



Département : Génie Logistique Et Transport

Mémoire de fin d'étude en vue de l'obtention du diplôme

D'INGENIEUR d'État

- Filière -

Ingénierie Des Transports

- Spécialité -

Ingénierie Des Transports

Thème :

Amélioration de la sécurité routière pilotée par l'IA pour les véhicules de transport public:

Une approche par le management des risques

Réalisé par :

AISSAOUI Mohamed

BOUCHENAF Fadia

Les membres de Jury

M AKNINE Mohamed / MAA	Président
M BOUGHALEB Sadek El Amine / MAA	Promoteur
M ANNAD Oussama / MCB	Co-promoteur
Mme REZKI Nafissa / MCB	Examinatrice
M AGGUINI Chafik / MAB	Examineur

Alger, le 23 /06 /2024

Année universitaire :2023 - 2024

Dédicace

« À mes chers parents, qui m'ont toujours soutenu et guidé avec amour et sagesse. À mes adorables sœurs, FatimaZohra, Imaneet Maroua, pour leur affection et leurs encouragements constants. À mes frères, Mohamed Abd El Kader, pour leur fraternité

À mes petits anges, Abd El Halime, Ayhem, Marame, Abd El Wahab, Sojoud, Selma, et Chahine, qui apportent tant de joie et de lumière dans ma vie.

Je dédie cette œuvre à vous tous. »

Fadia BOUCHENAF

« To my beloved mother,

This work is dedicated to you, for your unwavering love, endless patience, and constant encouragement. Your strength and dedication have been my guiding light throughout this journey. Thank you for believing in me, even when I doubted myself, and for always being there with open arms and a warm heart.

With all my love and gratitude. »

Mohamed AISSAOUI

Remerciement

Au commencement de cette œuvre, nos cœurs s'emplissent d'une gratitude envers le Tout-Puissant, Allah, qui nous a insufflé le courage et la patience, et a facilité notre parcours pour mener à bien ce travail.

Nos notes de remerciements les plus sincères s'élancent vers nos chers encadrants, Monsieur ANNAD Oussama et Monsieur BOUGHALEB Sadek el Amine. Leur soutien indéfectible et leurs encouragements constants ont été comme une lumière guidant nos pas. Leur confiance inébranlable en notre potentiel a été une source de motivation inestimable, nous insufflant chaque jour la force de persévérer et d'exceller. Grâce à leur accompagnement bienveillant, nous avons pu révéler notre capacité à réussir et à concrétiser nos aspirations les plus audacieuses.

Nous tenons aussi à remercier chaleureusement nos deux encadrants chez Logitrans, Monsieur ALAOUCHICHE Abdenour directeur exploitation et Madame DELLOUL Samia chef service central, dont la bienveillance et le professionnalisme ont enrichi notre stage. Leurs conseils avisés et leur soutien constant ont été essentiels à notre développement.

Un solo de reconnaissance particulier est dédié à Monsieur Mouaouia Cherif BOUZID, dont les encouragements au début de notre aventure ont été une source de motivation inestimable.

Nous tenons également à exprimer notre gratitude envers ceux qui nous ont aidés à rassembler les données nécessaires pour notre projet. Leur contribution a été essentielle pour la réussite de ce travail.

Nous adressons également l'expression de notre gratitude la plus profonde aux membres du jury, qui nous honorent en prenant le temps de lire et d'évaluer notre travail. Leurs commentaires éclairés et leurs précieux conseils nous permettront d'affiner notre composition et de l'améliorer encore davantage.

Nous tenons à exprimer notre profonde gratitude envers tous les enseignants, en particulier ceux du département GLT, pour leur soutien inestimable et leurs conseils précieux tout au long de notre parcours universitaire.

Enfin, un refrain vibrant de remerciements s'élève vers nos parents, notre famille et nos amis, dont l'amour et le soutien indéfectible ont été le socle de notre existence. Nous sommes immensément reconnaissants envers toutes les personnes qui, de près ou de loin, ont contribué à la réalisation de ce mémoire. Chaque geste, chaque mot d'encouragement a joué une note dans la symphonie de notre réussite.

À vous tous, du fond du cœur : MERCI

ملخص:

تظل سلامة المرور مصدر قلق كبير في مجال النقل العام بسبب التأثير الكبير للحوادث على الأداء العام لنظام النقل. لتخفيف هذه المخاطر، يقترح مشروعنا نظام إدارة مخاطر سلامة المرور القائم على الذكاء الاصطناعي. يتضمن مشروعنا تطوير نماذج للذكاء الاصطناعي قادرة على التنبؤ بالمخاطر المحتملة المرتبطة بسلوك السائقين. نركز على أسلوب القيادة والتشتت والنعاس. حققنا نتائج واعدة من حيث دقة التنبؤ. يمكن لنماذجنا تحديد السلوكيات المحفوفة بالمخاطر بدقة. تكمن فعالية هذا النظام في استخدام واجهات مستخدم مميزة، واحدة مخصصة للمشرفين والأخرى للسائقين. وبالتالي، يتمتع المشرفون بأداة مراقبة في الوقت الفعلي لأداء السائقين، بينما يتلقى السائقون تنبيهات مخصصة لتصحيح سلوكهم على الطريق. يساهم هذا النهج القائم على الذكاء الاصطناعي في تقليل مخاطر الحوادث وتحسين سلامة المرور.

الكلمات المفتاحية: سلامة المرور، بحوث الحوادث، الحوادث، المراقبة، النظام الذكي، إدارة المخاطر، الذكاء الاصطناعي، أداة، التعلم الآلي، تحليل سلوك السائق، الاكتشاف، النعاس، التشتت، أسلوب القيادة

Résumé :

La sécurité routière demeure une préoccupation majeure dans le domaine des transports publics en raison de l'impact significatif des accidents sur la performance globale du système de transport. Pour atténuer ces risques, notre projet propose un système de gestion des risques de sécurité routière basé sur l'intelligence artificielle. Notre approche consiste à développer des modèles d'intelligence artificielle capables de prédire les risques potentiels liés au comportement des conducteurs. Nous nous concentrons sur le style de conduite, la distraction et la somnolence. Nous avons obtenu des résultats prometteurs en termes de précision de prédiction. Nos modèles peuvent identifier avec précision les comportements à risque. L'efficacité de ce système réside dans l'utilisation de deux interfaces utilisateur distinctes, l'une dédiée aux superviseurs et l'autre aux conducteurs. Les superviseurs disposent ainsi d'un outil de supervision en temps réel des performances des conducteurs, tandis que ces derniers bénéficient d'alertes personnalisées visant à corriger leur comportement au volant. Cette approche basée sur l'intelligence artificielle contribue à réduire les risques d'accidents et à améliorer la sécurité sur nos routes.

Mots-clés : sécurité routière, accidentologie, accident, surveillance, system intelligent, management des risques, AI, outil, machine Learning, analyse de comportement du conducteur, détection, somnolence, distraction, style de conduite.

Abstract:

Road safety remains a critical concern in public transportation due to the significant impact of accidents on overall system performance. To address these risks, our project proposes an AI-based road safety risk management system. Our approach involves developing AI models capable of predicting potential risks associated with driver behavior. Specifically, we focus on driving style, distraction, and drowsiness. We have achieved promising results in terms of prediction accuracy. Our models can accurately identify risky behaviors. The effectiveness of our system lies in the utilization of two distinct user interfaces: one for supervisors and another for drivers. Supervisors benefit from real-time monitoring tools for driver performance, while drivers receive personalized alerts to correct their behavior. This AI-based approach contributes significantly to reducing accident risks and enhancing road safety.

Keywords: Road safety, accident research, accident, monitoring, intelligent system, risk management, AI, tool, machine learning, driver behavior analysis, detection, drowsiness, distraction, driving style

Table des matières

<i>Introduction générale.....</i>	<i>1</i>
--	-----------------

Chapitre 1 : Accidentologie et analyse du comportement des conducteurs

1 Contexte d'une Politique de Sécurité Routière : -----	4
1.1 Le Concept de Système Sûr : 5	
1.2 Les principes de Système Sûr : 6	
2 Le concept du l'analyse de comportement du conducteur-----	7
2.1 Les taches de l'analyse de comportement de conducteur : -----	8
2.2 L'importance de l'analyse de comportement de conducteurs -----	9
3 L'analyse des accidents : étude de cas 'AGEFAL' : -----	10
3.1 Présentation de AGEFAL-----	10
3.2 Les politique en sécurité routiers au sein d'AGEFAL-----	11
3.3 Les défis rencontrés par AGEFAL dans la sécurité routière : -----	12
3.4 Le bilan d'accident pour AGEFAL : -----	13
3.4.1 Collecte des données :-----	13
3.4.2 Visualisation des donnes-----	13
3.5 Evaluation des résultats par rapport la problématique -----	15
4 La Détection d'inattention du conducteur : -----	16
5 La détection du style de conduite : -----	17

Chapitre 2 : Systèmes intelligents au service de la sécurité routière :

1 Les Systèmes Intelligents et le Machine Learning : -----	19
1.1 Définition et Concept de Systèmes Intelligents : -----	19
1.2 Introduction au Machine Learning : -----	19
2 Techniques de Machine Learning pour la Classification et la Détection : -----	21
3 Applications des Systèmes Intelligents dans la Sécurité Routière : -----	22
3.1 Véhicules Connectés et Autonomes : -----	22
3.1.1 Concept de véhicules autonomes : -----	22
3.1.2 Technologies de Réseaux Neuronaux pour les Véhicules Autonomes-----	23
3.2 Systèmes d'Aide à la Conduite Avancée (ADAS) -----	24
3.2.1 Généralité sur ADAS -----	24
3.2.2 Principe de fonctionnement de l'ADAS : -----	24
3.2.3 Les Systèmes Avancés d'Aide à la Conduite (ADAS) : -----	25
3.3 Les Systèmes de Détection et de Prévention des Accidents -----	26

4 L'utilité des SI dans l'analyse de comportement des conducteurs -----27

Chapitre 3 : Conception d'un système intelligent pour l'analyse du comportement :

1 Conception des modèles : -----30

1.1 Modèles de détection de style de conduite agressive-----30

1.1.1 Données d'entrées et sorties : -----30

1.1.2 L'architecture des modèles : -----32

1.2 Modèle de détection de somnolence : -----34

1.2.1 Données d'entrées et sorties : -----34

1.2.2 L'architecture de modèle : -----36

1.3 Modèle de détection de la conduite distraite : -----37

1.3.1 Données d'entrées et sorties : -----37

1.3.2 L'architecture de modèle : -----38

2 L'architecture du système : -----39

2.1 Description des composants : -----39

2.2 Le cas d'utilisation : -----41

Chapitre 4 : Implémentation, tests et résultats

1 Choix technologiques :-----43

2 L'interface utilisateur : -----45

2.1 Les managers : -----45

2.2 Conducteur : -----47

3 Bases des données : -----50

3.1 UAH-DriveSet : -----50

3.2 Real-Life Drowsiness Dataset (UTA RLDD)-----51

3.3 StateFarm Distracted Driver Dataset : -----52

4 Prétraitement des données : -----53

4.1 Détection de conduite agressive : -----53

4.1.1 Prétraitement des données : -----53

4.1.2 Algorithme de prétraitement des données : -----54

4.2 Détection de somnolence : -----55

4.2.1 Prétraitement des données : -----55

4.2.2 Algorithme de prétraitement des données : -----57

4.3 Détection de la conduite distraite : -----58

4.3.1 Prétraitement des données : -----58

5 Sélection et Entraînement des Modèles : -----58

5.1 Détection du style de conduite agressive : -----58

5.2 Détection de la somnolence : -----59

5.3	Détection de la Conduite Distracte :-----	60
6	Résultats : -----	61
6.1	Détection du style de conduite agressive : -----	61
6.2	Détection de la somnolence : -----	66
6.3	Détection de la distraction du conducteur : -----	67
7	Perspectives : -----	68
 <i>Conclusion générale.....</i>		70
<i>Annexes</i>		72
<i>Bibliographies.....</i>		81

Liste des figures :

Chapitre 1 : Accidentologie et analyse du comportement des conducteurs :

Figure 1- 1 Le concept du « système sûr »	5
Figure 1- 2: Systématique de l'analyse du comportement de conducteur	7
Figure 1- 3 Implantation des unités AGEFAL	10
Figure 1- 4: Une section des rapports mensuels fournie par l'outil de géolocalisation utilisé par AGEFAL	11
Figure 1- 5: l'évolution des accidents au sein d'AGEFAL -ALGER	13
Figure 1- 6: la répartition des accidents dans l'air d'activité AGEFAL	14
Figure 1- 7: les causes des accidents au sein d'AGEFAL-ALGER	14
Figure 1- 8: Schéma d'un système d'analyse de la fréquence des clignements des yeux	16
Figure 1- 9: Schéma d'un système de détection d'un conduit agressif.	17

Chapitre 2 : Systèmes intelligents au service de la sécurité routière :

Figure 2- 1 ; les types des captures des véhicules autonomes.	23
Figure 2- 2: Le flux de données de vision pour l'ADAS]	24
Figure 2- 3: Schéma de détection des accidents via GSM et GPS	26
Figure 2- 4: schéma représentative d'un SI.	27

Chapitre 3 : Conception d'un système intelligent pour l'analyse du comportement :

Figure 3- 1: Schéma des dynamiques du véhicule.	31
Figure 3- 2: Schéma de l'architecture du modèle Conv1D montrant les différentes couches.	34
Figure 3- 3: la variation de EAR en temps réel	35
Figure 3- 4: Séquence d'entrée.	35
Figure 3- 5: rapport hauteur/largeur des yeux pendant les clignements éveillés (étiquette 0). et somnolents (étiquette 1)	35
Figure 3- 6: Schéma de l'architecture du modèle Residual network montrant les différentes couches.	37
Figure 3- 7: Vue de la détection de la conduite distraite. Source : dos1.com.ph	37
Figure 3- 8: L'architecture du modèle ViT.	38
Figure 3- 9: Diagramme de composants du système de gestion des risques de la flotte.	40
Figure 3- 10: Diagramme de cas d'utilisation du système de gestion des risques de la flotte.	41

Chapitre 4 : Implémentation, tests et résultats :

Figure 4- 1: Vue d'ensemble de la gestion de la flotte.-----	45
Figure 4- 2:Suivi en temps réel des conducteurs. -----	46
Figure 4- 3:Rapports d'accidents. -----	46
Figure 4- 4:L'interface utilisateur permet au conducteur de choisir la tâche qu'il souhaite analyser et activer--	47
Figure 4- 5: l'interface de surveillance en Temps Réel de comportement de conducteur le cas de détection de style de conduite (a) et la détection de somnolence (b). -----	48
Figure 4- 6:l'interface de l'historique-----	49
Figure 4- 7: Illustration de la détection de la distraction au volant à partir des images de l'ensemble de données StateFarm. Source : Kaggle-----	52
Figure 4- 8:Flux de données prétraitement et détection du style de conduite agressive. -----	55
Figure 4- 9:Flux de données prétraitement et détection de la somnolence. -----	57
Figure 4- 10: Schéma du processus de Transfer Learning pour la détection de la somnolence. Les vidéos spécifiques à un sujet sont prétraitées en séquences de clignement. Les poids du réseau de neurones sont partiellement gelés et partiellement entraînaibles. -----	60
Figure 4- 11: les matrices de confusion pour cinq conducteurs en autoroute. -----	62
Figure 4- 12: les matrices de confusion pour trois conducteurs en route secondaire. -----	63
Figure 4- 13: La matrice de confusion pour les deux sujets. -----	66

Liste des tables

Chapitre 1 : Accidentologie et analyse du comportement des conducteurs :

<i>Tableau 1- 1: Comportements auto-rapportés des usagers de la route</i>	<i>9</i>
---	----------

Chapitre 2 : Systèmes intelligents au service de la sécurité routière :

<i>Tableau 2- 1: Techniques de Machine Learning pour la Classification et la Détection.</i>	<i>21</i>
---	-----------

Chapitre 4 : Implémentation, tests et résultats :

<i>Tableau 4 - 1 : Performance du modèle de détection de style de conduite agressive sur autoroute.</i>	<i>62</i>
<i>Tableau 4 - 2: Performance du modèle de détection de style de conduite agressive sur route secondaire.</i>	<i>63</i>
<i>Tableau 4 - 3 : Les scores de conduite, sur une échelle de 10, des conducteurs lorsqu'ils ont été instruits de conduire de manière agressive sur autoroute.</i>	<i>65</i>
<i>Tableau 4 - 4: Performance du modèle de détection de style de la somnolence.</i>	<i>66</i>

Table des abbreviations

DBA	DriverBehaviorAnalysis.
OMS	Organisation Mondiale de la Santé.
SI	SystemIntelligent.
V2I	Vehicle-to-Infrastructure
V2V	Vehicle-to-Vehicle
V2P	Vehicle-to-Pedestrian
GPS	Global PositioningSystem.
CAN-bus	Controller Area Network -bus
LiDAR	Light Detection and Ranging.
Radar	Radio Detection and Ranging.
GSM	Global System forMobile Communications.
FIFO	First-In, First-Out
ADAS	Advanced Driver-Assistance Systems.
AEB	AutomaticEmergency Breaking.
LDW	Lane DepartureWarning.
BSM	Blind Spot Monitoring.
ACC	Adaptive Cruise Control.
TSR	Traffic SignRecognition.
IA	Intelligence Artificielle.
ML	Machine Learning.
CNN	ConvolutionalNeural Network.
ConvTrans	ConvolutionalTransformer.
SVM	Support VectorMachine.
LSTM	Long Short-TermMemory.
CNN-BiLSTM	Convolutional Neural Network - Bidirectional Long Short-Term Memory
RCNN	Region-based Convolutional Neural Network.
SLAM	SimultaneousLocalizationAnd Mapping.
YOLO	You Only Look Once.
ReLU	RectifiedLinear Unit.
EAR	Eye Aspect Ratio.
Conv1D	Convolutional1Dimension.
ViT	Vision Transformer.
KSS	KarolinskaSleepinessScale.
FFT	Fast Fourier Transform.
Adam	Adaptive Moment Estimation
GRU	GatedRecurrentUnit.

Introduction générale

Introduction générale :

‘Au cœur du désert algérien, sous un soleil implacable, un camion suivait seul une route interminable. Le conducteur, épuisé par le voyage du nord au sud, luttait contre la fatigue. Les heures s'écoulaient, la chaleur étouffante enveloppait tout. Emporté par le sommeil, le murmure des pneus sur l'asphalte brûlant le berçait. Inévitablement, le camion dévia et, dans un silence absolu, s'écrasa. Dans l'immensité déserte, son périple s'acheva non avec fracas, mais dans une tranquillité tragique.’

Cette histoire tragique nous est souvent racontée lorsqu'on aborde le sujet des accidents au sein de l'entreprise. En parallèle, ces dernières années, les accidents de bus tragiques, entraînant la mort de centaines d'Algériens et faisant de nombreux blessés, ont marqué l'ensemble du pays.

