies de localisation	9
1.2.6.3	Technologies de capteurs	9
1.2.7	Avantages et limitations des STI	9
1.2.7.1	Avantages d'utilisation des STI	9
1.2.7.2	Déficits rencontrés par les STI	10
1.3	Sûreté	10
1.4	Réseaux de neurones artificiels	11
1.4.1	Fonction d'activation	11
1.4.2	Apprentissage profond	12
1.4.2.1	Apprentissage supervisé	13
1.4.2.2	Apprentissage non-supervisé	13
1.4.3	Réseaux de neurones convolutifs	13
1.4.4	Réseaux de neurones récurrents	14
1.4.5	Long Short Term Memory	14
1.5	Modèle de mélange	15
1.6	Modèle de mélanges Gaussien	15
1.7	Algorithme d'Expectation-Maximisation	16
1.8	Conclusion	17

2 Approches de reconnaissance du comportement du conducteur : État de l'art **18**

2.1	Introduction	19
2.2	Critères de comparaison	19
2.2.1	Précision	19
2.2.2	Temps de réponse	19
2.2.3	Complexité	20
2.2.4	Nécessite du matériel supplémentaire	20
2.2.5	Capacité à détecter les comportements dangereux	20
2.2.6	Capacité à détecter les comportements de conduite inattentive	20
2.3	Classification	20
2.3.1	Approches basées sur les signaux EEG	21
2.3.2	Approches basées sur les réseaux de neurones	21
2.3.3	Approches basées sur les capteurs de smartphone	21
2.3.4	Approches basées sur les radars portables	21
2.4	Étude critique des travaux	21
2.4.1	Driving behavior recognition using EEG data from a simulated car-following experiment	22
2.4.2	Toward Extremely Lightweight Distracted Driver Recognition With Distillation-Based Neural Architecture Search and Knowledge Transfer	23
2.4.3	Distracted Driver Detection Based on a CNN With Decreasing Filter size	23
2.4.4	A similarity-based neuro-fuzzy modeling for driving behavior recognition applying fusion of smartphone sensors	23
2.4.5	Inattentive Driving Behavior Detection Based on Portable FMCW Radar	24
2.4.6	A Hybrid Deep Learning Model for Recognizing Actions of Distracted Drivers	24

2.4.7	Abnormal Driving Detection With Normalized Driving Behavior Data : A Deep Learning Approach	25
2.4.8	A Lightweight Attention-Based Network towards Distracted Driving Behavior Recognition	25
2.5	Comparaison des approches étudiées	26
2.6	Synthèse	26
2.7	Conclusion	27
3	LSTM-RNN and GMM based approach for vehicle driver behavior recognition	28
3.1	Introduction	29
3.2	Motivation	29
3.3	Solution proposée	30
3.3.1	Phase de reconnaissance	30
3.3.1.1	Phase de détection basée sur LSTM-RNN	30
3.3.1.2	Phase de reconnaissance basée sur GMM	31
3.4	Evaluation de performances	32
3.4.1	Environnement de développement	33
3.4.2	Langage de programmation et bibliothèques	34
3.4.3	Dataset	35
3.4.4	Prétraitement des données	35
3.4.5	Entraînement de LSTM-RNN	36
3.4.6	Métriques de simulation	37
3.5	Résultats obtenus	38
3.5.1	Matrice de confusion	38

3.5.2	Rapport de classification	39
3.5.2.1	Interprétation et Evaluation des résultats obtenus	39
3.6	Conclusion	41
	Conclusion Générale et Perspectives	42

Table des figures

1.1	Exemple de Systèmes de Transport Intelligents.	6
1.2	Avantages d'intégration des STI dans nos vies quotidiennes [12].	10
1.3	Réseaux de neurones artificiels.	11
1.4	Différentes formes de la Fonction d'activation [1].	12
1.5	réseau-recurrent-avec-deux-couches-cachées.	14
1.6	Cellule LSTM.	15
1.7	Une variable aléatoire décomposée en deux variables distincts (deux composent) [10].	16
2.1	Classification des approches de reconnaissance du comportement du conducteur automobile.	22
3.1	Structure de la solution proposée.	30
3.2	Étapes des expérimentations effectuées.	33
3.3	Attributs du Dataset.	35
3.4	Structure du modèle LSTM-RNN.	37
3.5	La matrice de confusion de la solution proposée.	39
3.6	Rapport de classification de notre solution.	39

Liste des tableaux

2.1	Comparaison des approches étudiées.	26
-----	---	----

Introduction générale

Depuis des temps immémoriaux, la nécessité de transporter des personnes et des biens est essentielle pour garantir le bon fonctionnement de la société. Les raisons qui sous-tendent cette nécessité ont changé avec le temps, allant de l'économie à la santé, en passant par l'emploi, l'éducation, la défense et le tourisme. Toutefois, aujourd'hui, grâce aux nouvelles technologies, à la modernisation des infrastructures et à la prévention, les moyens de transport sont devenus de plus en plus sûrs. Parmi les modalités les plus utilisées, notamment en Europe et en Amérique du Nord, la voiture occupe une place prépondérante [25].

Les Systèmes de Transport Intelligents (STI) ont connu une forte évolution pour améliorer la sécurité, l'efficacité et la durabilité des systèmes de transport. Dans ce contexte, la reconnaissance du comportement des conducteurs automobiles est une application clé des STI pour prévenir les accidents routiers. Cependant, malgré les avancées significatives dans ce domaine, il reste des défis à relever pour améliorer l'efficacité des méthodes de reconnaissance du comportement des conducteurs automobiles. Dans ce contexte, plusieurs travaux ont été proposés pour répondre à cette problématique. Cependant, la plupart des solutions existantes ne sont pas adaptées, où elles les rendent encore plus complexes et moins efficaces, ce qui nécessite des révisions ou le développement de nouvelles solutions.

Dans ce travail, notre objectif est de construire un modèle pour reconnaître le comportement des conducteurs automobiles. La solution proposée est conçue pour déterminer si un conducteur adopte un comportement sûr. La résolution de ce problème apportera des avantages considérables. Elle permettra non seulement d'améliorer la circulation routière, mais aussi d'assurer une gestion plus efficace de l'infrastructure. Pour y aboutir, nous nous appuyons sur l'utilisation de réseaux neuronaux récurrents LSTM-RNN et d'un modèle de mélange gaussien (GMM). Afin de démontrer l'efficacité de l'approche proposée, nous évaluons ses performances en utilisant des données de conduite réelles.

Notre travail est structuré en Trois chapitres.

Le chapitre I donne une vue d'ensemble des STIs, ainsi que de leur impact sur les systèmes de transport modernes. En plus de présenter les objectifs des STIs et leurs nombreuses applications, nous avons également inclus des définitions générales sur les composantes de notre modèle. En somme, ce chapitre offre une lecture approfondie sur

les STIs, qui est cruciale pour la compréhension de ce manuscrit.

Le chapitre II approfondit notre compréhension de la reconnaissance du comportement des conducteurs automobiles en examinant les différentes méthodes proposées dans la littérature pour répondre à ce défi.

Enfin, Le chapitre III présente notre approche pour la construction d'un modèle de reconnaissance du comportement des conducteurs automobiles en utilisant des LSTM-RNN et des GMM. Nous détaillons les différentes étapes de la construction du modèle. Nous passerons ensuite à l'évaluer la performance de notre modèle en mesurant la précision, le rappel et la F1-mesure. Nous discutons également des limites de notre modèle et des pistes pour son amélioration future.

1

NOTIONS FONDAMENTALES

1.1 Introduction

Les Systèmes de Transport Intelligent (STI) sont un domaine en pleine évolution qui combine les technologies de l'information et de la communication pour améliorer la sécurité, l'efficacité et la durabilité des systèmes de transport. Dans ce premier chapitre, nous allons présenter les Systèmes de Transport Intelligent, pour mettre en avant le background sur lequel nous travaillons. Nous examinerons également les technologies qui soutiennent les STI, notamment les réseaux de neurones artificiels, l'apprentissage profond (Deep learning), les réseaux de neurones convolutifs, les réseaux de neurones récurrents, les LSTM (Long Short Term Memory), le modèle de mélanges gaussiens et l'algorithme d'Expectation-Maximisation.

1.2 Système de Transport Intelligent

1.2.1 Définition des STI

Le Système de Transport Intelligent (STI) est un système complet de gestion des services de transport qui intègre des fonctions liées à l'intelligence, telles que le traitement de l'information. Ce système permet ainsi de traiter, d'analyser et de communiquer des informations relatives aux services de transport en utilisant une large gamme de technologies, notamment la télématique, l'électronique embarquée ou fixe (tels que les capteurs et les moyens de calcul), les télécommunications, les bases de données et d'information, les systèmes de régulation et les paiements électroniques [6].

Les applications du STI sont destinées à tous les modes de transport, y compris routier, ferroviaire, aérien et maritime. Elles ont pour but de garantir la sûreté et la régulation des flux de circulation, ainsi que de fournir des informations aux usagers des transports en commun ou des usagers du transport de marchandises [6]. Ces derniers sont particulièrement importants car ils représentent une part significative de transport dans de nombreux pays. Les technologies du STI peuvent ainsi être utilisées pour améliorer l'efficacité et la sécurité du transport routier, ainsi que pour fournir des informations en temps réel aux usagers [6].



FIGURE 1.1 – Exemple de Systèmes de Transport Intelligents.

1.2.2 Evolution des STI

Les STI ont connu une évolution rapide au cours des dernières décennies. Les progrès technologiques ont permis la mise en place de systèmes de plus en plus sophistiqués et intégrés, capables de collecter, traiter et transmettre des données en temps réel.

1.2.2.1 Les premiers développements des STI (années 1960-1990)

- Les systèmes de contrôle de la circulation routière.
- Les systèmes de navigation assistée par ordinateur.

1.2.2.2 L'extension des STI à d'autres modes de transport (années 1990-2000)

- Les systèmes de gestion de flotte et de suivi des véhicules pour le transport de marchandises.
- Les systèmes de billetterie électronique pour les transports en commun.

1.2.2.3 Les développements récents des STI (années 2000-2020)

- La communication véhicule-à-infrastructure (V2I) et la communication véhicule-à-véhicule (V2V).
- Les applications mobiles pour les usagers de transport.

1.2.2.4 L’avenir des STI (années 2020 et au-delà)

- La voiture autonome.
- L’Internet des Objets (IoT) dans les systèmes de transport.
- Les systèmes de transport durables et intelligents.

1.2.3 Politique des STI dans l’Union Européenne

En décembre 2008, la Commission Européenne a adopté une politique de STI pour mieux utiliser les technologies de l’Information et de la Communication (TIC) dans les services de transport en Europe. Cette politique vise à améliorer la traçabilité des trajets via les satellites, les ordinateurs, les téléphones et tout type d’appareil de géolocalisation, ainsi que les puces RFID. Cependant, ce déploiement des STI pose des questions importantes en matière de protection de la vie privée et de protection des données personnelles. Le Contrôleur Européen de la Protection des Données (CEPD) a souligné que ces systèmes permettent de suivre les véhicules et de collecter un large éventail de données relatives aux habitudes de conduite des usagers européens de la route [20].

