



HAL
open science

Estimation et analyse de risque de collision pour un véhicule autonome

Amin Mechernene

► **To cite this version:**

Amin Mechernene. Estimation et analyse de risque de collision pour un véhicule autonome. Intelligence artificielle [cs.AI]. Université Paris-Saclay, 2023. Français. NNT : 2023UPAST075 . tel-04210363

HAL Id: tel-04210363

<https://theses.hal.science/tel-04210363>

Submitted on 18 Sep 2023

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

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

Estimation et analyse de risque de collision pour un véhicule autonome

Detection and analysis of collision risk for autonomous vehicle

Thèse de doctorat de l'université Paris-Saclay

École doctorale n° 575, electrical, optical, bio : physics and engineering (EOBE)

Spécialité de doctorat : Génie électrique

Graduate School : Sciences de l'ingénierie et des systèmes. Référent : Faculté
des sciences d'Orsay

Thèse préparée dans l'unité de recherche ESTACA'Lab S2ET (Systèmes et Énergie Embarqués pour les Transport), sous la direction de **Moussa BOUKHNIFER**, Maître de conférences HDR, Université de Lorraine, le co-encadrement de **Vincent JUDALET**, Maître de conférences, ESTACA, et de **Ahmed CHAIBET**, Maître de conférences HDR, Université bourgogne Franche-Comté

Thèse soutenue à Paris-Saclay, le 25 mai 2023, par

Amin MECHERNE

Composition du Jury

Membres du jury avec voix délibérative

Jérôme BOSCHE

Professeur, Université de Picardie

Président & Rapporteur

Tarek AHMED-ALI

Professeur, Université de Caen
Normandie

Rapporteur & Examineur

Olivier ORFILA

Chercheur HDR rattaché à l'école
doctoral de Paris Saclay, Vedecom

Examineur

Abdelmoudjib BENTERKI

Maître de conférences, ESTACA

Examineur

Titre : Estimation et analyse de risque de collision pour un véhicule autonome

Mots clés : Véhicule automatisé, évaluation du risque, prise de décision.

Résumé : L'un des domaines qui a vu les plus grandes évolutions ces dernières années dans l'industrie automobile est certainement ADAS (Advanced Driver-Assistance Systems), toutes ces technologies visent à améliorer la sécurité routière et le confort des conducteurs et des passagers. Le véhicule automatisé doit être capable de réaliser plusieurs tâches simultanément. La perception qui consiste à construire une carte de l'environnement. La prise de décision décide de la trajectoire optimale à suivre en temps réel. La conduite automatisée s'appuie sur le contrôle des organes du véhicule (moteur, freins, direction, etc.) afin de suivre une trajectoire donnée par le module de décision. Le travail de cette thèse s'inscrit dans le développement d'algorithmes pour la prise de décision, et plus précisément pour les manœuvres de changement de voie sur autoroute et voies rapides. L'étude commence par un point sur les travaux réalisés concernant l'analyse des risques pour les véhicules automatisés, également sur les différents algorithmes pour la prise de décision pour le changement de voie. Une métrique pour évaluer le risque lors des manœuvres de changement de voie est

développée. Cette métrique est construite à partir de la base de données MOOVE de l'Institut VEDECOM pour la conduite en conditions réelles. Sur la base de l'échelle de risque proposée, une méthodologie de prise de décision pour le changement de voie est développée. Elle repose sur 3 étapes successives : prédiction de trajectoires des véhicules environnants, évaluations des risques à partir des trajectoires prédites et choix du moment optimal pour commencer la manœuvre, et finalement l'algorithme de prise de décision qui, en se basant sur la valeur du risque et du gain décide de réaliser la manœuvre de changement de voie ou non. Quatre algorithmes ont été proposés, Arbre de décision, forêt d'arbres décisionnels, logique floue et réseau de neurones. Les quatre algorithmes ont été validés de deux méthodes. La première est une validation sur la base de données HighD en comparant les décisions des algorithmes aux décisions humaines. La seconde est une validation sur simulateur pour évaluer les niveaux de risque pris par les algorithmes. De ces deux validations il en ressort que la forêt d'arbres décisionnels est l'algorithme qui obtient les meilleures performances.

Title : Detection and analysis of collision risk for autonomous vehicle

Keywords : Automated vehicle, risk assessment, decision making.

Abstract : One of the areas that has seen the greatest developments in recent years in the automotive industry is certainly ADAS (Advanced Driver-Assistance Systems), all these technologies aim to improve road safety and comfort of drivers and passengers. The autonomous vehicle must be able to perform several tasks simultaneously. The perception which consists in building a map of the environment. The decision making process decides the optimal trajectory to follow in real time. The automated driving is based on the control of the vehicle's organs (engine, brakes, steering, etc.) in order to follow a trajectory given by the decision module. The work of this thesis is part of the development of algorithms for decision making, and more precisely for lane change maneuvers on highways and expressways. The study starts with a review of the work done on risk analysis for autonomous vehicles, and also on the different algorithms for lane change decision making. A metric to evaluate the risk during lane change maneuvers is developed. This

metric is built from the MOOVE database of the VEDECOM Institute for driving in real conditions. Based on the proposed risk scale, a decision-making methodology for lane change is developed. It is based on 3 successive steps : prediction of trajectories of surrounding vehicles, risk assessment from the predicted trajectories and choice of the optimal moment to start the maneuver, and finally decision making algorithm which, based on the value of risk and gain, decides to perform the lane change maneuver or not. Four algorithms have been proposed, Decision Tree, random Forest, Fuzzy Logic and Neural Network. The four algorithms have been validated in two ways. The first one is a validation on the HighD database by comparing the decisions of the algorithms to human decisions. The second is a validation on a simulator to evaluate the risk levels taken by the algorithms. From these two validations, it appears that the random forest is the algorithm that obtains the best performances.

J_E dédie ce travail :

- à mes défunts grands parents Rahma, Aïcha et Mohamed,
- à mon grand père Abdelkader,
- à mon père et à ma mère, pour leurs éternels soutiens,
- à ma sœur Naïma,
- à mon épouse Lamia,
- à mes cousins Abdelhalim et Mohammed Abdallah, les grands frères que je n'ai pas eu.
- Mes cousines Fouzia, Fatima Zohra, Malika,
- à mes oncles Sidi Mohamed et Omar et mes tantes Haféda, Amina et Khadidja,

Amin MECHERNENE

Ce document présente les travaux effectués dans le cadre d'une collaboration entre l'ESTACA'LAB, laboratoire de recherche de l'école supérieure des techniques aéronautiques et de construction automobile, et Vedecom, Institut français de recherche dédié à la mobilité individuelle décarbonée et durable. Je tiens à remercier monsieur Chérif LAROUCI de m'avoir accueilli au sein du laboratoire. Je remercie également Sandrine PIOGER pour son aide au volet administratif.

Je souhaiterais exprimer ma gratitude à mes encadrants, Vincent JUDALET et Ahmed CHAIBET, et mon directeur de thèse Moussa BOUKHNIFER, pour m'avoir offert l'opportunité de réaliser cette thèse, de m'avoir encadré durant ces années, et pour leur patience.

Je remercie également Gildas THIOLON pour l'aide qu'il m'a apportée à l'extraction de données depuis la base de données MOOVE.

Et pour finir un grand merci à tous mes collègues doctorant que j'ai pu rencontrer durant mes années à l'ESTACA, et sans qui l'ambiance au bureau aurait été très différente. Je pense notamment à Abdelmoudjib, Nadir, Antoine, Adriano, Aissam, Kunal et Khansa.

Amin MECHERNENE

Table des matières

Introduction générale	1
0.1 Contexte	1
0.2 Contributions et objectifs de la thèse	3
1 Etat de l’art sur la prise de décision pour la conduite automatisée	7
1.1 Introduction	9
1.2 Introduction aux véhicules automatisés	9
1.3 La prise de décision pour la conduite automatisée	15
1.4 Modèles de prédiction basés sur les trajectoires	17
1.4.1 Modèles dynamiques	17
1.4.2 Modèles cinématiques	23
1.4.3 La prédiction de trajectoire	24
1.4.4 Limites des modèles basés sur la physique	26
1.5 Modèles de prediction basés sur les manœuvres	26
1.6 Analyse du risque de collision	29
1.7 Prise de décision pour les manœuvres de changement de voie	31
1.7.1 Modèle basé sur des règles	32
1.7.2 Modèle basé sur l’intelligence artificielle	32
1.7.3 Modèle basé sur les «incitations»	34
1.8 Axes d’améliorations par rapport à l’état de l’art	34
1.9 Bases de données de roulage	35
1.9.1 NGSIM	35
1.9.2 HighD	35
1.9.3 MOOVE	37
1.9.4 KITTI	40

TABLE DES MATIÈRES

1.10	Conclusion	41
2	Définition d'une échelle du risque, et gain	43
2.1	Introduction	44
2.2	Extraction de données	44
2.2.1	Choix de la base de données	44
2.2.2	Caractéristiques de la base de données MOOVE	45
2.2.3	Méthodologie d'extraction des données	48
2.3	Analyse des résultats pour les changement de voie vers la gauche . .	50
2.3.1	Véhicule leader sur la voie initiale	50
2.3.2	Véhicule leader sur la voie finale	51
2.3.3	Véhicule arrière sur la voie finale	53
2.4	Méthode d'évaluation du risque	55
2.5	Définition du gain	60
2.6	Conclusion	63
3	Algorithmes de prise de décision et validation	65
3.1	Introduction	66
3.2	Organigramme de prise de décision	66
3.3	Prédiction de trajectoire	70
3.4	Base de données HighD	73
3.5	Extraction des manœuvres dans la base de données	73
3.6	Logique Floue	74
3.7	Arbre de décision	79
3.8	Réseau de neurones artificiels	82
3.9	Forêt d'arbres décisionnels	85
3.10	Validation sur simulateur	87
3.10.1	CARLA	88
3.10.2	Matlab Driving Simulator	90
3.10.3	CarMaker	91
3.10.4	Développement d'un simulateur de conduite	93
3.11	Étude des résultats	95
4	Conclusion générale	99

Introduction générale

0.1 Contexte

Cette thèse s'inscrit dans le cadre d'une collaboration entre l'institut Vedecom et l'École supérieure des techniques aéronautiques et de construction automobile (ESTACA) pour le développement de nouvelles fonctions d'aide à la conduite ADAS (advanced driver-assistance systems) pour les véhicules automatisés.

Les travaux consistent à développer la compréhension du comportement humain lors des manœuvres de changement de voie sur la base de manœuvres réalisées par des conducteurs humains et compilées au sein de bases de données afin de proposer un algorithme de prise de décision qui reproduit au mieux le comportement humain. Pour cela, nous devons introduire une méthode d'analyse du risque inspirée de la perception qu'ont des humains de ce dernier, et finalement développer des algorithmes de prise de décision pour reproduire un comportement humain. Cette partie pose le contexte et décrit les motivations scientifiques de notre travail de recherche dans le cadre de cette thèse.

Les transports sont au cœur de notre société, des moyens de transport plus automatisés et plus rapides permettent un gain de temps et de confort et ainsi une productivité plus élevée et plus d'innovations.

La révolution industrielle et toutes les innovations successives qui en découlent (la machine à vapeur, les moteurs à combustion interne, les moteurs électriques. . .) ont permis de s'affranchir des animaux tels que les chevaux, comme principale source de puissance mécanique, et ainsi d'en disposer à n'importe quel moment souhaité, et avec une régularité jamais atteinte jusqu'à lors.

L'avènement de ces technologies à l'usage des transports ont été à la base de l'industrialisation des sociétés et de l'explosion de la croissance économique mondiale au cours des deux derniers siècles, améliorant la vie de milliards de personnes [Moh19].

Dès lors, les véhicules motorisés n'ont cessé d'évoluer pour améliorer plusieurs points. Tout d'abord les rendements de moteurs pour plusieurs raisons : baisser les couts d'usage, prolonger l'autonomie, et réduire l'impact écologique qui est un défi majeur pour nos sociétés actuelles, améliorer le confort des passagers des véhicules. Ce dernier point passe notamment par l'introduction d'automatisations toujours plus important pour faciliter la tâche des conducteurs via des assistances à la conduite plus ou moins évoluées (directions assistée, régulateur de vitesse...), jusqu'à l'automatisation complète de certaines actions (boîte de vitesse automatique). Le dernier point d'amélioration est la sécurité qui est devenu un élément fondamental dans la conception des véhicules modernes. Plusieurs aspects peuvent améliorer la sécurité, mécaniques (points de déformations de la structure en cas de chocs, travail sur la tenue de route pour améliorer la stabilité), mais également électroniques telles que les systèmes de sécurité active (ABS, ESP, AFU) et les ADAS « Advanced Driver-Assistance Systems » ou « système avancé d'aide à la conduite ».

Les ADAS peuvent se présenter sous plusieurs formes, certains ne concernent que quelques aspects de la conduite pour faciliter la tâche au conducteur sans ambitionner de le remplacer, tel que le régulateur de vitesse adaptatif ou le maintien de voie. Là où d'autres algorithmes permettent quant à eux de complètement se substituer au conducteur dans certaines circonstances telles que les voitures automatisés qui prennent le contrôle des véhicules au sein d'un parking ou encore la conduite automatisée sur autoroute qui gère seule la vitesse, la direction et les changements de voie...etc.

L'automatisation promet de surmonter l'un des derniers obstacles à une amélioration de la sécurité des transports, à savoir le facteur humain. Même si les humains sont d'excellents conducteurs, ils doivent se reposer, peuvent faire des erreurs, et leur temps est précieux. Les véhicules automatisés peuvent rouler sans conducteur humain et ainsi libérer le temps de trajet qui peut servir à autre chose. La révolution imminente est comparable à la révolution industrielle qui a permis de

passer de l'animal à la machine en tant que source de puissance mécanique, et ouvre la voie à d'autres innovations tel que la planification des trajets individuels à l'échelle d'une ville dans le cadre des villes connectées et ainsi réduire la congestion des routes et, in fine, la pollution et les temps de trajets, ou encore la fin du véhicule personnel et le développement du CaaS « Car as a Service » ou « voiture en tant que service ».

0.2 Contributions et objectifs de la thèse

L'un des défis que devra relever l'industrie automobile qui vise une totale autonomie des véhicules est l'acceptabilité des passagers. En effet ces derniers, habitués à une conduite humaine, s'attendent à un comportement similaire. Un algorithme qui prend des risques trop élevés comparativement à un conducteur humain (ce qui peut théoriquement être possible sans mettre en danger les passagers du fait de temps de réactions des calculateurs bien inférieurs aux humains) conduirait à un sentiment d'insécurité, et donc d'inconfort. Au contraire une conduite trop prudente et qui allongerait les temps de trajets, pourrait mener à un rejet total des passagers de ces algorithmes.

Il est donc nécessaire de comprendre comment un humain perçoit le risque dans un contexte de conduite automobile, et d'utiliser cette compréhension pour développer des algorithmes de prise de décision qui ont pour objectifs de reproduire le comportement humain.

Un autre bénéfice d'avoir des véhicules automatisés qui imitent l'humain est d'être compréhensible par les autres véhicules non automatisés. En effet, sur la route, l'humain adopte des comportements pour interagir avec les autres usagers de la route de manière implicite, comme ralentir pour laisser un véhicule changer de voie ou serrer à gauche de la voie actuelle pour signifier une intention de changer de voie. Tant que les véhicules automatisés devront partager la route avec des véhicules non automatisés, il est important que ces derniers puissent comprendre et anticiper les comportements du véhicule automatisé.

Parmi les objectifs de la thèse, étudier le comportement humain spécifiquement lors des manœuvres de changement sur autoroutes et voies rapides, de s'en inspirer pour développer une métrique du risque propre à ce type de manœuvre. Le second

objectif est le développement d'algorithmes de prise de décision pour le changement de voies qui se basent sur la métrique du risque précédemment citée.

Le développement de ces deux briques repose sur des manœuvres réalisées par des conducteurs humains et qui sont compilées au sein de bases de données. Deux sont utilisés : MOOVE de l'institut Vedecom, et HighD de l'institut d'ingénierie automobile IKA en Allemagne ([KBKE18a]).

Le chapitre I est consacré à un état de l'art sur la prédiction de trajectoire qui est un élément indispensable pour l'évaluation du risque et la prise de décision, les méthodes d'évaluation du risque, et des algorithmes de prise de décision pour les manœuvres de changement de voies. En fin de chapitre, seront présentées les différentes bases de données véhiculaires.

Le chapitre II concerne les travaux réalisés sur les bases de données ; les résultats obtenus seront également présentés, ainsi que les enrichissements que nous avons apportés.

Le chapitre III présente l'échelle du risque développée et basée sur les travaux réalisés sur les bases de données, et introduit un paramètre que nous appelons le gain et qui est également utilisé pour la prise de décision.

Le développement des algorithmes de prise de décision et la validation de ces derniers sur simulateurs viennent clôturer ce dernier chapitre.

Enfin une conclusion résumera les différents travaux effectués durant la thèse ainsi que les résultats obtenus et les perspectives de recherche pour des travaux futurs.

Les travaux de cette thèse ont donné lieu aux publications suivantes :

— Journaux internationaux

1. A. Mechernene, V. Judalet, A. Chaibet, M. Boukhniifer, "Motion prediction and risk assessment for the decision making of autonomous vehicles." *International Journal of Robotics and Automation* 5 (2019) : 32-39.
2. A. Mechernene, V. Judalet, A. Chaibet, M. Boukhniifer. "Detection and Risk Analysis with Lane Changing Decision Algorithms for Autonomous Vehicles", *Sensors Special Issue "Machine Learning for Connected and Autonomous Vehicle for Mixed Traffic Environment"*. Accepted, 2022.

— Conférences internationales avec comité de lecture

1. A. Mechernene, V. Judalet, A. Chaibet, M. Boukhniifer. "Risk analysis method for a lane change maneuvers on highways." 2020 International Conference on Control, Automation and Diagnosis (ICCAD). IEEE, 2020.
2. A. Mechernene, V. Judalet, A. Chaibet, M. Boukhniifer. "Lane Change Decision Algorithm based on Risk Prediction and Fuzzy Logic Method", 2021 25th International Conference on System Theory, Control and Computing (ICSTCC). IEEE, 2021.

Chapitre 1

Etat de l'art sur la prise de décision pour la conduite automatisée

Sommaire

1.1	Introduction	9
1.2	Introduction aux véhicules automatisés	9
1.3	La prise de décision pour la conduite automatisée	15
1.4	Modèles de prédiction basés sur les trajectoires	17
1.4.1	Modèles dynamiques	17
1.4.2	Modèles cinématiques	23
1.4.3	La prédiction de trajectoire	24
1.4.4	Limites des modèles basés sur la physique	26
1.5	Modèles de prediction basés sur les manœuvres	26
1.6	Analyse du risque de collision	29
1.7	Prise de décision pour les manœuvres de changement de voie	31
1.7.1	Modèle basé sur des règles	32
1.7.2	Modèle basé sur l'intelligence artificielle	32
1.7.3	Modèle basé sur les «incitations»	34
1.8	Axes d'améliorations par rapport à l'état de l'art	34
1.9	Bases de données de roulage	35
1.9.1	NGSIM	35

1.9.2	HighD	35
1.9.3	MOOVE	37
1.9.4	KITTI	40
1.10	Conclusion	41

1.1 Introduction

Ce chapitre présente une synthèse des différents travaux sur le véhicule automatisé. Une introduction aux véhicules automatisés, suivi d'un état de l'art sur les différents modèles de représentation des véhicules pour la prédiction de trajectoire, ainsi qu'un résumé des différents modèles utilisés pour la prise de décision des véhicules automatisés, et enfin un aperçu des bases de données que nous pouvons retrouver auprès de la communauté scientifique pour le développement des ADAS.

1.2 Introduction aux véhicules automatisés

L'histoire de la voiture sans conducteur est presque aussi ancienne que la voiture elle-même. L'une des premières démonstrations de l'idée, qui a également attiré l'attention au-delà des experts, a eu lieu dans le cadre du Futurama à l'exposition General Motors Highways and Horizons à l'Exposition universelle de New York en 1939. « Bientôt, des voitures automatisées conduiraient des familles à travers les États-Unis en toute sécurité et efficacement » - du moins c'était la vision.

Cela s'est avéré différent, mais l'idée est restée. Le concept de l'époque reposait sur des adaptations plus ou moins importantes de l'infrastructure, la voiture pourrait rouler sans surveillance ni intervention humaine. Même si des expériences ont été menées (par exemple à l'Ohio State University [FM91]) ou au National Automated Highway System Research Program ([Boa98]) menant à des concepts tels que les pelotons automatisés, les véhicules automatisés n'ont trouvé d'applications dans le monde réel que dans systèmes appelés « Personal Rapid Transport » (PRT) et « Automated People Mover » (APM). Dans les systèmes PRT et APM, les véhicules roulent de manière automatisé sur des trajets prédéfinis dans des environnements contrôlés. L'embarquement et le débarquement ne sont possibles que dans des terminaux spéciaux. Les exemples actuels de PRT et d'APM sont les navettes aéroportuaires automatisés ou les métros automatisés.

Il y a deux raisons principales pour lesquelles les véhicules automatisés n'ont pas trouvé d'application plus large alors que l'idée existe depuis des décennies. La première raison est que la technologie n'était pas prête à faire face à des situations inattendues et donc ont besoin d'environnements contrôlés. Cependant,

une deuxième raison a empêché une application généralisée. Des investissements d'infrastructure à grande échelle (par exemple, placer des câbles dans la chaussée) seraient nécessaires pour que la technologie fonctionne, mais ces investissements ne seraient pas justifiés tant que la technologie n'aurait pas suffisamment pénétré le marché. Et la technologie ne peut pas être vendue tant que l'infrastructure n'est pas là pour l'utiliser.

Basé sur les développements et la miniaturisation de l'informatique et des technologies réseau, l'idée de voitures sans conducteur a été relancée au cours du nouveau millénaire. Depuis 2004, le fond de recherche de l'armée américaine (DARPA) a organisé plusieurs concours pour la conception et la construction de véhicules sans conducteur (2004 DARPA Grand Challenge, 2005 DARPA Grand Challenge, et 2007 DARPA Urban Challenge). Alors que lors du premier défi, aucun véhicule n'a pu terminer le parcours de 240 km à travers le désert de Mojave. Déjà un an plus tard, 5 véhicules ont terminé le parcours tout-terrain, le plus rapide à une vitesse moyenne de 30,7 km/h. Seulement deux ans plus tard, déjà 4 voitures ont alors pu terminer un parcours urbain de 96 km avec du trafic et en respectant le code de la route.

Aujourd'hui, plusieurs entités travaillent sur le développement de technologies à destination des véhicules automatisés. Les constructeurs automobiles eux-mêmes, on peut citer Tesla qui en fait un de ses principaux arguments marketing, mais également la majorité des grands groupes automobiles mondiaux, tel que Toyota, Volkswagen A.G, BMW, General Motors, Stellantis, Renault... etc

Également les différents équipementiers automobiles qui fournissent les capteurs, calculateurs, actionneurs et également les logiciels nécessaires aux véhicules automatisés aux constructeurs. Parmi eux Bosh, Valeo, Aptiv, Continental... etc

Moins connues, mais tout aussi avancées, certaines entreprises venues du monde de l'informatique ont également investi ce secteur. Alphabet (société mère de Google) en tête via sa filial Waymo, qui ambitionne de développer les taxis automatisés (figure 1.1) mais également le transport routier automatisé de marchandises (figure 1.2).