Dans le vaste réseau mondial de transport, la sécurité routière apparaît comme un problème de santé publique crucial. En 2021, environ 1,19 million de personnes ont perdu la vie sur la route, et entre 20 et 50 millions de personnes supplémentaires ont subi des blessures, selon le rapport de l'Organisation mondiale de la santé [1]. Malgré les progrès technologiques et les réglementations en matière de sécurité routière, les accidents de la route continuent de représenter une menace majeure pour la santé publique internationale, soulignant l'importance cruciale de stratégies globales et inclusives pour améliorer la sécurité sur nos routes.

Le comportement des conducteurs est un facteur clé dans la majorité de ces accidents [2], [3]. La vitesse excessive, la conduite distraite et la fatigue conduisent souvent à des conséquences désastreuses. Cette réalité soulève une question cruciale : **‘comment pouvons-nous modifier le comportement des conducteurs pour améliorer la sécurité routière ?’**

La réponse réside, en partie, dans les efforts collaboratifs du monde académique et de l'industrie. Les universités, les entreprises technologiques et les acteurs de transports sont à l'avant-garde de la recherche pionnière en analyse comportementale et développent des programmes visant à réduire les risques de la sécurité routière.

L'innovation technologique joue un rôle crucial dans cette lutte contre les accidents mortels de la route. Les systèmes avancés d'aide à la conduite (ADAS), tels que le freinage automatique et l'assistance au maintien de voie, deviennent de plus en plus sophistiqués avec l'intégration de l'IA et de l'apprentissage automatique, offrant des mécanismes de sécurité non seulement réactifs mais prédictifs. De plus, l'essor de la télématique et des appareils IoT

permet une surveillance en temps réel des comportements des conducteurs, fournissant ainsi des informations basées sur les données qui conduisent à des améliorations concrètes de la sécurité.

L'objectif de ce projet est de contribuer à ces efforts en cours en se concentrant sur le développement et l'évaluation d'un système qui prédit et atténue les comportements de conduite à risque. En tirant parti d'algorithmes d'apprentissage automatique de pointe et de données de conduite réelles, ce projet aspire à réduire l'incidence des accidents de la route et à ouvrir la voie à des routes plus sûres. Notre objectif n'est pas seulement de repousser les frontières technologiques de la sécurité routière, mais également d'inculquer un respect plus profond de la vie à chaque conducteur.

S'appuyant sur la compréhension fondamentale des problèmes en question, notre méthodologie adopte une approche rigoureuse et basée sur les données pour relever efficacement les défis de la sécurité routière. La première étape passe par une analyse des données spécifiques à chaque flotte. Reconnaissant que chaque flotte possède des caractéristiques uniques et des nuances opérationnelles, nous approfondissons les données disponibles pour identifier les principales lacunes dans les mesures de sécurité et identifier les comportements spécifiques des conducteurs qui nécessitent une intervention.

Une fois ces lacunes identifiées, la phase suivante consiste à sélectionner et à adapter des algorithmes et des technologies adaptés à nos besoins. Cela implique de tirer parti de techniques d'apprentissage automatique et d'intégrer des technologies de capteurs pour développer un système robuste capable d'évaluer les risques avec précision tout en répondant efficacement à la nature dynamique des comportements des conducteurs et des conditions routières.

Notre objectif ultime est de créer un système de sécurité proactif. Ce système détectera et réagira aux dangers en temps réel, mais contribuera également à réduire les incidents de la route à long terme. Notre objectif est de modifier les comportements des conducteurs à long terme grâce à un feedback et à une éducation continue [4], rendant ainsi les routes plus sûres pour tous.

Les chapitres à venir aborderons les thèmes essentiels suivants :

- **Accidentologie et analyse du comportement des conducteurs** : Ce chapitre offre une revue de la littérature approfondie sur la sécurité routière et l'analyse du comportement des conducteurs, en plus d'examiner les données spécifiques aux accidents survenus au sein de l'entreprise.
- **Systèmes intelligents au service de la sécurité routière** : Ce segment explore les différents systèmes intelligents utilisés en sécurité routière, avec un accent particulier sur les applications d'apprentissage automatique visant à améliorer la sécurité.
- **Conception d'un système intelligent pour l'analyse du comportement** : détaille la conception de notre système, y compris les modèles d'apprentissage automatique et l'architecture logicielle.
- **Implémentation, tests et résultats** : discute des choix technologiques, présente l'interface utilisateur et présente les résultats et les interprétations des tests.
- **Conclusion générale** : résume les principales conclusions et l'impact de notre projet sur la sécurité routière.

Chapitre 1 :

***Accidentologie et analyse du
comportement des conducteurs***

Introduction :

En reconnaissant le rôle central de l'être humain en tant que lien entre les principaux facteurs d'accidents, il devient essentiel de prioriser l'analyse et la prédiction de ses comportements. Cet objectif revêt une grande importance pour réduire la fréquence de ces tragédies en évaluant attentivement les actions humaines qui sont des facteurs majeurs contribuant à ces accidents, notamment l'excès de vitesse, la conduite sous l'influence de substances diverses, la fatigue et les distractions. Chacun de ces comportements entraîne des conséquences indésirables et nécessite une attention particulière dans les efforts visant à améliorer la sécurité routière.

Ce chapitre vise à expliquer le concept de l'analyse de comportement du conducteur et son importance dans la fréquence des accidents. Nous commencerons par définir l'analyse de comportement du conducteur et ses différentes tâches. Ensuite, nous procéderons à une analyse approfondie de l'évolution des accidents en nous basant sur les données de l'entreprise AGEFAL. Cette analyse nous permettra d'identifier les aspects clés des accidents afin de mieux définir les problématiques auxquelles nous sommes confrontés.

1 Contexte d'une politique de sécurité routière :

La sécurité routière représente un enjeu crucial à l'échelle mondiale. Actuellement, les accidents de la route sont considérés comme la neuvième cause de décès, affectant toutes les tranches d'âge. Chaque année, plus de 1,19 million de vies sont perdues et jusqu'à 50 millions de personnes subissent des blessures non mortelles à cause des accidents de la route. Ces incidents, bien que fréquents, sont à la fois prévisibles et évitables grâce à une compréhension approfondie des facteurs de risque et des mesures de sécurité éprouvées. [5]

La sécurité routière repose sur une approche systémique qui intègre la tolérance aux erreurs humaines et vise à créer des systèmes de transport sûrs pour tous les usagers de la route

1.1 Le Concept de système sûr :

Le concept de "système sûr" offre un cadre durable pour aborder de manière globale les facteurs de risque des accidents de la route et les interventions nécessaires. Cette approche s'inspire de la stratégie Vision Zéro de la Suède, qui vise à long terme à éviter que quiconque soit tué ou gravement blessé sur la route. Elle repose sur l'idée que le système de transport doit être conçu pour prévenir les accidents et minimiser les conséquences des erreurs humaines [6]



Figure 1- 1 Le concept du « système sûr » [6]

1.2 Les principes de système sûr :

L'approche du système sûr vise à améliorer la sécurité routière en intégrant la prévention des accidents, la réduction de leurs conséquences et la tolérance aux erreurs humaines. Cela se réalise par une combinaison des caractéristiques de sécurité des véhicules, d'une infrastructure routière sûre, du respect des limitations de vitesse, ainsi que d'une prise en charge médicale d'urgence efficace.[7]

Prévention des accidents :

- Conception des infrastructures : L'approche du système sûr met l'accent sur la conception des infrastructures routières pour minimiser les risques d'accident. Cela inclut des éléments tels que des passages piétons sécurisés, des pistes cyclables, et des dispositifs pour ralentir la circulation.
- Réglementation et normes : L'établissement de limites de vitesse appropriées, de règles de conduite strictes, et de normes de sécurité pour les véhicules est crucial pour prévenir les accidents.

Réduction des conséquences des accidents :

- Limitation des forces d'Impact : La conception des véhicules et des routes doit permettre de limiter les forces d'impact en cas de collision pour réduire les traumatismes. Cela inclut l'utilisation de technologies comme les airbags, les systèmes de contrôle de stabilité, et les zones de déformation des véhicules.
- Interventions post-Accident : L'approche du système sûr insiste sur l'importance de la rapidité et de l'efficacité des interventions après un accident, y compris les services de secours et les soins médicaux d'urgence.

Intégration de l'erreur humaine :

- Conception tolérante aux erreurs : Reconnaître que les erreurs humaines sont inévitables et concevoir des systèmes de transport qui tolèrent ces erreurs sans entraîner de conséquences graves est un principe fondamental de l'approche du système sûr. [8]

Cependant, il est crucial de comprendre l'interaction des conducteurs avec ce système pour améliorer la sécurité routière. L'analyse du comportement des conducteurs permet de voir comment ils réagissent aux conditions routières variées et aux systèmes de sécurité en place. Dans la section suivante nous discuterons du concept de l'analyse de comportement du conducteur et de son importance dans cette approche

2 Le concept de l'analyse de comportement du conducteur

Le comportement des conducteurs est un facteur crucial dans la sécurité routière, influençant directement le risque d'accidents. Comprendre et améliorer ce comportement est essentiel pour réduire les incidents sur les routes.

L'analyse du comportement du conducteur (driver behavior analysis (DBA)) consiste à observer et à évaluer la manière dont les conducteurs pilotent leur véhicule. Elle se concentre sur les actions, qu'elles soient intentionnelles ou non, qui influent sur la sécurité et l'efficacité de la conduite. Cette analyse examine des aspects tels que le freinage, l'accélération, les changements de voie, ainsi que la concentration et la vigilance du conducteur. Son objectif est d'identifier les comportements à risque, de favoriser une conduite plus sûre, d'optimiser la gestion de flotte. [9]




Figure 1- 2: Systématique de l'analyse du comportement de conducteur [9]

Selon la figure (1-2) L'analyse du comportement des conducteurs (DBA) utilise des données provenant de smartphones, GPS, CAN-bus, LIDAR, et radar pour collecter des informations détaillées sur les habitudes de conduite. Cette analyse inclut la détection du style de conduite, l'identification du conducteur, la détection de somnolence et de conduite en état d'ivresse, ainsi que la prédiction des incidents. Pour ce faire, des modèles tels que l'apprentissage automatique, l'apprentissage profond, les méthodes basées sur des seuils et la logique floue sont utilisés pour développer des systèmes d'évaluation sophistiqués et efficaces.

2.1 Les tâches de l'analyse de comportement de conducteur :

L'analyse du comportement du conducteur est un domaine étendu englobant plusieurs facteurs influençant le taux d'accidents. Parmi les nombreuses tâches qui le composent, on retrouve notamment :

- L'identification des conducteurs

Ce processus base sur des techniques telles que la reconnaissance faciale, les empreintes digitales ou les cartes d'identité électroniques pour s'assurer que la personne au volant est autorisée à conduire ce véhicule. Cela peut être particulièrement important dans les cas de véhicules partagés ou d'entreprises de transport pour garantir la sécurité et la responsabilité.

- La détection de la conduite en état d'ivresse

Cette tâche repose souvent sur l'utilisation de capteurs d'alcoolémie dans le véhicule ou sur des méthodes plus avancées telles que l'analyse des mouvements oculaires ou la surveillance des réactions physiologiques du conducteur. L'objectif est de repérer les signes d'ivresse ou d'altération de l'état mental qui pourraient compromettre la sécurité de la conduite.

- La prévision des événements de conduite

Son objectif est de prédire les événements de conduite sur la base d'une analyse en temps réel des informations collectées par des capteurs à l'intérieur de la voiture, tels que des caméras, des radars et les lidars. Son objectif est d'anticiper les situations dangereuses sur la route, comme la présence d'obstacles, de piétons, de feux tricolores ou de conditions météorologiques défavorables.

- La détection de l'inattention du conducteur

Cette tâche utilise généralement des capteurs pour surveiller le comportement du conducteur, tels que la détection des mouvements des yeux, la reconnaissance vocale ou la surveillance de l'activité sur le volant. L'objectif est d'identifier les signes d'inattention, de fatigue ou de distraction qui pourraient compromettre la sécurité de la conduite.

- L'analyse du style de conduite.

Cette activité implique l'évaluation des comportements de conduite du conducteur en examinant diverses données telles que la vitesse, les accélérations, les décélérations, les virages et les freinages brusques.

2.2 L'importance de l'analyse de comportement de conducteurs

L'objectif principal de cette analyse est de réduire l'influence des facteurs de risque identifiés par l'OMS. Ces tâches visent à identifier les comportements à risque tels que la vitesse excessive, la distraction au volant, et la conduite sous l'influence de l'alcool ou de drogues.

Ces éléments sont présentés de manière organisée dans le tableau 1 qui présente les résultats d'une enquête réalisée auprès de 114 pays sur les comportements des usagers de la route. L'enquête a été menée par l'Organisation mondiale de la santé (OMS) dans le cadre de son rapport mondial sur la sécurité routière 2023.

	Rapport de situation mondial sur la sécurité routière Enquête 2023(114pays)	Rapport de l'Association Européenne de Recherche en Enquêtes (48 pays)
Excès de vitesse	1-66 %	50%
Conduite en état d'ivresse	10 % des décès (77 pays)	16-21%
Distraction (utilisation du téléphone portable)	--	29 – 52%

Tableau 1- 1:1 Comportements auto-rapportés des usagers de la route [10]

3 L'analyse des accidents : étude de cas 'AGEFAL' :

3.1 Présentation de AGEFAL

La filiale AGEFAL se positionne en tant qu'acteur majeur dans le domaine du transport routier de marchandises, avec une spécialisation marquée dans le transport spécifique, ses activités englobent un large éventail de services, notamment :

- Le transport de marchandises liquides en vrac, telles que le carburant, le bitume
- Le transport de marchandises en vrac, comprenant les agrégats et les minerais.

En plus de ces services de transport, AGEFAL propose une gamme complète de prestations complémentaires, telles que l'affrètement, le groupage, le stockage, la livraison, la distribution, la consignation, ainsi que la commission de transport et le courtage de fret.

AGEFAL poursuit son activité traditionnelle de transporteur routier de marchandises à travers tout le territoire, avec une concentration particulière sur le Sud du pays. La société dispose d'une flotte de 318 camions, auxquels s'ajoutent les camions loués pour répondre à la demande croissante de ses services.

Implantation nationale :

AGEFAL dispose d'un vaste réseau de transport couvrant l'ensemble du territoire algérien. Ses unités sont stratégiquement implantées dans différentes régions, notamment à Annaba, Arzew, Bouira, Skikda, Batna, Ghardaia, Hassi Messaoud, Sidi Bel Abbès, Tlemcen, Béchar et Adrar.




Figure 1- 3 Implantation des unités AGEFAL

3.2 Les politique en sécurité routiers au sein d'AGEFAL

- Inspection des camions

AGEFAL assure la sécurité de sa flotte en effectuant des inspections régulières de chaque camion, en suivant de près l'entretien et la maintenance pour garantir leur bon fonctionnement. (Contrôle des freins, des pneus, des feux ...)

Documentation complète : Chaque chauffeur de camion est accompagné d'une fiche technique détaillée et d'une feuille de route précise, contenant toutes les informations nécessaires sur l'itinéraire prévu et les délais de livraison.

Validation préalable : Avant chaque mission, une validation est effectuée pour s'assurer que le camion est prêt à réaliser sa mission en toute sécurité.

- Suivi des trajets :

AGEFAL assure le suivi de ses camions grâce à un outil de géolocalisation. Cet outil fournit des informations détaillées sur les déplacements des camions pendant leurs missions. Bien que la précision et la présentation des informations puissent parfois être limitées, cet outil reste un élément crucial pour la gestion des risques.

Rapport mensuel des trajets

ATS_LOGITRANS (Location)

Du: 01/02/2023 Vers 31/01/2024



Mois	Description du bien	Durée de conduite vs Temps d'attente	Durée de conduite (hh:mm:ss)	Temps d'attente (hh:mm:ss)	Durée (hh:mm:ss)	Durée de ralenti (hh:mm:ss)	Temps de parking (hh:mm:ss)	Distance (km)	Days With Trips	Vitesse moy. (km/h)	Vitesse max. (km/h)
Février - 2023	03ZC506		117:46:06	63:12:35	180:58:41	61:47:10	491:01:19	6 862,25	27	58,27	107,00
Mars - 2023	03ZC506		176:08:10	74:55:40	251:03:50	80:46:14	492:56:10	8 902,02	28	50,54	106,00
Avril - 2023	03ZC506		121:13:52	64:03:39	185:17:31	52:35:57	534:42:29	6 684,09	28	55,14	102,00
Mai - 2023	03ZC506		163:53:46	83:36:19	247:30:05	68:24:37	496:29:55	8 306,73	31	50,68	105,00
Juin - 2023	03ZC506		84:53:29	49:55:34	134:49:03	38:51:09	585:10:57	4 443,14	27	52,34	101,00
Juillet - 2023	03ZC506		152:22:20	123:25:46	275:48:06	74:05:58	468:11:54	7 883,39	31	51,74	101,00
Août - 2023	03ZC506		149:09:28	156:56:05	306:05:33	150:57:19	437:54:27	6 099,06	30	40,89	102,00
Septembre - 2023	03ZC506		130:38:42	89:34:17	220:12:59	76:13:17	499:47:01	7 411,56	29	56,73	102,00
Octobre - 2023	03ZC506		116:12:49	54:32:40	170:45:29	40:39:51	573:14:31	6 424,77	28	55,28	102,00
Novembre - 2023	03ZC506		105:57:43	41:34:19	147:32:02	33:54:18	572:27:58	6 334,25	25	59,78	106,00
Décembre - 2023	03ZC506		52:27:58	103:29:29	155:57:27	76:54:24	588:02:33	1 208,78	25	23,04	92,00
Janvier - 2024	03ZC506		36:19:24	47:15:15	83:34:39	51:14:27	660:25:21	1 083,98	19	29,84	101,00

Figure 1- 4: Une section des rapports mensuels fournie par l'outil de géolocalisation utilisé par AGEFAL

- Gestion des accidents :

AGEFAL met en place des protocoles pour gérer les accidents sur les routes. Cela inclut la mise en œuvre de procédures d'urgence efficaces pour intervenir rapidement en cas d'accident. De plus, la société établit des rapports d'accident détaillés pour documenter les événements survenus.

En cas d'accident, des experts spécialisés sont dépêchés sur les lieux pour soutenir les enquêtes menées par les gendarmeries et la police et pour décrire les circonstances de l'accident de manière précise à travers un rapport d'expertise approfondie.

Enfin, AGEFAL travaille avec les agences d'assurance pour estimer les dommages et faciliter le processus de réparation et d'indemnisation des parties impliquées.

3.3 Les défis rencontrés par AGEFAL dans la sécurité routière :

La société AGEFAL rencontre des défis dans son activité de transport routier, ce qui se traduit par une fréquence élevée d'accidents. Plusieurs facteurs contribuent à cette situation, notamment :

L'étendue géographique de son air d'activité, qui couvre notamment le grand Sud algérien qui force les conducteurs de parcourir de longues distances dans des conditions parfois difficiles, ce qui peut affecter à la fois leurs performances et celles des camions. De plus, la qualité des réseaux de communication rend parfois difficile le suivi des camions en temps réel.