1.2.4 Politique des STI en Algérie

En Algérie, la crise du trafic routier dans certaines villes, notamment Alger, Oran, Constantine et Annaba a conduit les pouvoirs publics à installer des systèmes de contrôle de la circulation dans 25 carrefours de la wilaya d’Alger. Ce projet, réalisé en partenariat algéro-espagnol avec un budget de 19 milliards DA, est prévu en trois phases sur une période de 55 mois. Il permettra de connaître le trafic routier en temps réel, d’améliorer les conditions de déplacement et de réduire les congestions de trafic. Il s’agit d’une initiative importante pour améliorer la gestion du trafic routier en Algérie et réduire les temps de déplacement pour les usagers de la route. Cependant, il est également important de prendre en compte les questions de protection de la vie privée et de protection des données personnelles dans la mise en place de ces systèmes de contrôle de la circulation [5].

1.2.5 Objectifs des STI

Les STI ont pour but de résoudre des problèmes sociaux liés à l'utilisation des transports. Ils opèrent dans un contexte d'amélioration des systèmes pour les usagers, les conducteurs et les gestionnaires. Les STI sont principalement utilisés pour gérer la congestion du trafic routier et développer de nouvelles technologies d'information embarquées dans les véhicules [6]. Les STI connaissent de nombreuses applications dont :

- Systèmes de contrôle de la circulation : ces systèmes utilisent des capteurs et des caméras pour surveiller la circulation routière et ajuster les feux de signalisation en temps réel afin de réduire la congestion et d'améliorer la fluidité du trafic.
- Applications mobiles de transport : ces applications permettent aux usagers de planifier leurs trajets, d'acheter des billets de transport en commun, de localiser les stations de recharge pour les véhicules électriques, et de recevoir des alertes en temps réel sur les perturbations de la circulation.
- Systèmes de navigation assistée par ordinateur : ces systèmes utilisent des données de géolocalisation pour aider les conducteurs à trouver leur chemin et à éviter les embouteillages.
- Systèmes de péage électronique : ces systèmes permettent aux usagers de payer les péages sur autoroute sans avoir à s'arrêter aux barrières de péage.
- Systèmes de transport intelligent pour les marchandises : ces systèmes utilisent des capteurs et des technologies de suivi pour suivre les marchandises à travers la chaîne d'approvisionnement, améliorer la planification logistique, et réduire les coûts et les délais de livraison.
- Systèmes de communication véhicule-à-infrastructure (V2I) et de communication véhicule-à-véhicule (V2V) : ces systèmes permettent aux véhicules de communiquer entre eux et avec les infrastructures routières pour améliorer la sécurité, la fluidité du trafic et la gestion des situations d'urgence.
- Systèmes de voiture autonome : ces systèmes utilisent des capteurs, des caméras et des algorithmes pour permettre aux véhicules de se déplacer sans conducteur, offrant ainsi une solution de transport plus sûre et plus efficace.

1.2.6 Technologies des STI

Les STI utilisent une variété de technologies pour répondre à des problèmes de transport spécifiques. Les technologies utilisées peuvent aller des systèmes de gestion de base comme les feux de signalisation et les panneaux à messages variables, jusqu'à des applications plus avancées qui intègrent des données en temps réel provenant de nombreuses sources, telles que les informations météorologiques et les systèmes de navigation embarqués [5].

1.2.6.1 Technologies de calcul avancées

Les STI sont également équipés de technologies de calcul avancées, telles que des processeurs informatiques plus performants et des plates-formes informatiques embarquées capables d'exécuter des applications logicielles sophistiquées comme la modélisation, l'intelligence artificielle et l'Informatique omniprésente. L'intelligence artificielle est particulièrement importante pour les STI, car elle permet de traiter des données massives et complexes en temps réel [5].

1.2.6.2 Technologies de localisation

Les STI utilisent également des technologies de localisation, telles que la géolocalisation par système de positionnement par satellite comme le GPS et Galileo, ainsi que la téléphonie mobile.

1.2.6.3 Technologies de capteurs

Les STI sont équipés de technologies de capteurs, telles que les capteurs vidéo, les boucles électromagnétiques et les réseaux de capteurs sans fil, qui permettent de collecter des données sur les caractéristiques des véhicules et la circulation routière [5].

1.2.7 Avantages et limitations des STI

1.2.7.1 Avantages d'utilisation des STI

L'utilisation de l'ITS présente de nombreux avantages, dont voici quelques-uns :

- Amélioration de la sécurité routière : les STI peuvent aider à réduire les accidents de la route en fournissant des informations en temps réel sur les conditions de circulation et en alertant les conducteurs en cas de danger imminent.
- Réduction de la congestion routière : les STI peuvent aider à optimiser le trafic en fournissant des informations en temps réel sur les conditions de circulation, en régulant les feux de signalisation et en proposant des itinéraires alternatifs.
- Augmentation de l'efficacité énergétique : les STI peuvent aider à réduire la consommation de carburant en optimisant les itinéraires et en régulant la circulation.
- Amélioration de la qualité de vie : les STI peuvent réduire le temps de déplacement et le stress associé à la conduite dans des conditions de circulation difficiles

1.2.7.2 Défis rencontrés par les STI

En ce qui concerne les défis rencontrés par les STI sont les suivants :

- Coût élevé : les technologies nécessaires pour implémenter les STI peuvent être coûteuses, en particulier pour les infrastructures routières existantes.
- Besoin de collaboration entre les acteurs : les STI nécessitent une collaboration entre les gouvernements, les entreprises privées et les usagers pour être efficaces.
- Risque de dépendance technologique : les STI peuvent rendre les usagers dépendants de la technologie, ce qui peut entraîner des problèmes si les systèmes ne fonctionnent pas correctement.
- Protection de la vie privée : les STI peuvent collecter des données personnelles sur les usagers, ce qui soulève des préoccupations en matière de protection de la vie privée.

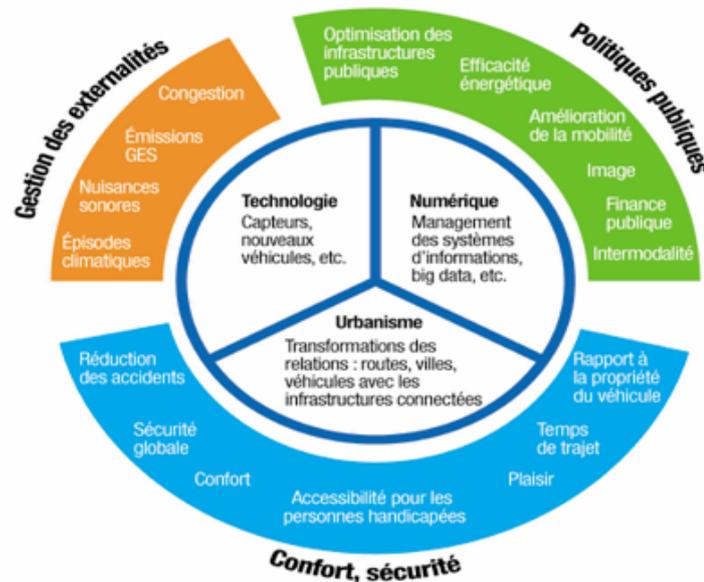


FIGURE 1.2 – Avantages d'intégration des STI dans nos vies quotidiennes [12].

1.3 Sûreté

La sûreté des STI est essentielle pour garantir la sécurité des personnes et des biens, ainsi que la protection de la vie privée et des données personnelles dans le contexte de l'utilisation de technologies intelligentes pour le transport. Les STI comprennent divers systèmes tels que la navigation, la communication entre véhicules et avec les infrastructures, la gestion de flotte, l'assistance à la conduite et les véhicules autonomes. La sûreté des STI nécessite la prise en compte de nombreux facteurs tels que la fiabilité des capteurs et des systèmes de communication, la sécurité des données, la conformité aux normes de sécurité et la formation des utilisateurs. Pour garantir la sûreté des STI, il est important de mettre en place des processus de développement rigoureux, de tester les systèmes dans

des conditions réelles et de sensibiliser les utilisateurs aux risques liés à l'utilisation des STI [13].

1.4 Réseaux de neurones artificiels

Les réseaux de neurones artificiels (RNA) sont des réseaux fortement connectés de processeurs élémentaires fonctionnant en parallèle. Chaque processeur élémentaire est un neurone artificiel qui reçoit plusieurs variables d'entrée provenant d'autres neurones en amont. Chacune de ces entrées est associée à un poids W qui représente la force de la connexion. Chaque processeur élémentaire calcule une sortie unique en fonction des informations qu'il reçoit, qui se ramifie ensuite pour alimenter un nombre variable de neurones en aval. Chaque connexion est associée à un poids, comme illustré dans la figure 1.3 [2].

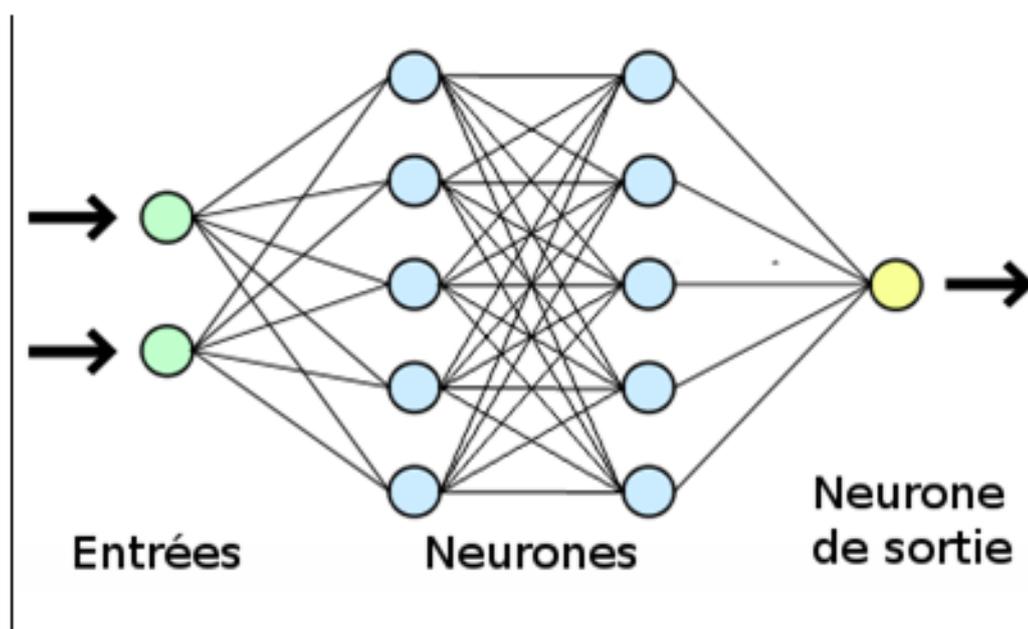


FIGURE 1.3 – Réseaux de neurones artificiels.

1.4.1 Fonction d'activation

La fonction d'activation, également appelée fonction de transfert, est utilisée pour convertir le résultat de la somme pondérée des entrées d'un neurone en une valeur de sortie. Le biais b joue un rôle de seuil : lorsque le résultat de la somme pondérée dépasse ce seuil, l'argument de la fonction de transfert devient positif ou nul. Dans le cas contraire, il est considéré comme négatif. En fin de compte, si le résultat de la somme pondérée est : [1]

- en dessous du seuil, le neurone est considéré comme non-actif.
- aux alentours du seuil, le neurone est considéré en phase de transition.
- au-dessus du seuil, le neurone est considéré comme actif.