Intel via sa filiale Mobileye développe des solutions matérielles et logicielles

CHAPITRE 1. ETAT DE L'ART SUR LA PRISE DE DÉCISION POUR LA CONDUITE AUTOMATISÉE

pour la perception des véhicules automatisés au travers de différentes technologies de capteurs.

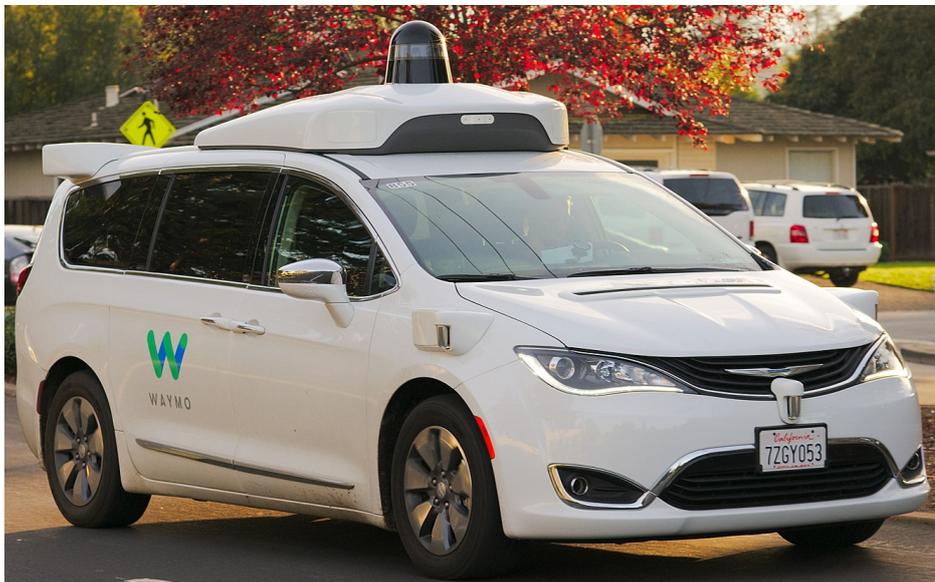


FIGURE 1.1 – Taxi automatisé Waymo.



FIGURE 1.2 – Semi-remorque Waymo pour le transport routier de marchandises.

Le développement d'un véhicule automatisé nécessite l'utilisation des 3 fonctions suivantes (voir figure 1.3) :

- **Perception** : est un module qui utilise plusieurs capteurs embarqués au sein du véhicule pour générer une carte de son environnement. Les principaux capteurs sont les capteurs ultrasons, les Radars, les Lidars, et les

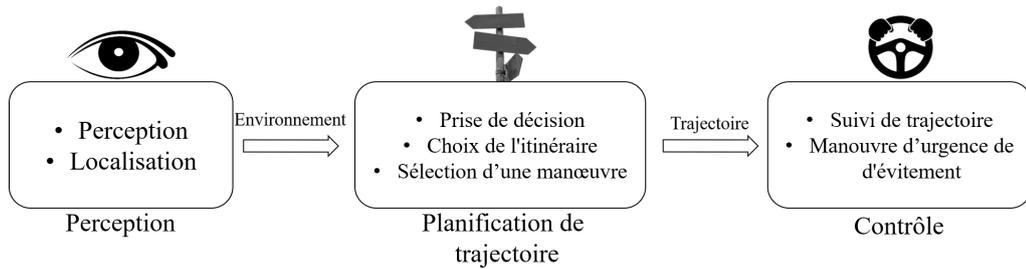


FIGURE 1.3 – Les 4 modules de base nécessaires à la conduite automatisée

caméras (figure 1.4). Une redondance de capteurs est nécessaire pour avoir une représentation plus précise et palier aux limites de chaque une des technologies. Les caméras par exemple sont très efficaces pour identifier les types des objets, mais très peu fiable pour mesurer les vitesses et les positions de ces derniers. Faiblesse qui est compensée par les Radars et Lidar. Ils diffèrent également pour ce qui est de leurs portées respectives. Également utilisé, un algorithme de fusion de données en temps réel qui associe les mesures provenant des différents capteurs qui prend en compte leurs incertitudes de mesure respectives et ainsi avoir une représentation plus fiable.

- **Planification de trajectoire** : le but de ce module est de tracer un chemin que le véhicule doit suivre, et prend en compte les informations des modules « Prise de décision » et « Perception » pour y parvenir.
- **Contrôle** : ce composant contrôle les paramètres physiques des actionneurs du véhicule (régime moteur, angle de braquage, freins...) pour faire correspondre la trajectoire réelle à la trajectoire souhaitée. Cette fonction est suffisamment bien maîtrisée, car elle s'apparente plus à de l'automatique classique avec une boucle de régulation et un correcteur qui reçoit les consignes du module de génération de la trajectoire.

Les avancées connues ces 15 dernières années dans le domaine des véhicules automatisés ont été permises par les progrès dans d'autres secteurs ; l'électronique embarquée et les calculateurs en tête. En effet, leur miniaturisation, la puissance de calcul toujours plus importante et la baisse de la consommation énergétique

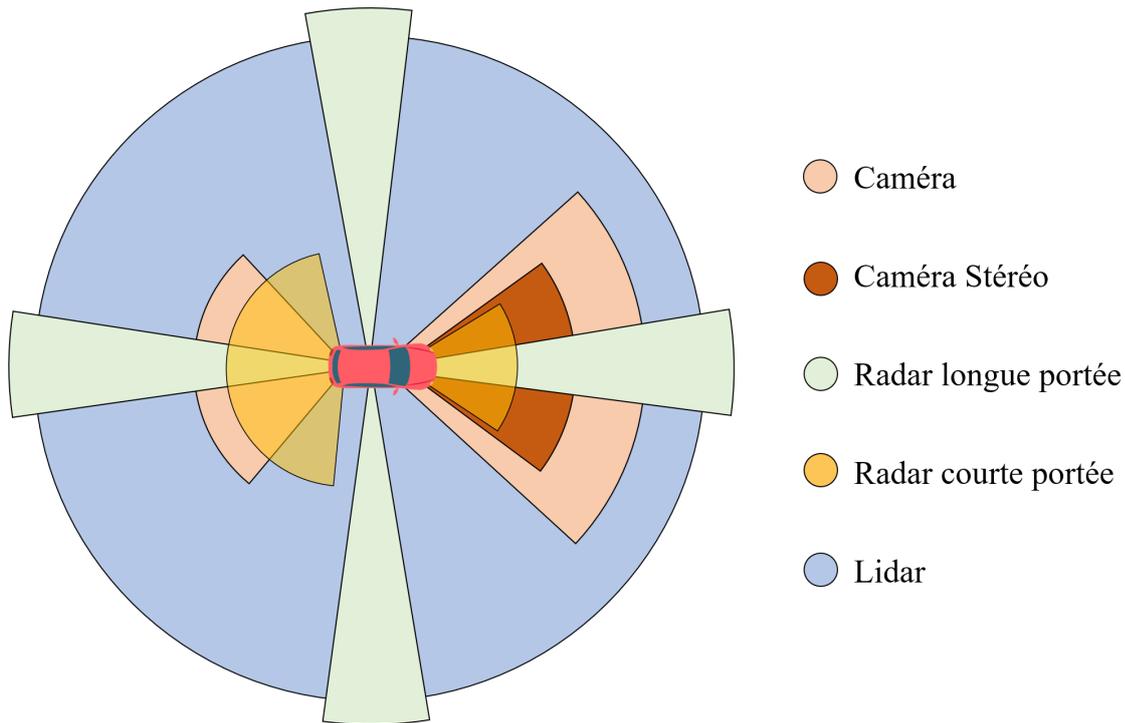


FIGURE 1.4 – Représentation du champ de détection des différents capteurs embarqués

ont permis d'intégrer des calculateurs toujours plus puissants dans les véhicules. Les évolutions logicielles sont également une base importante, notamment en intelligence artificielle ce qui permet d'améliorer la prise de décision et également la perception avec la reconnaissance d'images.

Les experts résument l'état des avancées technologiques en conduite automatisée actuellement comme ceci : « On peut faire des manœuvres complexes dans des environnements complexes à basse vitesse et des manœuvres simples dans des environnements simples à grande vitesse ». Un jugement précis de l'état actuel du développement technique est délicat, tant les industriels communiquent peu sur les limites actuelles des systèmes qu'ils développent. Néanmoins, nous pouvons catégoriser toutes les technologies liées au ADAS. La SAE International « Society of Automotive Engineers » a défini une classification plus complète des niveaux d'autonomie et résumé par le tableau 1.1. Elle date de 2016, mais est unanimement

reconnue par la communauté scientifique comme la plus pertinente est toujours d'actualité :

- **SAE Niveau 0 (Aucune assistance à la conduite)** : le véhicule est incapable de conduire de manière automatisé et est uniquement contrôlé par un conducteur humain. Toutes les décisions de conduite et tous les mouvements relèvent de la responsabilité du conducteur. Cela n'empêche pas d'avoir un système d'avertissement en cas de détection d'une situation dangereuse, tel que la détection de véhicule dans les angles morts ou l'alerte de franchissement de ligne.
- **SAE Niveau 1 (Une assistance à la conduite)** : c'est le niveau d'automatisation le plus bas. Le véhicule dispose d'un seul système automatisé d'assistance à la conduite, comme la direction ou l'accélération (régulateur de vitesse). Le régulateur de vitesse adaptatif, où le véhicule peut être maintenu à une distance de sécurité derrière la voiture voisine, est qualifié de niveau 1 car le conducteur humain surveille les autres aspects de la conduite tels que la direction et le freinage.
- **SAE Niveau 2 (Des assistances à la conduite)** : il s'agit de l'état actuel de la technologie automobile sur le marché (par exemple, régulateur de vitesse adaptatif, assistants de maintien de voie, assistants de freinage, etc.). Initialement réservés aux véhicules haut de gamme, on les retrouve aujourd'hui très communément dans toutes les gammes. La présence de ces assistances est même devenue un critère de notation pour l'EURO NCAP qui évalue le niveau de sécurité d'un véhicule. Elles sont donc obligatoires pour tout constructeur prétendant à la note maximale de 5 étoiles.
- **SAE Niveau 3 (Automatisation partielle)** : Il s'agit de la capacité qu'a un véhicule à être totalement automatisé dans certaines conditions, tel que l'assistant de conduite dans les embouteillages, ou la conduite sur autoroute. Techniquement, cela devient actuellement disponible pour l'utilisateur final, mais reste réservé à des véhicules haut de gamme. Autopilot de Tesla (Tesla, 2017), Super Cruise de Cadillac (Cadillac, 2017), AI trafic jam pilot d'Audi (Audi, 2017), ou l'ensemble des systèmes d'assistance avancés de Mercedes (Daimler, 2017). Cependant, pour des raisons juri-

diques (et probablement aussi par manque d'expérience), les constructeurs exigent toujours du conducteur de rester vigilant et à être prêt à reprendre le contrôle du véhicule à tout moment. Ils se déchargent également de toute responsabilité en cas de problème et informent le conducteur qu'il reste responsable des actions entreprises par son véhicule via un message affiché sur l'instrumentation numérique et dans les conditions utilisateurs.

- **SAE Niveau 4 (Automatisation totale)** : c'est le niveau auquel la conduite sans conducteur devient possible et ainsi la technologie devient vraiment révolutionnaire. Des tests sont prévus ou en cours avec des véhicules sans conducteur chez les constructeurs automobiles, les équipementiers et les laboratoires de recherche. Cependant, la technologie n'est pas encore prête et il est très difficile de prévoir quand elle le sera. Elle a cependant certaines limites, notamment en rapport avec la perception d'environnement, si les algorithmes décident qu'à certains instants, la perception n'est pas d'une qualité suffisante, ils peuvent désactiver la conduite automatisée et demander au passager de reprendre le contrôle.
- **SAE Niveau 5** : le niveau 5 représente un véhicule entièrement automatisé, capable d'effectuer toutes les fonctions de conduite dans toutes les conditions. Cela signifie que même si un humain peut reprendre la conduite s'il le souhaite, ce n'est pas nécessaire, et même les commandes manuelles peuvent être retirées. L'objectif final du niveau 5 est que chaque véhicule sur la route soit entièrement automatisé.

1.3 La prise de décision pour la conduite automatisée

Les algorithmes de prise de décisions pour les véhicules automatisés représentent l'un des éléments les plus importants de la conduite automatisée. Ils utilisent la représentation de l'environnement fournie par le module de perception, ainsi qu'une carte numérique des routes pré-enregistrés dans la mémoire du véhi-

1.3. LA PRISE DE DÉCISION POUR LA CONDUITE AUTOMATISÉE

	 Niveau 0	 Niveau 1	 Niveau 2	 Niveau 3	 Niveau 4	 Niveau 5	
Rôle du conducteur	Le conducteur doit rester maître du véhicule même si les assistances sont activées. Il est responsable de superviser le bon fonctionnement de ces fonctions et doit freiner, contrôler la trajectoire ou accélérer si besoin.			Le conducteur n'a plus besoin de superviser la conduite lorsque ces fonctions sont activées. Il peut déléguer complètement le contrôle du véhicule à l'ordinateur.		L'ordinateur peut demander au conducteur de reprendre le contrôle dans certaines circonstances.	L'ordinateur est totalement autonome et n'aura jamais à demander au conducteur de reprendre le contrôle.
Rôle du Véhicule	Ces fonctions sont limitées à des assistances passives telles que des alertes et des assistances ponctuelles.	Ces fonctions prodiguent une assistance à la direction OU au freinage/accélération.	Ces fonctions prodiguent une assistance à la direction ET au freinage/accélération.	L'ordinateur contrôle tous les aspects de la conduite sous certaines conditions.		L'ordinateur contrôle tous les aspects de la conduite, quelque soit les conditions.	
Exemples d'applications	- Alerte de franchissement de ligne. - Alerte de véhicule dans l'angle mort.	- Maintien dans la voie. OU - Régulateur de vitesse adaptatif.	- Maintien dans la voie. ET - Régulateur de vitesse adaptatif.	- Conduite en embouteillage.	- Taxi Autonome. - Transport publics et de marchandises	- Similaire au niveau 4. l'ordinateur peut en plus conduire sous toutes conditions.	

TABLE 1.1 – Les 6 niveaux d'autonomie définis par la SAE.

culé pour décider du comportement à adopter. Il s'agit d'une décision haut niveau tel que : changer de voie vers la gauche, s'arrêter car le feu est rouge, tourner à droite au carrefour. Plusieurs approches peuvent être utilisées. Les plus utilisées reposent soit sur des algorithmes d'apprentissage automatique, ou sur un modèle qui repose sur des règles définies au préalable par le constructeur.

1.4 Modèles de prédiction basés sur les trajectoires

Ce type de modèle représente les véhicules comme des entités dynamiques régies par les lois de la physique, le mouvement peut être prédit à l'aide de modèles dynamiques ou cinématiques. Les états actuels (par exemple la vitesse, l'angle de braquage), les entrées de commande (par exemple le volant, l'accélération) et les propriétés du véhicule (par exemple le poids) sont pris en compte pour calculer les états futurs. Plusieurs travaux ont été réalisés sur ce type de modèles, et c'est le plus couramment utilisé pour la prédiction de trajectoire à court terme. La complexité des modèles dépend de leur degré de fidélité à la réalité.

Dans cette partie, nous présentons deux types de modèles de mouvement basés sur la physique, les modèles dynamiques et les modèles cinématiques.

1.4.1 Modèles dynamiques

Les modèles dynamiques décrivent le mouvement du véhicule selon la deuxième loi du mouvement de Newton en considérant différentes forces qui l'affectent, telles que le couple moteur, les freins, les forces latérales des pneus. Les plus complexes peuvent impliquer de nombreux paramètres internes ou encore la dynamique du moteur.

Modèle point matériel 2D

Ce modèle considère le véhicule comme un point unique dans l'espace (centre de gravité) avec une masse [Qia17], ce modèle peut être linéaire avec une vitesse et des forces découplées, comme le montre la figure 1.5. Le modèle point-masse est un modèle dynamique simplifié utilisé pour décrire les mouvements d'une voiture. Il ne tient pas compte des détails de la géométrie ou de la dynamique de la voiture. Ce modèle est souvent utilisé pour des applications de simulation rapide, comme les jeux vidéo, les systèmes de navigation GPS, et les systèmes de contrôle de trafic routier.

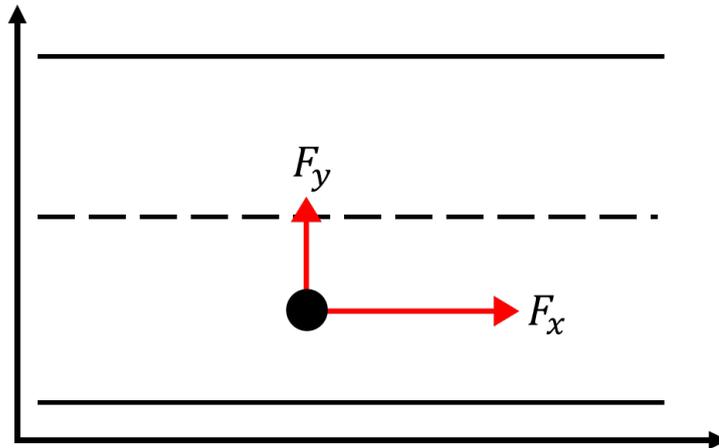


FIGURE 1.5 – Modèles point matériel 2D

Les équations 1.1 représentent le modèle mathématique d'un système point masse.

$$\begin{aligned}
 \dot{x} &= v_x \\
 \dot{y} &= v_y \\
 \dot{v}_x &= a_x \\
 \dot{v}_y &= a_y
 \end{aligned}
 \tag{1.1}$$

Avec x et y la position longitudinale et latérale, v_x et v_y la vitesse longitudinale et latérale, et a_x et a_y l'accélération longitudinale et latérale.

Ce modèle est pertinent pour les déplacements sur autoroutes ou artères urbaines, mais il devient moins précis lorsque la dynamique longitudinale n'est plus dominante (route non-rectiligne). Une autre représentation peut également être faite en couplant les deux forces. Dans ce cas, le modèle devient non linéaire (figure 1.6). Et les équations deviennent comme suit :

Et les équations deviennent :

$$\begin{pmatrix} \dot{x} \\ \dot{y} \\ \dot{\theta} \\ \dot{v} \end{pmatrix} = \begin{pmatrix} v \cos(\theta) \\ v \sin(\theta) \\ \omega \\ a \end{pmatrix}
 \tag{1.2}$$

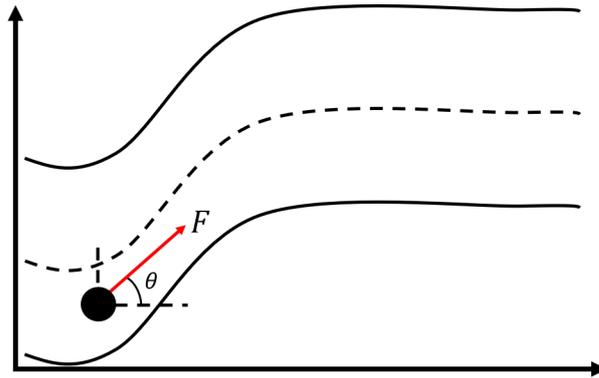


FIGURE 1.6 – Modèles point matériel 2D non-linéaire

où v et θ sont la vitesse et le cap du point, a et ω l'accélération et la vitesse de lacet.

Modèle dynamique bicyclette

Les modèles dynamiques bicyclette fusionnent les roues gauches et droites pour obtenir une disposition où les deux-roues résultants sont disposés au centre des essieux avant et arrière, et à égale distance du centre de gravité du véhicule (figure 1.7 et équation 1.3) [KPSB15]. Ces modèles sont plus réalistes que les modèles point matériel, et offrent un bon compromis entre complexité et réalisme. Ce modèle est utilisé pour des applications de simulation de conduite réaliste, comme les systèmes de conduite automatisée, et les systèmes de contrôle de trajectoire pour les véhicules à haute performance.

Les équations de mouvement pour un modèle bicyclette sont basées sur les équations de Newton, en utilisant les variables de l'angle de braquage (δ) et de l'angle de chasse (ψ) pour les modèles le plus complexes pour décrire les mouvements de la direction.

$$\begin{pmatrix} \dot{x} \\ \dot{y} \\ \dot{\theta} \\ \dot{v} \end{pmatrix} = \begin{pmatrix} v \cos(\theta) \\ v \sin(\theta) \\ v \tan(\delta)/L \\ (F - F_r)/m \end{pmatrix} \quad (1.3)$$

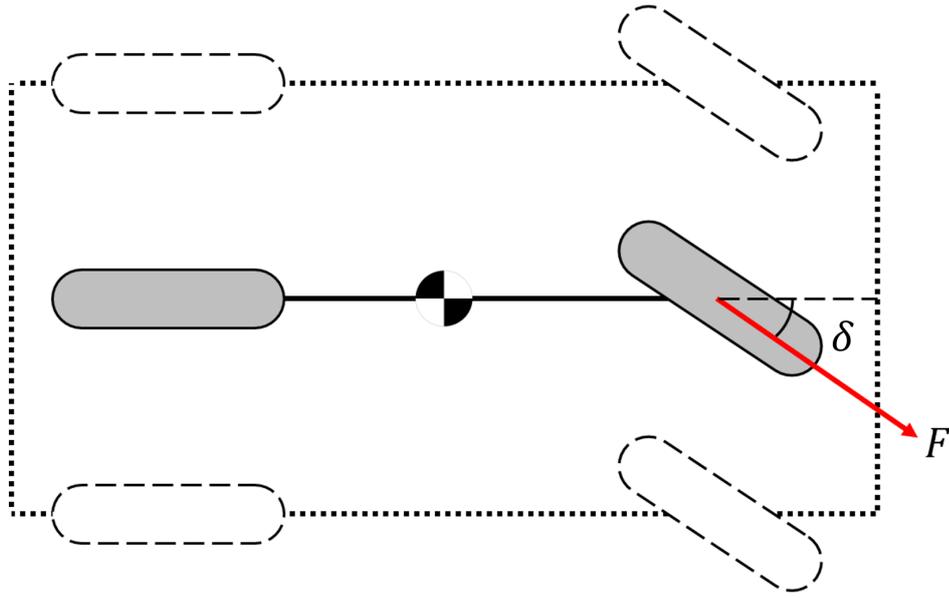


FIGURE 1.7 – Modèle dynamique bicyclette

où :

- x et y sont les coordonnées de la position de la roue arrière.
- δ est l'angle de braquage en radians.
- v est la vitesse du véhicule.
- θ l'angle du véhicule par rapport au repère.
- L est la distance entre la roue avant et la roue arrière.
- F est la force de propulsion.
- F_r est la force de freinage.

Modèle quadricycle

Avec ce modèle, le véhicule est modélisé avec quatre roues (voir figure 1.8), et la dynamique de chacune est considérée indépendamment [FRR⁺12]. Le modèle quadricycle peut être trop complexe à calculer en temps réel pour la planification et la prédiction de trajectoire, sachant que des modèles comme le modèle bicyclette ont une précision suffisante pour ce type d'application. Cependant, cela peut être pertinent pour des applications de contrôle telles que le système de contrôle électronique de la stabilité (ESC).