Le comportement des conducteurs est également un élément déterminant dans la prévention des accidents. AGEFAL adopte une approche de gestion des ressources humaines basée sur la méthode FIFO, où la rémunération des conducteurs est proportionnelle à la distance parcourue lors de leurs missions. Cette méthode encourage les chauffeurs à atteindre rapidement leur destination afin de pouvoir effectuer d'autres trajets, ce qui peut parfois compromettre la sécurité sur la route.

3.4 Le bilan d'accident pour AGEFAL :

3.4.1 Collecte des données :

À travers l'examen minutieux des archives d'AGEFAL-ALGER, une collecte exhaustive de données sur les accidents a été réalisée dans le but d'évaluer le niveau de sécurité routière au sein de l'entreprise. Cette démarche analytique approfondie a permis de recueillir des informations essentielles telles que la nature de l'accident, ses causes, son lieu, ainsi que les dommages matériels et humains associés. En analysant ces données de manière proactive, nous avons repéré les principaux éléments de risque associés aux incidents routiers. Cette compréhension approfondie nous permettra de déployer des mesures préventives précises afin d'améliorer la sécurité des trajets de nos collaborateurs et de réduire les risques d'accidents

3.4.2 Visualisation des données

- L'évolution des accidents

Au sein de l'unité d'AGEFAL à Alger, une fréquence significative d'accidents a été constatée, englobant à la fois des incidents liés à la circulation et des accidents survenant lors des opérations de manutention des marchandises. Après une analyse méticuleuse des données et une sélection rigoureuse des cas les plus pertinents par rapport à nos objectifs, il est apparu qu'au cours des trois dernières années, un total de 49 incidents ont été répertoriés. Notamment, une tendance à la hausse a été observée au cours des deux dernières années.




Figure 1- 5: l'évolution des accidents au sein d'AGEFAL -ALGER

- La répartition des accidents :

L'analyse visuelle des données relatives aux accidents met en évidence une prédominance marquée des incidents dans la région sud saharienne de l'Algérie, représentant 66 % des cas recensés.




Figure 1- 6:la répartition des accidents dans l'air d'activité AGEFAL

- Les causes des accidents

Dans l'étude des causes des accidents, trois facteurs prédominants ont été identifiés. Dans un tiers des cas, soit 33%, l'excès de vitesse a été déterminant, soulignant. Environ 30% des accidents sont attribuables à l'inattention du conducteur. De plus, dans 17% des cas, la perte de contrôle du véhicule a été la cause principale, souvent liée à des comportements imprudents ou à des conditions météorologiques difficiles.




Figure 1- 7:les causes des accidents au sein d'AGEFAL-ALGER

3.5 Evaluation des résultats par rapport la problématique

Cette observation met en lumière l'influence significative des caractéristiques spécifiques de l'infrastructure routière locale sur le comportement des conducteurs et leur performance. Les routes de la zone saharienne se distinguent par leur longueur et leur rectitude, ainsi que par un faible volume de trafic. Cependant, une préoccupation majeure réside dans le fait qu'une partie importante de ces itinéraires, souvent supérieure à 200 kilomètres, manque d'équipements et de services essentiels. Cette situation peut inciter les conducteurs à adopter des comportements agressifs ou à ressentir une fatigue accrue, augmentant ainsi considérablement le risque d'accidents. Ces facteurs montrent comment les conditions routières peuvent influencer le comportement humain et contribuer aux risques mortels sur les routes.

Grâce aux données fournies par l'OMS sur les pourcentages des facteurs de risque liés aux accidents de la route et aux statistiques de l'AGFAL, nous avons identifié des priorités clés pour notre projet de fin d'études. En particulier, les chiffres concernant la vitesse excessive, l'alcool et les drogues au volant, ainsi que la distraction, mettent en lumière l'importance cruciale de développer des systèmes de détection avancés pour améliorer la sécurité routière.

Dans ce contexte, la détection du style de conduite et la détection de la somnolence émergent comme des problématiques essentielles à résoudre grâce à l'intégration des technologies dans un système global qui comprend également l'amélioration des politiques de sécurité, afin de réduire efficacement le nombre d'accidents graves sur nos routes.

Notre projet s'efforcera donc de développer des solutions innovantes pour ces défis critiques, en tirant parti des dernières avancées technologiques et des données probantes fournies par les organisations internationales de santé et de sécurité routière.

Cette section se concentrera sur les tâches que nous considérons comme ayant le plus d'impact sur la sécurité routière et la performance des conducteurs sur la route. Notamment :

- La Détection d'inattention du conducteur
- La détection du style de conduite

4 La Détection d'inattention du conducteur :

L'inattention des conducteurs est un enjeu majeur de sécurité routière, influençant directement la fréquence et la gravité des accidents de la route à travers le monde. Cette forme de distraction peut résulter de diverses activités qui détournent l'attention du conducteur de la route, comme l'utilisation de téléphones portables, manger, ajuster la radio, ou même simplement penser à autre chose. Ces comportements réduisent le temps de réaction du conducteur et sa capacité à anticiper les dangers potentiels sur la route.

En d'autres termes, elle englobe toute action qui détourne le regard de la route (distraction visuelle), qui détourne l'esprit de la conduite (distraction cognitive), ou qui détourne les mains du volant (distraction manuelle).[11]

La somnolence au volant est une condition critique associée à des risques d'accident accrus sur les routes. Pour détecter la somnolence, diverses approches ont été explorées, telles que l'utilisation de vidéos et de signaux biomédicaux. Ces méthodes surveillent les signes physiologiques de la somnolence, comme les mouvements oculaires et la fréquence cardiaque, afin d'alerter les conducteurs en cas de risque accru d'endormissement au volant. [12]

Les techniques basées sur des caractéristiques visuelles utilisent la vision par ordinateur pour détecter la somnolence. Elles analysent divers aspects du visage du conducteur pour identifier les signes de fatigue, comme l'état des yeux (ouverts, fermés, à semi-ouverts), le clignement des yeux (fréquence et durée), les mouvements de la bouche et les signes de bâillement, ainsi que les expressions faciales pour détecter les changements subtils indiquant une baisse d'attention ou de la fatigue.




Figure 1- 8: Schéma d'un système d'analyse de la fréquence des clignements des yeux [11]

5 La détection du style de conduite :

La détection du style de conduite c'est un élément essentiel pour la prévention des accidents routiers. Il s'agit d'une tâche critique qui implique l'évaluation de différents paramètres tels que les accélérations, les décélérations et les manœuvres soudaines.

Il existe plusieurs travaux qui visent à détecter différents styles de conduite. Par exemple, l'article [12] montre que le style de conduite peut être divisé en deux catégories : agressif et normal. D'autres études ajoutent une troisième classe qui représente le style écologique [13] . Cependant, dans [14] et [15], on trouve plus de cinq classes. Cette variété de classes est due aux différentes bases de données et aux différents modèles utilisés pour la détection.

La conduite agressive est l'un des comportements les plus couramment détectés sur la route, bien que sa définition exacte soit souvent sujette à débat. Malgré ça, les chercheurs s'accordent généralement sur deux aspects principaux : le caractère dangereux de cette conduite et son intentionnalité et parmi les comportements spécifiques associés à la conduite agressive, on trouve notamment une vitesse excessive, des freinages et des accélérations brusques, ainsi qu'une utilisation fréquente et inappropriée du klaxon [16].

De plus, son rôle dans les accidents de la route est largement reconnu, comme en témoignent les études menées dans différents pays qui ont établi un lien entre la conduite agressive et une augmentation du nombre d'accidents [18].




Figure 1- 9: Schéma d'un système de détection d'un conduit agressive. [17]

Conclusion :

La sécurité routière demeure une préoccupation majeure à l'échelle mondiale en raison des conséquences dévastatrices des accidents de la route sur les vies humaines et les infrastructures. L'analyse des données des accidents a mis en lumière que le comportement des conducteurs, en particulier en termes de vitesse excessive et de somnolence au volant, constitue un facteur déterminant dans la survenance de ces incidents.

Ces comportements à risque augmentent non seulement la probabilité d'accidents, mais aussi la gravité des blessures subies. Il est donc impératif de mettre en place des mesures rigoureuses pour sensibiliser les conducteurs aux dangers de ces comportements et pour renforcer les régulations visant à les prévenir. Alors que le premier chapitre a exploré les fondements de la sécurité routière, y compris les principes du système sûr et l'importance de l'analyse du comportement des conducteurs, le chapitre suivant se penchera sur l'intégration des systèmes intelligents dans la sécurité routière. Les progrès technologiques offrent des opportunités inédites pour améliorer la sécurité sur nos routes grâce à l'utilisation de systèmes intelligents capables de détecter et de prévenir les comportements à risque.

Chapitre 2 :
Systèmes intelligents
Au service de la sécurité routière

Introduction

La sécurité routière est un enjeu majeur pour les sociétés modernes, face à l'augmentation constante du nombre de véhicules et des kilomètres parcourus. Les accidents de la route causent chaque année des millions de décès et de blessures graves à travers le monde, ainsi que des pertes économiques substantielles. Dans ce contexte, l'adoption de solutions technologiques avancées est devenue indispensable pour améliorer la sécurité des infrastructures routières et réduire le nombre d'accidents.

Dans ce chapitre, nous discuterons des systèmes intelligents et de leur application pour améliorer la sécurité routière. Nous explorerons également les fondements du Machine Learning et ses techniques pour la classification et la détection.

1 Les systèmes intelligents et le machine learning :

1.1 Définition et concept de systèmes intelligents :

Un système intelligent est conçu pour imiter certaines capacités cognitives humaines, telles que la perception, la compréhension, la planification et la prise de décision. Ces systèmes peuvent comprendre des logiciels, des capteurs, des processeurs et des algorithmes qui travaillent ensemble pour réaliser des tâches complexes. Les caractéristiques clés des systèmes intelligents incluent l'autonomie, l'adaptabilité, l'apprentissage et la robustesse face aux environnements dynamiques.

Les systèmes intelligents peuvent être catégorisés en plusieurs types selon leur application et leur complexité. Par exemple, les systèmes embarqués dans les véhicules, les systèmes de gestion de la circulation et les infrastructures intelligentes qui intègrent des capteurs et des technologies de communication pour une gestion optimale du trafic. L'élément central de ces systèmes est leur capacité à traiter et à analyser de vastes quantités de données en temps réel, ce qui est rendu possible par les avancées en machine Learning. [19]

1.2 Introduction au Machine Learning :

Le Machine Learning, également appelé apprentissage automatique, est une branche essentielle de l'intelligence artificielle. Elle se concentre sur les méthodes et les algorithmes permettant à un ordinateur d'apprendre et de s'améliorer. Ce domaine est étroitement lié à l'intelligence artificielle, en particulier à l'intelligence computationnelle. [20]

La théorie de l'apprentissage repose sur des outils mathématiques issus de la théorie des probabilités et de la théorie de l'information, permettant d'évaluer l'efficacité de différentes méthodes les unes par rapport aux autres.

Parmi les types d'algorithmes d'apprentissage automatique, on distingue principalement trois catégories :

- L'apprentissage supervisé.
- L'apprentissage non supervisé.
- L'apprentissage par renforcement.

L'apprentissage supervisé :

L'apprentissage supervisé est une méthode d'apprentissage automatique où l'algorithme est entraîné sur un ensemble de données étiquetées. Ces données étiquetées sont des exemples où la réponse souhaitée est connue à l'avance. [21]

L'apprentissage non supervisé :

La deuxième catégorie d'algorithmes d'apprentissage automatique est connue sous le nom d'apprentissage non supervisé. Contrairement à l'apprentissage supervisé où les données sont préalablement étiquetées, dans l'apprentissage non supervisé, les données ne sont pas étiquetées et l'algorithme doit en tirer des conclusions par lui-même.

Les algorithmes d'apprentissage non supervisé sont souvent utilisés dans des problèmes de regroupement (clustering), où l'objectif est de comprendre et de montrer les relations entre différents objets. Une approche courante consiste à définir une mesure de similarité entre deux objets, puis à regrouper les objets qui sont les plus similaires les uns aux autres. [21]

A. L'apprentissage par renforcement :

L'apprentissage par renforcement est une méthode d'intelligence artificielle qui vise à améliorer les performances d'un système en interagissant avec son environnement. Dans ce type d'apprentissage, le système ajuste ses actions en fonction des réponses qu'il reçoit de l'environnement. Par exemple, considérons un système de recommandation de films qui suggère des films à un utilisateur. À chaque interaction, le système apprend des préférences de l'utilisateur et affine ses recommandations en conséquence. [21]

1.3 Techniques de Machine Learning pour la Classification et la Détection :

Algorithme de ML	Principe	Application dans la sécurité routier
Réseaux de neurones profonds	Capables de modéliser des relations complexes dans les données et sont particulièrement efficaces pour la détection d'objets et la reconnaissance de formes	Réseaux de neurones convolutifs (CNN) sont souvent utilisés pour la reconnaissance d'images, comme la détection de piétons
Support Vector Machines (SVM)	Utilisés pour la classification binaire et multi class. Ils cherchent à trouver l'hyperplan qui sépare les classes avec la marge la plus large possible.	Classifiez les séquences de conduite comme normales ou anormales, en se basant sur les données des capteurs de véhicules.
K-Means	Utile pour partitionner les observations en K clusters dans lesquels chaque observation appartient au cluster avec la moyenne la plus proche	Segmentation des zones géographiques selon les types d'accidents. Par l'identification des clusters de zones à haut risque sur la base de données historiques d'accidents
Réseaux de Neurones Artificiels (ANN)	Utilisé pour des tâches complexes où les relations entre les variables ne sont pas linéaires.	Les (ANN) peuvent analyser les données des capteurs pour identifier les signes de somnolence et alerter le conducteur
Random Forest	Utilisé pour Classification et Régression. Il crée plusieurs arbres de décision et les combine pour obtenir une prédiction plus précise et robuste.	Peut être utilisé pour déterminer quelles variables (comme la vitesse, la distraction, l'alcool) ont le plus grand impact sur la survenance des accidents.

Tableau 2- 1:Techniques de Machine Learning pour la Classification et la Détection.

2 Applications des systèmes intelligents dans la sécurité routière :

Les Systèmes intelligents (SI) jouent un rôle crucial dans cette démarche en intégrant des technologies de pointe pour optimiser la gestion du trafic et renforcer la sécurité routière. Ces systèmes utilisent des communications avancées, des capteurs sophistiqués, des algorithmes de traitement de données et des dispositifs embarqués dans les véhicules pour collecter, analyser et diffuser des informations en temps réel. Cette approche permet non seulement de réagir rapidement aux situations d'urgence, mais aussi de prévenir les accidents en fournissant des avertissements anticipés aux usagers de la route.

Les SI comprennent une variété de technologies et de dispositifs, tels que les systèmes d'aide à la conduite avancée (ADAS), les véhicules connectés, les réseaux de communication entre véhicules et infrastructures (V2I), et les centres de gestion du trafic en temps réel. Ensemble, ces composants forment un écosystème intégré qui vise à améliorer la fluidité du trafic, réduire les embouteillages et minimiser les risques d'accidents.

2.1 Véhicules connectés et autonomes :

2.1.1 Concept de véhicules autonomes :

Les technologies des véhicules connectés et autonomes représentent une révolution majeure dans le domaine de la sécurité routière. [22]

Les véhicules connectés utilisent des systèmes de communication avancés pour échanger des informations en temps réel avec d'autres véhicules (V2V), l'infrastructure routière (V2I) et les piétons (V2P), créant ainsi un écosystème de transport interconnecté. Cette capacité de communication permet une meilleure coordination du trafic, réduit les risques de collision et optimise les flux de circulation [23]. Les véhicules autonomes, quant à eux, sont équipés de capteurs sophistiqués de radars, de caméras et de systèmes LIDAR (**Figure 2-1**), leur permettant de percevoir leur environnement avec une précision élevée et de prendre des décisions de conduite en toute autonomie [24] .




Figure 2- 1 ; les types des captures des véhicules autonomes. [24]

2.1.2 Technologies de Réseaux Neuronaux pour les Véhicules Autonomes

Ces technologies intégrées dans les véhicules autonomes peuvent analyser les conditions routières, anticiper les dangers et réagir plus rapidement que les conducteurs humains, ce qui réduit considérablement le nombre d'accidents. Parmi ces technologies en citent :

- **CNN (Convolutional Neural Network)** : Utilisé pour le traitement d'images, le CNN extrait des caractéristiques distinctives en analysant la structure spatiale des pixels, ce qui permet la détection de piétons et la planification de trajectoire dans les véhicules autonomes.
- **RCNN (Region-based Convolutional Neural Network)** : Préféré pour la détection d'objets, le RCNN identifie les limites et étiquette les objets dans une image via une recherche sélective. Il est utilisé dans les véhicules autonomes pour détecter les piétons, les objets et les panneaux de signalisation.
- **SLAM (Simultaneous Localization and Mapping)** : Utilisé pour estimer la position des objets statiques via des capteurs LIDAR ou RADAR, le SLAM aide à la planification de trajectoire et au contrôle du mouvement dans les véhicules autonomes.
- **K-Means** : Algorithme non supervisé qui regroupe des données non classées en clusters, minimisant la distance entre les centroïdes et les points de données.
- **YOLO (You Only Look Once)** : Algorithme basé sur CNN pour la détection d'objets en temps réel. Il traite l'identification et la classification en un seul passage, offrant une détection efficace et facile à déployer dans les véhicules autonomes. [25]

2.2 Systèmes d'aide à la conduite avancée (ADAS)

2.2.1 Généralité sur ADAS

Les systèmes d'aide à la conduite avancée (ADAS) sont des technologies intégrées dans les véhicules pour améliorer la sécurité et le confort de conduite. Ces systèmes utilisent divers capteurs, caméras, radars et lidars pour surveiller l'environnement du véhicule et fournir des avertissements ou des actions automatiques en réponse aux conditions de conduite [26]. Les fonctionnalités courantes des ADAS incluent le freinage d'urgence automatisé, le maintien de voie, la détection des angles morts, et le régulateur de vitesse adaptatif. En analysant les données collectées en temps réel, les ADAS peuvent prévenir les collisions, réduire la fatigue du conducteur et optimiser la conduite dans des conditions variées. Ces systèmes jouent un rôle crucial dans la réduction des accidents de la route et constituent une étape importante vers le développement de véhicules entièrement autonomes [27].

2.2.2 Principe de fonctionnement de l'ADAS :

Les systèmes d'aide à la conduite avancée (ADAS) basés sur la vision exploitent les images capturées par des caméras embarquées pour extraire des informations cruciales grâce aux principes de la vision par ordinateur. Ces systèmes analysent en temps réel les flux vidéo pour identifier et interpréter divers éléments de l'environnement routier, tels que les marquages au sol, les panneaux de signalisation, les autres véhicules et les piétons. En utilisant des algorithmes avancés de traitement d'images et d'apprentissage automatique [28].