Il existe plusieurs types de fonctions de transfert qui peuvent être utilisées dans les RNA. Les fonctions d'activation les plus couramment utilisées sont présentées sur la figure 1.4 ;

Nom de la fonction	Relation entrée/sortie	Icône
Seuil	$y = 0$ si $s < 0$ $y = 1$ si $s \geq 0$	
Seuil symétrique	$y = -1$ si $s < 0$ $y = 1$ si $s \geq 0$	
Linéaire	$y = s$	
Linéaire saturée	$y = 0$ si $s \leq 0$ $y = s$ si $0 \leq s \leq 1$ $y = 1$ si $s \geq 1$	
Linéaire saturée symétrique	$y = -1$ si $s < -1$ $y = s$ si $-1 \leq s \leq 1$ $y = 1$ si $s > 1$	
Linéaire positive	$y = 0$ si $s \leq 0$ $y = s$ si $s \geq 0$	
Sigmoïde	$y = \frac{1}{1 + \exp^{-s}}$	
Tangente hyperbolique	$y = \frac{e^s - e^{-s}}{e^s + e^{-s}}$	
Compétitive	$y = 1$ si s maximum $y = 0$ autrement	

FIGURE 1.4 – Différentes formes de la Fonction d'activation [1].

1.4.2 Apprentissage profond

L'apprentissage profond (Deep learning) est une branche de l'apprentissage automatique qui repose sur des réseaux de neurones artificiels [26]. Contrairement à l'apprentissage automatique traditionnel, où la machine agit en fonction des informations fournies

par l'humain, l'apprentissage profond utilise des réseaux de neurones artificiels profonds pour apprendre par lui-même. Les réseaux de neurones profonds sont basés sur des approches mathématiques qui interconnectent des neurones pour traiter, mémoriser des informations, comparer des problèmes et analyser les solutions. L'apprentissage profond est utilisé dans des domaines tels que la vision par ordinateur, la reconnaissance vocale et l'auto-conduite [17]. Il est connu pour ses représentations hiérarchiques et sa robustesse.

Les deux principaux types de réseaux de neurones profonds sont les réseaux de neurones convolutifs et les réseaux de neurones récurrents. Il existe plusieurs types d'apprentissage, notamment l'apprentissage supervisé et l'apprentissage non-supervisé.

1.4.2.1 Apprentissage supervisé

Est une technique qui permet de créer des modèles en utilisant des exemples d'apprentissage ou d'entraînement, pour lesquels les comportements ou réponses sont connus. Ces modèles peuvent être utilisés dans diverses applications, telles que la prédiction ou la classification [1].

1.4.2.2 Apprentissage non-supervisé

Vise à créer un modèle qui structure les informations, mais sans avoir connaissance des comportements, des catégories ou des classes des données d'apprentissage. Il s'agit donc de trouver ces informations par soi-même [1].

1.4.3 Réseaux de neurones convolutifs

Les réseaux de neurones convolutifs CNN (pour Convolutional Neural Network) sont des systèmes de réseaux de neurones spécifiquement conçus pour résoudre des problèmes de vision par ordinateur tels que, la reconnaissance d'image, de l'écriture manuscrite et de visage. Leur structure repose sur l'échantillonnage d'une fenêtre ou d'une partie d'une image, la détection de ses caractéristiques, puis l'utilisation de ces caractéristiques pour créer une représentation. Les CNN sont connus pour être très complexes en termes de taille de paramètres et de nombre de calculs, ce qui nécessite de grandes exigences de calcul et de stockage pour leur mise en œuvre. Ils ont été les premiers modèles d'apprentissage profond.

1.4.4 Réseaux de neurones récurrents

Les réseaux de neurones récurrents RNN (pour Recurrent Neural Network) sont utilisés pour traiter les données séquentielles telles que le texte, l'audio et la vidéo. Ils sont composés de neurones interconnectés qui interagissent de manière non linéaire avec au moins un cycle dans la structure [21]. Les réseaux de neurones récurrents sont basés sur des séquences de vecteurs d'entrée qui représentent des événements ayant une signification temporelle [7]. La figure 1.5 illustre la structure en boucle des RNN.

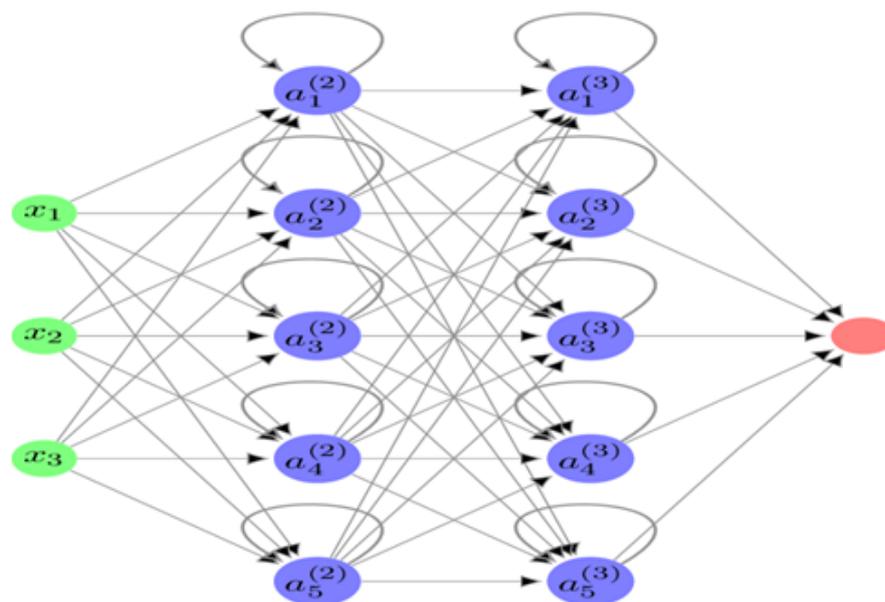


FIGURE 1.5 – réseau-recurrent-avec-deux-couches-cachees.

Les réseaux de neurones récurrents sont utilisés pour traiter des données séquentielles de taille variable. Ils sont adaptés à différents types d'architectures, notamment le "un à un", le "un à plusieurs", le "plusieurs à un" et le "plusieurs à plusieurs". Le premier type correspond à une entrée et une sortie, le deuxième à une entrée et plusieurs sorties, le troisième à plusieurs entrées et une seule sortie, et le quatrième à plusieurs entrées et plusieurs sorties. Les RNN sont particulièrement utiles pour les tâches de Traitement Automatique des Langues qui impliquent la prédiction d'une information séquentielle. Ils sont capables de prendre en compte le contexte passé lors du traitement de l'information courante, ce qui leur confère un avantage par rapport à d'autres modèles de traitement de données séquentielles.

1.4.5 Long Short Term Memory

La cellule LSTM (Long Short-Term Memory) est une architecture de réseau de neurones qui comprend trois portes de calcul. Ces portes régulent le flux d'informations en

réalisant des actions spécifiques et permettent au LSTM de conserver ou supprimer des informations qu'il a en mémoire. Les données sont stockées dans la mémoire du réseau sous forme d'un vecteur d'état de cellule, qui dépend de l'état précédent et permet au réseau de conserver des informations sur le long terme. Les trois portes sont :

- la porte d'oubli (forget gate) : qui décide quelle information doit être conservée ou jetée.
- la porte d'entrée (input gate) : qui extrait l'information de la donnée courante.
- la porte de sortie (output gate) : qui détermine la sortie de la cellule LSTM.

La combinaison de ces portes permet au LSTM de conserver les informations importantes et de les utiliser pour la prédiction de valeurs futures.

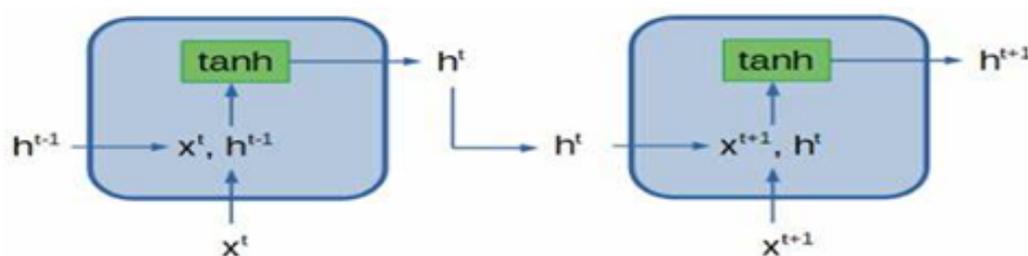


FIGURE 1.6 – Cellule LSTM.

1.5 Modèle de mélange

Un modèle de mélange est un modèle statistique qui suppose que les données proviennent d'une combinaison de plusieurs distributions différentes. Chaque distribution est appelée une "composante" du mélange. Le modèle de mélange est utilisé pour modéliser des données qui ne peuvent pas être facilement expliquées par une seule distribution.

Le modèle de mélange est généralement estimé à l'aide de l'algorithme de l'Espérance-Maximisation (EM). L'algorithme EM est un algorithme itératif qui maximise la vraisemblance du modèle en ajustant les paramètres de chaque composante [10]

1.6 Modèle de mélanges Gaussien

Le modèle de mélange, également connu sous le nom de Gaussian Mixture Model (GMM) en anglais, est un modèle statistique utilisé pour estimer paramétriquement la distribution de variables aléatoires. Il est souvent utilisé en classification automatique (clustering) pour modéliser des données qui ne peuvent pas être facilement expliquées par une seule distribution gaussienne. Le modèle suppose que les données proviennent

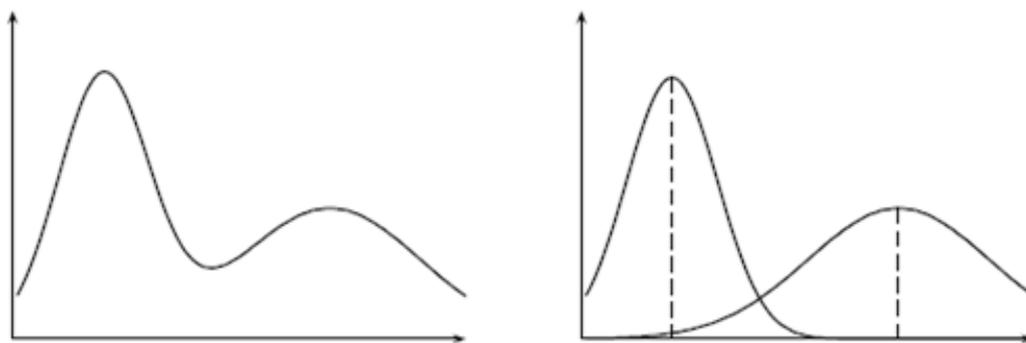


FIGURE 1.7 – Une variable aléatoire décomposée en deux variables distincts (deux composent) [10].

d'une combinaison de plusieurs distributions gaussiennes, et l'objectif est de déterminer les paramètres de chaque gaussienne, tels que la moyenne et la variance, en optimisant le critère de maximum de vraisemblance. Cette procédure est généralement réalisée à l'aide de l'algorithme Espérance-Maximisation [10].

Le modèle de mélange peut être utilisé pour modéliser des données de grande dimension, où les données sont représentées par de nombreuses variables. Il est également utile pour les données non supervisées, comme la segmentation de données et la détection d'anomalies. Le modèle de mélange peut être étendu pour inclure d'autres types de distributions, telles que les distributions de Poisson ou les distributions de Student [10].