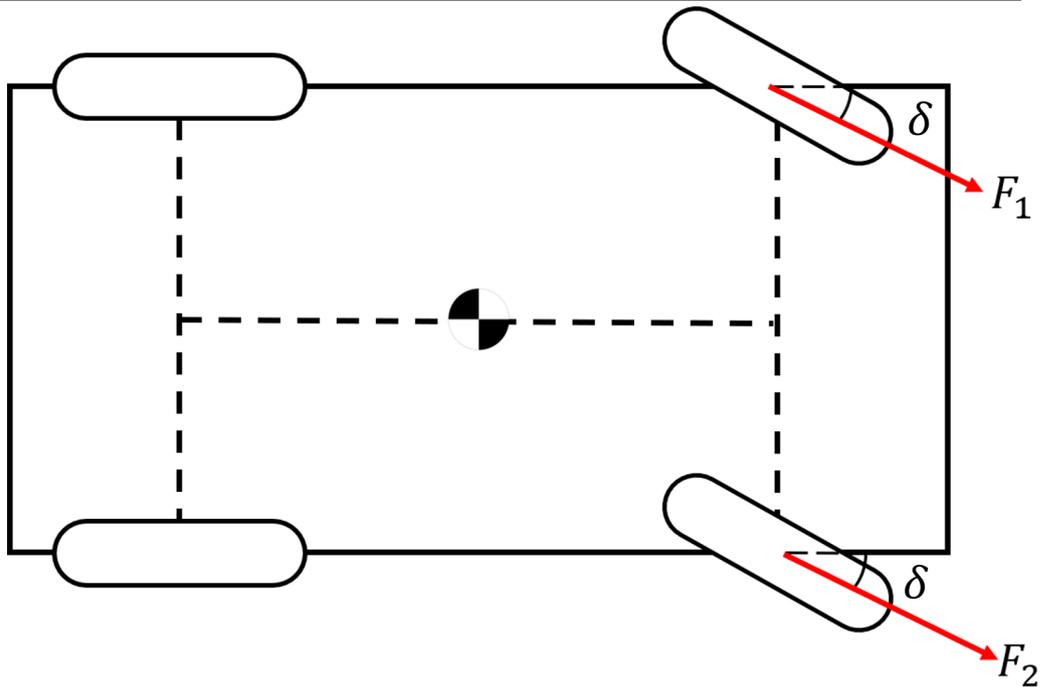


FIGURE 1.8 – Modèle quadricycle

Modèle Ackerman

Le modèle d'Ackerman est un modèle de conduite automobile qui décrit la relation entre la vitesse d'un véhicule, son angle de braquage et sa distance de braquage. Il a été breveté par Rodolphe Ackermann en 1818 .

Le modèle d'Ackerman postule que la distance de braquage d'un véhicule dépend de son angle de braquage et de sa vitesse. Plus précisément, lorsqu'un véhicule tourne à une vitesse élevée, il doit braquer plus pour suivre une courbe donnée que s'il était à une vitesse plus basse. De même, lorsqu'un véhicule braque à un angle plus prononcé, il doit parcourir une distance plus grande pour suivre une courbe donnée.

Le modèle d'Ackerman repose sur l'hypothèse que les roues avant d'un véhicule suivent une trajectoire circulaire lorsqu'elles tournent. Cependant, dans la réalité, les roues avant d'un véhicule suivent plutôt une trajectoire elliptique. Cela signifie que le modèle d'Ackerman est un modèle simplifié de la réalité et ne peut pas être

utilisé pour des calculs très précis.

Malgré cette limitation, le modèle d'Ackerman est largement utilisé dans l'industrie automobile pour la conception de systèmes de direction et de suspension. Il est également utilisé dans la robotique pour la conception de robots à roues qui doivent naviguer dans des environnements complexes. Enfin, il est utilisé dans les simulateurs de conduite pour reproduire les comportements de conduite réalistes.

Autres Modèles

Il existe des modèles plus complexes qui considèrent le tangage et le roulis [ILCD00] en intégrant la suspension et la répartition des masses, il sont utilisés pour étudier le mouvement du châssis afin d'améliorer le confort des passagers ou de minimiser le roulis dans le cas des voitures de sport.

Le modèle dynamique six degrés de liberté est un modèle utilisé pour décrire les mouvements d'un véhicule dans l'espace 3D en utilisant six degrés de liberté. Il prend en compte les mouvements de translation et de rotation de la voiture. Il est utilisé pour des applications de simulation haute précision, comme la conception de voitures de course haute performance.

Pour décrire les mouvements de la voiture, le modèle six degrés de liberté utilise des variables telles que la position, la vitesse, l'accélération, les angles d'attitude . Il utilise également les forces et les moments s'appliquant à la voiture, en prenant en compte des effets tels que la masse, la résistance de l'air, les forces générées par les moteurs, etc. Ces modèles sont basés sur des relations mathématiques et physique qui décrivent les effets de la gravité, des forces de propulsion, des forces de résistance, etc.

Le modèle six degrés de liberté est généralement très précis car il prend en compte des effets supplémentaires tels que les forces de résistance de l'air, les forces de propulsion et les moments de roulis. Cependant, il est également plus complexe à mettre en œuvre et nécessite des données supplémentaires pour être utilisé correctement.

D'autres modèles peuvent également intégrer la dynamique du moteur (et de la transmission) pour des usages comme le régulateur de vitesse, Ou les systèmes d'antipatinages [Oer97] (par exemple pour l'ABS et l'ESP).

1.4.2 Modèles cinématiques

Les modèles cinématiques pour les véhicules sont utilisés pour représenter les mouvements de celui-ci en prenant en compte uniquement des variables telles que la position, la vitesse et l'accélération. Ces modèles négligent les forces externes qui peuvent affecter le mouvement de la voiture, comme la friction. Ces modèles sont plus simples et peuvent être calculés plus rapidement en temps réel que les modèles dynamiques, qui tiennent compte de toutes les forces qui agissent sur un véhicule.

En raison de leur simplicité et de leur précision suffisante pour de nombreux cas d'utilisation, les modèles cinématiques sont fréquemment utilisés pour la prédiction de trajectoires. En outre, les paramètres internes d'un véhicule nécessaires pour les modèles dynamiques ne sont généralement pas disponibles via les capteurs extéroceptifs, il est donc plus pertinent d'utiliser des modèles cinématiques pour les véhicules environnants.

Les modèles cinématiques peuvent être utilisés pour simuler différentes situations de conduite, comme les manœuvres de virage et les dépassements, et pour évaluer les performances du véhicule dans ces situations. Ils peuvent également être utilisés pour développer des systèmes de contrôle automatisés, tels que les systèmes d'aide à la conduite et les systèmes de conduite automatisée. Les modèles cinématiques peuvent également être utilisés pour évaluer les performances des systèmes de suspension et pour aider à la conception de nouveaux systèmes de suspension.

Schubert et al. [SRW08] ont fait une comparaison des modèles cinématiques pour les véhicules du moins complexe au plus complexe. Le plus simple est les modèles à CV « Constant Velocity » ou « vitesse constante » et à CA « Constant Acceleration » ou « accélération constante » (figure 1.9). Les deux considèrent le mouvement rectiligne sur l'axe longitudinale et latérale pour les véhicules. Les modèles CTRV « Constant Turn Rate and Velocity » ou « vitesse et vitesse angulaire constants » et CTRA « Constant Turn Rate and Acceleration » ou « accélération et vitesse angulaire constants » (figure 1.10) prennent en compte la rotation autour de l'axe Z avec l'angle de lacet et la vitesse de lacet.

La complexité reste faible, car la vitesse et la vitesse de lacet sont découplées.

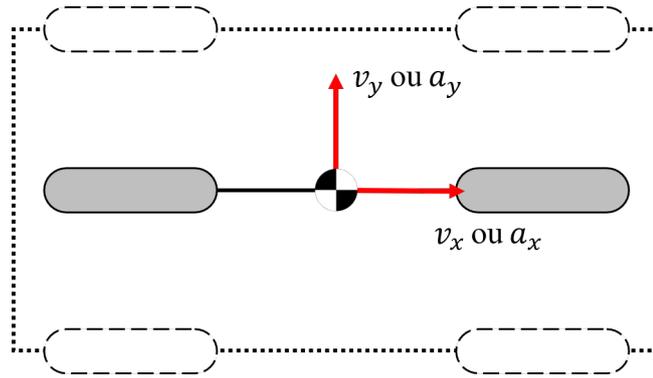


FIGURE 1.9 – Modèle « vitesse constante » (CV) et accélération constante (CA)

En considérant l'angle de braquage au lieu de la vitesse de lacet dans les variables d'état, on obtient une représentation « bicyclette », qui tient compte de la corrélation entre la vitesse et le lacet.

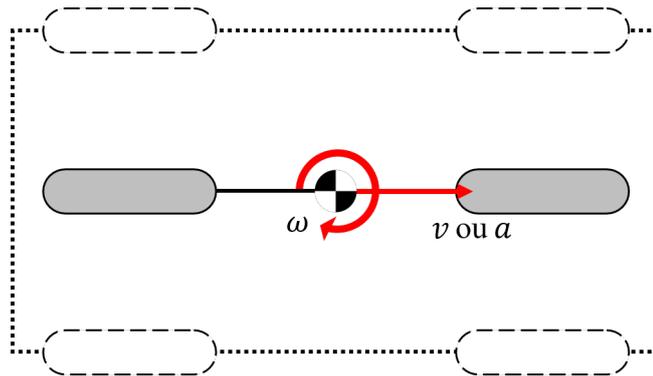


FIGURE 1.10 – Modèle vitesse et vitesse angulaire constants (CTRV) et accélération et vitesse angulaire constants (CTRA)

1.4.3 La prédiction de trajectoire

Dans la section précédente, nous avons présenté différentes manières de modéliser le mouvement du véhicule, mais cela est inutile sans un modèle d'évolution pour la prédiction de trajectoire. Ci-dessous, un aperçu des méthodes utilisées qui peuvent être relevées dans cette section.

Prédiction de trajectoire unique

Une méthode évidente pour prédire les trajectoires futures consiste simplement à ignorer les incertitudes et à appliquer un modèle d'évolution à l'état actuel d'un véhicule en supposant qu'il soit parfaitement connu et que le modèle d'évolution et ses paramètres sont suffisamment précis. Cette méthode peut être utilisée aussi bien avec des modèles dynamiques ou cinématiques [BCS10, HSK06, MH02]. Cependant, les modèles cinématiques sont utilisés pour estimer les trajectoires des véhicules environnant compte tenu de l'absence de mesures des forces agissant sur ces derniers qui empêche l'utilisation de modèles dynamiques.

L'avantage de cette méthode est le temps de calcul, ce qui la rend adaptée aux applications à fortes contraintes temps-réel. Toutefois, cette méthode ne considère pas les incertitudes sur les états actuels, l'évolution du modèle et par conséquent les trajectoires prédites ne sont pas fiables pour une prédiction à long terme.

Prédiction probabiliste linéaire

Une hypothèse peut être faite sur le bruit et l'incertitude des mesures en les modélisant par une distribution normale [AN09, PTAA07]. Ainsi, un filtre probabiliste tel que le filtre de Kalman peut être utilisé pour prédire la trajectoire du véhicule.

Le filtre de Kalman est une technique d'estimation récursive des états d'un système à partir de mesures bruitées et relativement incertaines. Il s'agit d'un cas particulier de filtrage bayésien où le modèle d'évolution est linéaire, et le bruit et l'incertitude sont considérés en utilisant une distribution normale.

L'avantage de ces techniques est qu'elles représentent une incertitude sur la trajectoire prédite. Cependant, il n'est pas toujours possible de faire des hypothèses sur la gaussianité des bruits. Un mélange de gaussiens peut être utilisé avec Switching Kalman Filter (SKF) [VPS06, DMM⁺11], ils s'appuient sur une banque de filtres de Kalman pour représenter les modèles d'évolution possibles d'un véhicule et basculer entre eux.

Prédiction non-linéaire

La faiblesse du filtre de Kalman est qu'il ne peut être utilisé qu'avec des modèles linéaires, cependant, le filtre de Kalman étendu (EKF) offre une solution en linéarisant le modèle non-linéaire autour du point de fonctionnement du système réel à chaque itération. Il peut être amélioré en utilisant la transformé inodore (UKF Unscented KF) et il est connu sous le nom de filtre de Kalman inodore (UKF).

Parfois, il n'est pas possible de présumer de la linéarité des modèles ou de la gaussianité des incertitudes, dans ce cas la méthode de Monte-Carlo peut être utilisée. Le principe de cette méthode est d'échantillonner aléatoirement l'évolution du modèle à partir des variables d'entrées pour générer d'éventuelles trajectoires futures. Un poids peut être appliqué pour pénaliser ceux qui ne respectent pas les contraintes du tracé de la route, ou, les trajectoires qui dépassent les limites physiques du véhicule [BBK05] [EP08].

1.4.4 Limites des modèles basés sur la physique

L'estimation future se base sur l'état actuel estimé. Ces modèles ne peuvent pas fournir une prédiction si la dynamique du véhicule change, l'estimation peut diverger par rapport à la réalité (ex : initier un changement de voie). Ils ne peuvent pas fournir une prédiction précise au-delà d'une ou deux secondes [BBJM20].

Pour obtenir une meilleure estimation des trajectoires futures, des modèles capables de comprendre le comportement du véhicule sont nécessaires, cela peut être réalisé par exemple par la prédiction des manœuvres.

1.5 Modèles de prediction basés sur les manœuvres

Le principe de ces modèles est de représenter les véhicules comme des entités indépendantes pouvant effectuer un nombre fini de manœuvres [ADSH12] en fonction du tracé de la route, et indépendamment des autres véhicules. L'itinéraire des véhicules peut être décrit comme une série de manœuvres, par conséquent, ce type de modélisation peut effectuer une meilleure prédiction à long terme par rapport aux modèles basés sur la physique. Une méthode consiste à considérer les

trajectoires possibles dans un nombre fini de classes, chacune correspondant à une manœuvre spécifique (figure 1.11) ; tourner à droite, tourner à gauche, rester dans la même direction.

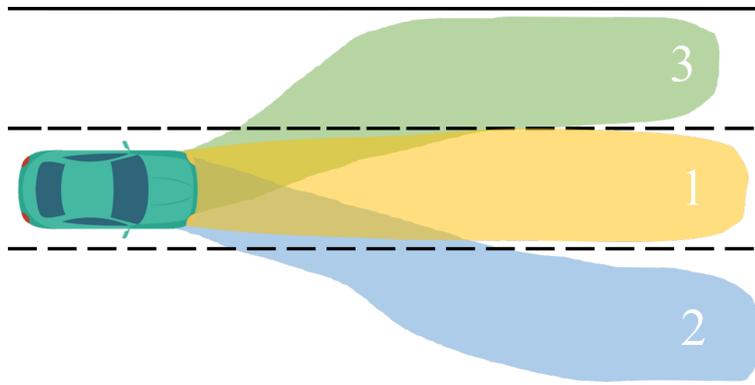


FIGURE 1.11 – Exemple de classes pour un modèle basé sur les manœuvres (1. Maintenir la direction, 2. Tourner à droite, 3. Tourner à gauche)

Ces classes peuvent être apprises à partir de données précédemment observées, avec des variables telles que les états physiques du véhicule (position, vitesse, lacet, clignotant) et des informations routières (topologie de la route, limites de vitesse, feux de circulation).

En théorie, n'importe quel algorithme de classification peut-être utilisé pour accomplir cette tâche, comme le Perceptron Multicouche (MLP) [OFKG11][BBJM20], la régression logistique ou les Machine à Vecteurs de Support (SVM) [MS05]... etc

Des travaux récents ont tendance à utiliser des processus gaussiens pour représenter les modèles de mouvement [Chr09, JDVHR11, TF14]. Cela peut être vu comme une généralisation des distributions de probabilité gaussiennes (GP). Les trajectoires dans l'ensemble des données d'apprentissage sont des exemples de fonctions d'un processus gaussien. Ainsi, l'apprentissage consiste à ajuster une distribution gaussienne sur ces fonctions. Les principaux avantages sont la robustesse des GP aux bruits et leur capacité à représenter la variation des trajectoires de manière probabiliste.

Une autre méthode pour reconnaître les comportements consiste à les représenter comme une série d'événements consécutifs dans un modèle de Markov caché

(HMM) [ADSH12, BED08], les probabilités de transition entre les événements peuvent être apprises à partir des données.

La limite de ce type de modélisation est qu'en pratique, l'hypothèse selon laquelle les véhicules se déplacent indépendamment les uns des autres sur la route et n'interagissent pas est fautive. En réalité, les véhicules interagissent continuellement les uns avec les autres, par exemple les intersections pour décider quelle voiture doit passer en premier ou pour changer de voie.

Pour palier à ce manquement, certains modèles considèrent que les véhicules peuvent s'influencer mutuellement les uns et des autres. Supposer que les voitures peuvent interagir entre elles fournit une modélisation plus réaliste pour prédire leur mouvement. Deux méthodes sont présentées ci-dessous, des modèles basés sur des prototypes de trajectoire, et basés sur des Réseaux Bayésiens Dynamiques (DBN).

Modèle basé sur des prototypes de trajectoire : cette méthode est similaire aux modèles de mouvement basés sur la manœuvre, à la différence qu'elle prend en compte l'influence mutuelle lorsque les trajectoires prédites de deux ou plusieurs véhicules entrent en conflit, l'algorithme va pénaliser les paires de trajectoires provoquant une collision, en supposant que les conducteurs prendront un chemin plus sûr la plupart du temps [KHW⁺10, LAP⁺13].

Modèle basé sur les réseaux bayésiens dynamiques : la plupart des modèles de mouvement sensibles aux interactions sont basés sur le réseau bayésien dynamique (DBN) [LVL14]. L'interaction entre deux voitures peut être modélisée par des modèles de Markov cachés couplés (CHMM). Cependant, le nombre d'interdépendances peut croître rapidement avec le nombre d'entités possibles. Une solution pour simplifier le modèle est de considérer les dépendances asymétriques. Ce modèle a été utilisé dans de nombreux travaux, notamment pour les changements de voie et les manœuvres de dépassement [Chr09].

1.6 Analyse du risque de collision

Cette section présente diverses méthodes pour estimer le risque d'une situation en temps réel. Pour cette tâche, la plupart du temps, il est nécessaire d'estimer les trajectoires futures des voitures entourant l'ego-véhicule à l'aide d'un des modèles présentés dans la section précédente ou une combinaison d'entre eux.

De nombreuses définitions peuvent être trouvées selon le contexte. Dans les Systèmes de Transport Intelligents (STI), elle est généralement qualifiée par la dangerosité d'une situation pour les passagers pouvant entraîner des blessures physiques. L'évaluation du risque est une étape importante dans le processus de prise de décision, car lorsque plusieurs manœuvres ou trajectoires deviennent possibles, il est préférable de choisir la moins risquée, ou si le risque devient trop élevé, effectuer une manœuvre ou un freinage d'urgence. À partir de cette mesure, plusieurs applications sont possibles : alertes conducteur, algorithme de prise de décision et génération de trajectoires et de manœuvres d'urgence. Une grande variété d'algorithmes de prise de décision peuvent prendre la valeur du risque en entrée, tel que ceux présentés ci-dessous.

Prédiction de collision binaire

Le principe est simple, la trajectoire future est estimée en résolvant les équations différentielles du modèle de véhicule pour l'ego-véhicule et les autres véhicules de la scène. On suppose que les trajectoires peuvent être calculées avec suffisamment de précision (bon modèle et mesures précises). Une façon de détecter une collision est de définir un seuil à respecter pour éviter la collision [LVL14].

Prédiction probabiliste des collisions

Lorsque le mouvement futur d'un véhicule est représenté par une distribution de probabilité, l'estimation probabiliste du risque peut être utilisée en détectant une collision entre toutes les paires de trajectoires possibles, plus le nombre de collision possible est important, plus le risque est élevé [LPP⁺11]. Cette approche offre une grande flexibilité dans la gestion des incertitudes et peut être adaptée à

tout modèle mentionné.

Risque basé sur les indicateurs

- L'une des méthodes les plus commune pour estimer le risque de collision consiste à calculer des indicateurs du type "Time-To-X" où X correspond à un événement en relation avec la collision [LVL14], comme le temps restant jusqu'à la collision elle-même (Time-To-Collision), qui est défini par l'équation suivante : $TTC = \frac{\Delta x}{\Delta v}$. Δx étant la distance longitudinale entre deux véhicules, et Δv la différence de vitesse longitudinale. Cet indicateur peut être comparé au temps nécessaire pour arrêter le véhicule. Il peut également être utilisé en situation de conduite humaine pour avertir le conducteur, dans ce cas, le temps de réaction du conducteur doit être ajouté au temps d'arrêt du véhicule.
- Un autre indicateur de temps lié au TTC est le TTR ou « Time-To-React », qui correspond au temps restant pour réagir avant que la collision ne devienne inévitable. Dans ce cas, le temps de réaction du conducteur doit être pris en compte.
- temps intrer-véhiculaire qui désigne le temps séparant deux véhicules successifs sur une même voie de circulation. Le code de la route impose un TIV de sécurité de deux secondes. En fonction de la vitesse, le conducteur doit déduire sa distance de sécurité par rapport au véhicule qui le précède.

Analyse du risque de collision avec les planificateurs de trajectoire

Les planificateurs de trajectoire sont des algorithmes qui décident de la trajectoire que le véhicule doit suivre en tenant compte de diverses contraintes telles que le temps, les conditions de circulation, l'état des routes et les différents obstacles pouvant être rencontrés. Certains algorithmes peuvent adapter le chemin suivi en temps réel si un événement inattendu se produit et donner une trajectoire alternative à suivre. Deux méthodes sont présentées ci-dessous, la méthode du champ de potentiel et celle des bandes élastiques.

- **Champ de potentiel** : cet algorithme inspiré de la robotique mobile considère le véhicule comme une particule en mouvement dans un plan soumis à un champ de potentiel qui est la somme de différents champs générés par différents éléments de la route (voie, route, voiture. . .) [WB08]. Les obstacles, les autres véhicules et les bords de la route ont un champ répulsif, tandis que la route a un champ attractif dans la direction qui doit être suivie.

L'avantage est que de nombreuses applications peuvent être visées avec cet algorithme, comme le choix de la bonne voie sur l'autoroute (où le trafic est plus fluide), l'évitement d'obstacles, le maintien de voie... etc

- **Bandes élastiques** : cet algorithme s'inspire de la robotique mobile et sert à calculer une trajectoire d'urgence pour éviter une collision avec un obstacle. La trajectoire est représentée par des ressorts reliés entre eux par des nœuds. Si un objet est détecté, le chemin sera déformé autour de lui, en respectant les contraintes physiques des ressorts [BSW05]. Cette méthode apporte une trajectoire fluide pour éviter les obstacles et permettre de revenir sur le chemin d'origine. En plus de cela, des ressorts peuvent être ajoutés en les connectant aux bords de la route et aux nœuds déjà existants pour empêcher une trajectoire hors route. Le niveau de risque peut être estimé en fonction de la tension appliquée aux ressorts pour effectuer la manœuvre d'évitement.

1.7 Prise de décision pour les manœuvres de changement de voie

Le comportement des conducteurs lors des changements de voie peut affecter à la fois la sécurité des passagers et la fluidité de la circulation sur les autoroutes et voies rapides. Pour ces raisons, la décision de quand et comment effectuer la manœuvre est très importante. Les modèles de décision pour le changement de voie ont été classés en 3 catégories dans [RCXH13].

1.7.1 Modèle basé sur des règles

Les modèles de prise de décision basés sur des règles pour le changement de voie des véhicules automatisés sont des algorithmes définis par un ensemble de règles précises. Ces règles sont généralement définies en fonction des informations sensorielles disponibles, telles que la distance par rapport aux véhicules environnants, la vitesse de ces véhicules et la distance par rapport aux limites de la voie, ou peuvent être calculés telles que le Time-To-Collision ou Time-To-React. Ces informations sont utilisées pour déterminer les actions appropriées à effectuer, telles que changer de voie pour éviter un obstacle.