Figure 2- 2: Le flux de données de vision pour l'ADAS [28]

2.2.3 Les Systèmes avancés d'aide à la conduite (ADAS) :

Afin d'améliorer la sécurité routière et faciliter les tâches de conduite, de nombreux systèmes d'aide à la conduite avancés (ADAS) ont été développés. Parmi ces systèmes :

Le Freinage d'Urgence Automatique (Automatic Emergency Braking (AEB)) : agit comme un copilote vigilant, détectant les collisions potentielles et appliquant automatiquement les freins pour prévenir ou minimiser l'impact des collisions. Cette fonctionnalité est particulièrement utile en cas de distraction ou de fatigue du conducteur, où les temps de réaction peuvent être altérés.

- L'Avertissement de Sortie de Voie (Lane Departure Warning (LDW)) : sert d'assistant de maintien de voie, alertant le conducteur lorsqu'il quitte involontairement sa voie de circulation. Sur les autoroutes, où les sorties de voie peuvent entraîner de graves accidents, cette fonctionnalité est particulièrement cruciale.
- La Surveillance des Angles Morts (Blind Spot Monitoring (BSM)) : élimine les zones aveugles en utilisant des capteurs pour détecter les véhicules dans ces zones et en émettant un avertissement visuel ou sonore pour éviter les collisions lors des changements de voie ou des manœuvres de dépassement.
- Le Régulateur de Vitesse Adaptatif (Adaptive Cruise Control (ACC)) : élimine le stress de la conduite sur autoroute en maintenant une distance de sécurité avec le véhicule qui précède, même lorsque les conditions de circulation changent. Cela réduit la fatigue du conducteur et favorise une circulation plus fluide.
- La Reconnaissance des Panneaux de Signalisation (Traffic Sign Recognition (TSR)) : agit comme un agent de la circulation virtuel, identifiant les panneaux de signalisation et affichant les informations pertinentes, telles que les limites de vitesse, les panneaux d'arrêt et les zones scolaires, directement sur le tableau de bord. Ce système aide les conducteurs à rester informés et à respecter les règles de circulation.

2.3 Les systèmes de détection et de prévention des accidents :

Les systèmes de détection et de prévention des accidents sont des composants essentiels des véhicules modernes, visant à minimiser les risques d'accidents et à protéger la vie des usagers de la route. Ces systèmes utilisent une combinaison de capteurs avancés tels que les radars, les caméras, les lidars et les ultrasons pour surveiller en temps réel l'environnement routier et détecter les situations dangereuses. Ils peuvent identifier les véhicules dans les angles morts, les piétons traversant la route, les obstacles sur la chaussée et les conditions météorologiques défavorables. Grâce à des algorithmes sophistiqués de traitement de données et d'intelligence artificielle, ces systèmes analysent les informations collectées pour anticiper les dangers et prendre des mesures préventives.

Dans la littérature scientifique, plusieurs systèmes de détection automatique d'accidents ont été proposés, utilisant des technologies telles que les smartphones, le GSM, le GPS, et les applications mobiles. La mise en œuvre d'un tel système, incluant la détection automatique des accidents et la communication d'informations dans chaque véhicule revêt une importance capitale [29] .

La figure ci-dessous illustre le concept d'un système de suivi de véhicule utilisant différentes technologies, telles que GSM e GPS.




Figure 2- 3:Schéma de détection des accidents via GSM et GPS [29]

3 L'utilité des SI dans l'analyse de comportement des conducteurs

Les systèmes intelligents (SI) ont une importance cruciale dans l'analyse du comportement des conducteurs grâce à l'intégration de l'intelligence artificielle (IA). En utilisant des capteurs embarqués, des caméras et des données en temps réel, les SI collectent une quantité massive d'informations sur les habitudes de conduite des conducteurs. L'IA analyse ces données pour identifier les schémas de comportement, les tendances de conduite dangereuses et les facteurs de risque potentiels sur les routes.




Figure 2- 4:schéma représentative d'un SI.

Cette analyse permet de prendre des mesures préventives ciblées pour améliorer la sécurité routière et les performances des conducteurs. Par exemple, en identifiant les zones à haut risque d'accidents ou les comportements de conduite agressifs, les SI peuvent proposer des recommandations personnalisées aux conducteurs, telles que des conseils sur la conduite défensive ou des itinéraires alternatifs pour éviter les embouteillages ou les conditions météorologiques dangereuses. En intégrant ces informations dans les véhicules connectés et les applications mobiles.

Les SI facilitent également l'auto-évaluation des conducteurs et favorisent une conduite plus sûre et plus responsable. Ainsi, les SI et l'IA représentent des outils puissants pour atteindre l'objectif commun d'améliorer les performances des conducteurs et la sécurité routière.

Conclusion :

Un aspect fondamental des système intelligents est leur capacité à s'adapter et à évoluer en fonction des avancées technologiques et des besoins changeants des sociétés modernes. Les progrès en matière d'intelligence artificielle, d'apprentissage automatique et de traitement de données massives ouvrent de nouvelles perspectives pour le développement de systèmes encore plus efficaces et intelligents. Par exemple, l'utilisation de l'intelligence artificielle pour analyser et prédire les comportements dangereux permet de prendre des mesures préventives plus ciblées.

Chapitre 3 :
Conception d'un système intelligent
pour l'analyse du comportement

Introduction :

Ces dernières années, l'apprentissage profond a démontré une efficacité remarquable dans diverses applications, de la reconnaissance d'image et de la parole à la conduite autonome. Sa capacité à traiter et à apprendre de vastes quantités de données a révolutionné les systèmes de transport, permettant la détection de motifs subtils auparavant difficiles à identifier. S'appuyant sur les informations des chapitres précédents, quatre cas d'application seront explorés en détail :

- Détection du style de conduite agressive sur les routes secondaires :

Ce modèle se concentre sur la détection de comportements de conduite agressifs sur les routes secondaires. Il exploite les données de dynamique du véhicule telles que la vitesse et l'accélération, combinées au nombre de véhicules devant et une distance de sécurité ainsi que le temps d'impact sur le véhicule en amont, pour identifier les comportements de conduite potentiellement dangereux. En analysant ces mesures, le modèle vise à identifier les conducteurs qui représentent un risque pour eux-mêmes et pour les autres en raison de leur style de conduite agressif.

- Détection du style de conduite agressive sur les autoroutes :

Semblable au modèle précédent, celui-ci se concentre sur la détection du style de conduite agressive mais dans le contexte des autoroutes. Les défis uniques des environnements à grande vitesse nécessitent une approche spécifique, dans laquelle les données de dynamique du véhicule, le changement des voies et le maintien d'une distance de sécurité sont étroitement surveillés. Le modèle est conçu pour capturer les nuances de la conduite sur autoroute, en identifiant les signes d'une conduite agressive.

- Détection de la somnolence :

Le troisième modèle se concentre sur la question critique de la conduite en état de somnolence, une cause importante d'accidents de la route [30] [31]. En utilisant des techniques d'apprentissage profond, y compris la détection d'objets, le modèle analyse le rapport hauteur/largeur des yeux (Eye aspect ratio) pour classer les schémas de clignement et distinguer les états somnolents et alertes. En détectant la somnolence tôt, le modèle vise à fournir des avertissements opportuns aux conducteurs et gestionnaires, permettant potentiellement d'éviter les accidents causés par la fatigue.

- **Détection de la conduite distraite :**

Le quatrième modèle se concentre sur la détection de la conduite distraite, un facteur majeur contribuant aux accidents de la route. Ce modèle utilise des techniques avancées de vision par ordinateur et d'apprentissage profond pour surveiller et analyser les comportements du conducteur. En se basant sur des flux vidéo de caméras embarquées, le modèle identifie des signes de distraction tels que l'utilisation d'un téléphone portable, le fait de manger, de boire, de se maquiller, ou de se tourner fréquemment pour parler aux passagers.

Dans ce chapitre nous examinons les considérations de conception de chaque modèle, y compris le choix de l'architecture et les données d'entrées et sorties. Le chapitre abordera également l'architecture du système, illustrée par des diagrammes UML.

1 Conception des modèles :

1.1 Modèles de détection de style de conduite agressive

1.1.1 Données d'entrées et sorties :

➤ **Sur les routes secondaires :**

Le modèle prend en entrée les données suivantes :

- **Données sur la dynamique du véhicule (vitesse et accélération) :** les mesures de vitesse et d'accélération sur les axes X et Y (figure 3-1), traitées par un filtre de Kalman, sont essentielles pour identifier divers comportements de conduite, tels que les freinages brusques, les accélérations agressives et les virages serrés.
- **Distance de sécurité avec le véhicule devant :** Maintenir une distance de sécurité avec le véhicule devant est un indicateur clé d'une conduite responsable. En intégrant cette information, le modèle peut identifier les cas où les conducteurs peuvent adopter un comportement risqué en roulant de trop près ou en se rapprochant trop des autres véhicules.
- **Temps d'impact avec le véhicule devant :** Cette caractéristique donne un aperçu du risque potentiel de collision avec le véhicule devant. En analysant le temps qu'il faudrait au véhicule pour percuter celui devant, le modèle peut identifier les situations où des actions agressives, telles que des freinages brusques ou des changements de voie rapides, pourraient être nécessaires pour éviter des accidents.

- **Nombre de véhicules :** Le nombre de véhicules à proximité, obtenu à partir des données vidéo, donne un contexte sur la densité du trafic. Un trafic plus dense peut augmenter la probabilité de conduite agressive en raison de la congestion ou de la frustration.

Ainsi, nous disposons de huit variables de base, chacune représentée par une séquence de 3000 valeurs (équivalant à 100 secondes). Le modèle produit en sortie une classification binaire du comportement de conduite en tant qu'agressif ou non agressif, permettant des décisions claires et des interventions telles que l'envoi d'alertes aux conducteurs ou aux gestionnaires.




Figure 3- 1:Schéma des dynamiques du véhicule. [32]

➤ Sur les autoroutes :

Le modèle pour les autoroutes partage les mêmes variables de base que le modèle pour les routes secondaires, avec l'ajout de deux variables :

- **Position sur la voie :** La position du véhicule sur la voie (par exemple, voie de gauche, centrale ou de droite) peut fournir des indications sur les intentions de conduite. Les conducteurs qui changent fréquemment de voie ou restent trop longtemps sur une voie de dépassement peuvent montrer des comportements agressifs.
- **Changements de voie :** Les changements de voie fréquents peuvent être un signe de conduite agressive.

1.1.2 L'architecture des modèles :

Couche d'entrée :

Le modèle accepte les données d'entrées séquentielles avec une longueur de pas de temps de 3000. Cette forme suggère que le modèle est conçu pour l'analyse de données temporelles.

Couches convolutionnelles :

- **Couche Conv1D** : La première couche est une couche de convolution 1D avec 64 filtres, qui extrait les caractéristiques de la séquence d'entrée en appliquant des filtres de convolution. La taille du noyau (kernel) de 40 signifie que chaque filtre couvre un champ récepteur de 40 pas de temps, permettant au modèle de capturer les motifs temporels. Le remplissage (padding) « same » garantit que la séquence de sortie conserve la même longueur que l'entrée, préservant la continuité des données pour les couches suivantes.
- **Couche MaxPooling1D** : Effectue un sous-échantillonnage de la représentation d'entrée en prenant la valeur maximale sur une fenêtre spatiale de taille pool_size. La fenêtre est décalée par strides.

La forme de la sortie résultante lors de l'utilisation de l'option de remplissage "same" est :
output_shape = input_shape / strides.

- **Normalisation par lot (BatchNormalization layer)** : Une couche qui normalise ses entrées. Elle normalise les activations à travers le lot pour une moyenne de zéro et une variance unitaire, stabilisant le processus d'apprentissage en réduisant le décalage covariant interne.
- **Activation ReLU (Rectified Linear Unit activation function layer)** : La fonction d'activation ReLU introduit de la non-linéarité dans le modèle, lui permettant d'apprendre des représentations complexes. Elle remplace les valeurs négatives par zéro tout en gardant les valeurs positives inchangées, empêchant efficacement le problème des gradients évanescents et accélérant la convergence.
- **Couche Dropout** : Une couche de dropout avec une probabilité d'abandon de 0,15 désactive aléatoirement une fraction des neurones de cette couche à chaque itération d'entraînement. Cette technique de régularisation empêche le surajustement en s'assurant que le modèle ne repose pas trop sur des caractéristiques spécifiques, encourageant l'apprentissage de représentations de caractéristiques plus robustes et générales.

Couche de pool global moyen (Global Average Pooling 1D layer) :

La couche de pool global moyen convertit chaque carte de caractéristiques en une seule valeur en calculant la moyenne sur tous les pas de temps. Cela réduit les cartes de caractéristiques à un vecteur 1D, rendant les données compatibles pour l'entrée dans des couches entièrement connectées. Cette couche conserve les caractéristiques les plus pertinentes tout en réduisant considérablement la dimensionnalité des données.

Couches denses :

- **Couche dense 1** : La première couche dense à 16 unités et utilise la fonction d'activation ReLU pour extraire davantage des représentations significatives des données poolées. Cette couche apprend les caractéristiques et motifs de haut niveau à partir des représentations de pool global moyen.
- **Couche Dropout** : La couche de dropout a une probabilité d'abandon de 0.1, ce qui aide à réduire le surajustement (overfitting) en désactivant aléatoirement les neurones pendant l'entraînement. Cela oblige le réseau à être plus robuste et empêche le modèle de s'appuyer excessivement sur des neurones spécifiques.
- **Couche dense 2** : La dernière couche dense se compose de 2 unités avec une fonction d'activation softmax. Cette couche agit comme la couche de sortie et convertit les caractéristiques apprises en probabilités de classe pour une tâche de classification binaire. La fonction d'activation softmax garantit que les sorties s'additionnent à un, représentant les probabilités prévues de chaque classe.

La conception globale de l'architecture tire parti des couches de convolution et des couches denses pour extraire efficacement les caractéristiques temporelles tout en utilisant des techniques de régularisation comme la normalisation par lot et le dropout pour améliorer la robustesse du modèle.

Ci-dessous, une figure illustrant l'architecture globale du modèle de détection de style de conduite agressive sur les autoroutes :




Figure 3- 2:Schéma de l'architecture du modèle Conv1D montrant les différentes couches.

En fait, ce qui différencie le premier modèle (route secondaire) du deuxième modèle (autoroute), c'est la séquence d'entrée. Le deuxième modèle prend en compte deux variables supplémentaires liées à la voie de circulation.

1.2 Modèle de détection de somnolence :

1.2.1 Données d'entrées et sorties :

Le modèle prend en entrée une séquence de valeurs d'EAR (Eye Aspect Ratio, ou rapport hauteur/largeur des yeux), qui mesure l'ouverture des yeux sur une période correspondante à un clignement (pour plus de détails, (voir les figures :3-3 et 3-4). En surveillant ces changements d'EAR au fil du temps, le modèle peut identifier les schémas caractéristiques associés à la somnolence (voir figure 3-5), offrant ainsi une détection précoce des signes de fatigue.

En sortie, le modèle catégorise l'état du conducteur comme somnolent ou alerte en fonction des valeurs EAR en entrée. Cette sortie binaire permet une intervention rapide pour prévenir les accidents potentiels causés par la fatigue du conducteur.

La détection de la somnolence au volant par l'analyse des clignements des yeux est soutenue par des preuves scientifiques solides indiquant que les paramètres des clignements tels que la durée, le temps de fermeture et le temps de réouverture sont des indicateurs fiables de somnolence.

Des études [33] ;[34] ; [35] confirment que ces paramètres sont fortement corrélés aux mesures traditionnelles de somnolence et peuvent être surveillés de manière continue et non intrusive. Des liens modérés à forts ont été trouvés entre les métriques des clignements des yeux et divers paramètres de conduite simulée tels que le positionnement dans la voie, la vitesse, les incidents de collision et les temps de réaction [36] ;[37]. De plus, l'échelle de somnolence de Johns montre une précision raisonnable (AUC 0,76) dans la prédiction des incidents hors route après une période prolongée d'éveil [38]. Ces résultats indiquent que les métriques des clignements des yeux pourraient être efficaces pour identifier les déficiences de performance de conduite dues à la fatigue.




Figure 3- 3:la variation de EAR en temp réel [39]




Figure 3- 4:Séquence d'entrée (1 /30 seconde).

Figure 3- 5: rapport hauteur/largeur des yeux pendant les clignements éveillés (étiquette 0). et somnolents (étiquette 1) .

1.2.2 L'architecture de modèle :

Couche d'entrée : Le modèle accepte les données d'entrées séquentielles avec une forme de (10, 8), où 8 représente le nombre de pas de temps et 10 le nombre de clignements.

Couches convolutionnelles :

- **Couche Conv1D :** La première couche est une couche de convolution 1D avec 8 filtres, qui extrait les caractéristiques de la séquence d'entrée en appliquant des filtres de convolution.
- **Couche MaxPooling1D :** Effectue un sous-échantillonnage de la représentation d'entrée en prenant la valeur maximale sur une fenêtre de taille 3. Cela réduit la dimensionnalité des données tout en conservant les caractéristiques les plus importantes.
- **Blocs Résiduels :** Le modèle intègre plusieurs blocs résiduels, chacun composé de :
 - Une couche Conv1D avec 8 filtres et un noyau de taille 3.
 - Une fonction d'activation ReLU.
 - Une autre couche Conv1D avec les mêmes paramètres.
 - Une addition entre l'entrée du bloc et la sortie de la deuxième couche Conv1D.
 - Une fonction d'activation ReLU finale.

Ces blocs résiduels permettent de faciliter l'apprentissage en évitant le problème de disparition du gradient.

Couche de pool global moyen (Global Average Pooling 1D layer) :

La couche de pool global moyen convertit chaque carte de caractéristiques en une seule valeur en calculant la moyenne sur tous les pas de temps. Cela réduit les cartes de caractéristiques à un vecteur 1D, rendant les données compatibles pour l'entrée dans des couches dense.

Couches denses :

- **Couche dense 1 :** La première couche dense comprend 32 unités.
- **Couche dense 2 :** La dernière couche dense se compose de 2 unités avec une fonction d'activation softmax.

Ci-dessous, une figure illustrant l'architecture globale du modèle :




Figure 3- 6:Schéma de l'architecture du modèle Residual network montrant les différentes couches.

1.3 Modèle de détection de la conduite distraite :

1.3.1 Données d'entrées et sorties :

Le modèle reçoit en entrée une image unique capturée par une caméra embarquée, représentant le conducteur dans son environnement de conduite. Cette image contient des informations essentielles sur les actions et l'attention du conducteur (Figure 3-7).