1.7 Algorithme d'Expectation-Maximisation

L'algorithme Espérance-Maximisation (EM) est largement utilisé dans divers domaines tels que la classification de données, l'apprentissage automatique, la vision artificielle et l'imagerie médicale. L'algorithme EM consiste en deux étapes :

1. Une étape d'évaluation de l'espérance (E) : où l'on calcule l'espérance de la vraisemblance en tenant compte des dernières variables observées.
2. Une étape de maximisation (M) : où l'on estime le maximum de vraisemblance des paramètres en maximisant la vraisemblance trouvée à l'étape E.

On utilise ensuite les paramètres trouvés à l'étape de maximisation M comme point de départ d'une nouvelle phase d'évaluation de l'espérance, et l'on itère ainsi le processus [10].

1.8 Conclusion

En conclusion, ce chapitre a présenté les différentes facettes des Systèmes de Transport Intelligents (STI) et leur impact sur les systèmes de transport modernes. Nous avons examiné les définitions et l'évolution des STI, ainsi que les politiques liées aux STI dans l'Union Européenne et en Algérie. Nous avons également étudié les objectifs des STI et les nombreuses applications qu'ils offrent, notamment la reconnaissance du comportement des conducteurs automobiles. Nous avons également exploré les technologies sous-jacentes qui permettent la mise en œuvre des STI, telles que les réseaux de neurones artificiels, l'apprentissage profond, les réseaux de neurones convolutifs et récurrents, LSTM, le modèle de mélanges gaussiens et l'algorithme d'Expectation-Maximisation.

Le chapitre suivant va détailler quelques méthodes utilisées pour répondre à ces limitations, telles proposées dans la littérature.

2

APPROCHES DE RECONNAISSANCE DU COMPORTEMENT DU CONDUCTEUR : ÉTAT DE L'ART

2.1 Introduction

La conduite est une activité complexe qui consiste à effectuer plusieurs tâches simultanément : suivre la route, surveiller la vitesse, éviter les obstacles, contrôler le véhicule, etc. Il est donc clair que cette activité nécessite une très grande vigilance pour éviter les accidents. Dans ce chapitre, nous étudierons quelques approches de reconnaissance du comportement du conducteur automobile jugées intéressantes. Pour cela, nous commencerons par déterminer les critères de comparaison, suivi par une classification des approches étudiées. Nous présenterons et discuterons par la suite chaque solution en analysant les avantages et les inconvénients de chaque une. Enfin, nous conclurons ce chapitre par une comparaison des travaux analysés et une synthèse.

2.2 Critères de comparaison

Nous avons fixé certaines critères de comparaison pour bien évaluer et comparer les différents travaux étudiés. Ces critères incluent la précision, le temps de réponse, le coût, la complexité, la nécessité de matériel supplémentaire, ainsi que la capacité à détecter les comportements dangereux, de conduite inattentive, de conducteurs distraits et de conduite agressive.

2.2.1 Précision

La précision mesure la capacité d'un modèle ou d'une méthode à prédire correctement les résultats. Plus la précision est élevée, meilleure est la capacité de l'approche à détecter les comportements dangereux et inattentifs des conducteurs.

2.2.2 Temps de réponse

Le temps de réponse mesure le temps nécessaire à un modèle ou à une méthode pour répondre à une requête ou accomplir une tâche. Un temps de réponse plus court est souvent préférable, surtout dans les systèmes en temps réel. Une réponse rapide est importante pour détecter rapidement les comportements dangereux et inattentifs des conducteurs.

2.2.3 Complexité

Elle mesure la complexité d'un modèle ou d'une méthode, qui peut être liée au nombre de paramètres, de caractéristiques ou de couches dans un réseau de neurones, par exemple. Un modèle moins complexe peut être préférable pour une meilleure interopérabilité ou pour réduire les coûts de formation. Une complexité élevée peut être un obstacle pour l'application en temps réel de l'approche.

2.2.4 Nécessite du matériel supplémentaire

L'utilisation de matériel supplémentaire peut augmenter les coûts et les complexités techniques. L'utilisation de matériel supplémentaire peut rendre l'approche plus coûteuse et plus complexe.

2.2.5 Capacité à détecter les comportements dangereux

Il s'agit d'un critère important pour les applications de la sécurité routière. Il mesure la capacité d'un modèle ou d'une méthode à détecter les comportements de conduite dangereux tels que la vitesse excessive, la conduite en état d'ivresse ou la conduite agressive.

2.2.6 Capacité à détecter les comportements de conduite inattentive

Une approche efficace devrait être capable de détecter les comportements inattentifs tels que la fatigue ou la distraction des conducteurs qui pourraient entraîner des accidents.

2.3 Classification

Dans le domaine de la reconnaissance des comportements de conduite, il existe de nombreuses approches utilisées pour identifier la conduite dangereuse et inattentive. Par conséquent, nous proposons de classer les travaux étudiés en fonction de la méthode utilisée en quatre classes, à savoir les approches basées sur les signaux électroencéphalogrammes (EEG), sur les réseaux de neurones, sur les capteurs de smartphone ou sur les radars portables. La figure 2.1 représente notre classification des différentes solutions proposées.

2.3.1 Approches basées sur les signaux EEG

Ces approches utilisent les signaux électroencéphalogrammes (EEG) pour mesurer l'activité électrique dans le cerveau des conducteurs. Les données EEG sont analysées pour détecter les états mentaux associés à la conduite dangereuse ou inattentive.

2.3.2 Approches basées sur les réseaux de neurones

Ces approches utilisent des réseaux de neurones artificiels pour apprendre à reconnaître les comportements de conduite dangereux ou inattentifs. Les données d'entraînement sont utilisées pour ajuster les poids et les biais des neurones jusqu'à ce que le réseau puisse identifier avec précision les comportements de conduite.

2.3.3 Approches basées sur les capteurs de smartphone

Ces approches utilisent des capteurs intégrés dans les smartphones des conducteurs pour mesurer les mouvements du téléphone et les activités de l'utilisateur. Ces données sont utilisées pour détecter les comportements de conduite dangereux ou inattentifs.

2.3.4 Approches basées sur les radars portables

Ces approches utilisent des radars portables pour mesurer la distance entre le véhicule et les autres objets sur la route. Les données de radar sont analysées pour détecter les comportements de conduite dangereux ou inattentifs, tels que le suivi de trop près ou la conduite à haute vitesse.

2.4 Étude critique des travaux

Dans ce qui suit, nous étudions le principe de fonctionnement des travaux qui ont été menées afin de détecter les comportements de conduite anormaux.



FIGURE 2.1 – Classification des approches de reconnaissance du comportement du conducteur automobile.

2.4.1 Driving behavior recognition using EEG data from a simulated car-following experiment

Liu Yang et al. [27] ont proposé l'utilisation de données EEG pour reconnaître le comportement de conduite dans une expérience de suivi de voiture simulée. Les auteurs ont utilisé un casque EEG pour enregistrer les signaux cérébraux de sujets pendant qu'ils suivaient une voiture virtuelle, puis ont appliqué des techniques d'apprentissage automatique pour classer les comportements de conduite. Les résultats montrent que les données EEG peuvent être utilisées pour reconnaître les comportements de conduite avec une précision de classification allant jusqu'à 82%. Les auteurs concluent que cette approche pourrait être utile pour développer des systèmes d'assistance à la conduite et des systèmes de sûreté qui peuvent détecter les comportements dangereux des conducteurs et agir en conséquence.

2.4.2 Toward Extremely Lightweight Distracted Driver Recognition With Distillation-Based Neural Architecture Search and Knowledge Transfer

Dichao Liu et al. [19] ont proposé une approche pour la détection des conducteurs distraits en utilisant l'apprentissage automatique. Les auteurs proposent une méthode basée sur la recherche d'architecture neuronale basée sur la distillation et la transfert de connaissance pour concevoir un réseau de neurones très léger capable de détecter les comportements de conduite inattentive en temps réel. La méthode a été testée sur un ensemble de données de conduite simulée et a montré des résultats prometteurs. Les auteurs ont également démontré l'efficacité du transfert de connaissance pour améliorer les performances du modèle. Cependant, une des limites de cette approche est que les tests ont été réalisés sur des données de conduites simulées et des tests supplémentaires sont nécessaires pour valider l'approche sur des données réelles.

2.4.3 Distracted Driver Detection Based on a CNN With Decreasing Filter size

L'approche proposée par Binbin Qin et al. [23] pour détecter les conducteurs distraits utilise un réseau de neurones à convolution (CNN) entraîné sur un ensemble de données de conduite contenant des exemples de conducteurs concentrés et distraits. Le CNN utilise une taille de filtre décroissante pour capturer les caractéristiques des images de conduite en entrée. La méthodologie comprend la collecte des données, le prétraitement des images de conduite en entrée, l'entraînement du CNN à partir de l'ensemble de données d'entraînement, l'évaluation des performances du CNN sur l'ensemble de données de validation et le test final sur l'ensemble de données de test. Les résultats ont montré que le CNN était capable de détecter avec précision les conducteurs distraits à partir des images de caméra de tableau de bord et de caméra de surveillance. Cependant, cette approche dépend de la qualité et de la quantité des données d'entraînement disponibles, de la conception du CNN et du choix des hyperparamètres, ainsi que des ressources informatiques suffisantes pour l'entraînement et le test du CNN.

2.4.4 A similarity-based neuro-fuzzy modeling for driving behavior recognition applying fusion of smartphone sensors

Hamid Reza Eftekhari and Mehdi Ghatee [11] ont proposé une approche de modélisation neuro-fuzzy basée sur la similarité pour la reconnaissance des comportements de conduite, en utilisant une fusion de capteurs de smartphones. La méthodologie proposée comprend l'Acquisition de données de capteurs de smartphones, Traitement préalable des données, la construction de modèles neuro-fuzzy et l'étude de l'efficacité du modèle. Les

résultats obtenus montrent que l'approche proposée permet une reconnaissance précise des comportements de conduite avec une précision moyenne de 93,48%. Cette approche est également comparée à d'autres approches existantes et montre des performances améliorées. Cependant, l'approche proposée souffre de certaines limites, notamment la nécessité d'un ensemble de données d'entraînement suffisamment important pour obtenir des performances précises et la sensibilité aux conditions de conduite spécifiques. En outre, l'approche proposée est limitée à l'utilisation de capteurs de smartphones et ne prend pas en compte d'autres facteurs tels que les conditions météorologiques et l'état de la route.

2.4.5 Inattentive Driving Behavior Detection Based on Portable FMCW Radar

Jing Wang et al. [8] ont proposé une approche de détection de comportements de conduite inattentive basée sur un radar FMCW portable. L'approche utilise un radar pour enregistrer les trajets du véhicule et les conditions de conduite, qui sont analysées pour identifier les comportements de conduite inattentif tels que l'utilisation du téléphone portable, le manque de vigilance et les erreurs de conduite. La méthodologie implique la collecte de données, la préparation des données et l'application d'un algorithme d'apprentissage automatique pour détecter les comportements de conduite distraite. Les résultats ont montré une grande précision dans la détection des comportements de conduite inattentive dans une variété de scénarios de conduite, mais l'approche est limitée par la qualité des données collectées et ne tient pas compte de certains comportements de conduite inattentive qui peuvent ne pas être détectables par le radar.