Les modèles basés sur des règles peuvent être utilisés pour prendre des décisions simples, telles que changer de voie pour éviter un obstacle ou pour maintenir une distance sûre par rapport aux véhicules environnants. Ces modèles sont généralement faciles à implémenter et peuvent être utilisés pour des situations de conduite spécifiques, telles que les situations de circulation dense ou les situations de conduite sur autoroute.

Cependant, les modèles basés sur des règles ont également des limites. Ils ne peuvent pas prendre en compte des facteurs plus complexes, tels que les intentions des conducteurs environnants, et peuvent ne pas être adaptés à des situations de conduite inhabituelles. De plus, ils ont tendance à être rigides et peuvent ne pas s'adapter à des variations dans les conditions de conduite.

Nous pouvons citer le modèle Gipps [Gip81], le modèle CORSIM [ZCZZ10], le modèle ARTEMIS [Hid05]. Ce type de modèle présente l'avantage d'être simple à modéliser et léger à calculer, mais peut être difficile à calibrer.

1.7.2 Modèle basé sur l'intelligence artificielle

les modèles basés sur l'intelligence artificielle pour le changement de voie dans les véhicules automatisés sont des algorithmes qui utilisent des techniques d'apprentissage automatique pour apprendre les comportements de conduite. Ces modèles peuvent prendre en compte des facteurs plus complexes, tels que les intentions des conducteurs environnants, et peuvent être utilisés pour prendre des décisions plus avancées, telles que choisir la meilleure voie pour atteindre une destination spécifique.

CHAPITRE 1. ETAT DE L'ART SUR LA PRISE DE DÉCISION POUR LA CONDUITE AUTOMATISÉE

Les modèles d'apprentissage automatique utilisent des techniques telles que les réseaux de neurones pour apprendre les comportements de conduite à partir de données de conduite réelles [DWWB13][MCNF17]. Les réseaux de neurones sont des modèles informatiques qui imitent le fonctionnement du cerveau humain en utilisant des connexions pondérées pour traiter les informations. Ces modèles peuvent être entraînés sur des données de conduite réelles pour apprendre les comportements de conduite appropriés.

Il existe plusieurs types de réseaux de neurones qui peuvent être utilisés pour les modèles d'apprentissage automatique pour le changement de voie dans les véhicules automatisés, tels que les réseaux de neurones récurrents (RNN), les réseaux de neurones à convolution (CNN) et les réseaux de neurones profonds (DNN). Ces différents types de réseaux de neurones ont des caractéristiques et des performances différentes, et peuvent être utilisés pour résoudre des tâches spécifiques.

Il est important de noter que les modèles d'apprentissage automatique nécessitent des données d'apprentissage de qualité et un grand nombre d'exemples pour être efficaces. De plus, ces modèles peuvent également avoir des biais liés aux données de formation et il est important de les évaluer et de les tester rigoureusement avant de les utiliser dans des situations de conduite réelles.

La logique floue est un autre modèle de prise de décision utilisé dans la conduite automatisée pour gérer les incertitudes et les imprécisions dans les données d'entrée. Les systèmes de logique floue peuvent prendre en compte les incertitudes dans les mesures des capteurs et les incertitudes dans les modèles de conduite pour générer des décisions de conduite robustes [BCSG16][KTH07]. Les systèmes de logique floue ont été utilisés pour la planification de trajectoire, la commande de vitesse et la commande de direction.

En conclusion, les modèles d'apprentissage automatique pour le changement de voie dans les véhicules automatisés sont des algorithmes qui utilisent des techniques d'apprentissage automatique pour apprendre les comportements de conduite. Ces modèles peuvent prendre en compte des facteurs plus complexes et sont capables de prendre des décisions plus avancées.

1.7.3 Modèle basé sur les «incitations»

Un autre type d'algorithme de prise de décision pour changement de voie est le modèle basé sur des incitations (incentive-based models), il mesure le niveau de «désir» de changement de voie qui représente le gain potentiel si la changement de voie est effectué. En plus d'autres paramètres tels que la vitesse souhaitée, la limite de vitesse et le gain de vitesse, le modèle prend la décision de changer de voie ou pas. MOBIL [KTH07] et LMRS [SKvA12] sont les principaux modèles de cette catégorie.

1.8 Axes d'améliorations par rapport à l'état de l'art

Le problème des méthodes citées précédemment est que le style de la conduite automatisée résultant sera nécessairement différent d'un conducteur humain, qui adopte généralement un style de conduite plus intuitif et parfois moins optimal. Dans de nombreuses situations, le conducteur humain doit anticiper le comportement des autres véhicules, par exemple en essayant une manœuvre d'insertion dans un trafic dense, et une coopération implicite entre les conducteurs est parfois nécessaire (un véhicule adapte sa vitesse pour permettre l'insertion d'un autre véhicule). L'introduction de véhicules automatisés avec un style de conduite "non-humain" (même optimal) pourrait perturber les autres conducteurs humains, augmentant ainsi le risque d'accident pour les usagers humains de la route.

De plus, si un véhicule automatisé ne se conduit pas comme un humain, son comportement peut être difficile à comprendre pour les occupants, induisant de la frustration si le véhicule automatisé est trop prudent et incapable de dépasser des véhicules lents dans un trafic dense, ou de la peur s'il engage des comportements inhabituels. Cela engendrerait des problèmes d'acceptabilité pour les véhicules automatisés.

1.9 Bases de données de roulage

1.9.1 NGSIM

Au début des années 2000, le projet Next Generation Simulation (NGSIM) a été entrepris par la Federal Highway Administration (FHA) aux états Unis pour collecter des données de roulage avec pour objectif premier l'étude des flux de trafics des véhicules sur autoroute [NGS]. À ce jour, les données NGSIM constituent un ensemble de données empiriques microscopiques sur le trafic disponible pour la communauté des chercheurs. Les données brutes ont été collectées par 8 caméras numériques synchronisées montées sur le toit de bâtiments adjacents aux autoroutes (figure 1.12), et des algorithmes de traitements d'images et de suivi visuel permettent d'extraire des mesures quantitatives sur les trajectoires des véhicules. Il existe quatre ensembles de données NGSIM, deux sur les autoroutes (I-80 et US-101) et deux sur les corridors artériels (Lankershim et Peachtree). Dans chaque cas, l'ensemble de données comprend les trajectoires complètes des véhicules pour tous les véhicules sur l'autoroute ou l'artère, de l'entrée à la sortie.

Bien que les ensembles de données NGSIM soient parmi les plus importants disponibles, ils sont encore relativement petits, chaque ensemble étant composé de quelques milliers de véhicules observés sur une courte distance (environ 500 mètres par ensemble) et durée (moins d'une heure par ensemble). Les données NGSIM sont devenues une norme auprès de la communauté scientifique au cours de la dernière décennie pour l'étude des flux de trafics, l'étude du comportement des conducteurs, et le développement d'algorithmes pour les véhicules automatisés, notamment pour l'entraînement de modèles d'intelligence artificielle.

1.9.2 HighD

Le data-set "HighD" est un jeu de données de trajectoires de véhicules sur les autoroutes allemandes pour la validation des systèmes de conduite automatisées. Le jeu de données a été collecté en utilisant un drone volant au-dessus d'autoroutes et contient des données de différents types de véhicules (figure 1.13), notamment des voitures, des camions et des bus. Le jeu de données contient des données provenant de plus de 110000 véhicules et de plus de 400 heures d'enregistrement.



FIGURE 1.12 – Exemple de Camera monté sur un toit et pointant sur un tronçon de l'autoroute I-80 et qui enregistre les trajectoires des véhicules.

Les limitations typiques des méthodes de collecte de données de trafic établies telles que les occlusions sont surmontées par la perspective aérienne.

Le jeu de données comprend des informations sur la position, la vitesse et l'accélération de chaque véhicule, ainsi que des informations sur le type et la taille du véhicule. Ces données sont automatiquement extraites en utilisant des algorithmes de vision par ordinateur et l'erreur de positionnement est généralement inférieure à dix centimètres. Les données couvrent une variété de conditions météorologiques, de scénarios de circulation, de densité de circulation.

la base de données est disponible pour une utilisation par les chercheurs et les ingénieurs travaillant sur le développement de systèmes de conduite automatisés [KBKE18b]. Il peut être utilisé pour entraîner et valider les algorithmes de perception, de prévision, de planification et de commande dans un environnement réaliste et diversifié. Le jeu de données peut aider à tester la robustesse des systèmes dans différents scénarios.

La méthodologie utilisée pour collecter les données consiste à utiliser un drone

CHAPITRE 1. ETAT DE L'ART SUR LA PRISE DE DÉCISION POUR LA CONDUITE AUTOMATISÉE

équipé d'une caméra pour voler à une altitude supérieure à 100m au-dessus de l'autoroute. Le drone était programmé pour voler parallèlement à la route. La caméra sur le drone était réglée pour enregistrer à une fréquence d'images à 25Hz.

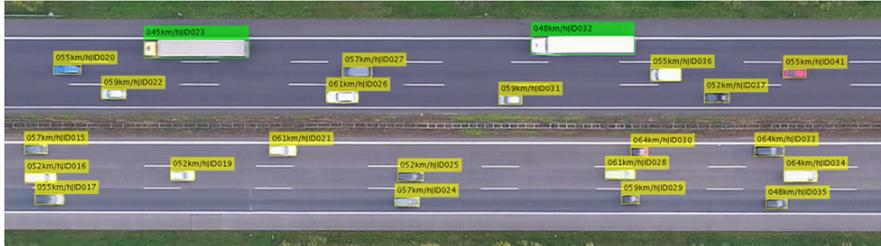


FIGURE 1.13 – Exemple d'enregistrement avec étiquetage des véhicules détectés. La couleur des étiquettes indique la classe de l'objet détecté (Jaune : voiture, camion : vert). Chaque véhicule se voit attribuer un identifiant unique pour le suivi.

1.9.3 MOOVE

Pour aider les ingénieurs à améliorer le véhicule automatisé, le projet MOOVE [BDGB17] a été initié en 2015 à l'institut VEDECOM dans le but de fournir une meilleure interprétation de l'environnement tel qu'il serait perçu par les véhicules automatisés.

La méthodologie MOOVE repose sur les étapes suivantes :

- La première étape est l'acquisition des données sur des véhicules équipés. Les données collectées sur chacun des véhicules MOOVE sont synchronisées, stockées sur une mémoire de masse SSD puis importées sur le data center pour effectuer des analyses. Enfin, les résultats de tous les partenaires partageant le projet MOOVE peuvent être exploités (figure 1.14).

Tous les véhicules MOOVE sont équipés de :

- Capteurs intelligents basés sur 3 technologies principales (Radar, Lidar, Caméra) (figure 1.15),
- Global Navigation Satellite System (GNSS),
- Caméras extéroceptives et caméra conducteur,

- Outil d’annotation embarqué,
- Outils d’enregistrement de conduite en temps réel (data logger).
- La deuxième étape est le traitement des données. Ces dernières sont analysées et les résultats apportent des informations concernant :
 - Les objets dynamiques et statiques entourant le véhicule MOOVE,
 - Les infrastructures routières,
 - Les conditions environnementales (y compris la météo).

Plus d’1 million de km de roulage ont déjà été collectés à l’aide de véhicules non automatisés. Les enregistrements de données sont représentatifs de toutes les conditions de circulation possibles sur les autoroutes et les routes périphériques. L’équipement est fortement intégré dans les véhicules MOOVE. De cette façon, ils ressemblent à des véhicules standards pour éviter que les autres usagers de la route aient une réaction anormale. Les principaux objectifs du projet sont :

- Identifier les situations critiques pour les véhicules automatisés.
- Quantifier les paramètres de dimensionnement liés au milieu environnant et à la dynamique, comme la distance et vitesse entre les véhicules à proximité, etc. Ces paramètres permettent d’extraire des situations critiques pour la sécurité.
- Réaliser des statistiques sur l’occurrence et les conséquences des situations critiques pour combiner chacune avec un niveau d’intégrité de la sécurité automobile (ASIL) [PWHR11]. Par conséquent, des critères de performance peuvent être identifiés pour améliorer la perception et la supervision des systèmes du véhicule automatisé.
- Mettre en place une base de données à utiliser dans des simulateurs de situations de conduite routière afin d’évaluer le comportement des systèmes de véhicules automatisés.

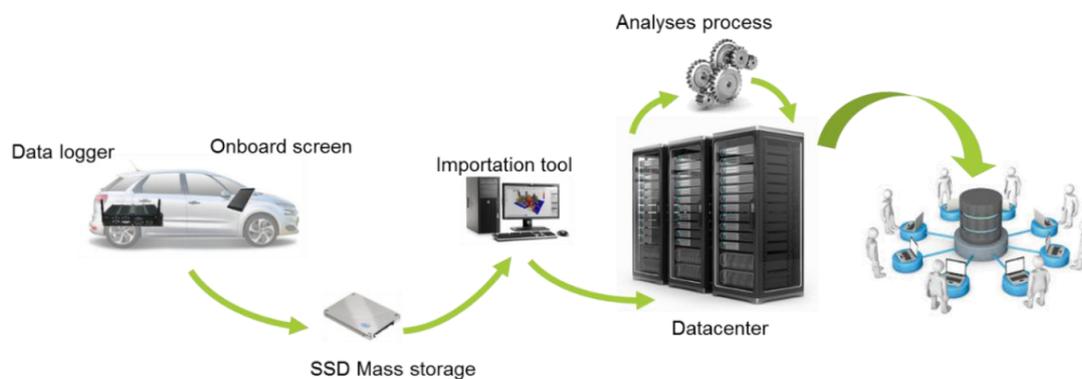


FIGURE 1.14 – Synopsis de la collecte de données dans MOOVE



FIGURE 1.15 – Véhicule MOOVE avec capteurs

1.9.4 KITTI

KITTI (Karlsruhe Institute of Technology and Toyota Technological Institute at Chicago) est une base de données populaire pour la recherche en vision par ordinateur, en particulier dans le domaine de la perception de véhicules automatisés. Elle a été créée pour fournir des données de qualité pour l'évaluation des algorithmes de détection, de localisation et de cartographie d'objets. Elle comprend des données de capteurs multiples, notamment des images RGB, des images de profondeur, des données lidar et des données GPS/IMU, qui ont été collectées à partir d'un véhicule automatisé équipé d'un système de capteurs embarqué. Les données sont collectées dans des environnements urbains réels et comprennent des scénarios tels que des intersections, des ronds-points, des routes à quatre voies et des rues étroites.

Les données de KITTI sont utilisées pour l'évaluation et le développement de systèmes de vision par ordinateur pour la détection, la localisation et la cartographie d'objets, ainsi que pour des applications de conduite automatisée. Les données de KITTI ont été utilisées dans de nombreuses études pour évaluer les performances des algorithmes de détection d'objets, de segmentation d'image, de reconnaissance de forme 3D, de suivi d'objets et de localisation. Les données de KITTI ont également été utilisées pour des applications de conduite automatisée telles que la planification de trajectoire, la perception de la voie, la reconnaissance de panneaux de signalisation et la détection d'obstacles.

En plus de ces données, la base de données KITTI fournit également des annotations pour les images et les données lidar. Ces annotations incluent des informations sur les positions, les tailles et les classes des objets détectés dans les images, ainsi que des informations sur les positions et les orientations des voitures, des camions et des piétons dans les données lidar. Ces annotations sont utilisées pour évaluer les performances des algorithmes de détection d'objets et de localisation en utilisant des métriques standard telles que la précision, le rappel et le F1-score.

En outre, KITTI a été utilisée pour évaluer les performances des systèmes de vision par ordinateur pour des tâches spécifiques telles que la reconstruction 3D, la reconnaissance de formes, la reconnaissance de panneaux de signalisation et la reconnaissance de voies. Ces tâches sont cruciales pour la conduite automatisée,

car elles permettent aux systèmes de voiture de comprendre leur environnement et de planifier des trajectoires sûres.

1.10 Conclusion

La prise de décision est un élément d'une importance cruciale pour le véhicule automatisé, autant du point de vue de la sécurité que pour l'acceptabilité des passagers. En effet, pour éviter le rejet des utilisateurs, les véhicules devront à certains égards se rapprocher d'un comportement humain. Également, ce comportement est important vis-à-vis des autres usagers de la route pour être compréhensible par ces derniers et pour faciliter les interactions.

Ce chapitre a présenté un historique du développement des technologies de véhicules automatisés. Ensuite il a posé le contexte actuel du marché automobile du point de vue des ADAS et expose les différents acteurs impliqués dans leurs développements, avant de poursuivre sur un état de l'art sur la prise de décision pour les véhicules automatisés, ainsi des différents modèles de prédiction de trajectoire, de prise de décision pour le changement de voie et des jeux de données de conduite naturaliste.

Chapitre 2

Définition d'une échelle du risque, et gain

Sommaire

2.1	Introduction	44
2.2	Extraction de données	44
2.2.1	Choix de la base de données	44
2.2.2	Caractéristiques de la base de données MOOVE	45
2.2.3	Méthodologie d'extraction des données	48
2.3	Analyse des résultats pour les changement de voie vers la gauche	50
2.3.1	Véhicule leader sur la voie initiale	50
2.3.2	Véhicule leader sur la voie finale	51
2.3.3	Véhicule arrière sur la voie finale	53
2.4	Méthode d'évaluation du risque	55
2.5	Définition du gain	60
2.6	Conclusion	63

2.1 Introduction

Ce chapitre est consacré dans un premier temps au travail réalisé sur la base de données MOOVE. Notamment l'extraction des données relatives aux manœuvres de changement de voie et l'analyse de ces dernières. Par la suite, une proposition de méthode d'évaluation du risque pour les manœuvres de changement de voie est développée ainsi qu'une mesure que nous avons dénommée « gain » qui mesure l'intérêt d'un véhicule à changer de voie.

2.2 Extraction de données

2.2.1 Choix de la base de données

Le choix de la base de données est d'une importance capitale lorsqu'il s'agit de développer une échelle de risque. En effet, cette base de données va déterminer la quantité, la qualité ainsi que le type de données utilisées pour le développement de l'échelle. Il existe une différence importante entre les différentes bases de données disponibles sur le marché, telles que MOOVE, NGSIM ou HighD.

MOOVE est une base de données qui repose sur des capteurs embarqués au sein du véhicule. Ces capteurs sont les mêmes que l'on peut retrouver dans un véhicule équipé de fonctions ADAS (Aide à la Conduite Assistée) destinées à l'utilisateur final. Ainsi, la qualité et le type de données présentes dans la base MOOVE sont très proches de ce que l'on peut rencontrer dans des conditions réelles d'utilisation. De plus, la représentation de l'environnement du véhicule dans cette base de données est égocentrée, c'est-à-dire qu'elle prend en compte la position et les mouvements du véhicule par rapport à lui-même.

À contrario, NGSIM est une base de données qui repose sur des caméras déportées installées en bordure de routes et en hauteur. Cette base de données permet de capturer des images vidéos des véhicules en mouvement et de calculer les grandeurs physiques relatives au déplacement et aux dimensions des véhicules à partir de ces images en utilisant des algorithmes de vision par ordinateur. La représentation de l'environnement dans cette base de données est géocentrée, c'est-à-dire qu'elle prend en compte la position et les mouvements des véhicules par rapport

à une origine fixe sur la route.

HighD est une base de données qui s'appuie sur des images vidéos enregistrées par des drones aériens. Cette base de données est similaire à NGSIM en ce qu'elle permet de capturer des images vidéos des véhicules en mouvement et de calculer les grandeurs physiques relatives au déplacement et aux dimensions des véhicules à partir de ces images en utilisant des algorithmes de vision par ordinateur. Toutefois, l'utilisation de drones aériens permet de capturer des images vidéos depuis des angles de vue différents et de couvrir des zones plus étendues que les caméras déportées utilisées dans NGSIM.

Afin de développer l'échelle du risque, il est donc important de choisir la base de données qui convient le mieux aux besoins en fonction des caractéristiques de chaque base de données. Dans notre cas, nous avons choisi de travailler avec la base de données MOOVE de l'institut VEDECOM [BDGB17]. Nous avons fait ce choix principalement pour sa représentation égocentrée et l'utilisation de capteurs proches du réel, qui nous permet de développer une échelle de risque qui est la plus proche possible des conditions réelles d'utilisation des véhicules. Nous avons également pris en compte la quantité de données disponibles dans cette base de données qui est largement supérieure aux autres solutions disponibles sur le marché.

En utilisant la base de données MOOVE, nous avons pu analyser les données de plusieurs milliers de manœuvres et de différents types de situations de conduite pour élaborer notre échelle de risque. Cette échelle prend en compte plusieurs paramètres tels que la vitesse, la distance de sécurité, la trajectoire, les manœuvres et les interactions entre les véhicules pour évaluer le niveau de risque de chaque situation de conduite.

2.2.2 Caractéristiques de la base de données MOOVE

La base de données MOOVE comporte 4 grandes catégories de données :

- Données infrastructures : comporte des mesures quantitatives et qualitatives concernant la route (type de route, nombre de voies, tracé, présence de bordures... etc) également de la signalisation (marquage au sol, panneaux de signalisation, feux rouges.)
- Données ego véhicule : les instruments de mesure embarqués enregistrent

en temps réel toutes les variables qu'il est possible de lire à partir du bus CAN du véhicule. Ainsi, on retrouve des mesures très complètes telles que la vitesse du véhicule, la vitesse de chaque roue, l'angle du volant de direction, la pression de la pédale d'accélérateur ou de frein, le rapport de boîte de vitesses engagé. . . , mais également les informations en provenance du GPS RTK pour une mesure précise de la position du véhicule.

- Données « obstacles » : on retrouve également des données concernant les obstacles autour de l'ego véhicule. Par « obstacle » il est question des autres véhicules (voitures, poids lourds, deux-roues) mais également des piétons ou tout autres obstacle susceptible d'être présent sur la route (plots de travaux publics par exemple). Ces informations sont obtenues au moyen de capteurs extéroceptifs intégrés à l'ego véhicule :
 - 2 Lidars (avant et arrière).
 - 1 Radar longue portée (avant).
 - 4 Radars courte portée.
 - 6 Cameras.
- Données météo : relatives aux conditions météo.

La figure 2.1 montre une capture d'écran du logiciel fourni avec le projet MOOVE, qui permet de visualiser graphiquement toutes les mesures et les vidéos enregistrées par les capteurs des véhicules équipés sur une seule et même interface. Cette interface est conçue pour faciliter l'analyse des données collectées par les véhicules, et offre une vue complète de l'environnement tel qu'il est perçu par les véhicules automatisés.

La partie supérieure de l'interface montre les enregistrements vidéo des caméras embarquées sur le véhicule, permettant ainsi de visualiser les images capturées par les caméras en temps réel. En bas à droite, on retrouve la position du véhicule sur une carte Google Maps, ce qui permet de suivre la trajectoire du véhicule et de situer les différentes captures d'images.

Au centre de l'interface, il est possible de choisir parmi tous les signaux présents dans la base de données pour tracer leurs évolutions sur une courbe. Cela permet de visualiser les variations des différentes mesures au cours du temps, et de mieux comprendre les différents phénomènes qui se produisent pendant la conduite.

Enfin, à droite de l'interface, on retrouve une vue aérienne simplifiée de l'en-



FIGURE 2.1 – Capture du logiciel MOOVE qui permet d’avoir une vue graphique des données.

vironnement tel que le perçoit le véhicule, avec les marquages, les véhicules ainsi que tout autre obstacle pouvant apparaître. Cela permet de visualiser les différents éléments présents dans l’environnement, et de mieux comprendre comment le véhicule perçoit et interagit avec ces éléments.