En sortie, le modèle classe l'image en une des dix catégories de distraction :

- C0 : Conduite normale
- C1 : Envoi de SMS - main droite
- C2 : Parler au téléphone - main droite
- C3 : Envoi de SMS - main gauche
- C4 : Parler au téléphone - main gauche
- C5 : Utilisation de la radio
- C6 : Boire
- C7 : Se retourner vers l'arrière
- C8 : Coiffure et maquillage
- C9 : Parler avec un passager



Figure 3- 7:Vue de la détection de la conduite distraite. Source : dos1.com.ph

1.3.2 L'architecture de modèle :

Le modèle de détection de la conduite distraite utilise le Vision Transformer (ViT), une architecture de pointe qui révolutionne la vision par ordinateur en remplaçant les réseaux de neurones convolutifs (CNN) traditionnels par des transformateurs. Contrairement aux CNN, qui se concentrent sur des relations locales à travers des filtres convolutifs, le ViT divise l'image en petits patches et traite chaque patch comme un token dans une séquence, similaire au traitement de texte par les transformateurs. Cette approche permet au ViT de capturer des dépendances globales à longue distance au sein de l'image, offrant une meilleure compréhension contextuelle et une vue d'ensemble plus complète. Grâce aux mécanismes d'attention multi-tête, le ViT peut se concentrer simultanément sur différentes parties de l'image, ce qui améliore considérablement la capacité du modèle à identifier des signes de distraction complexes et subtils chez le conducteur.

Ci-dessous, une figure illustrant l'architecture globale du modèle :




Figure 3- 8:L'architecture du modèle ViT. [40]

2 L'architecture du système :

Lors de la conception de l'architecture de notre système, nous avons mis l'accent sur une intégration harmonieuse du matériel et des logiciels. Ce système repose sur un modèle d'architecture en couches qui sépare les fonctionnalités en modules distincts, chacun responsable d'un aspect spécifique du processus de gestion de flotte. Cette approche modulaire simplifie non seulement la maintenance, mais améliore également l'évolutivité du système en permettant à chaque composant d'être mis à niveau indépendamment à mesure que de nouvelles technologies deviennent disponibles. L'architecture prend en charge le traitement des données et la prise de décision en temps réel, essentiels pour des réponses immédiates aux risques détectés, tout en fournissant également de solides capacités d'agrégation de données pour l'analyse historique et le reporting.

2.1 Description des composants :

- **Couche du véhicule :** Cette couche fondamentale se compose de divers capteurs et caméras qui recueillent des données en temps réel sur l'état du véhicule et son environnement. Les données collectées sont ensuite traitées par une unité centrale qui peut déclencher des alertes en cas de détection de conditions potentiellement dangereuses, améliorant ainsi la réactivité face aux incidents éventuels. Un dispositif de stockage local sauvegarde les informations traitées, permettant une utilisation immédiate ou future pour des analyses plus poussées.
- **Communication réseau :** Ce composant assure la transmission des données entre le véhicule et les autres niveaux du système. Il joue un rôle crucial dans la mise à jour des logiciels embarqués et dans l'envoi des données traitées vers des serveurs centraux pour un stockage à long terme.
- **Couche de gestion des Mises à Jour :** Elle centralise la distribution des mises à jour logicielles, garantissant que toutes les unités opèrent avec les versions les plus récentes et les plus sécurisées des logiciels, ce qui est vital pour maintenir l'intégrité et la performance du système.
- **Couche d'interface :** Le tableau de bord de gestion du risque d'accident de flotte constitue l'interface utilisateur du système. Il permet aux gestionnaires de flotte de visualiser et d'analyser en temps réel les données relatives aux risques, offrant ainsi les outils nécessaires pour une supervision efficace et proactive de la sécurité.
- **Couche de base de données centrale :** Cette dernière couche est responsable du stockage des données recueillies. Elle offre une infrastructure robuste pour l'archivage des informations et supporte des fonctionnalités avancées d'analyse et de rapport, essentielles pour les évaluations de performance.

Cette architecture détaillée garantit que notre système de gestion des risques de flotte répond non seulement efficacement aux problèmes de sécurité immédiats, mais soutient également la gestion stratégique des opérations de flotte grâce à une analyse et un reporting complets des données.

La figure 3-9 présente en détails le diagramme de composants complet du système.




Figure 3- 9:Diagramme de composants du système de gestion des risques de la flotte.

2.2 Le cas d'utilisation :

Le cas d'utilisation du système tourne autour de la surveillance continue du comportement de conduite afin d'identifier et d'atténuer les risques associés aux comportements dangereux. Il intègre les données des capteurs et caméras embarqués pour évaluer l'état du conducteur et ses habitudes de conduite. Lorsque le système détecte une indication de comportement à risque, il alerte immédiatement le conducteur avec des avertissements sonores, visant à inciter à une action corrective. De plus, le système compile ces données dans des rapports complets accessibles aux gestionnaires de flotte via un tableau de bord, qui fournit des informations sur les performances individuelles et globales de la flotte. Cette fonctionnalité prend en charge les décisions de gestion et les ajustements stratégiques à long terme, garantissant la sécurité et l'efficacité des opérations de la flotte. La figure 3-10 présente en détails le diagramme de cas d'utilisation complet du système.




Figure 3- 10:Diagramme de cas d'utilisation du système de gestion des risques de la flotte.

Conclusion :

Ce chapitre a exploré en profondeur la conception et l'architecture des modèles de détection de style de conduite agressive et de somnolence, tout en abordant l'architecture système nécessaire pour leur intégration efficace. L'accent a été mis sur la création d'une infrastructure robuste, capable de gérer les données en temps réel et de fournir des réponses immédiates, ce qui est essentiel pour la prévention proactive des accidents. Les architectures des modèles décrites ici sont conçues pour une intégration harmonieuse avec les composants matériels et logiciels du système, permettant une surveillance continue et fiable du comportement du conducteur.

Le prochain chapitre abordera l'implémentation pratique des modèles et de l'architecture système décrite précédemment, ainsi que l'évaluation des résultats obtenus.

Chapitre 4 :
Implémentation, tests et résultats

Dans ce chapitre, nous approfondissons les aspects pratiques du projet, en nous concentrant sur les choix technologiques qui ont façonné son développement, notamment les langages de programmation, les bibliothèques et les frameworks. Nous présenterons une partie de l'interface utilisateur, avec des captures d'écran pour mettre en évidence les caractéristiques clés du système. Ensuite, nous présenterons les méthodologies de prétraitement des données, d'entraînement et d'évaluation, ainsi que les résultats obtenus à partir des modèles. Enfin, nous fournirons une interprétation de ces résultats, offrant des perspectives sur les performances des modèles et leurs implications pour les travaux futurs.

1 Choix technologiques :

Tous ces choix technologiques ont été utilisés à des degrés divers pour atteindre les objectifs du projet, garantissant un processus de développement efficace et fluide.

- **Google Colab** : Google Colab a joué un rôle crucial dans la réalisation des objectifs du projet en offrant un environnement de développement complet basé sur le cloud. Avec une accélération matérielle puissante via des GPU et des TPU, ainsi qu'une connexion Internet rapide et une intégration avec Google Drive pour le stockage dans le cloud, il a grandement facilité le stockage des données, le prototypage rapide, le prétraitement des données, l'entraînement et l'évaluation des modèles. La plateforme a considérablement réduit le temps de développement. De plus, les fonctionnalités collaboratives de Colab ont permis une collaboration fluide et un partage sans effort, en faisant un environnement idéal pour un développement itératif et une collaboration efficace.
- **TensorFlow et Keras** : TensorFlow complétés par l'API Keras, ont été essentiels à l'aspect deep learning de ce projet. L'API Keras de haut niveau a permis de concevoir, entraîner et ajuster facilement des modèles complexes. L'écosystème étendu de TensorFlow a fourni des modèles pré-entraînés et des fonctionnalités avancées qui ont accéléré le processus de développement.
- **PyTorch** : Un framework de deep learning largement utilisé, connu pour sa flexibilité dans les graphiques de calcul dynamiques, le rendant idéal pour la recherche et le prototypage rapide. Il fournit également une collection diversifiée de modèles pré-entraînés via TorchHub, Un référentiel conçu pour promouvoir la reproductibilité dans la recherche et faciliter les expérimentations rapides.
- **Kaggle** : Kaggle a hébergé le grand ensemble de données (95 Go) nécessaire à la formation des modèles. Y accéder directement sur la plateforme a permis une gestion efficace des données sans avoir besoin de les télécharger et de les stocker localement. Cela a rationalisé

le flux de travail de traitement des données et a permis une intégration avec le processus d'entraînement des modèles.

- **Scikit-Learn** : Scikit-Learn a fourni des outils essentiels pour évaluer, traiter et effectuer la détection d'anomalies à l'aide du clustering k-means. Sa flexibilité et son efficacité en ont fait un choix idéal pour gérer les aspects de prétraitement et d'évaluation des données du projet.
- **NumPy et SciPy** : NumPy et SciPy ont été essentiels pour les opérations numériques et le traitement du signal. Ces bibliothèques ont permis d'effectuer facilement des calculs matriciels rapides et de traiter les signaux pour extraire des fonctionnalités essentielles à l'entraînement des modèles. Leurs fonctions optimisées ont assuré une gestion efficace des données tout au long du flux de travail.
- **OpenCV et MediaPipe** :
 - OpenCV est utilisé pour le traitement vidéo, jouant un rôle essentiel dans la lecture, la manipulation et l'analyse des images vidéo. Cela a été essentiel pour générer les données d'entrée requises par les modèles.
 - MediaPipe a fourni des outils avancés de machine learning pour la prédiction des points de repère du visage, permettant une détection précise des rapports d'aspect des yeux (EAR), ce qui est essentiel pour le modèle de détection de la somnolence.
- **Dépôts GitHub : MiDaS, ZoeDepth, ConvTrans**

Depth Anything et ZoeDepth : Ces dépôts GitHub ont proposé des modèles de pointe pour l'estimation de la profondeur métrique, utilisés particulièrement pour calculer la distance de sécurité.

ConvTrans : Un dépôt fournissant des modèles avancés pour la classification des séries temporelles.

- **HTML, CSS et JavaScript** :

Pour le développement web, HTML, CSS et JavaScript ont été des outils indispensables. HTML a permis de structurer les pages web, CSS a été utilisé pour le stylisme et la mise en page, et JavaScript a apporté une interactivité dynamique aux applications. Ces technologies combinées ont permis de créer l'interface utilisateur du système.
- **Android Studio** : Android Studio a été l'outil de choix pour le développement de l'application mobile. Cet environnement de développement a fourni tous les outils nécessaires pour créer et tester l'application.

En utilisant ces technologies, le projet a réussi à gérer de grands ensembles de données, des architectures de modèles complexes et des tâches intensives de traitement vidéo, conduisant finalement à des modèles efficaces pour l'analyse du comportement des conducteurs.

2 L'interface utilisateur :

Le système est conçu pour répondre aux besoins spécifiques de deux catégories d'utilisateurs :

2.1 Les managers :

L'interface utilisateur du système pour cette catégorie se compose de trois écrans principaux. Le premier écran (figure 4-1) affiche une vue d'ensemble de la gestion des risques de la flotte, avec des graphiques détaillant l'utilisation des véhicules (heures par jour), les types d'alertes reçues au cours des 7 derniers jours, les niveaux de somnolence au cours des dernières 24 heures, et les niveaux de risque sur la dernière semaine. Le deuxième écran (figure 4-2) se concentre sur le suivi en temps réel des conducteurs, montrant leur localisation actuelle sur une carte interactive ainsi qu'un tableau récapitulatif du temps de conduite, du niveau de somnolence, du nombre d'alertes et du niveau de risque associé pour chaque conducteur. Enfin, le troisième écran (figure 4-3) est dédié aux rapports d'accidents, listant les incidents survenus avec des détails tels que la date, le lieu et un résumé succinct de chaque accident. Ces interfaces permettent une surveillance efficace et proactive des comportements des conducteurs et des risques associés, contribuant ainsi à améliorer la sécurité de la flotte.



Figure 4- 2: Vue d'ensemble de la gestion de la flotte.




Figure 4- 3:Suivi en temps réel des conducteurs.




Figure 4- 4:Rapports d'accidents.

2.2 Conducteur :

Nous avons conçu une interface utilisateur sous forme d'une application mobile afin d'améliorer les performances et la sécurité routière des conducteurs. Cette application permet la collecte de données à travers les capteurs des téléphones portables, lesquels sont activés selon le choix du conducteur. Les données sont ensuite traitées à l'aide des modèles que nous avons développés. Lorsque l'application détecte un comportement dangereux ou anormal, elle envoie des alertes au conducteur pour l'avertir du danger et lui demander de corriger son comportement. Cette approche vise à fournir un outil pratique et efficace pour aider les conducteurs à adopter des habitudes de conduite plus sûres et responsables

Les fonctionnalités de l'application :

Une fois l'application ouverte, l'utilisateur est invité à sélectionner le mode d'utilisation qui convient le mieux à ses habitudes de conduite et à ses préoccupations en matière de sécurité (figure 4 - 4) :

1. La détection de style de conduite :

Celui-ci active les capteurs du téléphone tels que l'accéléromètre GPS et la caméra arrière pour collecter des données qui facilitent le suivi de son trajet en cours et reçoivent des alertes en temps réel en cas de comportement de conduite dangereux.

2. La détection de somnolence :

Pour détecter les signes de fatigue au volant et prévenir les risques d'accidents liés à la somnolence, suivi de l'activation des caméras frontales du téléphone pour collecter des données.

3. La détection distractions :

Pour identifier les moments où votre attention est détournée de la route et réduire les risques d'accidents liés à la distraction enregistrés par la caméra frontale.




Figure 4- 5:L'interface utilisateur permet au conducteur de choisir la tâche qu'il souhaite analyser et activer

Alertes en temps réel :

L'objectif principal de l'application se transforme en un véritable assistant de conduite vigilant, fournissant des alertes en temps réel pour avertir le conducteur des situations à risque (figure 4 - 5) :

➤ **Graphique clair et précis plus un rapport en temps réel :**

Lorsque l'option de détection du style de conduite est choisie, l'application permet de visualiser en temps réel les écarts de vitesse et les situations de ralentissement. Si l'option de détection de la somnolence est sélectionnée, l'application affiche les pourcentages de somnolence du conducteur (éveillé / somnolent).

➤ **Système d'alertes visuelles et sonores :** Dès qu'un comportement dangereux est détecté, l'application envoie des alertes sonores et visuelles. Ces alertes peuvent prendre la forme de messages visuels clairs et d'alertes sonores pour attirer l'attention du conducteur et l'inciter à corriger son comportement



Figure 4- 6: l'interface de surveillance en Temps Réel de comportement de conducteur le cas de détection de style de conduite (a) et la détection de somnolence (b).

Fonction Historique :

L'application dispose d'une fonction de journal approfondie qui permet d'analyser les performances de conduite à long terme. Cette fonction fournit un aperçu complet des voyages précédents (**figure 4 – 6**)




Figure 4- 7:l'interface de l'historique

La fonction journal est un outil essentiel pour évoluer vers une conduite plus sûre et plus responsable. En utilisant les données historiques, le conducteur peut identifier les compétences et les domaines à améliorer en découvrant les éléments de conduite qui sont plus forts et nécessitent plus d'attention pour adopter un comportement de conduite plus sûr.

3 Bases des données :

3.1 UAH-DriveSet :

Le UAH-DriveSet est un ensemble de données public conçu pour faciliter une analyse complète du comportement du conducteur. Développé en utilisant l'application mobile DriveSafe, cet ensemble de données a été compilé avec précision, impliquant six conducteurs différents naviguant sur des autoroutes et des routes secondaires.

Cet ensemble de données contient des données brutes de plus de 500 minutes de conduite, y compris des coordonnées GPS, des lectures d'accéléromètre et de gyroscope provenant des capteurs inertiels du smartphone, ainsi que des enregistrements vidéo détaillés. De plus, les données collectées ont subi un traitement approfondi pour identifier et classifier des manœuvres telles que l'accélération, le freinage, les changements de voie et le suivi de voiture.

Les informations affinées fournissent un aperçu des habitudes comportementales de chaque conducteur. Ce qui rend cet ensemble de données fiable, c'est la méthodologie utilisée pour collecter les données. Chaque conducteur a suivi des itinéraires préconçus tout en présentant différents comportements de conduite : normal, somnolent et agressif. Pour la conduite normale, les conducteurs ont été invités à conduire comme ils le feraient habituellement. Pour le scénario de conduite somnolente, les conducteurs ont simulé une somnolence légère, ce qui a généralement conduit à des moments d'inattention sur la route. Dans la conduite agressive, les conducteurs ont été invités à être aussi agressifs que possible sans compromettre la sécurité, ce qui se traduit généralement par de l'impatience et des manœuvres brusques. Ce sont les seules instructions qui ont été fournies au début des itinéraires. Un copilote était présent pour assurer la sécurité, mais n'est intervenu que si une manœuvre présentait un risque important[41]

3.2 Real-Life Drowsiness Dataset (UTA RLDD)

L'ensemble de données Real-Life Drowsiness de l'Université du Texas à Arlington (UTA-RLDD) est un ensemble de données large, public et réaliste, destiné à la détection de la somnolence. Il comprend environ 30 heures de données vidéo provenant de 60 participants en bonne santé, de diverses origines ethniques et d'âges variés, enregistrées dans des environnements intérieurs diversifiés. L'ensemble de données comprend 180 vidéos, chaque participant contribuant par trois vidéos représentant différents stades de vigilance selon l'échelle de somnolence de Karolinska (KSS) : alerte, faible vigilance et somnolence. Chaque vidéo dure environ dix minutes et les vidéos sont étiquetées avec leurs états respectifs.

Les sujets de l'ensemble de données ont été invités à enregistrer des vidéos à l'aide de leurs smartphones personnels ou de webcams, ce qui a entraîné des variations dans les modèles d'appareils photo, les résolutions et les environnements d'enregistrement. Cette approche visait à simuler les conditions réelles, offrant un large éventail d'éclairages, d'arrière-plans et de positions de caméra. L'ensemble de données a été collecté sur une période de 20 jours, permettant aux participants d'enregistrer dans des conditions naturelles. Cet ensemble de données constitue une ressource importante pour la recherche sur la détection de la somnolence, offrant une collection complète et variée de données vidéo en conditions réelles, que l'on ne trouve pas dans d'autres ensembles de données publics.

Pour détecter la somnolence, les auteurs ont développé un modèle temporel de référence qui utilise un réseau LSTM multiscale hiérarchique (HM-LSTM), conçu pour modéliser les relations temporelles des schémas de clignement. Des caractéristiques telles que la durée du clignement, l'amplitude, la fréquence et la vitesse d'ouverture des yeux ont été utilisées pour entraîner le modèle. Le modèle a été évalué sur la base de plusieurs paramètres d'évaluation, tels que la précision de la séquence de clignement, l'erreur de régression de la séquence de clignement, la précision vidéo et l'erreur de régression vidéo. Le modèle a atteint une précision supérieure à celle du jugement humain dans la détection de la somnolence à différents stades, démontrant son efficacité dans la détection précoce de la somnolence [42].

3.3 StateFarm Distracted Driver Dataset :

StateFarm Distracted Driver est un ensemble de données public largement utilisé pour la détection de la distraction au volant. Cet ensemble de données a été compilé par StateFarm Insurance pour aider à la recherche et au développement de modèles de vision par ordinateur capables de détecter les comportements de distraction au volant.