2.4.6 A Hybrid Deep Learning Model for Recognizing Actions of Distracted Drivers

Shuang-Jian Jiao et al. [16] ont proposé une approche hybride basée sur le deep learning pour la reconnaissance des actions de conducteurs distraits. Cette approche combine les caractéristiques spatiales et temporelles des images vidéo pour identifier les comportements de conduite dangereux. La méthodologie consiste à recueillir des données vidéo de conducteurs faisant des activités distrayantes, à extraire les caractéristiques spatiales et temporelles à l'aide de deux réseaux de neurones différents (CNN et RNN), à fusionner les résultats et à classer les comportements de conduite en fonction de leur degré de dangerosité. Les résultats obtenus montrent que le modèle proposé permet une reconnaissance précise des comportements de conduite dangereux, avec une précision moyenne de 94,23%. Cependant, l'approche proposée a certaines limites, notamment la nécessité d'un ensemble de données suffisamment grand pour obtenir des performances précises et la dépendance à la qualité de la vidéo et de l'équipement de capture. Également, l'approche peut être complexe à mettre en œuvre en raison de la nécessité de combiner plusieurs

architectures de réseaux de neurones. Dans l'ensemble, cette approche hybride basée sur le deep learning présente des résultats prometteurs dans la reconnaissance des comportements de conduite dangereux. Cependant, des travaux supplémentaires sont nécessaires pour améliorer la robustesse et l'efficacité de l'approche proposée, notamment en prenant en compte d'autres facteurs externes qui peuvent influencer les comportements de conduite

2.4.7 Abnormal Driving Detection With Normalized Driving Behavior Data : A Deep Learning Approach

Jie Hu et al. [15] ont proposé une approche de détection de conduite anormale à l'aide de données de comportement de conduite normalisées et d'apprentissage en profondeur. L'approche proposée implique l'obtention de données de conduite normales et anormales, la normalisation des données de comportement de conduite pour éviter les biais et la mise en œuvre d'un réseau de neurones convolutionnel (CNN) pour détecter les comportements de conduite anormaux. Les résultats montrent que cette approche permet de détecter les comportements de conduite anormaux avec une précision moyenne de 93,4%. Dans l'ensemble, cette approche de détection de conduite anormale à l'aide de données de comportement de conduite normalisées et d'apprentissage en profondeur présente des résultats encourageants. Cependant, nous avons souligné certaines limites de l'approche, telles que la nécessité de disposer d'un ensemble de données suffisamment grand pour obtenir des performances précises et la dépendance à la qualité des données de comportement de conduite collectées. En outre, l'approche proposée ne prend pas en compte les facteurs externes qui peuvent influencer les comportements de conduite, tels que les conditions météorologiques et l'état de la route.

2.4.8 A Lightweight Attention-Based Network towards Distracted Driving Behavior Recognition

Yingcheng Lin et al. [18] ont proposé une approche basée sur l'attention pour la reconnaissance des comportements de conduite distraite. L'approche proposée implique la mesure de données de conduite distraite, la mise en œuvre d'un réseau de neurones convolutif (CNN) avec une attention légère pour extraire les caractéristiques pertinentes et la classification des comportements de conduite distraite en utilisant un classificateur softmax. Les résultats montrent que cette approche permet de reconnaître les comportements de conduite distraite avec une précision moyenne de 88,7%. Cette approche basée sur l'attention pour la reconnaissance des comportements de conduite distraite présente des résultats prometteurs et peut être considérée comme une alternative intéressante aux approches plus lourdes en ressources computationnelles. Cependant, le manque de données de conduite distraite pour l'apprentissage influence les performances de l'approche proposée.

2.5 Comparaison des approches étudiées

Le tableau 2.1 illustre une comparaison entre les approches de détection de comportement du conducteur selon les critères d'évaluation sélectionnés. MS signifie nécessité du matériel supplémentaire, DCD signifie capacité à détecter les comportements dangereux et DC pour capacité à détecter les comportements de conduite inattentive.

Approches	Précision	Temps de réponse	Complexité	MS	DCD	DC
Liu Yang et al. [27]	82%	1s	Faible	EEG capteurs	Oui	Oui
Dichao Liu et al. [19]	97.80%	20ms	Faible	Caméra	Oui	Oui
Binbin Qin et al. [23]	97.89%	30ms	Moyenne	Caméra	Oui	Oui
Mehdi Ghatee et al. [11]	93,48%	1s	Faible	Smart-phone	Oui	Oui
Jing Wang et al. [8]	90.50%	10ms	Faible	Radar	Oui	Oui
Qian Liu et al. [16]	94,23%	200ms	Moyenne	Caméra	Oui	Oui
Jie Hu et al. [15]	93.40%	Non spécifié	Inconnu	Non spécifié	Oui	Oui
Yingcheng Lin et al. [18]	88,7%	300ms	Faible	Caméra	Oui	Oui

TABLE 2.1 – Comparaison des approches étudiées.

2.6 Synthèse

Dans notre comparaison des approches pour la reconnaissance de comportements de conduite, nous avons utilisé un ensemble de critères différents. Les approches examinées comprennent des méthodes basées sur des données EEG, des capteurs de smartphone, des radars portables et des réseaux de neurones.

En général, les approches ont montré une précision élevée dans la reconnaissance des comportements de conduite dangereux et inattentifs, avec des scores de précision allant de 60% à 80%. Cependant, certaines approches ont montré une complexité plus élevée, nécessitant plus de temps et de ressources pour mettre en œuvre.

Les approches basées sur des capteurs supplémentaires ont montré une nécessité de matériel supplémentaire plus élevée, tandis que les approches basées sur des réseaux de neurones ont montré une complexité plus élevée. Globalement, les approches basées sur des données EEG ont montré une précision et une capacité à détecter les comportements de conduite dangereux élevés, tandis que les approches basées sur des capteurs de smartphone ont montré une plus grande facilité d'utilisation et un coût moindre. En fin, le choix de l'approche dépendra des besoins spécifiques, y compris la précision nécessaire, les ressources disponibles, le budget et les contraintes matérielles.

2.7 Conclusion

En conclusion, de nombreuses approches qui ont été proposées dans la littérature pour détecter le comportement d'un conducteur automobile. Dans ce chapitre nous avons proposé une classification des solutions selon l'approche utilisée. Ensuite, nous avons présenté quelques approches jugées pertinentes avec une discussion des points forts et des points faibles de Chaque'une. Enfin, nous les avons comparées selon les différents d'évaluation discutés. Le chapitre suivant sera consacré à la description détaillée de notre approche pour détecter le comportement des conducteurs en temps réel.

3

LSTM-RNN AND GMM BASED APPROACH FOR VEHICLE DRIVER BEHAVIOR RECOGNITION

3.1 Introduction

L'identification des différents comportements de conduite des conducteurs, tels que la conduite agressive, normale et la somnolence, revêt une importance capitale pour garantir la sûreté du trafic et améliorer la sécurité routière en identifiant les conducteurs à risque. Dans ce chapitre, nous détaillerons l'approche proposée pour la reconnaissance du comportement de conduite, qui repose sur l'utilisation du modèle de mélange Gaussien GMM et du réseau de neurones récurrents RNN basé sur LSTM. Après avoir exposé la motivation initiale, nous présenterons en détail chaque étape de notre approche de reconnaissance du comportement de conduite.

Nous passerons ensuite à l'évaluation de notre modèle et à l'analyse des résultats obtenus par des simulations. Cette évaluation nous permettra de mesurer la précision, le rappel, l'exactitude et le F1-score de notre modèle. Nous commencerons par présenter le dataset utilisé et les étapes réalisées dans la phase de prétraitement, puis nous examinerons les métriques de performances utilisées pour évaluer notre solution. Enfin, nous fournirons une interprétation des résultats obtenus à partir de la simulation de la solution proposée.

3.2 Motivation

La principale cause des accidents de la route est liée principalement au comportement du conducteur. En effet, la conduite agressive expose non seulement le conducteur et le véhicule à un accident, mais affecte également dans la plupart des cas les conducteurs prudents. L'identification de la conduite dangereuse est alors une étape importante afin de prendre des mesures pour assurer la sûreté du trafic routier.

Le travail réalisé met l'accent sur la reconnaissance des comportements de conduite (y compris les comportements de conduite normaux, les comportements de conduite agressifs et la somnolence au volant) afin de promouvoir une conduite plus sûre et réduire les accidents de la route. L'idée principale de notre protocole est la combinaison des réseaux LSTM-RNN avec la méthode GMM qui participent extrêmement dans la l'exactitude de classification. Nous utilisons LSTM-RNN pour établir un pré-modèle, qui détectera le comportement de conduite à partir des données de conduite enregistrées de diverses variables collectées à partir de capteurs installés dans les véhicules, en les classant en trois classes, à savoir, normal, agressif et somnolent. En effet, l'élaboration d'un pré-modèle contribue énormément à l'accélération de la phase d'apprentissage du modèle principal et à sa précision. Sur la base des résultats de classification obtenus avec le pré-modèle basé sur LSTM-GMM, la méthode GMM est utilisée pour la reconnaissance finale du comportement. L'utilisation de cette méthode vise à améliorer la précision des résultats obtenus avec le pré-modèle. En fait, effectuer une classification supplémentaire à l'aide de la méthode GMM constitue une solution préférable dans le contexte de ce travail, car il s'agit d'une méthode probabiliste, ce qui permet de réduire les erreurs.

3.3 Solution proposée

Dans cette section, nous présentons notre approche de reconnaissance du comportement du conducteur. Notre solution est conçue en deux phases distinctes : une phase de reconnaissance et une phase d'avertissement. La première phase consiste à détecter le comportement du conducteur à travers les différents comportements qu'il effectue tout au long de la conduite. La seconde phase consiste à avertir le conducteur pour qu'il ajuste ou pas son comportement selon le types de comportement détectés. Dans ce qui suit, nous présentons en détail la solution proposée. La figure 3.1 illustre la structure de la solution proposée.

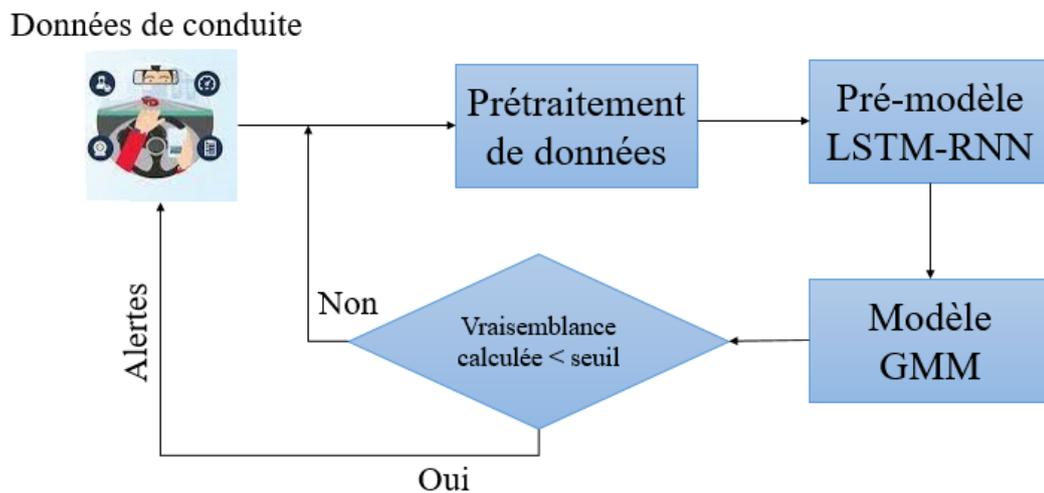


FIGURE 3.1 – Structure de la solution proposée.