Données brutes et données fusionnées

Les capteurs utilisés dans le projet MOOVE incluent des caméras, des capteurs radar, des capteurs lidar, etc. Cependant, chacun de ces capteurs a ses propres limites et faiblesses. Par exemple, les caméras peuvent être affectées par la luminosité, les capteurs radar peuvent avoir des angles morts, etc. Pour pallier ces faiblesses, le projet MOOVE utilise la redondance d’information. Cela signifie que les mesures brutes de chaque capteur sont collectées de manière individuelle, permettant ainsi de disposer d’une information complémentaire en cas de défaillance d’un capteur.

En outre, pour obtenir des informations plus robustes aux incertitudes de mesures et aux angles morts des capteurs, le projet MOOVE utilise des algorithmes de fusion de données. Ces algorithmes permettent de traiter les mesures brutes

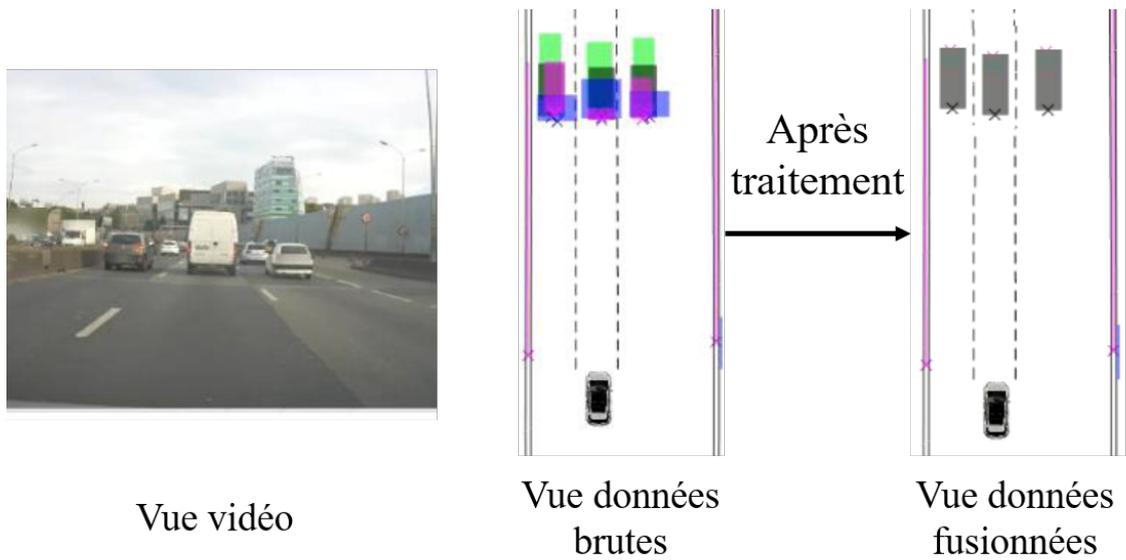


FIGURE 2.2 – Résultat de la visualisation après fusion.

(1- A gauche : la vue vidéo. 2- Au centre : visualisation avec les données brutes de tous les capteurs (chaque couleur représente un capteur). 3- A droite : visualisation avec les données fusionnées).

et de combiner les informations de différents capteurs pour obtenir une mesure plus précise de l'environnement (voir figure 2.2). Les données ainsi obtenues sont ensuite utilisées pour des statistiques, de l'apprentissage automatique...etc

2.2.3 Méthodologie d'extraction des données

Pour détecter les manœuvres de changement de voie, nous nous basons sur plusieurs variables du jeu de données. Parmi elles, le nombre de voies de la route et le numéro de la voie qu'occupe le véhicule. Mais ces deux éléments ne suffisent pas à eux seuls pour détecter un changement de voie de manière fiable et produisent un nombre non-négligeable de faux positifs. Cela étant dû au changement de marquage sur la route en cours de roulage, comme par exemple le passage de trois voies à deux qui peut induire en erreur l'algorithme. Le facteur le plus important à prendre en compte est le « lane Shift » qui mesure la distance entre le centre du pare-chocs avant et le marquage droit de la voie actuelle. Lors d'une manœuvre, nous pouvons

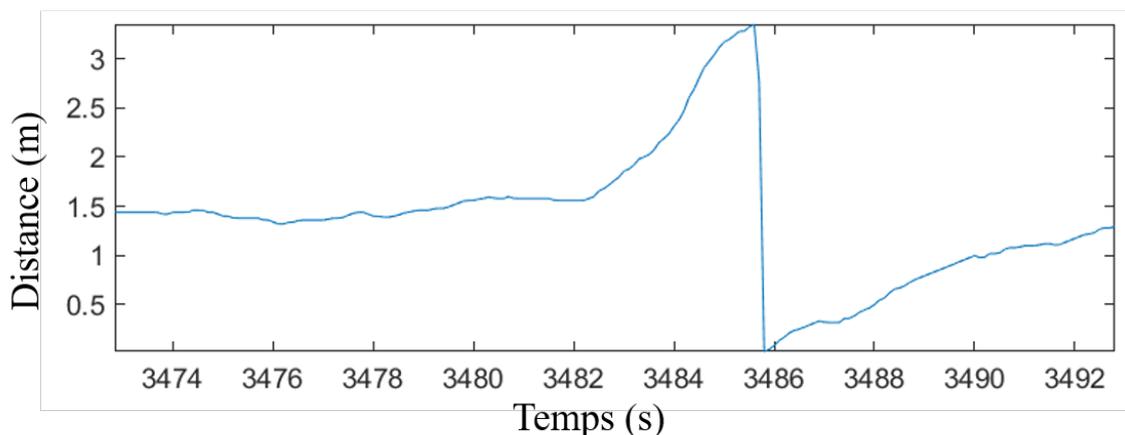


FIGURE 2.3 – Évolution du lane shift durant une manœuvre de changement de voie

observer une discontinuité de la courbe (figure 2.3) qui est dû au changement de repère, en effet à l'instant où le centre du pare-chocs avant franchi la ligne le repère de mesure passe du marquage droit de la précédente voie vers le marquage de la nouvelle voie. La détection de ce type de discontinuité permet de détecter un franchissement de ligne, et allié aux variables précédemment citées (numéro de la voie actuelle, nombre de changements de voie successifs), permet d'isoler de manière fiable les manœuvres de changement de voie

L'algorithme a été exécuté sur 8922 enregistrements de la base de données, chaque enregistrement durant entre 2 et 3 heures, le résultat obtenu est d'un total de 240941 changement de voie, où nous avons eu :

- vers la voie de gauche : 111.820 échantillons.
- vers la voie de droite : 129.081 échantillons.

Cependant, un filtrage a dû être appliqué pour éliminer plusieurs échantillons. Parmi eux, les cas de double changement de voie, également les échantillons dont les mesures présentent des valeurs aberrantes ou des niveaux de bruits trop importants, pour un résultat final de :

- vers la voie de gauche : 78.908 échantillons.
- vers la voie de droite : 84.158 échantillons.

2.3 Analyse des résultats pour les changement de voie vers la gauche

Pour étudier les données obtenues, nous isolons les changements de voie vers la gauche et vers la droite. Ces deux manœuvres étant réalisées pour des raisons différentes, il est pertinent d'étudier les deux indépendamment. Les conducteurs changent de voie vers la gauche le plus souvent pour dépasser un véhicule qui roule à une vitesse inférieure. Le changement de voie vers la droite quant à lui est le plus souvent effectué pour se rabattre et revenir à la voie la plus à droite comme l'exige le code de la route.

Dans la section qui suit, à gauche de chaque courbe nous présentons la situation qui correspond à la courbe (changement de voie vers la droite ou vers la gauche) ainsi qu'une mise-en-évidence du véhicule concerné (figure 2.4).

Nous nous intéressons d'abord à la vitesse de l'ego-véhicule lors des manœuvres. La figure 2.4 représente la distribution de la vitesse de l'ego-véhicule, l'instant choisi est celui du début de la manœuvre qui correspond à 3 secondes avant le franchissement de la ligne (voir figure 2.3).

Nous remarquons que nous avons des pics importants de changement de voie autour des limitations de vitesse en vigueur en France (90 – 110 – 130 Km/h). Nous remarquons également des cas de changement de voie allant de 130 à 160 km/h malgré la vitesse maximale autorisée de 130 km/h.

Nous nous intéressons également aux liens avec les véhicules autour de l'ego à travers les inter-distances et les vitesses relatives de ces derniers par rapport à l'ego.

2.3.1 Véhicule leader sur la voie initiale

La figure 2.5 représente la distance longitudinale entre le pare-chocs avant de l'ego-véhicule et le pare-chocs arrière du véhicule leader de la voie initiale. Quant à la figure 2.6 représente le temps inter-véhiculaire entre ces deux véhicules. On remarque que dans la majorité des cas, les conducteurs commencent la manœuvre de changement de voie avec un temps inter-véhiculaire inférieur à 1 seconde, ce qui est très faible par rapport à ce qui est imposé par la loi de 2 secondes. Cela

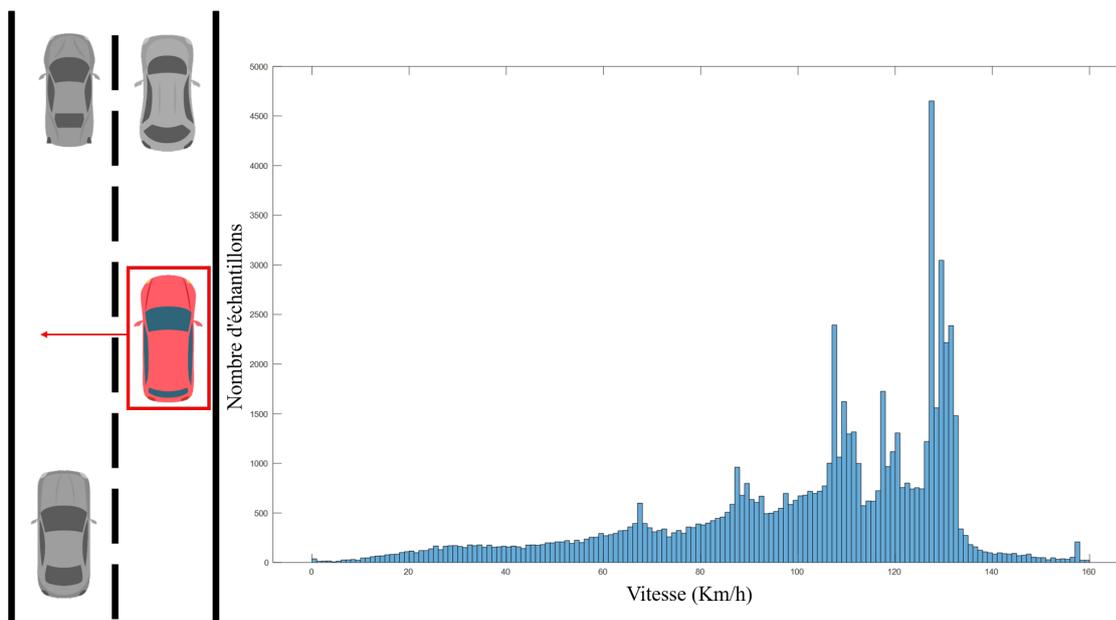


FIGURE 2.4 – Histogramme de distribution de la vitesse de changement de voie de l'ego-véhicule.

confirme l'hypothèse selon laquelle, dans les faits certains critères du code de la route ne sont pas du tout respectés par les conducteurs, et que si un véhicule automatisé devait respecter strictement ce dernier, son comportement serait assez différent du commun des conducteurs.

2.3.2 Véhicule leader sur la voie finale

La figure 2.7 représente la distance longitudinale entre le pare-chocs avant de l'ego-véhicule et le pare-chocs arrière du véhicule leader de la voie finale. Quant à la figure 2.8 représente la vitesse longitudinale relative entre ces deux véhicules. Concernant la distribution de la distance, nous pouvons voir un pic entre 0 et 20 mètres de distance et une décroissance progressive jusqu'à 140 mètres, au-delà, il ne reste que quelques faibles cas.

Pour ce qui est de la vitesse relative, nous observons une distribution gaussienne avec les valeurs les plus hautes comprises entre 0 et 10 km/h, et également beaucoup d'échantillons avec des vitesses relatives négatives, ce qui veut dire que

2.3. ANALYSE DES RÉSULTATS POUR LES CHANGEMENT DE VOIE VERS LA GAUCHE

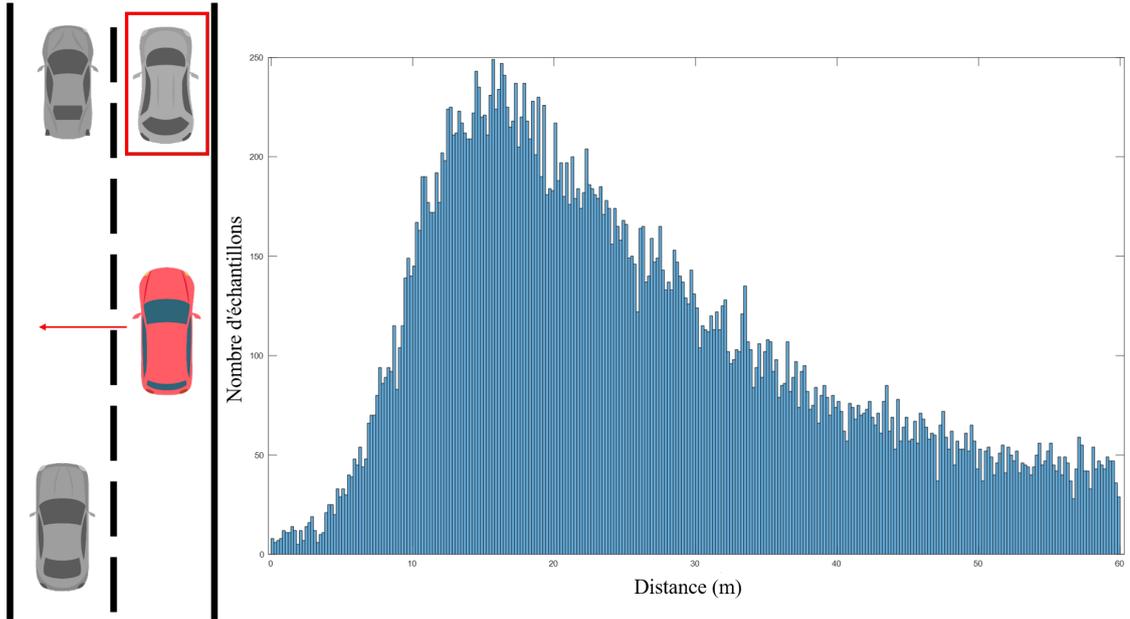


FIGURE 2.5 – Histogramme de distribution de la distance entre l'ego-véhicule et le véhicule leader sur la voie initiale.

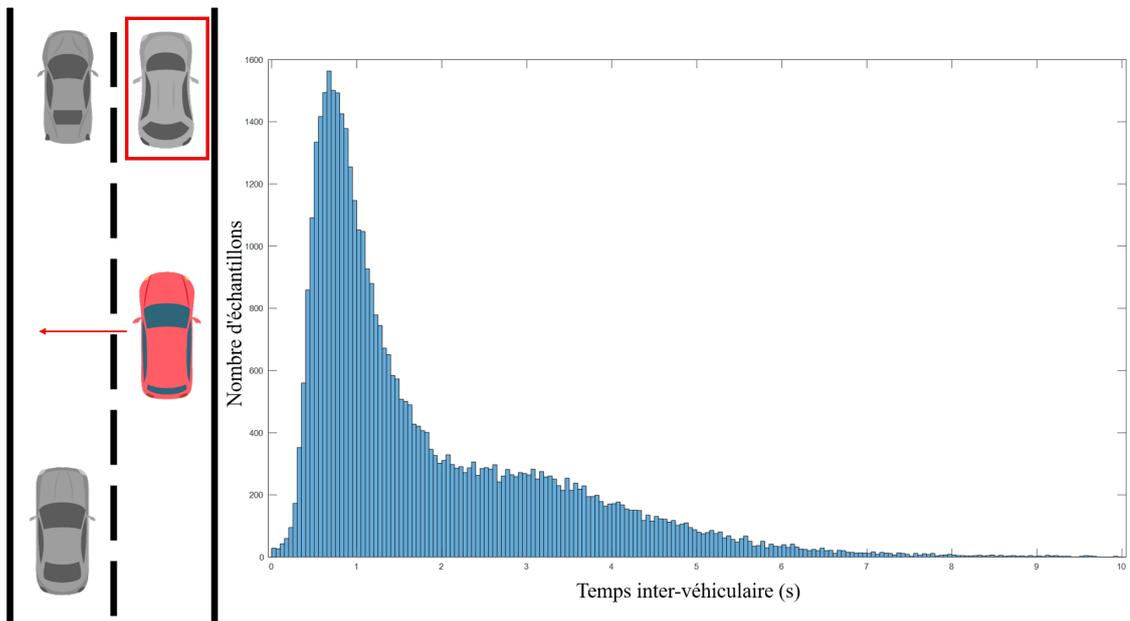


FIGURE 2.6 – Histogramme de distribution du temps inter-véhiculaire entre l'ego-véhicule et le véhicule leader sur la voie initiale.

le conducteur a réalisé la manœuvre de changement de voie alors que le véhicule leader roule à une vitesse inférieure.

Cependant, étudier la prise de risque et le comportement des conducteurs au travers de ces deux variables (distance longitudinale et vitesse relative) de manière indépendante est incomplet, car les deux facteurs affectent la décision simultanément. Pour cela, nous avons tracé un histogramme bi-variant qui exprime la répartition des échantillons selon ces deux variables (figure 2.9 et 2.10).

Un dernier paramètre à prendre en compte est la vitesse à laquelle l'ego-véhicule effectue le changement de voie, en effet le comportement diffère selon que la manœuvre est effectuée à faible vitesse (0 – 50 km/h) ou à des vitesses plus élevées (110 – 130 km/h). C'est pourquoi nous avons divisé l'histogramme 2.10 en 4 intervalles de vitesse (figure 2.11) :

- $[0 - 40]Km/h$
- $[40 - 80]Km/h$
- $[80 - 120]Km/h$
- $[120 - 140]Km/h$

Nous pouvons voir à partir de ces histogrammes que plus la vitesse de l'ego véhicule augmente, plus les conducteurs ont tendance à augmenter l'inter-distance et la vitesse relative entre eux et le véhicule leader sur la voie cible.

Ces différents intervalles ont été choisis pour englober les pics que l'on retrouve sur la figure 2.4

2.3.3 Véhicule arrière sur la voie finale

Nous réalisons le même travail pour le véhicule arrière pour arriver aux mêmes conclusions.

La figure 2.12 représente la distribution de la distance entre le pare-chocs arrière de l'ego-véhicule et le pare-chocs avant de véhicule arrière sur la voie cible.

La figure 2.13 représente la distribution de la vitesse relative entre les deux véhicules, nous remarquons qu'à la différence du véhicule leader, l'histogramme est centré en zéro pour ce cas.

La figure 2.14 représente les histogrammes bivariants pour les 4 intervalles de vitesse définis.

2.3. ANALYSE DES RÉSULTATS POUR LES CHANGEMENT DE VOIE VERS LA GAUCHE

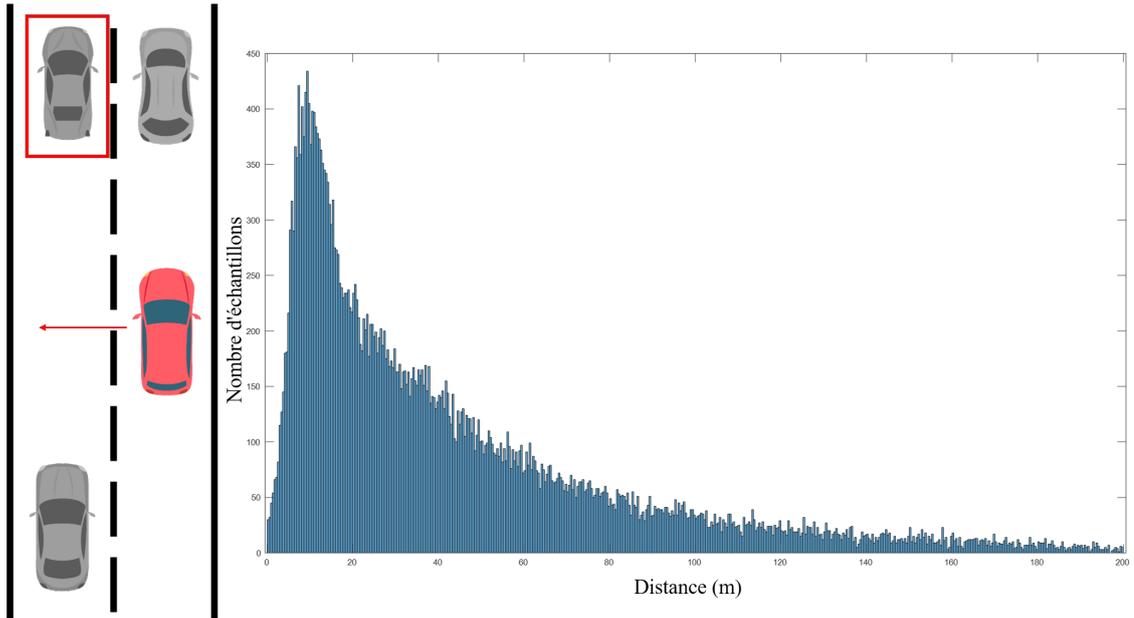


FIGURE 2.7 – Histogramme de distribution de la distance entre l'ego-véhicule et le véhicule leader sur la voie finale.

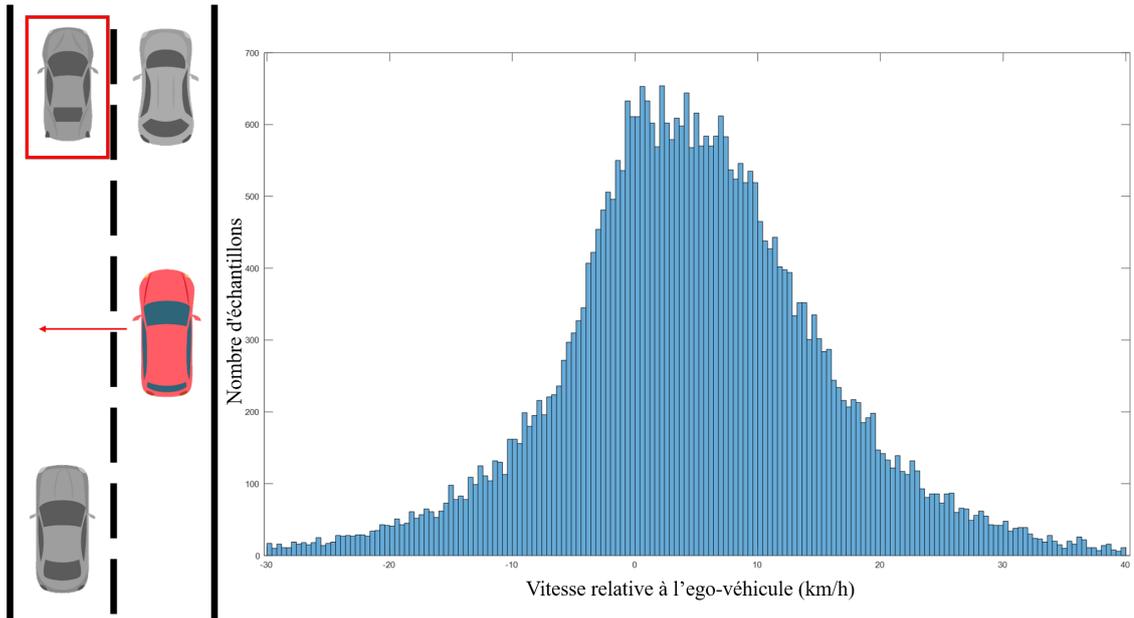


FIGURE 2.8 – Histogramme de distribution de la vitesse du véhicule leader sur la voie finale raltive à l'ego-véhicule.