Cet ensemble de données contient plus de 22 000 images étiquetées et plus de 79 000 images non étiquetées, représentant des conducteurs dans diverses postures et activités qui peuvent être classées comme des distractions. Les images sont capturées dans des conditions réelles, fournissant un riche éventail de situations de conduite. Les étiquettes de classe sont :

- C0 : Conduite normale
- C1 : Envoi de SMS - main droite
- C2 : Parler au téléphone - main droite
- C3 : Envoi de SMS - main gauche
- C4 : Parler au téléphone - main gauche
- C5 : Utilisation de la radio
- C6 : Boire
- C7 : Se retourner vers l'arrière
- C8 : Coiffure et maquillage
- C9 : Parler avec un passager



Figure 4- 8: Illustration de la détection de la distraction au volant à partir des images de l'ensemble de données StateFarm. Source : Kaggle

Les images sont prises sous différents angles et éclairages, ce qui ajoute à la variabilité et à la complexité de l'ensemble de données, rendant les modèles de détection plus robustes lorsqu'ils sont entraînés avec cet ensemble de données

4 Prétraitement des données :


4.1 Détection de conduite agressive :

4.1.1 Prétraitement des données :

- **Chargement des données :** Les données de chaque conducteur, stockées sur Google Drive, ont été lues dans des dataframes Pandas séparées en utilisant ``pandas.read_csv``. Chaque dataframe représente une combinaison de conducteur, de type de route (Secondaire/Autoroute), et de style de conduite (Normal/Agressif/Somnolent).
- **Organisation des données :** Les dataframes ont été étiquetés en fonction du numéro du conducteur et des conditions de conduite, facilitant l'identification des sources de données. Par exemple : `'D3_NORMAL_MOTORWAY_merged'` : Les données sont issues du conducteur numéro 3 (D3) dans des conditions de conduite normales sur une autoroute (NORMAL_MOTORWAY).
- **Filtrage et traitement du signal :** La transformation de Fourier rapide (FFT) a été utilisée pour transformer les données en domaine fréquentiel, permettant de filtrer le bruit. La FFT a été appliquée plusieurs fois avec différents seuils de composantes (80, 300, 600, 900) pour générer diverses caractéristiques.
- **Normalisation et mise à l'échelle des données :** Les variables ont été normalisées avec ``MinMaxScaler`` pour assurer une cohérence dans l'échelle des données.
- **Génération de séquences pour l'entrée du modèle :** Des séquences de longueur fixe de 3000 pas (100 secondes) ont été générées à partir des dataframes, introduisant de la variabilité avec des indices de départ aléatoires.
- **Création et préparation des données d'entraînement et de test :** Les séquences de comportements de conduite normaux et agressifs ont été combinées pour former les données d'entraînement (`X_train`) avec des étiquettes correspondantes (`y_train`). Les données de test (`X_test`) ont été générées à partir d'un ensemble distinct de dataframes. Les étiquettes ont été codées en valeurs numériques avec un ``LabelEncoder``, et l'ensemble de données a été mélangé pour éviter les motifs involontaires.
- **Extraction des caractéristiques à partir de vidéos pour les données de test :** Pour les données de test, nous avons utilisé YOLO pour extraire les caractéristiques des vidéos (distance de sécurité, nombre de véhicules).

Ce pipeline de prétraitement a structuré les données de manière à améliorer la capacité du modèle à prédire et classer les styles de conduite de manière efficace.

4.1.2 Algorithme de prétraitement des données :






Figure 4- 9: Flux de données prétraitement et détection du style de conduite agressive.

4.2 Détection de somnolence :

4.2.1 Prétraitement des données :

Cette section décrit un pipeline de prétraitement robuste conçu pour détecter avec précision les clignements dans les données vidéo.

1. Traitement vidéo pour extraire le rapport hauteur/largeur des yeux (EAR) :

La première étape du prétraitement consiste à extraire les points de repère pertinents des yeux de chaque image de la vidéo. Cela nécessite de vérifier la fréquence d'image de la vidéo pour s'assurer de la compatibilité avec le modèle de détection de la somnolence, qui fonctionne de manière optimale à des fréquences d'images standard (29-31 fps). En lisant chaque image individuellement, en la convertissant au format requis et en utilisant un détecteur de repères faciaux sophistiqué, les principaux points de repère des yeux peuvent être identifiés. L'EAR est calculé en mesurant les distances verticales et horizontales entre les repères prédéfinis autour des yeux. Cette méthode a été choisie parce qu'elle est un indicateur fiable de l'activité de clignement. Ce qui distingue notre approche des autres recherches est l'utilisation du modèle FaceLandmarker de MediaPipe pour la détection des repères faciaux, qui emploie des techniques de détection d'objets spécifiquement adaptées au traitement vidéo (mode vidéo). En comparaison avec les modèles des bibliothèques comme dlib et OpenCV, nos résultats étaient nettement supérieurs.

2. Lissage du signal :

Une fois les valeurs EAR extraites, le signal est lissé à l'aide d'un filtre passe-bas Butterworth. Ce filtre est efficace pour éliminer le bruit haute fréquence tout en préservant les informations critiques nécessaires à la détection des clignements. Les paramètres du filtre ont été choisis après avoir testé plusieurs configurations pour garantir un équilibre optimal entre la réduction du bruit et l'intégrité du signal. Des alternatives comme le filtre de Savitzky-Golay et FFT ont été explorées, mais n'ont pas aussi bien réussi à maintenir les caractéristiques du signal de clignement.

3. Extraction des séquences de clignement :

Le signal EAR lissé est ensuite analysé pour extraire les séquences de clignement individuelles. Les creux dans le signal représentent des clignements potentiels et sont identifiés en détectant les minima locaux. Un seuil quantile filtre les creux insignifiants, ne conservant que ceux qui correspondent probablement à de vrais clignements. Chaque séquence de clignement est normalisée pour atténuer les variations d'intensité. D'autres méthodes heuristiques ont été essayées, mais se sont révélées inadéquates pour gérer les diverses séquences de clignement. Cette approche d'extraction et de normalisation des segments de données à partir de creux significatifs fournit une méthode cohérente pour détecter les clignements.

4. Filtrage des Valeurs Aberrantes via le Clustering :

Pour éliminer les valeurs aberrantes des séquences de clignement extraites, le clustering k-means est employé. Cette méthode regroupe les séquences avec des caractéristiques similaires, et les deux plus grands clusters représentent la majorité des séquences de clignement. Toute séquence n'appartenant pas à ces clusters est considérée comme une valeur aberrante et retirée des données. Cela garantit que l'ensemble final des séquences de clignement est représentatif des clignements naturels. D'autres méthodes de détection des valeurs aberrantes, telles que DBSCAN et Isolation Forests, ont été explorées, mais k-means a été choisi pour son efficacité.

Les méthodes choisies dans ce pipeline de prétraitement ont été testées par rapport à diverses alternatives, et celles sélectionnées ont fourni les résultats les plus précis et fiables, garantissant ainsi une détection précise des clignements.

4.2.2 Algorithme de prétraitement des données :

La structure algorithmique suivante fournit une description concise mais complète des étapes de prétraitement des données de détection des clignements :

Entrée : { - Données vidéo.

Sortie : { - Séquences prétraitées (X_{train} , y_{train} , X_{test} , y_{test}).

- Étapes :** {
1. Lire la vidéo image par image avec *OpenCV*
 2. Extraire les valeurs *EAR* en utilisant le modèle *Facelandmarker* de *MediaPipe*.
 3. Lisser le signal extrait avec le filtre *Butterworth*.
 4. Extraire les séquences de clignements à partir des valeurs *EAR* lissées.
 5. Détecter les *Outliers* avec *K-means* : Séparer les outliers des deux plus grands clusters.
 6. Augmenter les données : faire un tirage avec remise en introduisant un bruit faible aux séquences de clignements.
 7. Générer les données d'entraînement et de test.




Figure 4- 10: Flux de données prétraitement et détection de la somnolence.

4.3 Détection de la conduite distraite :

4.3.1 Prétraitement des données :

Chaque image est chargée à partir de son chemin d'accès et convertie en mode RGB avec ``Image.open(image_path).convert("RGB")``. Cette conversion assure un format de couleur cohérent pour toutes les images.

Ensuite, l'image est transformée à l'aide de ``ViTImageProcessor`` de Hugging Face Transformers, incluant :

- **Redimensionnement** : Les images sont ajustées à 224x224 pixels pour correspondre à la taille d'entrée du modèle ViT.
- **Mise à l'échelle de l'image** : par le facteur spécifié (par défaut 1/255) pour ajuster les valeurs de pixels.
- **Normalisation** : Normaliser l'image en utilisant la moyenne et l'écart-type spécifiés par défaut aux valeurs standard d'ImageNet.

Ces transformations préparent les images pour une utilisation efficace avec le modèle ViT.

5 Sélection et Entraînement des Modèles :

5.1 Détection du style de conduite agressive :

Sélection de modèle : Lors du processus de sélection du modèle pour la détection des styles de conduite agressifs, une gamme de modèles sophistiqués a été rigoureusement testée. Cela comprenait des modèles tels que LSTM, CNN-LSTM, CNN-BiLSTM, ConvTrans, et autres. Malgré leurs architectures robustes, ces modèles n'ont pas réussi à offrir des résultats satisfaisants en termes de précision et de temps d'inférence. Leur grande complexité a entraîné un surapprentissage des données d'entraînement en plus de prolonger les temps d'inférence, les rendant inadaptés aux applications en temps réel.

Stratégie d'entraînement : La stratégie d'entraînement pour ces modèles impliquait d'optimiser divers hyperparamètres et d'utiliser des techniques spécifiques pour améliorer leurs performances. Le callback `'ReduceLROnPlateau'` surveillait la perte de validation (validation loss) et réduisait le taux d'apprentissage d'un facteur de 0,2 après deux époques sans amélioration. Cette réduction s'est poursuivie jusqu'à ce que le taux d'apprentissage atteigne un seuil minimum. Pour éviter le surapprentissage, le callback `'EarlyStopping'` a été utilisé, ce qui

a arrêté l'entraînement après cinq époques consécutives sans amélioration de la perte de validation (validation loss). Le modèle a été compilé en utilisant l'optimiseur 'adam', largement reconnu pour ses capacités de taux d'apprentissage adaptatif, et entraîné avec une fonction de perte 'sparse categorical cross entropy', qui donne souvent les mêmes résultats qu'une fonction de perte d'entropie croisée binaire pour les tâches de classification binaire. Le processus d'entraînement comprenait l'ajustement du modèle avec 30 % des données mises de côté pour la validation, fonctionnant pendant 20 époques avec une taille de lot de 32 et utilisant les deux callbacks pour optimiser l'apprentissage.

5.2 Détection de la somnolence :

Sélection de modèle : Pour la détection de la somnolence, des modèles comme Random Forest, LSTM, GRU et CNN ont été explorés. Cependant, ces modèles n'étaient pas seulement inefficaces pour fournir le niveau de précision attendu, mais souffraient également d'un temps d'inférence élevé, ce qui limitait encore davantage leur utilité pratique.

Stratégie d'entraînement : Pour le modèle de détection de la somnolence, une fonction de perte plus spécialisée, 'BinaryFocalCrossentropy', a été utilisée pour traiter le déséquilibre des classes. Cette fonction, avec une valeur gamma de 2,0, pénalise davantage le modèle pour les mauvaises classifications de la classe minoritaire. L'optimiseur utilisé était 'adam'. Pour affiner davantage le processus d'apprentissage, le callback 'ReduceLROnPlateau' a été appliqué, surveillant la perte de validation (validation loss) et réduisant le taux d'apprentissage d'un facteur de 0,2 lorsque les améliorations se sont stabilisées. Le processus d'entraînement a également intégré 'EarlyStopping', cette fois en surveillant la précision de la validation (validation accuracy) et en restaurant les meilleurs poids après dix époques sans amélioration. Le modèle a été entraîné avec une taille de lot de 16 pour un maximum de 150 époques.

Cette stratégie a permis de développer un modèle robuste qui est capable de détecter efficacement les signes de somnolence après l'ajout du transfer learning, le rendant plus adapté aux caractéristiques uniques du sujet sur lequel il a été entraîné. Les résultats indiquent une amélioration significative de la performance, avec une augmentation de la précision sur les données test spécifiques à l'individu, comparativement à l'approche traditionnelle qui n'utilisait pas le transfer learning. Ces améliorations montrent l'importance de personnaliser les modèles d'apprentissage automatique pour des applications spécifiques où la variabilité individuelle peut jouer un rôle crucial dans la performance du modèle.

La figure (4-10) montre le processus de Transfer Learning utilisé pour la détection de la somnolence :




Figure 4- 11: Schéma du processus de Transfer Learning pour la détection de la somnolence. Les vidéos spécifiques à un sujet sont prétraitées en séquences de clignement. Les poids du réseau de neurones sont partiellement gelés et partiellement entraînaibles.

5.3 Détection de la Conduite Distracte :

Sélection de modèle : D'autres modèles comme MobileNetV2, EfficientNet, MobileViT2, Swin Transformer et autres, ont également été testés, mais le ViT a démontré une supériorité en termes de précision et de robustesse, particulièrement dans des conditions de conduite variées et réalistes.

Stratégie d'entraînement : La stratégie d'entraînement du modèle ViT a utilisé l'apprentissage par transfert pour maximiser les performances. Le processus d'entraînement a été géré par la bibliothèque Hugging Face Transformers, utilisant les paramètres suivants :

- Nombre d'époques : 3 époques.
- Batch size : La taille de lot pour l'entraînement était de 16.
- Warmup steps : 500 étapes ont été utilisées pour stabiliser le taux d'apprentissage initial.
- Weight decay : Un facteur de 0.01 a été appliqué pour régulariser le modèle.

6 Résultats :

Dans cette partie, nous présentons les résultats de nos expérimentations et analyses. L'objectif principal est d'évaluer les performances de nos modèles dans la détection des styles de conduite agressive et de la somnolence, en utilisant les données que nous avons traitées.

6.1 Détection du style de conduite agressive :

Pour valider nos modèles de détection de conduite agressive, nous avons utilisé les données de UAH qui comprend plusieurs conducteurs. En utilisant les données de quatre conducteurs pour entraîner les modèles et les données du cinquième conducteur pour la validation, nous avons veillé à ce que nos modèles puissent se généraliser à différents styles de conduite et pas seulement aux modèles spécifiques observés dans l'ensemble d'entraînement.

. En parallèle, nous avons collecté des données sur les styles de conduite normale/sûre à la fois sur autoroute et sur route secondaire, impliquant un conducteur âgé de 30 à 35 ans ayant plus de 13 ans d'expérience de conduite. Le conducteur, dans les deux cas, maintenait des schémas de freinage fluides, évitait les accélérations brusques, respectait systématiquement les distances de sécurité avec les autres véhicules et adhéraient aux instructions pour conduire en toute sécurité et rester attentif. La durée totale de ces séances de conduite combinées était de plus de 30 minutes. En utilisant ces données, nous avons également simulé des données de conduite agressive en modifiant certains paramètres tels que la vitesse, la distance de sécurité et le changement de voie.

Pour l'évaluation du modèle, nous avons utilisé ces données collectées parallèlement à la méthode de validation croisée. Les données collectées ont subi un prétraitement pour s'aligner sur le format et les fonctionnalités des données d'entraînement. Ensuite, en calculant diverses mesures de performances telles que l'accuracy, la précision, le recall et le score F1.

La figure (4-11) illustre la capacité du modèle à classer correctement le style de conduite agressive en autoroute, pour les cinq conducteurs, fournissant un aperçu visuel de l'efficacité du modèle dans la discrimination entre les comportements de conduite normaux et agressifs.




Figure 4- 12: les matrices de confusion pour cinq conducteurs en autoroute.

Le tableau (4 - 1) présente les performances détaillées du modèle en termes de précision, de rappel et de score F1 pour chaque conducteur testé. Ces métriques fournissent une vue complète de l'efficacité du modèle dans la détection des différents styles de conduite

	Conducteur 1,2,5			Conducteur 3			Conducteur 4		
Style	Précision	Recall	Score F1	Précision	Recall	Score F1	Précision	Recall	Score F1
Agressif	1.00	1.00	1.00	0.00	0.00	0.00	1.00	0.39	0.56
Normal	1.00	1.00	1.00	0.50	1.00	0.67	0.62	1.00	0.77
Moyenne	1.00	1.00	1.00	0.25	0.50	0.33	0.81	0.70	0.69

Tableau 4 - 1 : Performance du modèle de détection de style de conduite agressive sur autoroute.

La figure (4 – 12) et le tableau (4-2) illustrent les performances détaillées du modèle à classer correctement le style de conduite agressive en route secondaire.




Figure 4- 13: les matrices de confusion pour trois conducteurs en route secondaire.

	Conducteur 3,4,5			Conducteur 1			Conducteur 2		
Style	Précision	Recall	Score F1	Précision	Recall	Score F1	Précision	Recall	Score F1
Agressif	1.00	1.00	1.00	0.00	0.00	0.00	1.00	0.60	0.75
Normal	1.00	1.00	1.00	0.50	1.00	0.67	0.71	1.00	0.83
Moyenne	1.00	1.00	1.00	0.25	0.50	0.33	0.86	0.80	0.79

Tableau 4 - 2:Performance du modèle de détection de style de conduite agressive sur route secondaire.

Les résultats obtenus à partir de ces séances de conduite ont été très satisfaisants. Les deux modèles développés ont classé les séquences de conduite avec une précision de 99%, tant pour les données simulées de conduite agressive que pour les données réelles de conduite normale.

Discussion :

Les résultats obtenus de la détection du style de conduite agressive en autoroute présentent une perspective intéressante lorsque comparés aux scores réels des trajets issus de l'article de l'UAH Driveset [43](voire tableau (4-3)). Bien que les matrices de confusion montrent certaines erreurs de classification, une analyse approfondie basée sur les scores réels révèle une efficacité significative du modèle.

Les matrices de confusion illustrées dans les Figures 1 semblent indiquer des erreurs de classification, notamment pour certains conducteurs. Ces erreurs pourraient initialement être interprétées comme des faiblesses du modèle. Cependant, les matrices de confusion ne reflètent pas toujours la réalité. En comparant les résultats du modèle avec les scores des trajets fournis dans l'article [3], il devient évident que le modèle correspond plus précisément aux évaluations réelles des styles de conduite. Par exemple :

- Conducteur 3 : Bien que les matrices de confusion puissent montrer des classifications erronées, les scores réels indiquent que ce conducteur avait un style de conduite normal. Le modèle a correctement classé ce conducteur comme normal, en alignement avec les scores réels.
- Conducteur 4 : Ce conducteur a été partiellement classé comme normal par le modèle. Les scores réels montrent que ce conducteur présente effectivement un mélange de styles de conduite, ce qui correspond aux prédictions du modèle.