3.3.1 Phase de reconnaissance

3.3.1.1 Phase de détection basée sur LSTM-RNN

— **Entraînement :**

Les données de conduite pré-traitées sont affectées au module RNN afin d'apprendre le modèle de chaque classe. La technique de rétropropagation à travers le temps (BPTT) (pour Backpropagation Through Time) est utilisé pour prévoir le comportement anormal.

les poids sont fixés, et les données sont transmises de la première couche à la dernière couche pour produire une sortie y en appliquant une fonction d'activation F à une combinaison linéaire des entrées a , avec

$$a = \sum_{i=1}^n (w_i x_i) + b, \quad (3.1)$$

$$y = F(a). \quad (3.2)$$

nous calculons l'erreur e entre cette sortie y et la sortie de référence r que l'on désire avoir. Pour cela, nous utilisons une fonction coût qui correspond dans ce cas à la somme des erreurs quadratiques observées $e_j = r - y_j$ sur l'ensemble des neurones de sortie C :

$$E = \frac{1}{2} \sum_{j \in C} (e_j^2). \quad (3.3)$$

nous mesurons comment la fonction coût varie par rapport à chaque couche de notre modèle, en propageant l'erreur à travers le réseau, en commençant par la dernière couche et en remontant jusqu'à la toute première. Donc, on calcule le Gradient (ou la dérivée) de la fonction Coût E par rapport au poids w_{ij} , $\frac{\partial E}{\partial w_{ij}}$, qui peut s'écrire :

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial F} \cdot \frac{\partial F}{\partial a} \cdot \frac{\partial a}{\partial w_{ij}}, \quad (3.4)$$

Sur la base des équations 3.1 à 3.4, le processus de calcul pour l'apprentissage des neurones LSTM est effectué. Dans la propagation en avant, pour les portes d'entrée, les portes d'oubli et les portes de sortie, les valeurs d'entrée et de sortie sont calculées. Également, pour les cellules de mémoire, les valeurs d'entrée, d'état et de sortie sont calculées. Finalement, dans la propagation en arrière, les coefficients de poids des neurones LSTM sont mis à jour avant de revenir à la première étape, pour commencer un nouveau cycle d'apprentissage.

- **Détection** : Une fois que le réseau est entraîné avec la technique de rétro-propagation, on peut l'utiliser pour faire des prédictions sur de nouvelles données de conduite et détecter les comportements dangereux.

3.3.1.2 Phase de reconnaissance basée sur GMM

La reconnaissance du comportement du conducteur est effectuée par la méthode GMM. Les données résultant du processus de classification effectué par RNN dans la phase précédente sont fournies à la méthode de classification GMM, où elles sont classées avec plus de précision grâce aux probabilités. Celles-ci sont calculées et comparées à la valeur seuil. Finalement, sur cette base, la décision est prise.

1. **Formulation du modèle GMM** : GMM est basé sur un mélange de $m = 3$ distributions gaussiennes. Soit x un vecteur de caractéristiques à $N = 14$ dimensions, μ_k et C_k sont, respectivement, la moyenne et la variance de chaque caractéristique. La probabilité des données dans le cadre d'un mélange GMM est alors donnée comme suit :

$$P(x_i|\mu_k, \alpha_k, C_k) = \sqrt{(2\pi)^{N/2}|\sigma_k|}^{-1} \cdot \exp[-\frac{1}{2}(x_i - \mu_k)^T C_k^{-1}(x_i - \mu_k)], \quad (3.5)$$

où, $k = 1 \dots N$, a_i est le coefficient de pondération de chaque composante gaussienne, qui satisfait : $\sum_{k=1}^N \alpha_k = 1$.

La fonction de vraisemblance (Likelihood function) du GMM est exprimée comme suit :

$$P(x|\mu_k, \alpha_k, C_k) = \prod_{i=1}^L P(x_i|\mu_k, \alpha_k, C_k), \quad (3.6)$$

où, L est le nombre d'échantillons d'apprentissage.

2. **L'algorithme EM (pour Expectation Maximization)** : Un nouveau paramètre μ'_k, α'_k, C'_k est estimé à l'aide de l'algorithme EM, de sorte que $P(X|\mu'_k, \alpha'_k, C'_k) \geq P(X|\mu_k, \alpha_k, C_k)$, la boucle itère jusqu'à ce que le modèle converge pour déterminer les différents paramètres du modèle GMM. L'algorithme EM comprend une étape d'estimation (étape E) et une étape de maximisation (étape M). L'étape E consiste à estimer la probabilité que l'échantillon d'entrée appartienne à chaque composante gaussienne unique, et l'étape M consiste à résoudre le modèle GMM en maximisant la fonction.
3. **Reconnaissance** : Le comportement de conduite est reconnu en comparant la probabilité calculée à la valeur seuil. Si la probabilité est supérieure ou égale au paramètre seuil, le comportement est normal. Dans le cas contraire, le comportement est considéré comme anormal (sommolence ou agressivité) et un signal d'alerte est activé pour avertir le conducteur.

3.4 Evaluation de performances

Dans cette partie, nous présentons le schéma d'expérimentation que nous avons développé pour évaluer la performance de notre modèle de reconnaissance du comportement du conducteur automobile basé sur LSTM-RNN et GMM. Les étapes des expérimentations que nous avons effectuées comprennent le prétraitement de données, l'entraînement et l'évaluation de notre modèle en utilisant plusieurs critères d'évaluation couramment utilisés pour les modèles de reconnaissance de comportement. La figure 3.2 illustre les étapes d'expérimentation réalisée.

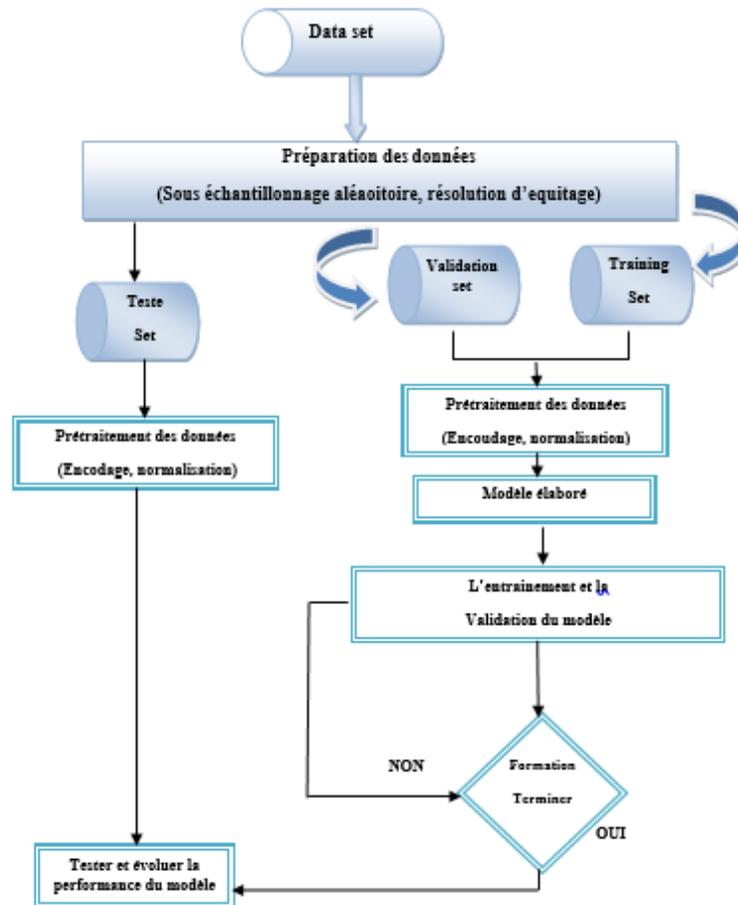


FIGURE 3.2 – Etapes des expérimentations effectuées.

Dans ce qui suit, nous allons intriduire les spécificités de l’environnement de développement et du langage de programmation utilisés pour créer notre système. Nous y présentons également de Dataset de données d’apprentissage et de test utilisée, les détails de l’implémentation de la solution proposée.

3.4.1 Environnement de développement

L’environnement de développement est un ensemble d’outils et de ressources qui permettent aux développeurs de concevoir, développer, tester et déployer des logiciels de manière efficace et fiable. Cet environnement comprend plusieurs éléments clés, tels que :

- **Google Colab** : Notre projet utilise Google Colab comme environnement d’exécution. Google Colab est un service gratuit en nuage qui prend en charge les GPU gratuits. Il nous permet d’améliorer nos compétences en programmation Python et de développer des applications d’apprentissage approfondi à l’aide de bibliothèques populaires telles que Keras, TensorFlow, PyTorch et OpenCV [4].

1. Nous utilisons google colab dans notre google drive
 2. Nous créons un dossier appel ‘ application ’
 3. Créons un nouveau carnet via Clic droit> Plus> Colaboratory
 4. Nous renommons le projet ‘ABSA’
 5. Modifions les paramètres de GPU (CPU en GPU ou inversement)
 6. En fin nous exécutons le code en choisissant les cellules de type ‘code’
- **Anaconda** : Anaconda est une distribution de Python conçue pour les applications scientifiques. Elle permet d’écrire et d’exécuter du code Python directement depuis un navigateur web. Anaconda Enterprise (gratuit) est livré avec Jupyter Notebook et est destiné à la formation et à la recherche en apprentissage automatique [9].

3.4.2 Langage de programmation et bibliothèques

- **Python** : Au fil des années, Python a connu une popularité grandissante auprès des informaticiens, devenant ainsi le langage de programmation le plus utilisé. Il s’est imposé en tant que leader dans différents domaines tels que la gestion d’infrastructure, l’analyse de données et le développement de logiciels. L’un des avantages majeurs de Python est qu’il permet aux développeurs de se concentrer sur ce qu’ils font plutôt que sur la manière dont ils le font. Il a ainsi libéré les développeurs des contraintes de forme associées aux langages de programmation plus anciens. En conséquence, coder en Python est plus rapide que dans d’autres langages [9].
- **Bibliothèques utilisées** : Les bibliothèques que nous avons utilisées pour notre modèle de reconnaissance du comportement du conducteur automobile sont :
- TensorFlow et Keras : pour la création et l’entraînement de notre modèle RNN-LSTM-GMM.
 - NumPy pour la manipulation des données d’entrée et la préparation des données pour l’entraînement du modèle.
 - Matplotlib : pour la visualisation des données d’entrée et la compréhension des caractéristiques des données.
 - Scikit-learn : pour la classification des différents comportements du conducteur en utilisant la méthode de mélange de Gaussiennes.
 - Pandas pour la manipulation des données en vue de l’entraînement et l’évaluation de notre modèle.
 - Tkinter : pour la création de l’interface utilisateur pour notre modèle de reconnaissance du comportement du conducteur automobile.