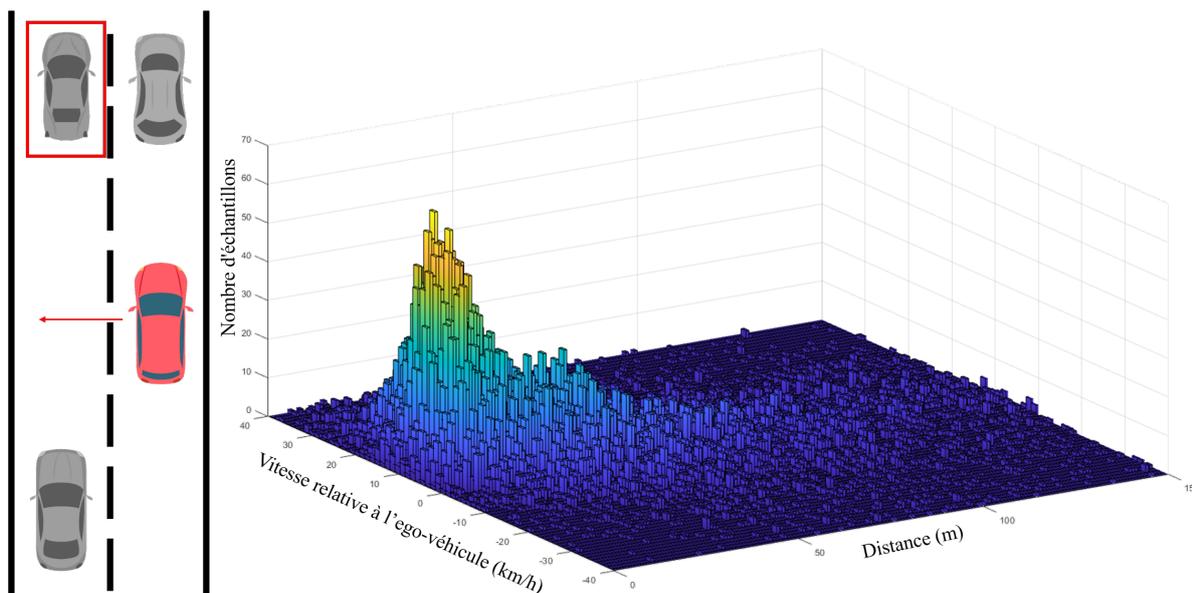


FIGURE 2.9 – Histogramme bi-variant de distribution de la vitesse et de la distance du véhicule leader sur la voie finale relative à l'ego-véhicule (3D).

2.4 Méthode d'évaluation du risque

Dans cette section, nous présentons la méthode d'évaluation du risque pour les manœuvres de changement de voie développé, cette dernière est directement inspirée des histogrammes montrés précédemment (figures 2.11 et 2.14).

Pour le véhicule leader sur la voie cible, nous considérons que pour une manœuvre de changement de voie donnée, plus on a d'échantillons effectués dans des conditions plus « risquées », moins la manœuvre est dangereuse, car cela signifie que plus les conducteurs sont enclins à changer de voie dans ces conditions. Dans ce cas, « situation plus risquée » signifie une distance longitudinale plus faible et/ou une vitesse relative plus faible.

Il en résulte un histogramme cumulatif au lieu d'un histogramme classique, décrit par l'équation 2.1.

$$cH_{Leader(intervalle)}(i, j) = \sum_{n=1}^i \sum_{m=1}^j H_{Leader(intervalle)}(n, m) \quad (2.1)$$

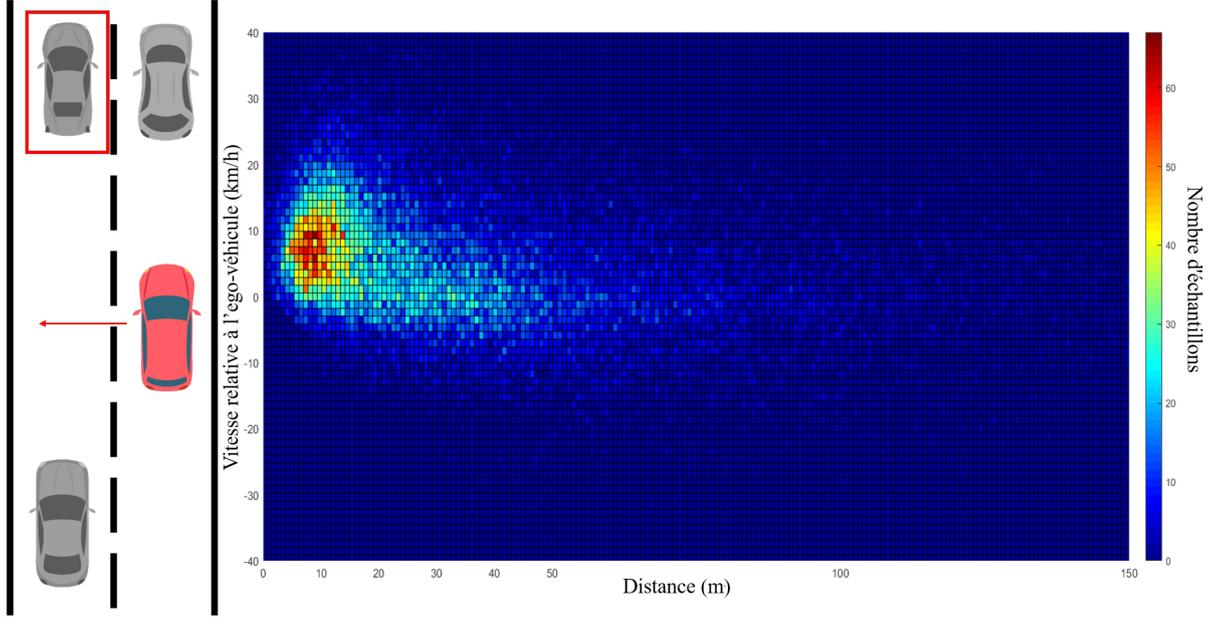


FIGURE 2.10 – Histogramme bi-variant de distribution de la vitesse et de la distance du véhicule leader sur la voie finale relative à l'ego-véhicule (2D).

Avec : $cH_{Leader(intervalle)}$ est la matrice de l'histogramme cumulatif pour le véhicule leader, i et j sont respectivement la distance et la vitesse relative du véhicule leader par rapport à l'ego-véhicule, $H_{leader(intervalle)}$ est la matrice de l'histogramme bi-variant du véhicule leader. ($intervalle$) représente l'intervalle de vitesse de l'ego-véhicule correspondant à la situation.

Pour uniformiser les résultats, une normalisation est appliquée pour contraindre le risque entre deux valeurs 0 et 1 selon l'équation suivante :

$$uH_{Leader(intervalle)}(i, j) = \frac{cH_{Leader(intervalle)}(i, j) - \min(cH_{Leader(intervalle)}(i, j))}{\max(cH_{Leader(intervalle)}(i, j)) - \min(cH_{Leader(intervalle)}(i, j))} \quad (2.2)$$

Avec $Leader(intervalle)$ est la matrice d'histogramme cumulatif uniformisé pour le véhicule leader.

De plus, une inversion de l'échelle est effectuée dans laquelle 1 (ce qui signifie

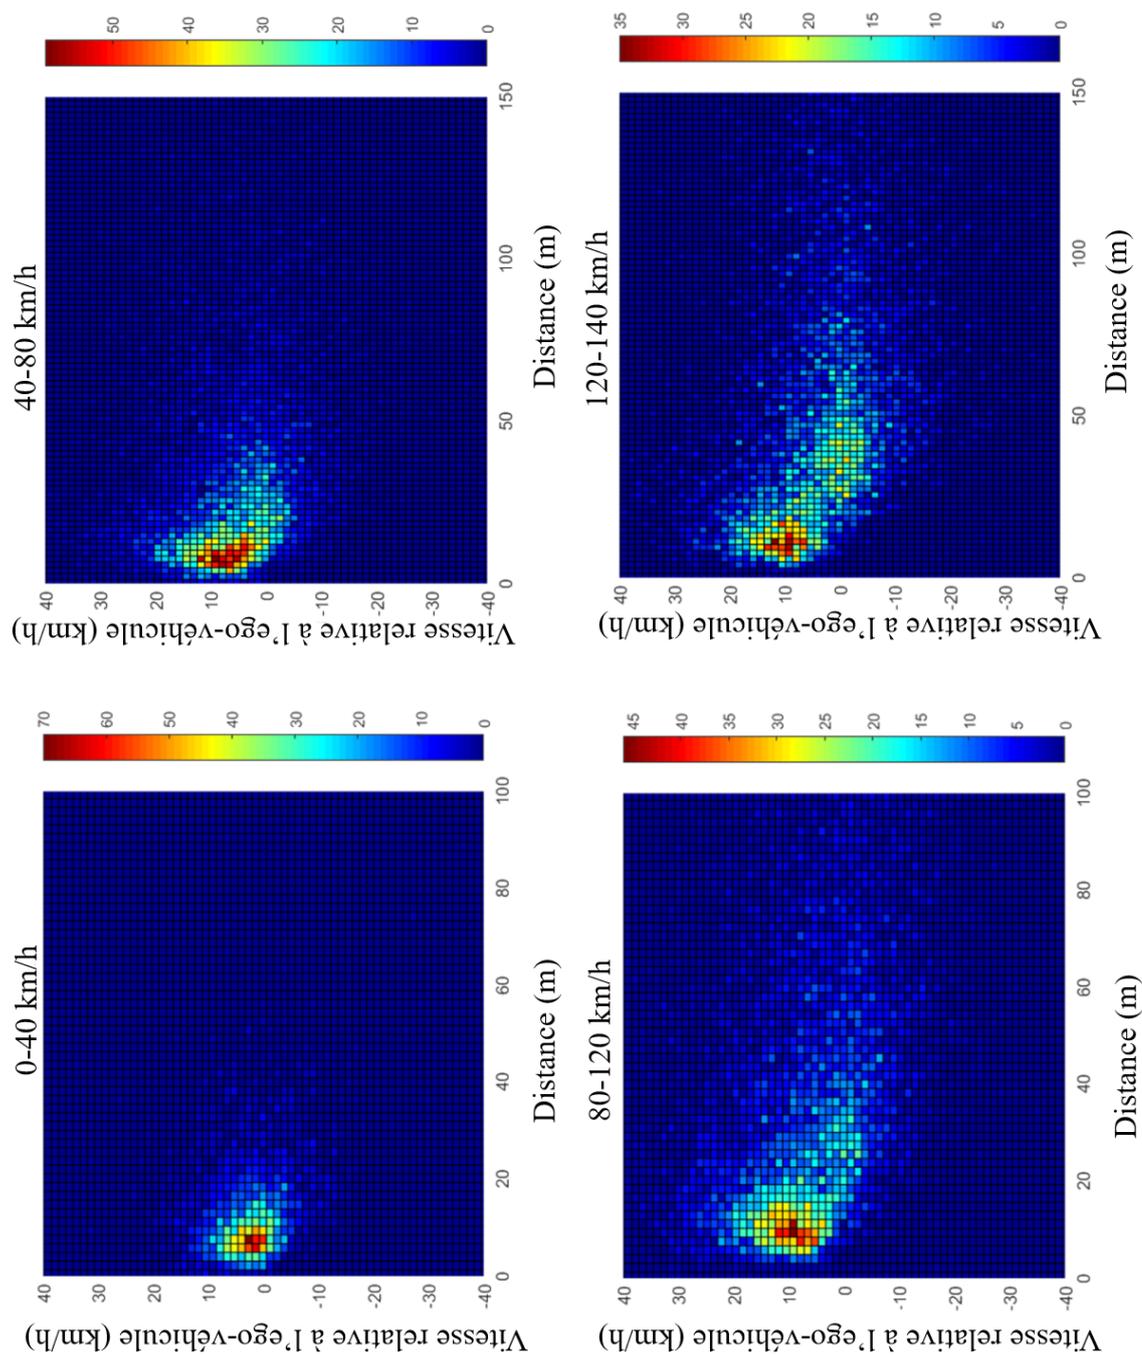


FIGURE 2.11 – Histogramme bi-variant de distribution de la vitesse et de la distance du véhicule leader sur la voie finale relative à l'ego-véhicule divisé en 4 intervalles de vitesses.

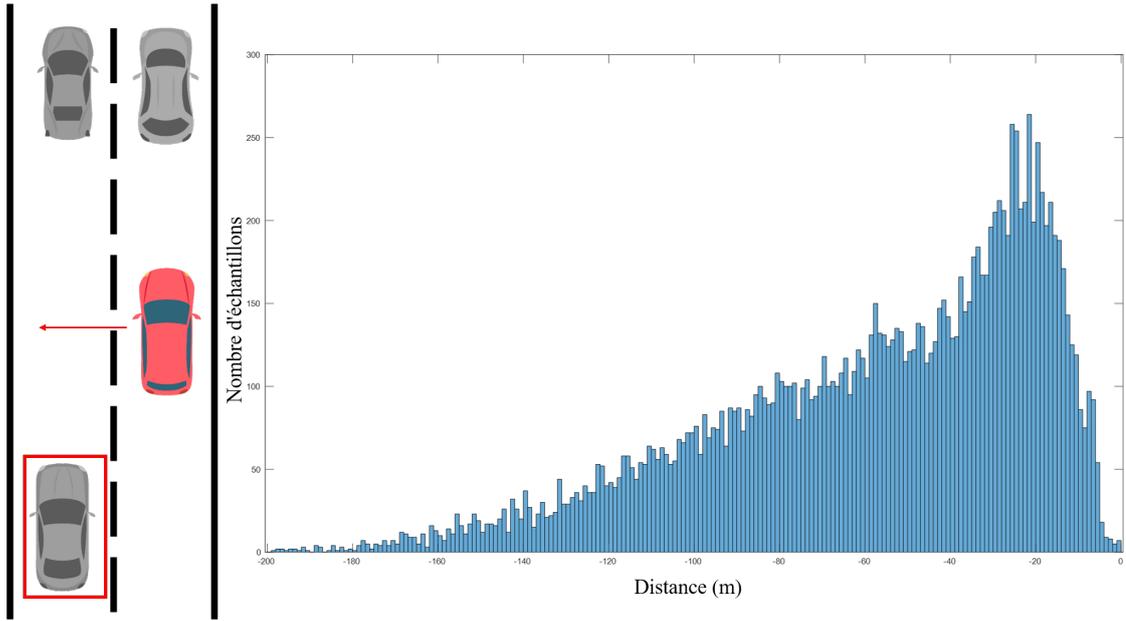


FIGURE 2.12 – Histogramme de distribution de la distance entre l'ego-véhicule et le véhicule arrière sur la voie finale.

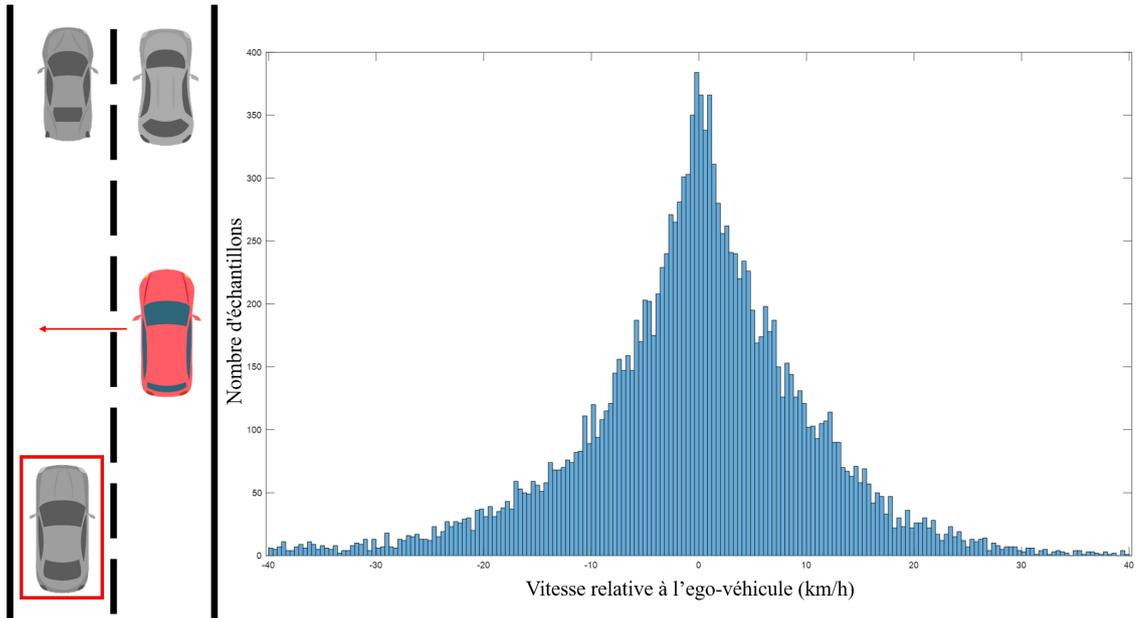


FIGURE 2.13 – Histogramme de distribution de la vitesse du véhicule arrière sur la voie finale relative à l'ego-véhicule.

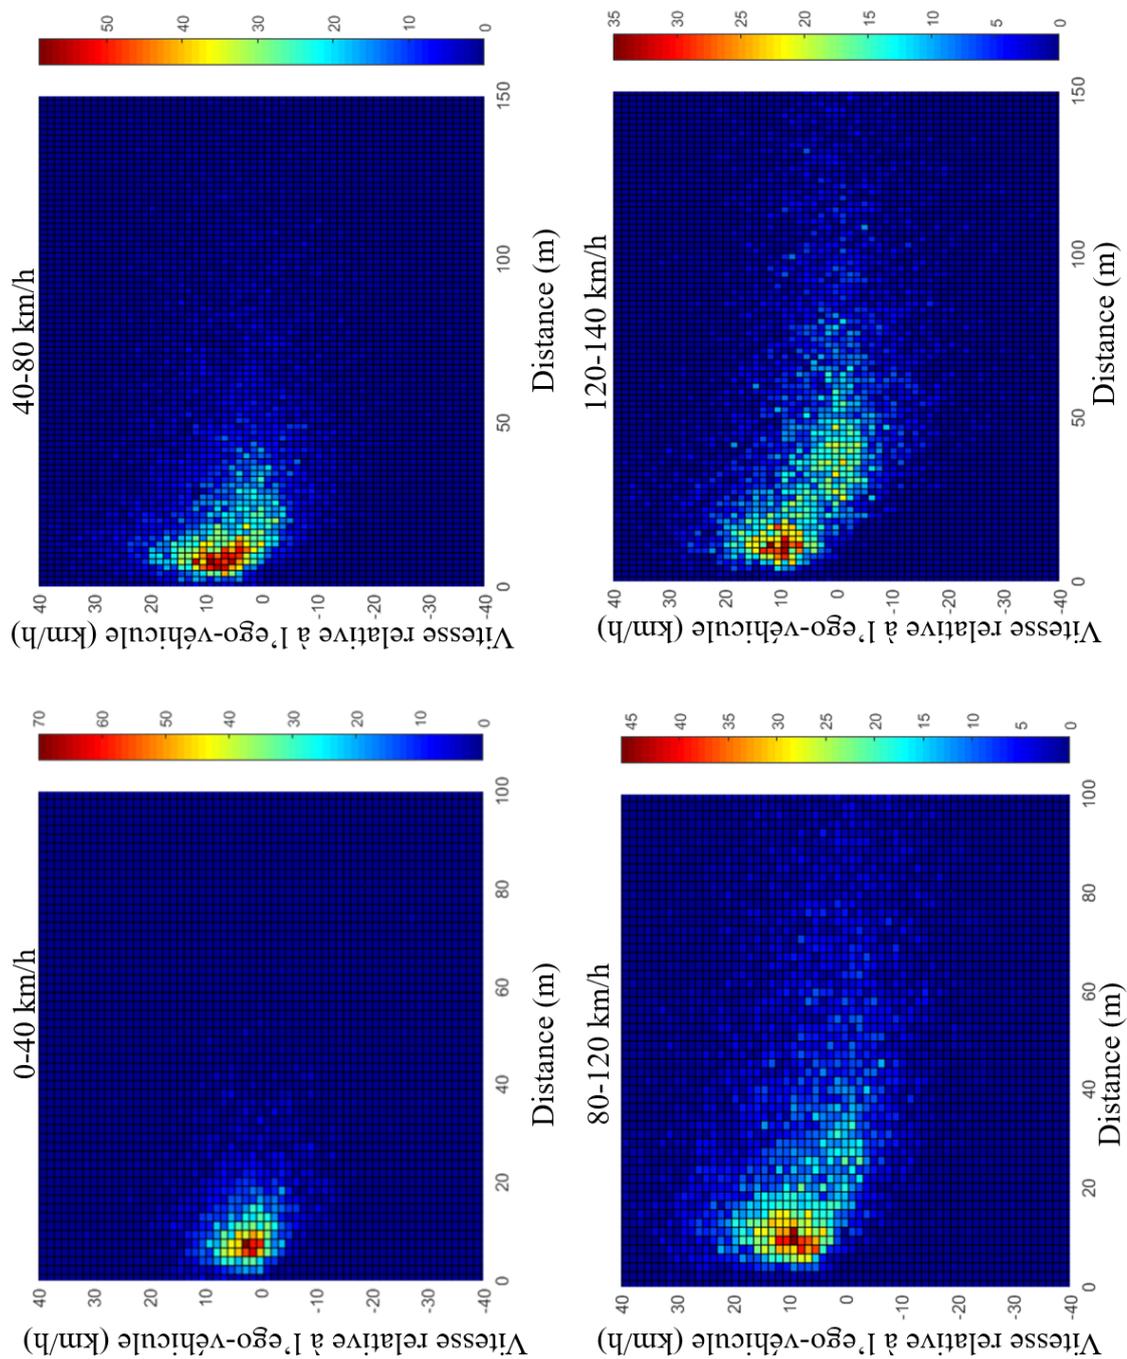


FIGURE 2.14 – Histogramme bi-variant de distribution de la vitesse et de la distance du véhicule arriere sur la voie finale relative à l'ego-véhicule diviséen 4 interalles de vitesses.

2.5. DÉFINITION DU GAIN

qu'un maximum de conducteurs sont enclins à changer de voie dans une telle situation) devient 0 (ce qui signifie un risque minimum), et 0 devient 1. Le résultat est décrit par l'équation 2.3 et représenté sur la figure 2.15.

$$R_{Leader}(i, j) = -uH_{Leader(intervalle)}(i, j) + 1 \quad (2.3)$$

Avec R_{Leader} est la matrice de risque pour le véhicule avant.

Les figures 2.15 et 2.16 décrivent la méthode pour les véhicules avant et arrière respectivement pour les changements de voie vers la gauche.

L'avantage de la méthode proposée par rapport à celles présentées dans l'état de l'art est qu'elle s'inspire directement du comportement humain en observant les échantillons du jeu de données MOOVE. De plus, elle peut facilement être adaptée à n'importe quelle région, sachant que des différences de comportement peuvent être observées entre des pays comme les États-Unis, et ce, en modifiant le jeu de données.