Un autre aspect important à considérer est la perception individuelle de l'agressivité au volant. La manière dont chaque individu perçoit l'agressivité peut varier considérablement. Par exemple, un conducteur peut adopter un style de conduite que d'autres pourraient juger agressif tout en le percevant comme normal. Inversement, un conducteur qui est perçu comme normal par les autres peut se considérer comme conduisant de manière agressive. Ces perceptions subjectives ajoutent une couche de complexité à l'évaluation des comportements de conduite et expliquent en partie pourquoi les labels initiaux peuvent parfois être en désaccord avec les scores réels.

Cependant, le modèle de détection de conduite agressive sur route secondaire n'a pas été capable de classer correctement le Conducteur 1, et a également montré des difficultés partielles avec le Conducteur 2. En notre opinion, le modèle a besoin de plus de données. La collecte directe de données étant hors du cadre de ce projet pour des raisons de sécurité, une alternative pour collecter des données serait d'utiliser l'apprentissage non supervisé sur des données non étiquetées, ce qui constitue un autre travail à réaliser.

Néanmoins, la technique de simulation de données de conduite agressive peut être probablement très utile pour entraîner le modèle, permettant ainsi de générer des scénarios variés sans risques.

	Score de comportement normal	Score de comportement agressif
Conducteur 1	5.1	4.0
Conducteur 2	1.2	6.1
Conducteur 3	5.4	3.4
Conducteur 4	3.7	5.3
Conducteur 5	1.3	7.2

Tableau 4 - 3 : Les scores de conduite, sur une échelle de 10, des conducteurs lorsqu'ils ont été instruits de conduire de manière agressive sur autoroute. [43]

6.2 Détection de la somnolence :

L'évaluation du modèle a été réalisée sur un ensemble de données spécifiques à un sujet, fournissant une analyse ciblée de l'efficacité du modèle pour une utilisation individuelle. Pour le premier sujet, le modèle a atteint une précision moyenne de 84%. Cependant, cette précision a montré une certaine variabilité, tombant parfois à 79% lorsqu'elle est testée avec le même ensemble de données. La matrice de confusion pour le premier sujet est montrée dans la Figure (4-13).




Figure 4- 14: La matrice de confusion pour les deux sujets. Source : Auteurs.

La précision, le recall et le score F1 du modèle ont été calculés et présentés dans le Tableau (4-4) pour fournir une compréhension plus complète de ses performances.

	Sujet 1			Sujet 2		
Etat du conducteur	Précision	Recall	Score F1	Précision	Recall	Score F1
Alerté	0.79	0.92	0.85	0.96	0.72	0.82
Somnolant	0.91	0.75	0.82	0.78	0.97	0.86
Moyenne	0.85	0.84	0.83	0.87	0.84	0.84

Tableau 4 - 4:Performance du modèle de détection de style de la somnolence.

Discussion :

Le modèle semble être efficace en termes de performances et de temps d'exécution. Cependant, si nous souhaitons implémenter ce modèle, la méthodologie de collecte des données reposera largement sur des heuristiques et des méthodes d'apprentissage non supervisé. Ce processus pourrait prendre un certain temps avant que le modèle puisse fonctionner efficacement pour chaque individu.

6.3 Détection de la distraction du conducteur :

L'évaluation du modèle de détection de la distraction du conducteur a été réalisée sur un ensemble de 192 images, fournissant une analyse détaillée de son efficacité dans divers scénarios de distraction. Le modèle a atteint une précision impressionnante de 96%, démontrant une capacité notable à identifier correctement les comportements de distraction du conducteur.

Cependant, bien que le modèle ait montré une haute précision globale, certaines catégories de distractions ont présenté des défis spécifiques. En particulier, les étiquettes "utilisation de la radio" et "coiffure et maquillage" ont été les plus fréquemment mal prédites. Cette confusion peut être attribuée à des similitudes visuelles entre ces activités et d'autres comportements moins distrayants, ou à des variations dans la façon dont ces actions sont réalisées par différents conducteurs.

Discussion :

L'utilisation du modèle ViT Base pour la détection de la distraction du conducteur a ses implications. Bien qu'il soit légèrement exigeant en ressources et nécessite un GPU pour fonctionner, il se distingue comme le meilleur modèle comparé à d'autres pour les classes disponibles. La haute précision de 96% démontre sa capacité de généralisation. De plus, ce modèle facilite l'ajout de nouvelles classes de distraction, telles que "manger" ou "fumer", en s'appuyant sur sa capacité à généraliser et à distinguer des comportements complexes.

7 Perspectives :

Les applications pratiques de ce projet sont vastes et variées. L'implémentation de ce système dans les flottes de transport public pourrait réduire significativement le nombre d'accidents de la route, améliorant ainsi la sécurité des passagers et des autres usagers de la route. De plus, ce système pourrait être intégré dans les programmes de formation des conducteurs, fournissant un feedback en temps réel et des alertes proactives pour corriger les comportements à risque. Les entreprises de transport pourraient également bénéficier d'une réduction des coûts liés aux accidents et d'une amélioration de leur réputation en tant qu'opérateurs sûrs et fiables.

Le projet a rencontré plusieurs défis et limitations. Par exemple, la qualité et la quantité des données disponibles pour entraîner les algorithmes d'IA peuvent varier considérablement entre les entreprises de transport. Les contraintes matérielles et logicielles ont également posé des défis pour la mise en œuvre du système en temps réel. Ces limitations ont été partiellement atténuées.

Il existe plusieurs domaines où des recherches supplémentaires sont nécessaires pour améliorer et étendre les capacités de notre système. Un axe de recherche prometteur concerne la collecte de grandes quantités de données et l'utilisation de techniques avancées pour étiqueter ces données. Cela faciliterait l'adaptation des modèles pour différents types de flottes, qu'il s'agisse de camions, de motos ou de bus. En automatisant le processus de personnalisation des modèles, nous pourrions créer des systèmes plus robustes et adaptés à une variété de véhicules et de conditions de conduite. Atteindre cette échelle permettrait à de nombreuses entreprises de bénéficier des avancées de notre système, répondant ainsi à l'objectif de la plupart des entreprises de transport public de rendre leurs opérations plus sûres et plus efficaces.

Un autre domaine de recherche important est l'étude de l'impact de ces systèmes sur le comportement des conducteurs et sur les entreprises de transport public à court et à long terme. Il est crucial de comprendre comment l'implémentation de ces systèmes influence les habitudes de conduite et les performances des conducteurs. Pour ce faire, des études pourraient être menées pour mesurer les changements observés après l'introduction du système. Parallèlement, il serait pertinent d'analyser les bénéfices économiques et opérationnels pour les entreprises de transport. Ces études fourniraient des preuves concrètes de l'efficacité des systèmes de gestion des risques et guideraient les améliorations futures pour maximiser leur impact positif.

Enfin, l'utilisation des technologies de capteurs pour améliorer l'acquisition des données représente un domaine de recherche stratégique. En intégrant des capteurs avancés pour mesurer des variables critiques telles que la distance de sécurité, et en utilisant des caméras infrarouges pour permettre le fonctionnement du système la nuit, nous pourrions améliorer la précision et la fiabilité des données collectées. Par exemple, des capteurs de distance peuvent éviter les limitations computationnelles des GPU en fournissant des mesures précises en temps réel. Ces technologies permettraient une acquisition de données plus complète et précise, augmentant ainsi la réactivité et l'efficacité du système dans des conditions variées et difficiles.

Ces axes de recherche visent à renforcer la capacité de notre système à s'adapter à différentes situations et à maximiser son efficacité à long terme, tout en ouvrant la voie à des innovations futures dans le domaine de la sécurité routière.



Conclusion générale



Conclusion générale :

Ce mémoire s'inscrit dans le contexte préoccupant de la sécurité routière, un enjeu majeur de santé publique mondiale. L'analyse des données d'accidents d'AGEFAL a révélé que les comportements des conducteurs, notamment l'excès de vitesse et la somnolence au volant, constituent des facteurs déterminants dans la survenance de ces incidents. Face à ces défis, le développement de solutions technologiques innovantes permettant de détecter et de prévenir les comportements à risque s'avère crucial pour améliorer la sécurité sur nos routes.

Ce mémoire a exploré les différentes facettes de la sécurité routière et de l'analyse du comportement des conducteurs. Le premier chapitre a présenté une revue de la littérature sur la sécurité routière, en se focalisant sur le concept du système sûr et l'importance de l'analyse du comportement des conducteurs. Il a également analysé les données des accidents d'AGEFAL, permettant d'identifier les principaux facteurs de risque et de définir les priorités pour notre projet

. Le second chapitre a exploré les systèmes intelligents et le machine learning, en mettant en avant l'importance de ces technologies dans le domaine de la sécurité routière. Il a ensuite présenté les systèmes d'aide à la conduite avancée (ADAS) et les systèmes de détection et de prévention des accidents.

Le troisième chapitre a détaillé la conception d'un système intelligent pour l'analyse du comportement des conducteurs. Il a présenté quatre modèles d'apprentissage automatique : deux pour la détection de la conduite agressive (sur routes secondaires et autoroutes), un pour la détection de la somnolence et un pour la détection de la distraction au volant. L'architecture du système global a également été présentée.

Enfin, le quatrième chapitre a présenté l'implémentation, les tests et les résultats obtenus. Il a mis en avant les choix technologiques, l'interface utilisateur et l'évaluation des performances des modèles.

Ce travail de recherche présente plusieurs intérêts :

- Contribuer à l'amélioration de la sécurité routière en permettant de détecter les comportements à risque en temps réel, apportant ainsi la possibilité de prévenir les accidents.
- Offrir des solutions innovantes grâce à l'utilisation du machine learning et des systèmes intelligents pour la gestion des risques liés aux comportements des conducteurs.
- Fournir des outils pour la gestion de flotte en collectant et analysant les données pour optimiser les opérations et améliorer la sécurité des conducteurs.
- Contribuer au développement de la recherche en enrichissant les connaissances scientifiques dans le domaine de la sécurité routière et de l'analyse du comportement.

Cependant, ce projet comporte certaines limites, telles que : la qualité des données, la complexité du système et l'acceptabilité de la technologie. Il est crucial de s'assurer que les données utilisées pour entraîner les modèles sont complètes, précises et représentatives de la réalité. Le développement d'un système intelligent complet et efficace pour l'analyse du comportement des conducteurs est un défi complexe nécessitant des ressources importantes et des compétences spécialisées.

De plus, l'intégration de technologies de surveillance et d'analyse du comportement des conducteurs soulève des questions éthiques et de respect de la vie privée.

Des perspectives futures s'ouvrent pour améliorer et élargir le système développé : intégrer des capteurs avancés pour une collecte de données plus complète et précise, personnaliser les modèles aux caractéristiques uniques de chaque conducteur pour améliorer la précision des prédictions, et intégrer le système avec d'autres technologies de sécurité routière, comme les systèmes d'aide à la conduite avancée (ADAS). Enfin, il sera important d'analyser l'impact du système sur le comportement des conducteurs et sur les entreprises de transport public à court et à long terme.

L'amélioration de la sécurité routière nécessite une approche globale impliquant les conducteurs, les gestionnaires de flotte, les gouvernements et les chercheurs. En combinant les efforts de chacun, il est possible de réduire le nombre d'accidents de la route et de construire un système de transport plus sûr pour tous.



Annexes



A.1 Introduction

Cette annexe fournit des extraits de code utilisés dans ce projet pour l'entraînement et l'évaluation des modèles d'IA. Veuillez noter que ce ne sont que des parties du code complet.

A.2 Modèle 1 : Détection de la conduite agressive

A.2.1 Prétraitement des données

```
import numpy as np
import random
from sklearn.preprocessing import MinMaxScaler

scalers = {col: MinMaxScaler() for col in selected_columns}

for col in selected_columns:
    scalers[col].fit(D1_NORMAL1_SECONDARY_merged[col].values.reshape(-1, 1))

def apply_fft_and_filter(series, n_components):
    # The output of this function is a complex number
    fft_result = np.fft.fft(series)
    fft_result[n_components:] = 0
    return np.fft.ifft(fft_result)

def add_gaussian_noise(sequence, mean=0, std_dev=0.01):
    noise = np.random.normal(mean, std_dev, sequence.shape)
    return sequence + noise

def generate_sequences_with_fft(dataframes_list, selected_columns, sequence_length, sequences_per_df,
                               fft_columns, components_list, noise_mean=0, noise_std_dev=0.01):
    all_sequences = []

    for df in dataframes_list:
        df_selected = df[selected_columns].copy()
        # fft_columns and selected_columns 2 lists of columns names
        for column in fft_columns:
            if column in df_selected.columns:
                for n in components_list:
                    transformed_column = apply_fft_and_filter(df_selected[column], n).real
                    transformed_column = scalers[column].transform(transformed_column.reshape(-1,
1)).reshape(-1)

                    df_selected[f'{column} FFT {n}'] = transformed_column

        # Drop original columns
        df_selected.drop(fft_columns, axis=1, inplace=True)

        # Generate sequences
        for _ in range(sequences_per_df):
            max_start_index = len(df_selected) - sequence_length
            start_index = random.randint(0, max_start_index)
            end_index = start_index + sequence_length
            sequence = df_selected.iloc[start_index:end_index].to_numpy()
            sequence = add_gaussian_noise(sequence, mean=noise_mean, std_dev=noise_std_dev)

            all_sequences.append(sequence)

    return np.array(all_sequences)
```

```

%cd /content/
!pip install --upgrade torchvision==0.15.2
!pip install --upgrade numpy==1.23.5
!pip install --upgrade torch==2.1.0
!pip install --upgrade timm==0.6.7
!pip install --upgrade pillow==9.4.0

!git clone https://github.com/isl-org/ZoeDepth.git
%cd ZoeDepth

import cv2
import torch
from PIL import Image
from zoedepth.models.builder import build_model
from zoedepth.utils.config import get_config

DEVICE = "cuda" if torch.cuda.is_available() else "cpu"

# ZoeD_K on kitti dataset
conf = get_config("zoedepth_nk", "infer", config_version="kitti")
#model_zoe_nk = build_model(conf)
zoe = model_zoe_nk.to(DEVICE)

def get_depth_map(image):
    depth_numpy = zoe.infer_pil(image, pad_input=False)
    return depth_numpy

def load_object_detection_model():
    model = torch.hub.load('ultralytics/yolov5', 'yolov5s', force_reload=True)
    return model.to(DEVICE)

#object_detector = load_object_detection_model()

def filter_classes(detection_results):
    filtered_detections = []
    for detection in detection_results:
        class_id = detection[5]
        if class_id in [5.0, 7.0, 2.0, 3.0]:
            filtered_detections.append(detection)
    return filtered_detections

video_path = '/content/drive/MyDrive/Projects/PFE/UAH Driveset/UAH/UAH-DRIVESET-
v1/D1/20151110175712-16km-D1-NORMAL1-SECONDARY/20151110175712-16km-D1-NORMAL1-
SECONDARY.mp4'
cap = cv2.VideoCapture(video_path)
frame_count = 0

while True:
    ret, frame = cap.read()
    frame_count += 1

    if not ret:
        break
    if frame_count % 30 != 0: # Skip frames
        continue
    frame_count = 0

    # Convert frame to PIL Image
    pil_image = Image.fromarray(cv2.cvtColor(frame, cv2.COLOR_BGR2RGB))

    # Estimate depth map
    depth_numpy = get_depth_map(pil_image)

    results = object_detector(frame)
    objects = results.xyxy[0]
    if len(objects) == 0:
        continue
    print(objects)
    vehicles = filter_classes(objects)
    num_vehicles = len(vehicles)
    print('the number of vehicles : ', num_vehicles)
    for vehicle in vehicles:
        x1, y1, x2, y2 = map(int, vehicle[:4]) # Extract bounding box coordinates

```

```

import torch
import cv2
import numpy as np

DEVICE = 'cpu'

def load_object_detection_model():
    modelyolo = torch.hub.load('ultralytics/yolov5', 'yolov5s', force_reload=True)
    return modelyolo.to(DEVICE)

def distance_to_camera(knownWidth, focalLength, perWidth):
    return (knownWidth * focalLength) / perWidth

def point_in_triangle(pt, v1, v2, v3):
    def sign(p1, p2, p3):
        return (p1[0] - p3[0]) * (p2[1] - p3[1]) - (p2[0] - p3[0]) * (p1[1] - p3[1])

    b1 = sign(pt, v1, v2) < 0.0
    b2 = sign(pt, v2, v3) < 0.0
    b3 = sign(pt, v3, v1) < 0.0

    return ((b1 == b2) and (b2 == b3))

def process_video(video_path, focal_length, known_width, modelyolo):
    cap = cv2.VideoCapture(video_path)
    if not cap.isOpened():
        print("Error opening video file")
        return
    cpt = 0
    frame_width = int(cap.get(cv2.CAP_PROP_FRAME_WIDTH))
    frame_height = int(cap.get(cv2.CAP_PROP_FRAME_HEIGHT))
    fps = cap.get(cv2.CAP_PROP_FPS)

    triangle_vertices = [(0, frame_height), (frame_width, frame_height), (frame_width // 2, 0)]

    distances = []
    vehicle_counts = []

    while cap.isOpened():
        cpt += 1
        ret, frame = cap.read()
        if not ret:
            break
        if cpt % (fps // 2) == 0:
            results = modelyolo(frame)
            detections = results.xyxy[0].cpu().numpy()
            cars = detections[detections[:, 5] == 2]

            vehicle_counts.append(len(cars))

            if len(cars) > 0:
                min_distance = float('inf')
                closest_car = None

                for car in cars:
                    x1, y1, x2, y2, conf, class_id = car
                    box_center = np.array([(x1 + x2) / 2, (y1 + y2) / 2])

                    if point_in_triangle(box_center, *triangle_vertices):
                        distance_to_center = np.linalg.norm(box_center - np.array([frame_width / 2,
frame_height / 2]))

                        if distance_to_center < min_distance:
                            min_distance = distance_to_center
                            closest_car = car

                if closest_car is not None:
                    x1, y1, x2, y2, conf, class_id = closest_car
                    perWidth = x2 - x1
                    distance = distance_to_camera(known_width, focal_length, perWidth) / 1000
                    if distance < 2:
                        distances.append(-1)
                    else:
                        distances.append(distance)
                else:
                    distances.append(-1)
            else:
                distances.append(-1)

        cap.release()
        cv2.destroyAllWindows()

    return distances, vehicle_counts

```

A.2.2 Architecture du modèle

```
model = Sequential([
    Conv1D(filters=64, kernel_size=10, padding='same', input_shape=(time_steps, num_features)),
    MaxPool1D(pool_size=4, strides=2, padding="same"),
    BatchNormalization(),
    ReLU(),
    Dropout(0.5),
    GlobalAveragePooling1D(),
    Dense(16, activation='relu'),
    Dropout(0.5),
    Dense(num_classes, activation='softmax')
])
```

A.2.3 Entraînement du modèle

```
reduce_lr = ReduceLROnPlateau(
    monitor='val_loss',
    factor=0.2,
    patience=2,
    min_lr=0.000000001
)
early_stopping = EarlyStopping(monitor='val_loss', patience=5)

model.compile(optimizer='adam', loss='sparse_categorical_crossentropy', metrics=['accuracy'])
model.summary()

model.fit(X_train, y_train_encoded, epochs=15, validation_split=0.3, batch_size=32, callbacks=[reduce_lr,
early_stopping])
```