3.4.3 Dataset

L’UAH-DriveSet [24] est une collection de données capturées avec des conducteurs testeurs dans différents environnements. Cet ensemble de données fournit une grande quantité de variables qui ont été capturées et traitées par tous les capteurs et toutes les capacités d’un smartphone au cours de tests de conduite indépendants (4800 échantillons). L’application a été exécutée sur 6 conducteurs et véhicules différents, adoptant 3 comportements différents (normal, somnolent et agressif) sur deux types de routes (autoroute et route secondaire). La figure 3.3 illustre les attributs importants utilisés dans notre simulation.

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 2299 entries, 0 to 2298
Data columns (total 15 columns):
#   Column                                     Non-Null Count  Dtype
---  -
0   'Speed (km/h)'                             2299 non-null   float64
1   'Latitude coordinate (degrees)'             2299 non-null   float64
2   'Longitude coordinate (degrees)'            2299 non-null   float64
3   'Altitude (meters)'                         2299 non-null   float64
4   'Course (degrees)'                          2299 non-null   float64
5   'Difcourse course variation (degrees)'      2299 non-null   float64
6   'Acceleration in X (Gs)'                    2299 non-null   float64
7   'Acceleration in Y (Gs)'                    2299 non-null   float64
8   'Acceleration in Z (Gs)'                    2299 non-null   float64
9   'Roll (degrees)'                            2299 non-null   float64
10  'Pitch (degrees)'                           2299 non-null   float64
11  'Yaw (degrees)'                             2299 non-null   float64
12  'GPS speed (km/h)'                          2299 non-null   float64
13  'Maximum speed (km/h)'                      2299 non-null   int64
14  Classes                                     2299 non-null   object
dtypes: float64(13), int64(1), object(1)
memory usage: 269.5+ KB
```

FIGURE 3.3 – Attributs du Dataset.

3.4.4 Prétraitement des données

Le prétraitement des données de conduite est une étape cruciale dans le traitement de données liées à la conduite, qui vise à préparer les données brutes pour l’analyse et la modélisation. Cette étape comprend plusieurs étapes essentielles, telles que la collecte des données, le nettoyage des données, la normalisation des données, la transformation des données et l’extraction de fonctionnalités.

Voici les étapes détaillées du prétraitement des données de conduite :

1. **Nettoyage des données** : Cette étape consiste à supprimer les erreurs et les données aberrantes, à remplacer les valeurs manquantes et à éliminer les bruits. Les erreurs dans les données peuvent être causées par des capteurs défectueux ou des perturbations environnementales, tandis que les données aberrantes peuvent être causées par des événements imprévus tels que des accidents ou des incidents de conduite. Le remplacement des valeurs manquantes est essentiel pour éviter les erreurs dans les analyses et les modèles, tandis que l'élimination des bruits est importante pour réduire la variabilité dans les données. Les techniques courantes utilisées pour le nettoyage des données incluent la détection de données aberrantes, l'imputation de données manquantes et le filtrage des données.
2. **Normalisation des données** : Cette étape consiste à mettre les données à la même échelle pour faciliter leur utilisation. Les données collectées peuvent être dans des formats différents et avec des échelles différentes, ce qui peut rendre difficile leur comparaison et leur utilisation dans les modèles. La normalisation des données implique une transformation des données pour les mettre à la même échelle, ce qui permet de comparer les données et de les utiliser dans les modèles. Les techniques courantes utilisées pour la normalisation des données incluent la normalisation min-max et la normalisation z-score.
3. **Transformation des données** : Cette étape consiste à convertir les données en un format structuré qui peut être facilement utilisé pour l'analyse et la modélisation. Les données collectées peuvent être brutes et non structurées, nécessitant une transformation pour les rendre utilisables. Cette étape implique souvent l'utilisation de techniques telles que la réduction de dimensionnalité, la discrétisation des données, la normalisation et le filtrage. Les techniques courantes utilisées pour la transformation des données incluent la réduction de dimensionnalité, la discrétisation des données, la normalisation et le filtrage.
4. **Extraction de fonctionnalités** : Cette étape consiste à identifier les caractéristiques importantes des données et à les extraire pour faciliter leur utilisation dans les modèles de conduite. Les données collectées peuvent contenir des informations redondantes, ce qui peut rendre difficile leur utilisation dans les modèles. Cette étape implique souvent l'utilisation de techniques telles que l'analyse de composantes principales (PCA), l'analyse en composantes indépendantes (ICA), la régression logistique, la régression linéaire et la classification. Les techniques courantes utilisées pour l'extraction de fonctionnalités incluent l'analyse de composantes principales, la régression logistique et la classification.

3.4.5 Entraînement de LSTM-RNN

L'entraînement de LSTM-RNN est essentiel pour obtenir des modèles d'intelligence artificielle performants. Pour modéliser des données séquentielles dans le temps, un modèle LSTM-RNN avec une couche LSTM a été construit. Donc, nous nous concentrerons sur l'entraînement des RNN, en particulier sur les architectures de RNN telles que les LSTM et GRU, ainsi que sur leurs applications pratiques dans la reconnaissance du com-

portement du conducteur automobile et la prédiction de séries temporelles. Les étapes clés de l'entraînement de réseaux de neurones qui seront également abordées. La structure du modèle RNN est présentée sur la figure 3.4.

```

Model: "sequential_1"

```

Layer (type)	Output Shape	Param #
lstm_1 (LSTM)	(None, 64)	20224
dense_1 (Dense)	(None, 3)	195

```

Total params: 20,419
Trainable params: 20,419
Non-trainable params: 0

```

FIGURE 3.4 – Structure du modèle LSTM-RNN.

3.4.6 Métriques de simulation

Dans cette partie, nous allons présenter les différentes métriques d'évaluation couramment utilisées en apprentissage automatique pour évaluer la performance de notre modèle de reconnaissance du comportement du conducteur automobile. Ces métriques incluent la précision, exactitude (Accuracy), le rappel (Recall) et le F-score, qui sont des mesures importantes pour évaluer la capacité de notre modèle à classer correctement les comportements des conducteurs. En comprenant la signification de chacun de ces critères et en les appliquant à notre modèle, nous pourrions mieux comprendre sa précision et son efficacité.

- **Précision** : La précision de classification, qui est la mesure de performance la plus courante pour les algorithmes de classification, est utilisée pour évaluer la performance. Cette métrique mesure le nombre de prédictions correctes effectuées par rapport à l'ensemble des prédictions. Dans cette étude elle permet de déterminer la capacité de notre modèle à classer correctement les différents comportements du conducteur.

La formule pour calculer le rappel est la suivante :

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (3.7)$$

- **Accuracy** : L'exactitude est la métrique la plus utilisée et la plus intuitive pour évaluer les performances des algorithmes d'apprentissage, y compris notre modèle de reconnaissance du comportement du conducteur automobile. Il s'agit de mesurer la proportion de prédictions correctes et elle est particulièrement importante pour notre modèle, qui vise à détecter et classer les différents comportements du

conducteur avec une grande précision [22]. La formule pour calculer le rappel est la suivante :

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \times 100\% \quad (3.8)$$

- **Le rappel (Recall ou RC) :** Est une mesure de performance utilisée en classification qui permet de mesurer la capacité d'un modèle à identifier tous les exemples positifs. Dans notre étude le rappel mesure la capacité de notre modèle à détecter tous les comportements du conducteur qui doivent être identifiés comme positifs dans l'ensemble de données [3] [14]. La formule pour calculer le rappel est la suivante :

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (3.9)$$

- **Le F1-score :** Le F1-score (aussi appelé F1-mesure) est une métrique couramment utilisée pour évaluer les performances des algorithmes d'apprentissage. Contrairement à l'exactitude, le F-score prend en compte à la fois la précision et le rappel du modèle, ce qui en fait un compromis entre ces deux mesures. En effet, le F1-score est calculé en prenant la moyenne harmonique de la précision et du rappel, ce qui permet de donner une mesure globale de la performance du système [22]. La valeur du F1-score varie de 0 à 1, où une valeur de 1 indique une performance optimale et une valeur de 0 indique une performance nulle [3] [14]. La formule pour calculer le rappel est la suivante :

$$F1 \text{ score} = \frac{Precision \times Recall}{Precision + Recall} \times 2 \quad (3.10)$$

où TP , FP , TN et FN désignent, respectivement, les vrais positifs, les faux positifs, les vrais négatifs et les faux négatifs.

3.5 Résultats obtenus

3.5.1 Matrice de confusion

La matrice de confusion fournit une vue détaillée des performances du modèle de classification, permettant d'identifier les erreurs de prédiction et d'évaluer la capacité du modèle à différencier les classes. Elle est utilisée pour évaluer et améliorer le modèle de classification. La Matrice de confusion de notre modèle de classification est représentée sur la figure 3.5.