De plus, le risque pour toutes les situations (les 4 intervalles de vitesse pour le véhicule avant et arrière dans la voie cible) peut être calculé au préalable dans des matrices où les lignes correspondent à la distance longitudinale, et les colonnes présentent la vitesse longitudinale relative. Cela fournit un algorithme rapide à exécuter pour évaluer le risque, et cela peut être fait en temps réel en chargeant la bonne matrice qui dépend de la situation et en lisant la valeur du risque par projection de la distance longitudinale et de la vitesse relative.

2.5 Définition du gain

Pour décider si le changement de voie doit être effectué ou non, il faut savoir si le risque en vaut la peine. En parallèle, on définit un coefficient appelé gain (G), qui mesure l'intérêt du conducteur à changer de voie et l'attractivité de la voie adjacente, il est inspiré des travaux de A.Kesting et all [KTH07], et est défini par l'équation suivante :

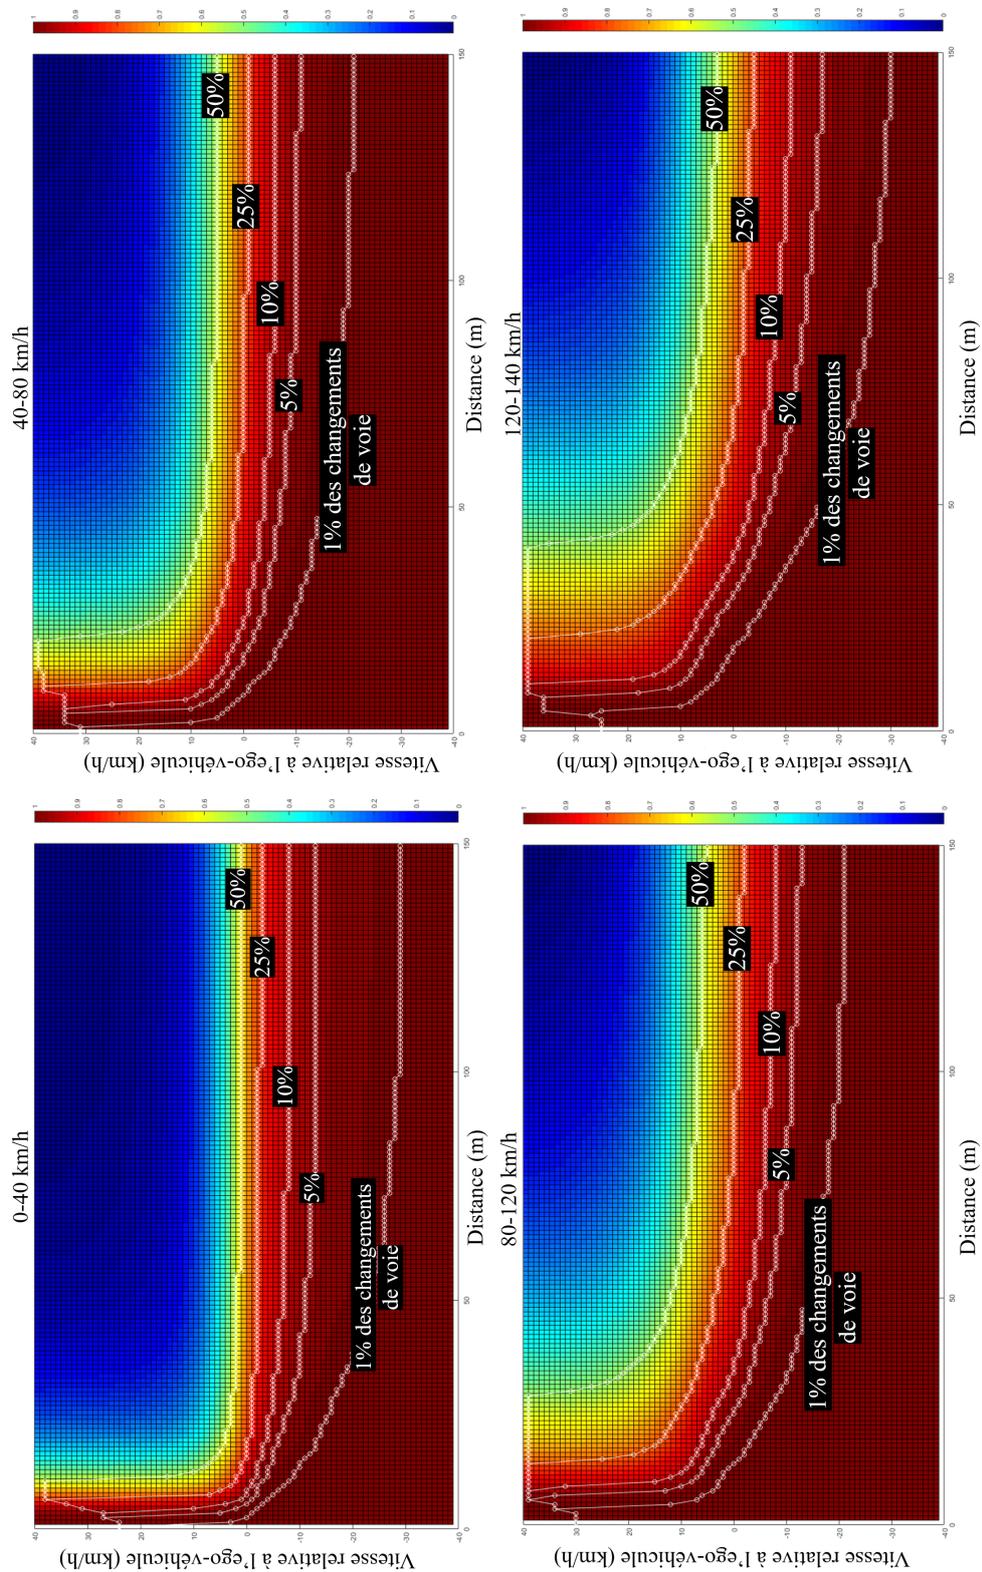


FIGURE 2.15 – Matrice de risque pour le véhicule leader avec courbes de Centile des manœuvres effectués

2.5. DÉFINITION DU GAIN

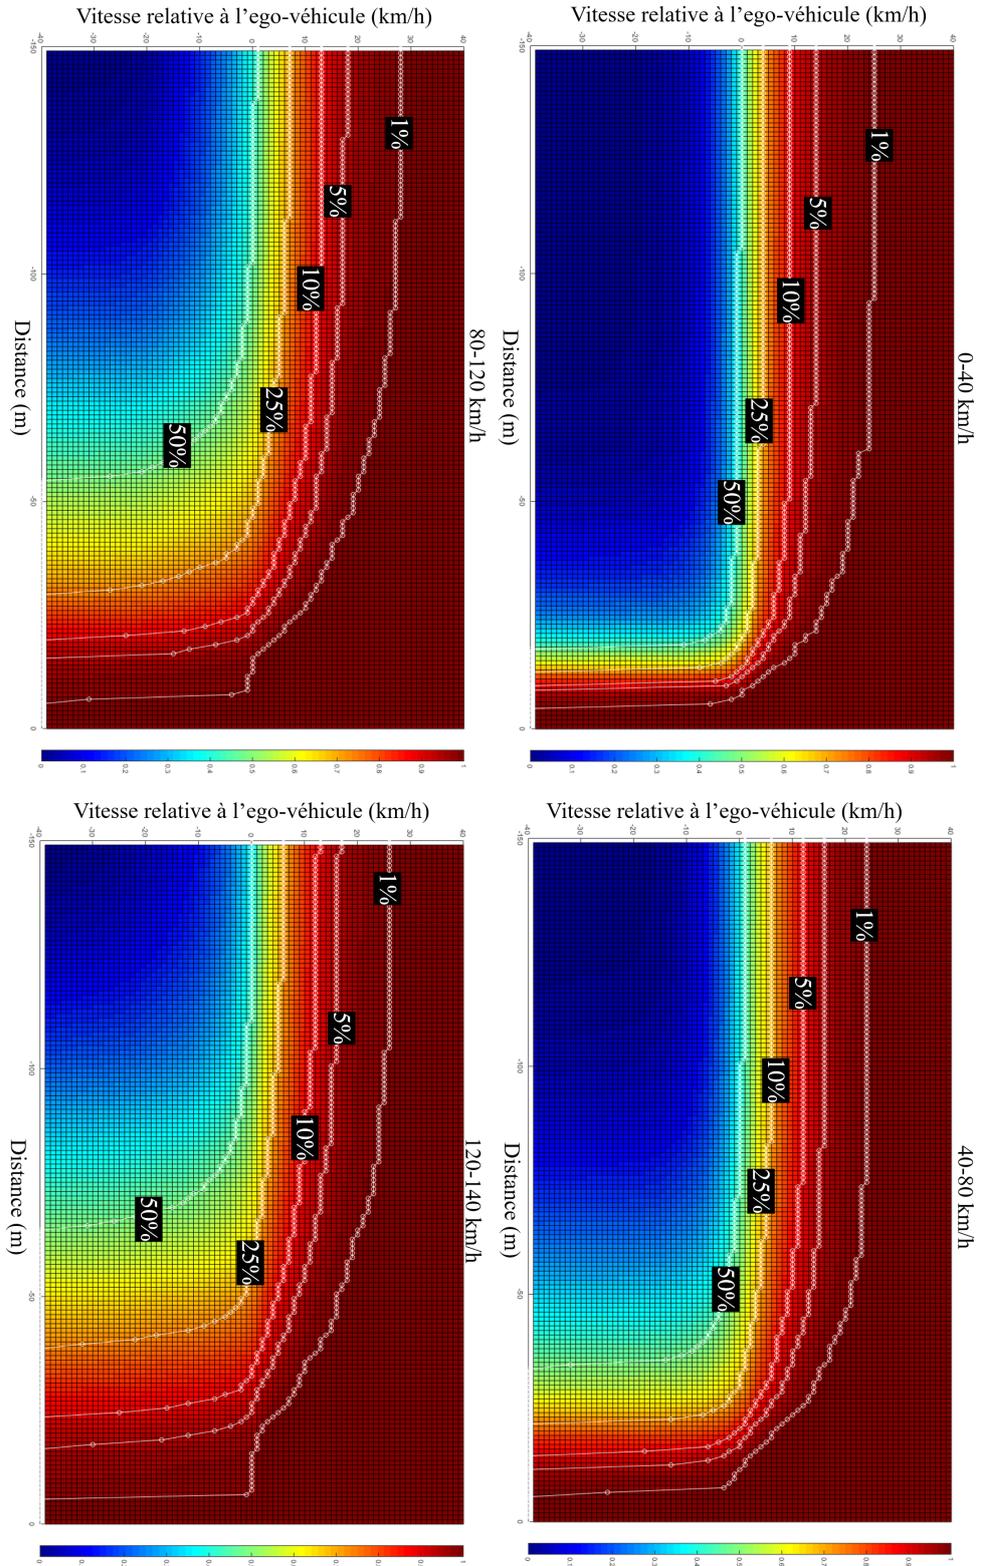


FIGURE 2.16 – Matrice de risque pour le véhicule arrière avec courbes de Centile des manœuvres effectués

$$G = \begin{cases} V_{Leader_cible} - V_{leader_initial} & \text{Si } V_{Leader_cible} < V_{Limite} \\ V_{Limite} - V_{Leader_initial} & \text{Si } V_{Leader_cible} > V_{Limite} \end{cases} \quad (2.4)$$

Avec V_{Leader_cible} est la vitesse du véhicule leader dans la voie cible, $V_{Leader_initial}$ est la vitesse du véhicule avant dans la voie initiale, et V_{Limite} est la limitation de vitesse appliquée à la route actuelle.

Ce paramètre nous permet de mesurer l'intérêt qu'à un véhicule à changer de voie, et le gain potentiel en temps que cela permettrait. Cet indicateur, à l'instar du gain précédemment défini, n'a pas d'unité. Dans l'ensemble des échantillons de la base de données MOOVE ce dernier varie entre 0 et 8 pour la majorité des cas avec quelques rares cas négatifs et au-delà de 8.

Le gain associé au risque défini dans ce chapitre permet d'avoir une vision d'ensemble sur la situation pour prendre une décision sur le changement de voie. Ce qui fait l'objet du chapitre suivant.

2.6 Conclusion

Dans ce chapitre, nous avons présenté en détail la base de données MOOVE et ses différentes caractéristiques. La base de données MOOVE est une source précieuse d'informations sur les manœuvres de changement de voie réalisées par les conducteurs. Elle contient des données sur la vitesse, l'accélération, la position et les actions des conducteurs pendant les manœuvres de changement de voie. Ces données ont été collectées à partir de capteurs installés sur des véhicules réels, permettant ainsi une observation précise des comportements réels des conducteurs. Le projet MOOVE utilise des algorithmes de fusion de données pour obtenir des mesures plus robustes et précises.

Pour extraire les informations de cette base de données, nous avons développé un algorithme qui a permis de filtrer les données pour ne conserver que les manœuvres de changement de voie valides. Cet algorithme a été testé sur un grand nombre d'échantillons de données, ce qui a permis d'obtenir un total de 163.066 échantillons de manœuvre directement exploitable. Ces données nous ont permis

2.6. CONCLUSION

d'étudier le comportement des conducteurs lors des manœuvres de changement de voie et de comprendre ce qui motive ces derniers à adopter ce choix.

Nous avons ensuite présenté les données sous forme d'histogrammes et d'histogrammes bivariants, ce qui a permis de visualiser les résultats de manière claire et concise. Les histogrammes ont montré les tendances générales dans les données, tandis que les histogrammes bivariants ont permis de voir les relations entre différentes variables, comme la vitesse et la distance pendant les manœuvres de changement de voie.

Pour finir, nous avons présenté la méthode d'analyse du risque pour les manœuvres de changement de voie que nous avons développée durant cette thèse. Cette méthode permet d'évaluer le risque associé à chaque manœuvre de changement de voie en utilisant les données collectées dans la base de données MOOVE. Elle est basée sur les comportements observés chez les conducteurs réels et permet de prendre en compte les différents facteurs qui peuvent influencer le risque, comme la vitesse et la distance par rapport aux autres véhicules.

Nous avons également présenté un paramètre appelé "gain" qui permet de mesurer l'intérêt qu'a le véhicule à changer de voie. Ce paramètre est calculé à partir des données de vitesse du véhicule, ainsi que des informations sur la densité de trafic sur la voie cible. Il permet de mesurer l'avantage potentiel qu'un véhicule peut tirer d'une manœuvre de changement de voie.

En combinant ces deux paramètres, la méthode d'analyse du risque et le gain, nous pourrions développer des algorithmes de prise de décision pour les manœuvres de changement de voie. Ces algorithmes sont conçus pour aider les véhicules automatisés à évaluer les risques et les avantages associés à chaque manœuvre de changement de voie, et à prendre les décisions les plus appropriées pour garantir la sécurité de tous les usagers de la route.

Chapitre 3

Algorithmes de prise de décision et validation

Sommaire

3.1	Introduction	66
3.2	Organigramme de prise de décision	66
3.3	Prédiction de trajectoire	70
3.4	Base de données HighD	73
3.5	Extraction des manœuvres dans la base de données	73
3.6	Logique Floue	74
3.7	Arbre de décision	79
3.8	Réseau de neurones artificiels	82
3.9	Forêt d'arbres décisionnels	85
3.10	Validation sur simulateur	87
3.10.1	CARLA	88
3.10.2	Matlab Driving Simulator	90
3.10.3	CarMaker	91
3.10.4	Développement d'un simulateur de conduite	93
3.11	Étude des résultats	95

3.1 Introduction

Après l'évaluation du risque et du gain, l'étape suivante est logiquement la prise de décision. Ce chapitre est consacré au développement d'une méthodologie complète de prise de décision pour les changements de voie, avec en bout de chaîne l'algorithme qui donne la décision finale en se basant sur les indicateurs de gain et de risque et une prédiction de trajectoire. L'algorithme final est interchangeable et nous en avons sélectionné quatre pour comparaison : arbre de décision, forêt aléatoire, réseau de neurones artificiels et logique flou.

3.2 Organigramme de prise de décision

L'objectif principal de ce chapitre est de développer un algorithme de prise de décision pour les manœuvres de changement de voie, basé sur la comparaison de deux variables qui reflètent respectivement le risque pris si le changement de voie est effectué, et le gain qui résulterait du changement de voie. La première étape de l'algorithme de décision consiste à décider de l'instant optimal pour démarrer la manœuvre. La figure 3.1 représente une situation typique pour une manœuvre de changement de voie, avec l'ego-véhicule (rouge), un véhicule de tête dans la même voie et deux véhicules dans la voie cible (véhicule 2 et 3).

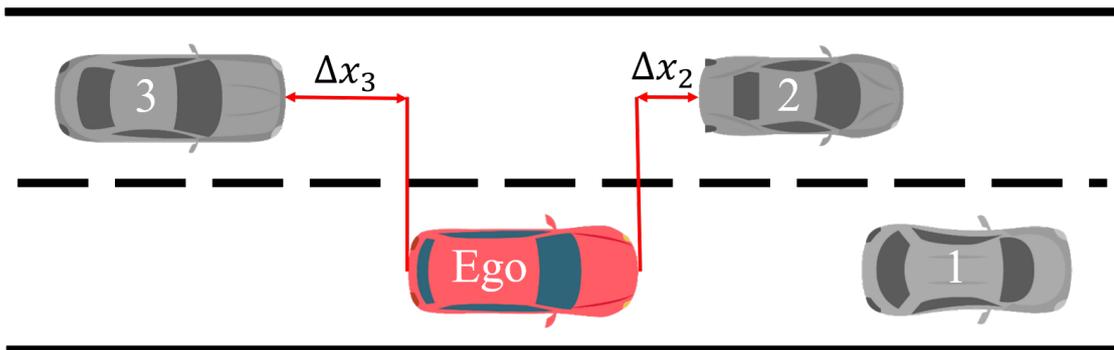


FIGURE 3.1 – Configuration de la route avec les véhicules environnants.

CHAPITRE 3. ALGORITHMES DE PRISE DE DÉCISION ET VALIDATION

Pour chaque véhicule dans la voie cible, un algorithme de prédiction de trajectoire est effectué sur 3 secondes. Au-delà, la fiabilité de la prédiction devient moins précise. Cet algorithme repose sur une approche hybride : une classification des manœuvres avec un réseau de neurones artificiels suivi d'un modèle LSTM (Long short-term memory) pour la prédiction de trajectoire [BBJM20]. Il est détaillé dans la section suivante. Avec la trajectoire prédite, nous pouvons calculer le risque associé aux véhicules à chaque pas de temps, et ainsi, tracer l'évolution du risque pour les deux véhicules. Le risque associé au véhicule avant (véhicule 2) va diminuer (à mesure qu'il s'éloigne), tandis que celui associé à l'arrière (véhicule 3) va augmenter (à mesure qu'il se rapproche) (figure 3.2). Le risque associé à l'ensemble de la manœuvre est le maximum entre le risque du véhicule avant et celui de l'arrière à chaque pas de temps, et on considère le moment où les deux courbes se croisent comme étant le moment optimal pour démarrer la manœuvre et changer de voie, car il est le minimum du risque total (figure 3.3).

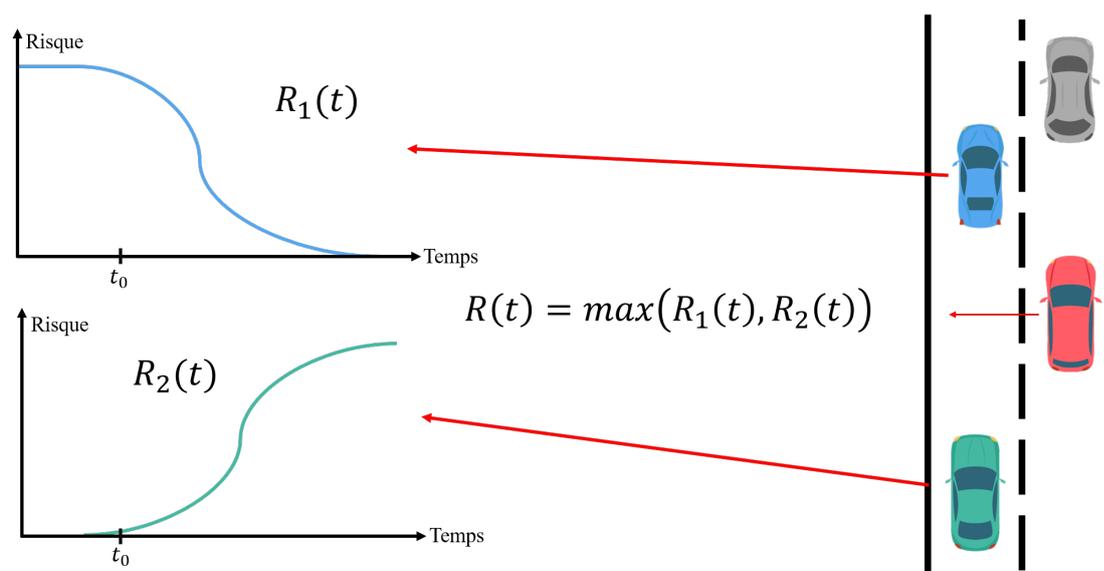


FIGURE 3.2 – Évolution du risque associé aux deux véhicules sur la voie cible.

Pour valider cette hypothèse, l'algorithme a été testé sur des échantillons de manœuvre de changement de voie extraits de la base de données MOOVE. Une prédiction de trajectoire a été effectuée entre 6 secondes et 3 secondes avant le franchissement de voie pour simuler la décision en temps réel et calculer le risque

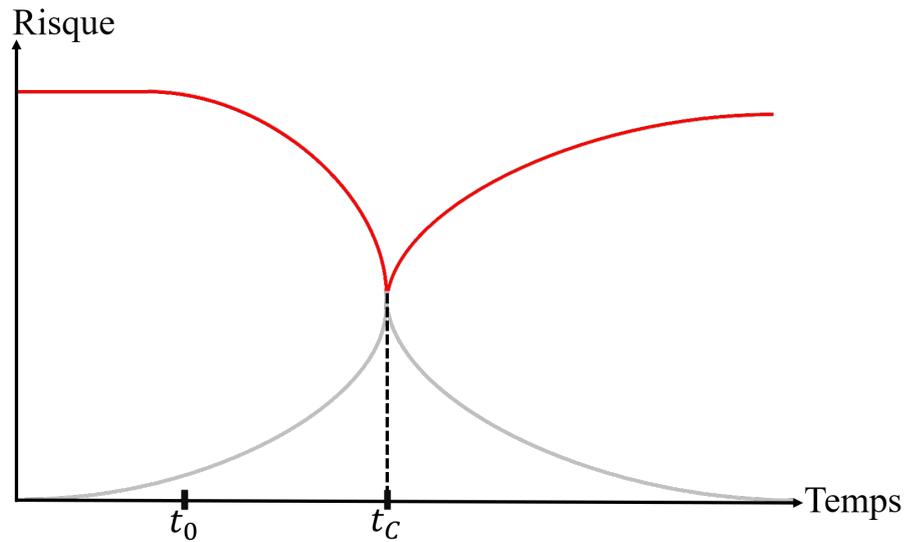


FIGURE 3.3 – Risque associé à la manœuvre (combinaison entre le risque du véhicule 2 et 3). t_c étant le meilleur instant pour changer de voie.

en fonction de la trajectoire prédite. Pour des situations comme celle décrite précédemment (figure 3.1), nous obtenons un modèle comme décrit dans la figure 3.4. Le changement de voie de l'ego-véhicule représente la distance latérale entre le centre du pare-chocs avant et le marquage de la voie de droite. La discontinuité au milieu de la courbe correspond au moment du franchissement de voie. La première est l'évolution des risques. Comme on peut le voir, l'instant de croisement des deux courbes est proche de l'instant où le conducteur entame la manœuvre. Dans les échantillons que nous avons testés, il est compris entre 0,5 et 1,5 seconde.