A.3 Modèle 2 : Détection de distraction du conducteur

A.3.1 Importation des bibliothèques

```
%%capture --no-display
!pip install ultralytics
!pip install split-folders
!pip install -U ipywidgets

import matplotlib.pyplot as plt
import os
import splitfolders
from IPython.display import display, Image
import pandas as pd
from torch.utils.data import Dataset, DataLoader
from PIL import Image
import torch
from sklearn.preprocessing import LabelEncoder
from transformers import ViTForImageClassification, Trainer, TrainingArguments, ViTImageProcessor
import warnings
warnings.filterwarnings('ignore')
```

A.3.2 Utilisation de ViT pour la classification d'images

```
from transformers import ViTForImageClassification, Trainer, TrainingArguments, ViTImageProcessor

class CustomDataset(Dataset):
    def __init__(self, img_dir, image_processor):
        self.img_dir = img_dir
        self.image_processor = image_processor
        self.images = []
        self.labels = []

        self.label_encoder = LabelEncoder()
        label_dirs = [d for d in os.listdir(img_dir) if os.path.isdir(os.path.join(img_dir, d))]
        self.label_encoder.fit(label_dirs)

        for label_dir in label_dirs:
            class_dir = os.path.join(img_dir, label_dir)
            for image_file in os.listdir(class_dir):
                self.images.append(os.path.join(class_dir, image_file))
                self.labels.append(label_dir)

    def __len__(self):
        return len(self.images)

    def __getitem__(self, idx):
        image_path = self.images[idx]
        image = Image.open(image_path).convert("RGB")
        label = self.label_encoder.transform([self.labels[idx]])[0]

        inputs = self.image_processor(images=image, return_tensors="pt").data
        inputs = {key: tensor.squeeze() for key, tensor in inputs.items()}
        inputs['labels'] = torch.tensor(label, dtype=torch.long)

        return inputs

image_processor = ViTImageProcessor.from_pretrained('google/vit-base-patch16-224-in21k')
train_dataset = CustomDataset(img_dir='/kaggle/working/output/train', image_processor=image_processor)
train_loader = DataLoader(train_dataset, batch_size=16, shuffle=True)
model = ViTForImageClassification.from_pretrained('google/vit-base-patch16-224-in21k', num_labels=10)

training_args = TrainingArguments(
    output_dir='./results',
    num_train_epochs=3,
    per_device_train_batch_size=16,
    per_device_eval_batch_size=64,
    warmup_steps=500,
    weight_decay=0.01,
    logging_dir='./logs',
    logging_steps=200,
    report_to=[]
)

trainer = Trainer(
    model=model,
    args=training_args,
    train_dataset=train_dataset
)

trainer.train()
```

A.3.3 Utilisation de MobileNetV2 pour la classification d'images

```
from transformers import AutoImageProcessor, MobileViTV2ForImageClassification, Trainer,
TrainingArguments, MobileViTV2Config

image_processor = AutoImageProcessor.from_pretrained('apple/mobilevitv2-1.0-imagenet1k-256')
train_dataset = CustomDataset(img_dir='/kaggle/working/output/train', image_processor=image_processor)
train_loader = DataLoader(train_dataset, batch_size=16, shuffle=True)

config = MobileViTV2Config.from_pretrained('apple/mobilevitv2-1.0-imagenet1k-256',
num_labels=len(set(train_dataset.labels)))
model = MobileViTV2ForImageClassification.from_pretrained('apple/mobilevitv2-1.0-imagenet1k-256',
config=config, ignore_mismatched_sizes=True)
model.classifier = torch.nn.Linear(model.classifier.in_features, config.num_labels)

training_args = TrainingArguments(
    output_dir='./results',
    num_train_epochs=4,
    per_device_train_batch_size=16,
    per_device_eval_batch_size=64,
    warmup_steps=500,
    weight_decay=0.01,
    logging_dir='./logs',
    logging_strategy="steps",
    logging_steps=5,
    evaluation_strategy="steps",
    eval_steps=500,
    save_strategy="steps",
    load_best_model_at_end=True,
    report_to=[]
)

trainer = Trainer(
    model=model,
    args=training_args,
    train_dataset=train_dataset,
)

trainer.train()
```


A.3.4 Utilisation de Swin Transformer pour la classification d'images

```
from transformers import SwinForImageClassification, SwinConfig
from torch.optim import AdamW

train_dataset = CustomDataset(img_dir='/kaggle/working/output/train')
train_loader = DataLoader(train_dataset, batch_size=16, shuffle=True)

config = SwinConfig.from_pretrained('microsoft/swin-base-patch4-window7-224', num_labels=10)
model = SwinForImageClassification.from_pretrained(
    'microsoft/swin-base-patch4-window7-224',
    config=config,
    ignore_mismatched_sizes=True
)

model.classifier = torch.nn.Linear(model.config.hidden_size, 10)

device = torch.device("cuda" if torch.cuda.is_available() else "cpu")
model.to(device)
criterion = CrossEntropyLoss()
optimizer = AdamW(model.parameters(), lr=0.001)

def train_model(model, criterion, optimizer, num_epochs=3):
    model.train()
    for epoch in range(num_epochs):
        running_loss = 0.0
        for images, labels in train_loader:
            images, labels = images.to(device), labels.to(device)
            optimizer.zero_grad()
            outputs = model(pixel_values=images, labels=labels)
            loss = outputs.loss
            loss.backward()
            optimizer.step()
            running_loss += loss.item() * images.size(0)
        print(f"Epoch {epoch+1}, Loss: {running_loss / len(train_loader.dataset)}")

train_model(model, criterion, optimizer)
```

A.4 Modèle 3 : Détection de la somnolence

A.4.1 L'architecture du modèle

```
from keras.models import Model
from keras.layers import Input, Conv1D, MaxPooling1D, Flatten, Dense, Add, ReLU, GlobalAveragePooling1D, Dropout
from keras.callbacks import EarlyStopping, ReduceLROnPlateau

def residual_block(input_tensor, filters, kernel_size):
    x = Conv1D(filters, kernel_size, padding='same')(input_tensor)
    x = ReLU()(x)
    x = Conv1D(filters, kernel_size, padding='same')(x)
    x = Add()([x, input_tensor])
    return ReLU()(x)

def build_resnet1d_model(input_shape):
    inputs = Input(shape=input_shape)
    x = Conv1D(8, 7, padding='same', activation='relu')(inputs)
    x = MaxPooling1D(3)(x)
    x = residual_block(x, 8, 3)
    x = residual_block(x, 8, 3)
    x = residual_block(x, 8, 3)
    x = residual_block(x, 8, 3)
    x = residual_block(x, 8, 3)
    x = GlobalAveragePooling1D()(x)
    x = Dense(16, activation='relu')(x)
    outputs = Dense(2, activation='softmax')(x)

    model = Model(inputs, outputs)
    model.compile(optimizer='adam', loss='binary_focal_crossentropy', metrics=['accuracy'])
    return model

resnet1d_model = build_resnet1d_model(input_shape=(10, 8))

# Callbacks
early_stopping = EarlyStopping(monitor='val_loss', patience=20, verbose=1, mode='min')
reduce_lr = ReduceLROnPlateau(monitor='val_loss', factor=0.2, patience=7, verbose=1, mode='min', min_lr=0.000000001)

resnet1d_model.fit(X_train_filtered, y_train_encoded, epochs=150, batch_size=32, validation_split=0.2,
callbacks=[early_stopping, reduce_lr])

test_loss, test_accuracy = resnet1d_model.evaluate(X_test_filtered, y_test_encoded, verbose=1)
print(f"Resnet Test Loss: {test_loss}")
print(f"Resnet Test Accuracy: {test_accuracy}")
```

A.4.2 Entraînement du modèle

```
# Callbacks
early_stopping = EarlyStopping(monitor='val_loss', patience=20, verbose=1, mode='min')
reduce_lr = ReduceLROnPlateau(monitor='val_loss', factor=0.2, patience=7, verbose=1, mode='min', min_lr=0.000000001)

resnet1d_model.fit(X_train_filtered, y_train_encoded, epochs=150, batch_size=32, validation_split=0.2,
callbacks=[early_stopping, reduce_lr])
```

A.4.3 Transfer Learning

```
from keras.optimizers import Adam

modelp = resnet1d_model
for layer in modelp.layers[:-2]:
    layer.trainable = False

adam_optimizer = Adam(learning_rate=0.001)
modelp.compile(optimizer=adam_optimizer, loss='binary_crossentropy', metrics=['accuracy'])

# callbacks
callbacks = [
    EarlyStopping(monitor='val_loss', patience=10, verbose=1, mode='min', restore_best_weights=True),
    ReduceLROnPlateau(monitor='val_loss', factor=0.5, patience=3, min_lr=0.0001),
    ModelCheckpoint('best_model.keras', monitor='val_loss', save_best_only=True, mode='min', verbose=1)
]

# Train the model on new data
history = modelp.fit(
    X_train, y_train_encoded,
    epochs=60,
    validation_data=(X_val, y_val_encoded),
    callbacks=callbacks
)

# Evaluate the model
test_loss, test_acc = modelp.evaluate(X_test_prepared, y_test_encoded)
print("Test accuracy:", test_acc)
```



Bibliographies



- [1] : *Global status report on road safety 2023*
- [2]: Chand, A., Jayesh, S., & Bhasi, A. B. (2021). Road traffic accidents: An overview of data sources, analysis techniques and contributing factors. *Materials Today: Proceedings*, 47, 5135-5141.
- [3] : Abdullah, P., & Sipos, T. (2022). Drivers' behavior and traffic accident analysis using decision tree method. *Sustainability*, 14(18), 11339.
- [4] : Bassani, M., Catani, L., Hazoor, A., Hoxha, A., Lioi, A., Portera, A., & Tefa, L. (2023). Do driver monitoring technologies improve the driving behaviour of distracted drivers? A simulation study to assess the impact of an auditory driver distraction warning device on driving performance. *Transportation research part F: traffic psychology and behaviour*, 95, 239-250.
- [5]: World Health Organization : WHO. (2023a, Decembre 13). Malgré des progrès appréciables, la sécurité routière reste un problème urgent dans le monde. <https://www.who.int/fr/news/item/13-12-2023-despite-notable-progress-road-safety-remains-urgent-global-issue#cms>
- [6] : Organisation mondiale de la Santé. (2017). Sauver des VIES – Module technique sur la sécurité routière. Genève. Licence : CC BY-NC-SA 3.0 IGO.
- [7] : Principes d'un système sûr | Manuel de sécurité routière - Association mondiale de la Route (AIPCR). (s. d.-b). <https://roadsafety.piarc.org/fr/gestion-de-la-securite-routiere-4-approche-systeme-sur/principes-dun-systeme-sur>
- [8]: World Health Organization : WHO. (2023, 13 décembre). Traumatismes dus aux accidents de La circulation. <https://www.who.int/fr/news-room/fact-sheets/detail/road-traffic-injuries>
- [9]: Azadani, M. N., & Boukerche, A. (2021). Driving behavior analysis guidelines for intelligent transportation systems. *IEEE transactions on intelligent transportation systems*, 23(7), 6027-6045.
- [10]: Wang, W., Xi, J., & Chen, H. (2014). Modeling and recognizing driver behavior based on driving data: A survey. *Mathematical Problems in Engineering*, 2014.
- [11]: *Global status report on road safety 2023*

- [12]: Kaplan, S., Guvensan, M. A., Yavuz, A. G., & Karalurt, Y. (2015). *Driver behavior analysis for safe driving: A survey. IEEE Transactions on Intelligent Transportation Systems*, 16(6), 3017-3032.
- [13]: Wang, W., Xi, J., Chong, A., & Li, L. (2017). *Driving style classification using a semisupervised support vector machine. IEEE Transactions on Human-Machine Systems*, 47(5), 650-660.
- [14]: Magaña, V. C., & Muñoz-Organero, M. (2015). *Artemisa: A personal driving assistant for fuel saving. IEEE Transactions on Mobile Computing*, 15(10), 2437-2451.
- [15]: Han, W., Wang, W., Li, X., & Xi, J. (2019). *Statistical-based approach for driving style recognition using Bayesian probability with kernel density estimation. IET Intelligent Transport Systems*, 13(1), 22-30.
- [16]: Yang, S., Wang, W., Zhang, F., Hu, Y., & Xi, J. (2018). *Driving-style-oriented adaptive equivalent consumption minimization strategies for HEVs. IEEE Transactions on Vehicular Technology*, 67(10), 9249-9261.
- [17]: Moukafih, Y., Hafidi, H., & Ghogho, M. (2019, July). *Aggressive driving detection using deep learning-based time series classification. In 2019 IEEE international symposium on INnovations in intelligent SysTems and applications (INISTA) (pp. 1-5). IEEE.*
- [18]: Özkan, T., Lajunen, T., Parker, D., Sümer, N., & Summala, H. (2011). *Aggressive driving among british, dutch, finnish and turkish drivers. International journal of crashworthiness*, 16(3), 233-238
- [19]: Perallos, A., Hernandez-Jayo, U., Onieva, E., & Zuazola, I. J. G. (Eds.). (2015). *Intelligent transport systems: technologies and applications. John Wiley & Sons.*
- [20]: El Naqa, I., & Murphy, M. J. (2015). *What is machine learning? (pp. 3-11). Springer International Publishing.*
- [21] : Slimane, Y. & Tahar Djoudi, S. (2020). *Extraction De Motifs Basée Sur Word2vec [Mémoire de Master, Université Saad Dahleb - Blida*
- [22]: Jadaan, K., Zeater, S., & Abukhalil, Y. (2017). *Connected vehicles: an innovative transport technology. Procedia Engineering*, 187, 641-648.

- [23]: Chen, S., Hu, J., Shi, Y., Peng, Y., Fang, J., Zhao, R., & Zhao, L. (2017). *Vehicle-to-everything (V2X) services supported by LTE-based systems and 5G*. *IEEE Communications Standards Magazine*, 1(2), 70-76.
- [24]: Schwarting, W., Alonso-Mora, J., & Rus, D. (2018). *Planning and decision-making for autonomous vehicles*. *Annual Review of Control, Robotics, and Autonomous Systems*, 1, 187-210.
- [25]: Parekh, D., Poddar, N., Rajpurkar, A., Chahal, M., Kumar, N., Joshi, G. P., & Cho, W. (2022). *A review on autonomous vehicles: Progress, methods and challenges*. *Electronics*, 11(14), 2162.
- [26]: Bengler, K., Dietmayer, K., Farber, B., Maurer, M., Stiller, C., & Winner, H. (2014). *Three decades of driver assistance systems: Review and future perspectives*. *IEEE Intelligent transportation systems magazine*, 6(4), 6-22.
- [27]: Antony, M.M., Whenish, R. (2021). *Advanced Driver Assistance Systems (ADAS)*. In: Kathiresh, M., Neelaveni, R. (eds) *Automotive Embedded Systems*. EAI/Springer Innovations in Communication and Computing. Springer, Cham. https://doi.org/10.1007/978-3-030-59897-6_9.
- [28]: Kukkala, V. K., Tunnell, J., Pasricha, S., & Bradley, T. (2018). *Advanced driver-assistance systems: A path toward autonomous vehicles*. *IEEE Consumer Electronics Magazine*, 7(5), 18-25.
- [29]: Khalil, U., Javid, T., & Nasir, A. (2017, November). *Automatic road accident detection techniques: A brief survey*. In *2017 International Symposium on Wireless Systems and Networks (ISWSN)* (pp. 1-6).
- [30]: Lowrie, J., & Brownlow, H. (2020). *The impact of sleep deprivation and alcohol on driving: a comparative study*. *BMC public health*, 20, 1-9.
- [31]: Bharadwaj, N., Edara, P., & Sun, C. (2021). *Sleep disorders and risk of traffic crashes: A naturalistic driving study analysis*. *Safety science*, 140, 105295.
- [32]: Jin, X., Yin, G., & Chen, N. (2019). *Advanced estimation techniques for vehicle system dynamic state: A survey*. *Sensors*, 19(19), 4289.

- [33]: Caffier, P. P., Erdmann, U., & Ullsperger, P. (2003). *Experimental evaluation of eye-blink parameters as a drowsiness measure. European journal of applied physiology*, 89, 319-325.
- [34]: Alvaro, P. K., Jackson, M. L., Berlowitz, D. J., Swann, P., & Howard, M. E. (2016). *Prolonged eyelid closure episodes during sleep deprivation in professional drivers. Journal of clinical sleep medicine*, 12(8), 1099-1103.
- [35]: Cori, J. M., Anderson, C., Soleimanloo, S. S., Jackson, M. L., & Howard, M. E. (2019). *Narrative review: Do spontaneous eye blink parameters provide a useful assessment of state drowsiness? Sleep medicine reviews*, 45, 95-104.
- [36]: Jackson, M. L., Kennedy, G. A., Clarke, C., Gullo, M., Swann, P., Downey, L. A., ... & Howard, M. E. (2016). *The utility of automated measures of ocular metrics for detecting driver drowsiness during extended wakefulness. Accident Analysis & Prevention*, 87, 127-133.
- [37]: Johns, M. W., Chapman, R., Crowley, K., & Tucker, A. (2008). *A new method for assessing the risks of drowsiness while driving. Somnologie*, 12(1), 66-74.
- [38]: Shiferaw, B. A., Downey, L. A., Westlake, J., Stevens, B., Rajaratnam, S. M., Berlowitz, D. J., ... & Howard, M. E. (2018). *Stationary gaze entropy predicts lane departure events in sleep-deprived drivers. Scientific reports*, 8(1), 2220.
- [39]: Pothiraj, S., Vadlamani, R., & Reddy, B. P. K. (2021). *A NON-INTRUSIVE METHOD FOR DRIVER DROWSINESS DETECTION USING FACIAL LANDMARKS*.
- [40]: Alrfou, K., Kordijazi, A., & Zhao, T. (2022). *Computer vision methods for the microstructural analysis of materials: The state-of-the-art and future perspectives. arXiv preprint arXiv:2208.04149*.
- [41]: Romera, E., Bergasa, L. M., & Arroyo, R. (2016, November). *Need data for driver behaviour analysis? Presenting the public UAH-DriveSet. In 2016 IEEE 19th international conference on intelligent transportation systems (ITSC) (pp. 387-392). IEEE*.
- [42]: Ghoddoosian, R., Galib, M., & Athitsos, V. (2019). *A realistic dataset and baseline temporal model for early drowsiness detection. In Proceedings of the ieee/cvf conference on computer vision and pattern recognition workshops (pp. 0-0)*.

[43]: Romera, E., Bergasa, L. M., & Arroyo, R. (2016, November). Need data for driver behaviour analysis? Presenting the public UAH-DriveSet. In *2016 IEEE 19th international conference on intelligent transportation systems (ITSC)* (pp. 387-392). IEEE.