```
[[ 78,  1,  2],
 [  0, 17, 14],
 [  3,  7, 338]]
```

FIGURE 3.5 – La matrice de confusion de la solution proposée.

3.5.2 Rapport de classification

Le rapport de classification (classification report) est un outil qui fournit une évaluation détaillée des performances d'un modèle de classification pour chaque classe. Il est généralement utilisé lorsque le problème de classification comporte plusieurs classes. Le rapport de classification de notre modèle de classification est illustré sur la figure 3.6.

	precision	recall	f1-score	support
0	0.96	0.96	0.96	81
1	0.68	0.55	0.61	31
2	0.95	0.97	0.96	348
accuracy			0.94	460
macro avg	0.87	0.83	0.84	460
weighted avg	0.94	0.94	0.94	460

FIGURE 3.6 – Rapport de classification de notre solution.

3.5.2.1 Interprétation et Evaluation des résultats obtenus

Dans ce rapport de classification, l'interprétation des différentes métriques est comme suit :

- **Pour la classe 0 (conduite agressive) :**
 - **Precision :** 0.96, ce qui indique que 96% des prédictions positives pour la classe 0 sont correctes. Cela indique que le modèle a une très bonne capacité à identifier la conduite agressive.
 - **Recall :** 0.96, ce qui signifie que 96% des exemples réels de la classe 0 ont été correctement identifiés par le modèle. Le modèle a une haute sensibilité pour détecter la conduite agressive.
 - **F1-score :** 0.96, qui est une mesure équilibrée de la précision et du rappel. Cela indique une performance globale élevée pour la détection de la conduite agressive.
 - **Support :** 81, c'est le nombre d'exemples réels de la classe 0 dans les données de test.
- **Pour la classe 1 (conduite somnolent) :**

- **Precision** : 0.68, ce qui indique que 68% des prédictions positives pour la classe 1 sont correctes. cela indique que le modèle a des difficultés à identifier la conduite somnolente avec précision.
- **Recall** : 0.55, ce qui signifie que seulement 55% des exemples réels de la classe 1 ont été correctement identifiés par le modèle. Le modèle a une faible sensibilité pour détecter la conduite somnolente.
- **F1-score** : 0.61, une mesure moyenne de précision et de rappel pour la classe 1. Cela montre que la performance du modèle pour la détection de la conduite somnolente est relativement faible.
- **Support** : 31, c'est le nombre d'exemples réels de la classe 1 dans les données de test.

- **Pour la classe 2 (conduite normal) :**
 - **Precision** : 0.95, ce qui indique que 95% des prédictions positives pour la classe 2 sont correctes. Le modèle a une très bonne précision pour identifier la conduite normale.
 - **Recall** : 0.97, ce qui signifie que 97% des exemples réels de la classe 2 ont été correctement identifiés par le modèle. Le modèle a une haute sensibilité pour détecter la conduite normale.
 - **F1-score** : 0.96, une mesure équilibrée de la précision et du rappel pour la classe 2. Cela montre une performance globale élevée pour la détection de la conduite normale.
 - **Support** : 348, c'est le nombre d'exemples réels de la classe 2 dans les données de test.

En ce qui concerne les métriques globales, nous avons :

- **Accuracy** : 0.94, ce qui signifie que le modèle a correctement prédit la classe de 94% des exemples dans les données de test. C'est un indicateur de la performance globale du modèle.
- **Macro avg** : Une moyenne non pondérée des métriques pour toutes les classes. Dans ce cas, la précision moyenne est de 0.87, le rappel moyen est de 0.83 et le F1-score moyen est de 0.84. Cela fournit une évaluation globale des performances du modèle.
- **Weighted avg** : Une moyenne pondérée des métriques pour toutes les classes, pondérée par le nombre d'exemples réels de chaque classe. Dans ce cas, la précision moyenne pondérée est de 0.94, le rappel moyen pondéré est de 0.94 et le F1-score moyen pondéré est de 0.94. Cette métrique tient compte de la distribution des classes dans les données de test.

En conclusion, le modèle semble performant pour la détection de la conduite agressive et normale, avec des scores élevés de précision, de rappel et de F1-score. Cependant, il présente des difficultés dans la détection de la conduite somnolente, avec des scores

inférieurs. L'accuracy globale de 94% est également encourageante.

3.6 Conclusion

Dans ce chapitre, nous avons décrit notre solution pour la reconnaissance du comportement des conducteurs automobiles, basée sur le réseau RNN à base de LSTM et sur la méthode GMM. Cette approche permet l'identification de divers comportements de conduite, tels que l'agressivité, la somnolence et la conduite normale, assurant ainsi la sécurité du trafic. Nous avons également présenté les résultats de nos expérimentations pour évaluer les performances de notre modèle de reconnaissance du comportement du conducteur automobile. Nos expériences ont démontré que notre modèle est très performant en termes d'exactitude et de vitesse de traitement, ce qui le rend pertinent pour des applications en temps réel. En conclusion, notre modèle de reconnaissance du comportement du conducteur automobile est capable de fournir des prédictions précises et fiables pour la détection et la classification des différents comportements du conducteur, ce qui en fait un outil utile pour des applications de sécurité routière et de conduite autonome.

CONCLUSION GÉNÉRALE ET PERSPECTIVES

Aujourd'hui très médiatisé, le véhicule autonome est au cœur de toutes les attentions et représente un énorme défi pour les entreprises en terme d'innovation technologique. La sécurité routière est une préoccupation majeure dans notre société actuelle, et la reconnaissance du comportement des conducteurs peut jouer un rôle essentiel pour réduire les accidents de la route.

Dans ce contexte, nous avons proposé une approche novatrice en utilisant les réseaux de neurones récurrents (LSTM-RNN) et le Modèle de Mélange Gaussien (GMM), qui permet de classer le comportement en trois classes distinctes. L'approche proposée est capable de distinguer entre la conduite sûre et non-sûre. Egaleme nt, elle permet aux conducteurs de se surveiller eux-mêmes et d'ajuster leur conduite si nécessaire, ce qui contribue extrêmement dans la sûreté du trafic routier en prévenant les accidents de la route et améliorer la sécurité des usagers de la route.

Dans ce travail, nous avons donné une vue d'ensemble des STIs, ainsi que leurs objectifs et leurs nombreuses applications. Nous avons également inclus des définitions générales des méthodes sur lesquelles notre modèle repose. Nous avons ensuite approfondit notre compréhension de la reconnaissance du comportement des conducteurs automobiles en examinant les différentes méthodes proposées dans la littérature. Par la suite, nous avons détaillé notre approche de reconnaissance du comportement des conducteurs. Enfin, en utilisant un dataset de données de conduite très important, nous avons évalué la performance de notre modèle protocole sous langage de programmation Python, en mesurant la précision, le rappel et la F1-mesure, et dont les résultats sont très encourageants.

Notre modèle nécessite des données d'apprentissage de haute qualité et en grande quantité, ainsi que la prise en compte de facteurs contextuels pour une reconnaissance de comportement plus précise. Pour améliorer notre modèle, nous envisageons d'utiliser des techniques d'apprentissage plus avancées, d'augmenter la quantité et la qualité des données d'apprentissage et de prendre en compte davantage de facteurs contextuels.

Bibliographie

- [1] H. Belhadjer and B. Sarouer. Classification des images avec les réseaux de neurones convolutionnels. PhD thesis, Université Mouloud Mammeri, 2018.
- [2] A. S. Bellanger-Dujardin. Contribution à l'étude de structures neuronales pour la classification de signatures : application au diagnostic de pannes des systèmes industriels et à l'aide au diagnostic médical. PhD thesis, Paris 12, 2003.
- [3] A. Benhamahoum. Analyse des paramètres de haralick pour la classification des anomalies mammaires. 2020.
- [4] A. Bouguettaya. Une Approche Basée Deep Learning Pour La Classification des Sentiments. PhD thesis, Université laarbi tebessi tebessa, 2019.
- [5] Z. Boukemoum. Détection des véhicules par histogramme orienté gradient. 2019.
- [6] L. Bourkeb, S. Aissani, and K. Zizi. Authentification biométrique d'un conducteur dans les STIs. PhD thesis, Université Abderahmene Mira Bejaia, 2020.
- [7] H. Cruse. Neural networks as cybernetic systems. Brains, Minds & Media, Bielefeld, Germany, 2006.
- [8] C. Ding, R. Chae, J. Wang, L. Zhang, H. Hong, X. Zhu, and C. Li. Inattentive driving behavior detection based on portable fmcw radar. IEEE Transactions on Microwave Theory and Techniques, 67(10) :4031–4041, 2019.
- [9] M. A. Djaballah. Système de prédiction de la consommation d'énergie basé deep learning. 2021.
- [10] K. Djaroudib. Détection Multicritères des Anomalies sur des Mammographies. PhD thesis, Université de Batna 2, 2016.
- [11] H. R. Eftekhari and M. Ghatee. A similarity-based neuro-fuzzy modeling for driving behavior recognition applying fusion of smartphone sensors. Journal of Intelligent Transportation Systems, 23(1) :72–83, 2019.
- [12] E. Hache, C. Ternel, and L. Aissaoui. Intelligent transport system and mobility 3.0 : definition, challenges and players-panorama 2018. 2017.
- [13] H. Hadj-Mabrouk. Analyse des risques des systèmes de transport intelligents. In Workshop/Rôle des Nouvelles Technologies et des Infrastructures dans la Sûreté et la Sécurité des Systèmes de Transport, pages 1–5, 2009.
- [14] D. Hamouda. Un système de détection d'intrusion pour la cybersécurité. 2020.

- [15] J. Hu, X. Zhang, and S. Maybank. Abnormal driving detection with normalized driving behavior data : a deep learning approach. IEEE transactions on vehicular technology, 69(7) :6943–6951, 2020.
- [16] S. J. Jiao, L. Y. Liu, and Q. Liu. A hybrid deep learning model for recognizing actions of distracted drivers. Sensors, 21(21) :7424, 2021.
- [17] É Larousse. Encyclopédie larousse en ligne-intelligence artificielle.
- [18] Y. Lin, D. Cao, Z. Fu, Y. Huang, and Y. Song. A lightweight attention-based network towards distracted driving behavior recognition. Applied Sciences, 12(9) :4191, 2022.
- [19] D. Liu, T. Yamasaki, Y. Wang, K. Mase, and J. Kato. Toward extremely lightweight distracted driver recognition with distillation-based neural architecture search and knowledge transfer. IEEE Transactions on Intelligent Transportation Systems, 2022.
- [20] N. Marref. Apprentissage Incrémental & Machines à Vecteurs Supports. PhD thesis, Université de Batna 2, 2013.
- [21] M. Mezid. Approximation du modèle géométrique inverse d’un robot manipulateur par les réseaux de neurones artificiels. PhD thesis, Université Mohamed Boudiaf-M’Sila, 2019.
- [22] S. Nouas. Analyse sémantique des publications dans les réseaux sociaux par apprentissage profond. Master’s thesis, Université Saad Dahleb - Blida, 2019.
- [23] B. Qin, J. Qian, Y. Xin, B. Liu, and Y. Dong. Distracted driver detection based on a cnn with decreasing filter size. IEEE Transactions on Intelligent Transportation Systems, 23(7) :6922–6933, 2021.
- [24] E. Romera, L. M. Bergasa, and R. Arroyo. Need data for driving behavior dnalysis ? presenting the dublic uah-driveset. In IEEE International Conference on Intelligent Transportation Systems (ITSC), pages 387–392, 2016.
- [25] J. Sobieraj. Méthodes et outils pour la conception de Systèmes de Transport Intelligents Coopératifs. PhD thesis, Université Paris-Saclay ; Université d’Evry-Val-d’Essonne, 2018.
- [26] A. Yahi. Clustering des données de puces à ADN. PhD thesis, Université Mohamed Boudiaf-M’Sila, 2019.
- [27] L. Yang, R. Ma, H. M. Zhang, W. Guan, and S. Jiang. Driving behavior recognition using eeg data from a simulated car-following experiment. Accident Analysis & Prevention, 116 :30–40, 2018.

Résumé

La reconnaissance du comportement des conducteurs automobiles dans le cadre des Systèmes de Transport Intelligents (ITS) est devenue de plus en plus importante, étant donné l'augmentation exponentielle de la production et de la vente de moyens de transport, et le nombre croissant de conducteurs insouciants qui contribuent à une fréquence accrue d'accidents. Dans le cadre de ce travail, nous avons proposé un modèle de reconnaissance du comportement de conducteur, qui permet la distinction entre la conduite sûre et non-sûre. Il permet ainsi aux conducteurs de se surveiller eux-mêmes et d'adapter leur conduite si nécessaire, ce qui contribue extrêmement dans la sûreté du trafic routier. L'idée principale de notre solution est l'utilisation des réseaux de neurones récurrents basés sur LSTM combinés avec la méthode de mélange Gaussien (GMM), qui permet de classer le comportement en trois classes distinctes. Les performances de la méthode proposée ont été évaluées en utilisant différentes métriques d'évaluation importantes telles que la précision, le rappel et la F1-mesure. Les résultats montrent que l'approche proposée offre une meilleure performance.

Mots clés : Système de Transport Intelligent (STI), Sûreté, Reconnaissance de comportement, Réseaux de neurones récurrents (RNN), LSTM, Modèle de mélange gaussien (GMM).

Abstract

Recognition of car driver behavior as part of Intelligent Transport Systems (ITS) has become increasingly important, given the exponential increase in the production and sale of means of transport, and the growing number of reckless drivers contributing to an increased frequency of accidents. In this work, we have proposed a driver behavior recognition model that distinguishes between safe and unsafe driving. This enables drivers to monitor themselves and adapt their driving if necessary, making a major contribution to road traffic safety. The main idea behind our solution is the use of LSTM-based recurrent neural networks combined with the Gaussian Mixture Method (GMM), which enables behavior to be classified into three distinct classes. The performance of the proposed method was evaluated using various important evaluation metrics such as precision, recall and F1-measurement. The results show that the proposed approach offers better performance.

Keywords : Intelligent Transportation Systems (ITS), Safety, Behavior recognition, Recurrent Neural Networks (RNN), LSTM, Gaussian Mixture Model (GMM).