Finalement, la dernière étape consiste à décider si le changement de voie doit être effectué ou non en fonction du gain et du risque à l'instant optimal (figure 3.5). Pour réaliser cette tâche, nous avons développé et comparé quatre algorithmes de décision : arbre de décision, forêt aléatoire, réseau de neurones artificiels et logique floue.

Il est important de considérer la sécurité comme une priorité absolue dans les algorithmes de changement de voie. L'intégration de mesures de sécurité pour gérer les événements imprévus est un aspect critique de l'algorithme. Dans le cas où un événement ou si un véhicule à un comportement inattendu alors que la

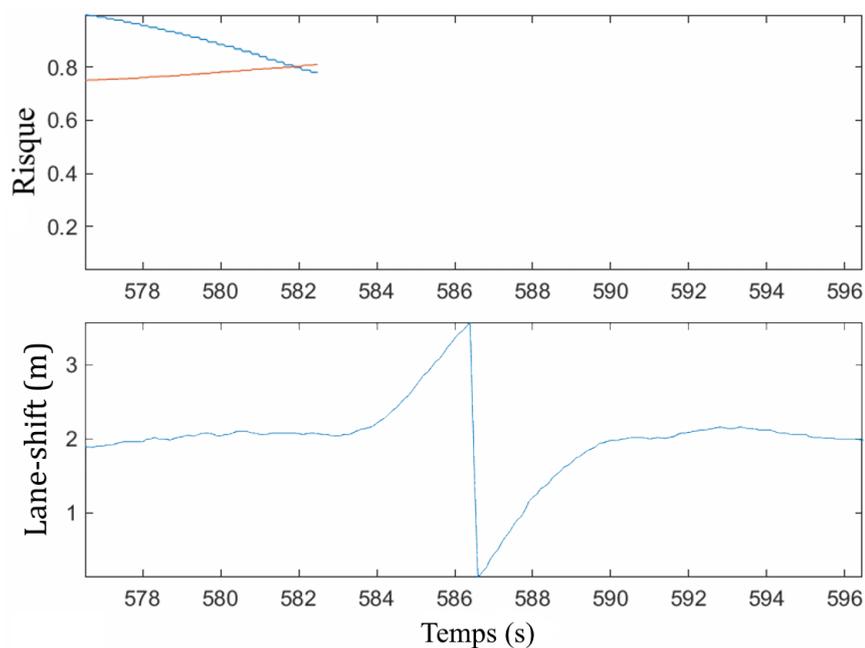


FIGURE 3.4 – Évolution du risque pour le véhicule avant (bleu) et le véhicule arrière (rouge) et le Lane-shift de l'ego-véhicule.

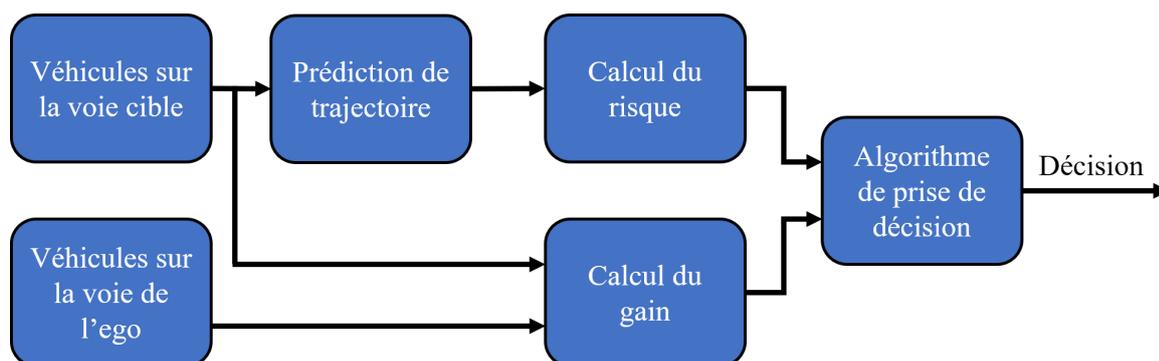


FIGURE 3.5 – Schéma de l'algorithme de prise de décision.

manœuvre a été engagé. Par exemple, si le véhicule leader de la voie cible freine durant la manœuvre. A cet effet, nous avons développé deux dispositifs de sécurité, l'algorithme complet est décrit dans la figure 3.6 :

- En amont de la prise de décision, une première prediction des intentions des 4 véhicules cibles les plus pertinents (leader et suiveur sur la voie initiale et la voie cible) est réalisé, si un changement de voie est prédit pour l'un des 4 véhicules, la manœuvre est mise en attente.
- Une surveillance des niveaux de risque des véhicules sur la voie cible avec abandon de la manœuvre si le risque dépasse la valeur lors de la prise de decision. A noter que si le risque dépasse le seuil, la manœuvre sera abandonnée que si le véhicule ego est toujours sur sa voie initiale.

En fin de compte, ces mesures de sécurité permettent de garantir que la manœuvre de changement de voie est exécutée de manière sûre et responsable, minimisant le risque d'accidents ou de situations dangereuses sur la route.

3.3 Prédiction de trajectoire

Pour la prédiction de trajectoire nous utilisons un modèle hybride basé sur une classification des manoeuvre qui repose sur les réseaux de neurones qui vise à prédire les changements de voie des véhicules tel que présenté par Benterki et al. [BBJM20] (figure 3.7). Les données utilisées pour entraîner le modèle proviennent de la base de données NGSIM, qui comprend des manoeuvres de changement de voie à droite, de changement de voie à gauche et de maintien de voie. Les changements de voie ont été extraits et étiquetés automatiquement à l'aide de la caractéristique "Lane ID" de la base de données. Pour chaque manœuvre, une série temporelle de 50 échantillons 5s avant et 50 échantillons 5s après le dépassement du marquage de la nouvelle voie. A partir de cette base de données, 380 RLC (Right Lane Change), 420 LLC (Left Lane Change) et plus de 1000 LK (Lane Keeping) ont été extraits.

L'architecture du modèle de classification des manoeuvre utilisé est un réseau de neurones profond. Les données d'apprentissages sont filtrées à l'aide d'un filtre Savitzky-Golay de premier ordre pour filtrer le bruit de mesure et les erreurs d'estimation, puis normalisées entre -2 et $+2$ avant d'être utilisées en entrée pour le modèle. La base de données est divisée en base de données d'apprentissage et de

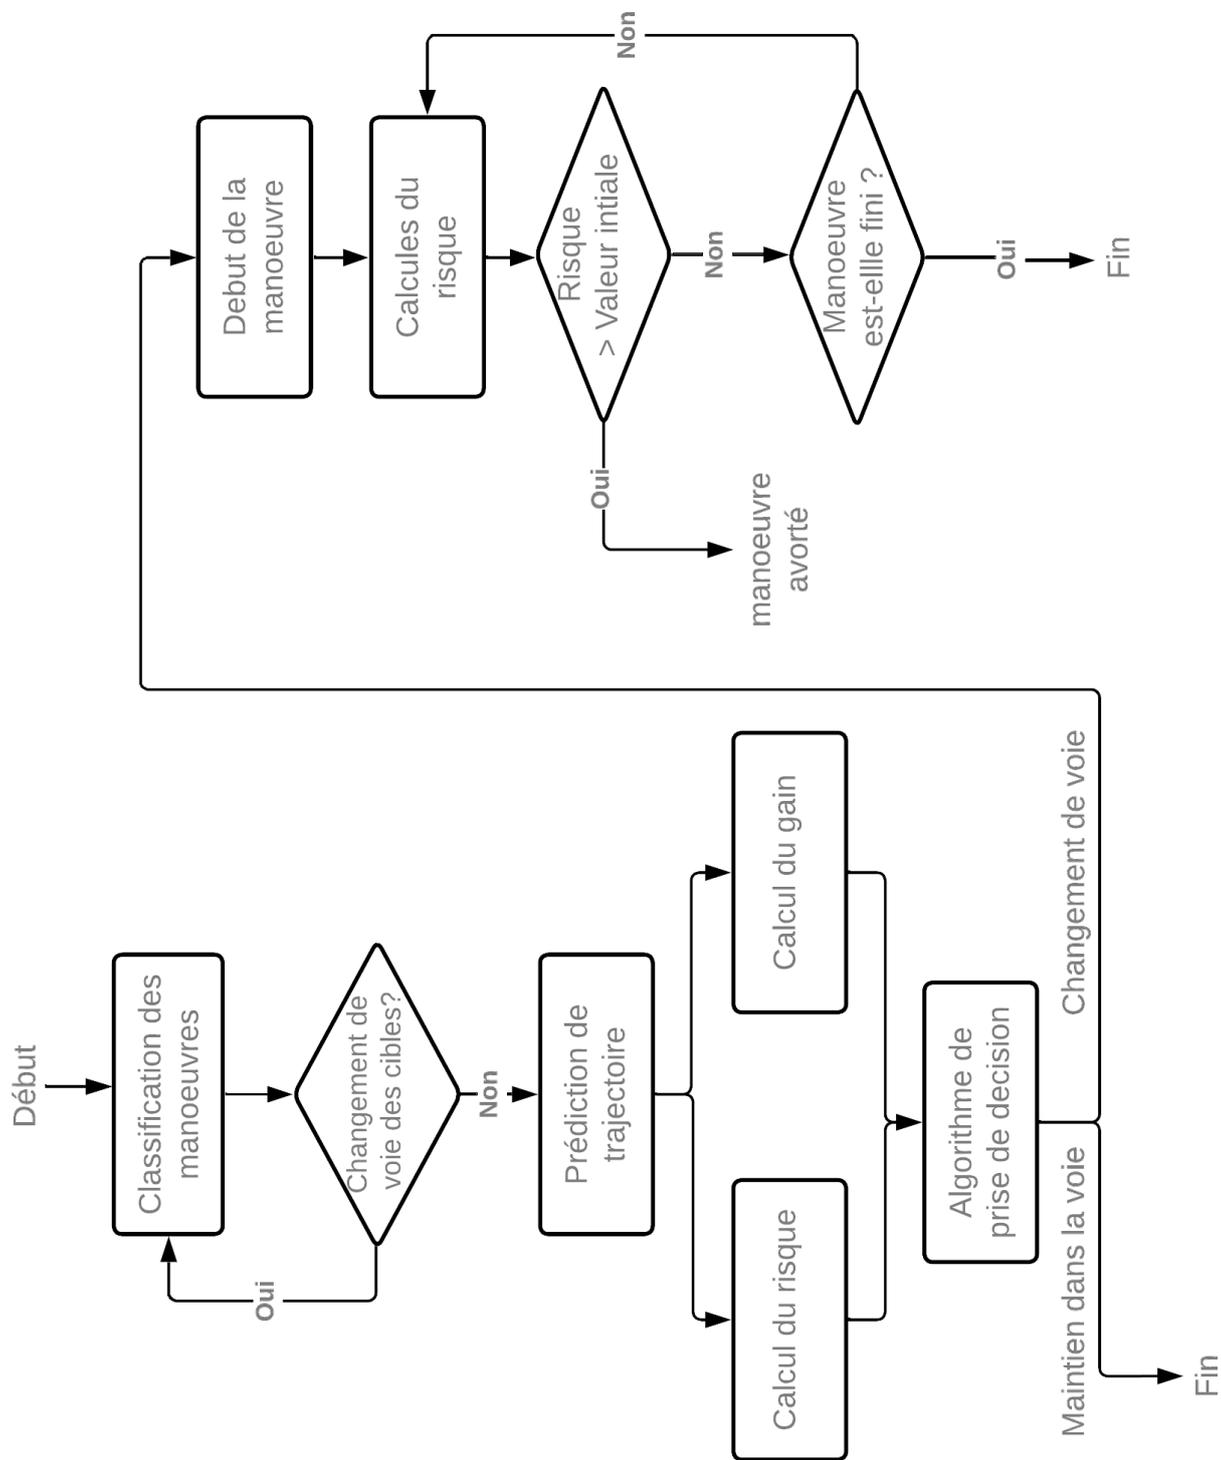


FIGURE 3.6 – Algorithme de prise de décision.

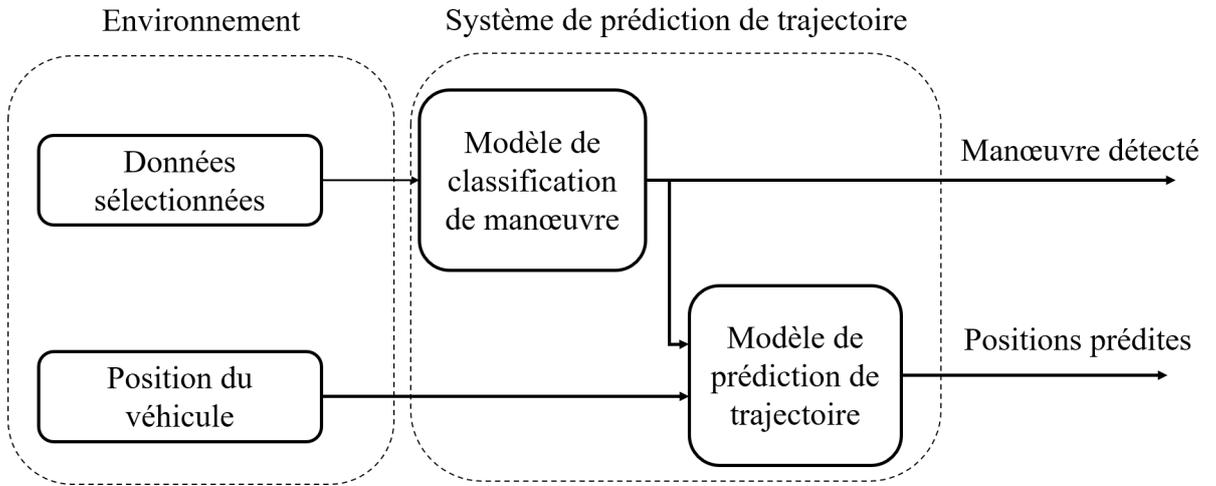


FIGURE 3.7 – Schéma du modèle de prédiction de trajectoire.

test, et quatre attributs (données d’entrée) sont extraites des données NGSIM : l’angle de braquage, le taux de braquage, la vitesse latérale et l’accélération latérale.

La deuxième étape est de prédire la trajectoire sur base de la classification de manœuvres. Le modèle de prédiction de trajectoires utilise une architecture profonde de réseau de neurones récurrent, avec une couche d’entrée de l’historique des positions passées du véhicule et de la manœuvre prédite, quatre couches cachées basées sur LSTM (Long-Short Terme Memory) et une couche de sortie qui fournit la position prédite. Cette architecture spécifique a été conçue et entraînée en utilisant les fonctions de la bibliothèque Keras et les réseaux de neurones récurrents optimisés de cuDNN de Nvidia.

Les résultats de la classification montrent une précision de 86,2% pour la détection correcte des manœuvres. Les séquences d’entrée plus longues donnent de meilleurs résultats de classification, avec une précision de 97,49% pour les séquences de 6s. Les résultats de prédiction montrent que la précision du modèle augmente avec la longueur de la séquence d’entrée et diminue avec l’augmentation de l’horizon de prédiction. Les erreurs pour les positions latérales et longitudinales sont faibles pour les prédictions à court terme mais augmentent de manière exponentielle avec l’augmentation de l’horizon temporel.

La précision de la prédiction est la plus élevée pour une séquence d'entrée de 6s et un horizon de prédiction de 5s, avec des erreurs d'environ 0,092m pour la position latérale et 0,112m pour la position longitudinale.

3.4 Base de données HighD

Nous avons choisi HighD qui est un jeu de données de trajectoires naturalistes de véhicules enregistrées sur les autoroutes allemandes à l'aide d'un drone. Les limitations typiques des méthodes de collecte de données de trafic établies telles que les occlusions sont surmontées par la perspective aérienne. Le trafic a été enregistré à six endroits différents et comprend plus de 110500 de véhicules. La trajectoire de chaque véhicule, y compris le type de véhicule, la taille et les manœuvres, est automatiquement extraite. En utilisant des algorithmes de vision par ordinateur de pointe, l'erreur de positionnement est généralement inférieur à dix centimètres. Bien que l'ensemble de données ait été créé pour la validation de la sécurité des véhicules hautement automatisés, il convient également à de nombreuses autres tâches telles que l'analyse des modèles de trafic ou le paramétrage des modèles de conducteur.

3.5 Extraction des manœuvres dans la base de données

L'extraction des échantillons positifs (échantillons correspondant aux changements de voie) est une tâche assez aisée puisque les voies sur lesquelles se trouvent les véhicules sont labellisées sur la base de données, il suffit de scanner l'ensemble des enregistrements à la recherche des instants où la valeur correspondant à la voie du véhicule change.

- | | |
|------------------|-------------------------|
| — Frame | — Largeur du véhicule |
| — ID du véhicule | — Longueur du véhicule |
| — Position X | — Numéro de la voie |
| — Position Y | — Vitesse selon l'axe X |

- Vitesse selon l'axe Y
- Accélération X
- Accélération Y
- Limitation de vitesse
- Direction

Cependant, pour les échantillons négatifs, la tâche est moins triviale. En effet, il n'est pas aisé de distinguer les instants pendant lesquels le conducteur n'a pas eu besoin de changer de voie, des instants pendant lesquels le conducteur a voulu changer de voie, mais ne l'a pas fait en raison d'un risque élevé par rapport au gain apporté par le changement de voie. Nous recherchons donc des situations où un véhicule présente un gain élevé. Le protocole suivant est défini : nous scannons tous les enregistrements, véhicule par véhicule, avec un pas de 10 secondes, et à chaque pas, nous calculons le gain et le risque, si le gain dépasse la valeur critique qui est définie à 2, et le risque dépasse 0,5, avec aucun changement de voie effectué dans les 10 secondes, nous considérons l'échantillon comme négatif. Sur l'ensemble de la base de données HighD, nous avons obtenu 12.218 d'échantillons positifs et 10.973 de négatifs.

3.6 Logique Floue

La logique floue est un concept mathématique qui a été introduit par Lotfi Zadeh [Zad65] en 1965 pour résoudre les problèmes d'incertitude et d'imprécision dans les systèmes complexes. Cette approche diffère des méthodes traditionnelles basées sur la logique binaire, car elle utilise des ensembles flous pour représenter les connaissances et les incertitudes.

Les ensembles flous sont des ensembles de valeurs où les membres peuvent être des éléments partiellement appartenant à l'ensemble. Par exemple, une tasse de café peut être considérée comme partiellement remplie, plutôt que complètement vide ou complètement pleine. Les membres d'un ensemble flou sont assignés une valeur de degré d'appartenance qui représente leur pertinence relative à l'ensemble.

En utilisant des ensembles flous, la logique floue peut modéliser des relations complexes entre les entrées et les sorties d'un système. Les relations sont décrites à l'aide de règles floues qui peuvent être utilisées pour déterminer la sortie d'un système en fonction de ses entrées. Les opérateurs flous, tels que l'intersection et

CHAPITRE 3. ALGORITHMES DE PRISE DE DÉCISION ET VALIDATION

l'union, peuvent être utilisés pour manipuler les ensembles flous et les règles floues pour résoudre des problèmes complexes. La logique floue peut être utilisée pour traiter de l'incertitude dans des domaines tels que la reconnaissance de formes, la commande et la planification, la classification, l'optimisation et la prise de décision. Parmi les quelques inconvénients de la logique floue, nous pouvons citer :

- Précision : la logique floue peut entraîner une perte de précision dans les résultats, car elle utilise des valeurs floues plutôt que des valeurs précises pour représenter les entrées et les sorties.
- Définition des règles : la définition des règles floues peut être difficile et dépendante de la subjectivité, car elle nécessite une évaluation humaine pour déterminer les niveaux de degré d'appartenance.
- Performances : la logique floue peut être plus lente que les méthodes traditionnelles en raison de la complexité de la manipulation des ensembles flous et des règles floues.

Malgré ces inconvénients, la logique floue reste une méthode très utile pour traiter de l'incertitude et de l'imprécision dans les systèmes complexes, en particulier dans des domaines tels que la reconnaissance de formes, la commande et la planification, la classification, l'optimisation et la prise de décision. La méthode consiste en 3 étapes (figure 3.8) :

- Fuzzifier toutes les valeurs d'entrée dans des fonctions d'appartenance floues.
- Exécuter toutes les règles applicables dans la base de règles pour calculer les fonctions de sortie floues.
- Défuzzifier les fonctions de sortie floues pour obtenir les valeurs de sortie.

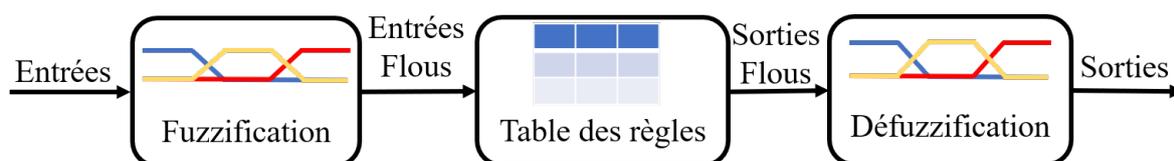


FIGURE 3.8 – Diagramme représentatif de l'algorithme de logique flou

La fuzzification est le processus d'attribution de l'entrée d'un système à des ensembles flous avec un certain degré d'appartenance. Ce degré d'appartenance peut être n'importe où dans l'intervalle $[0,1]$.

3.6. LOGIQUE FLOUE

L'algorithme de logique floue est utilisé pour prendre la décision de changement de voie, avec deux entrées : le risque au moment optimal précédemment défini, et le gain G. Pour la première version, nous avons défini les fonctions d'appartenance comme le montre les figures 3.9 et 3.10 pour la fuzzification.

Gain \ Risque	Faible	Moyen	Élevé
Faible	NON	NON	NON
Moyen	OUI	OUI	NON
Élevé	OUI	OUI	OUI

TABLE 3.1 – Tableau des règles du modèle de logique floue

La fonction d'appartenance du gain (G) est définie entre -8 et 8 , car après avoir calculé ce paramètre sur tous les échantillons du jeu de données MOOVE, il en ressort que le gain est principalement réparti entre -2 et 8 avec quelques échantillons sous -2 . Lorsque la valeur est hors de l'intervalle, elle est forcée à 8 si elle est supérieure et -8 si elle est inférieure (figure 3.9). Les règles sont définies dans le tableau 3.1, et la figure 3.11 représente la fonction d'appartenance de défuzzification. La surface de réponse est représentée par la figure 3.12. Finalement, nous considérons qu'une sortie supérieure à $0,5$ est une décision positive.

Ce modèle a été testé sur les échantillons extraits depuis la base de données HighD et nous avons obtenu le résultat résumé dans le tableau 3.2. Pour ce premier modèle, la transition entre une réponse négative et positive est progressive. Cela résulte d'une zone où le modèle peut vaciller ou mal fonctionner, typiquement pour des valeurs autour de $0,5$ pour le risque et 4 pour le gain. De plus, il donne une décision positive dans le cas où à la fois le risque et le gain sont élevés. Ce comportement peut être dangereux. Pour surmonter ces problèmes et augmenter la proportion de décision positive, nous avons testé un second modèle. Une quatrième fonction d'appartenance pour l'entrée de risque a été introduite, qui est "très élevée" (figure 3.13) dans laquelle la réponse doit être négative, quelle que soit la valeur du gain. Nous avons également resserré l'écart entre les fonctions d'appartenance pour accentuer la pente de transition. Les règles ont été modifiées en conséquence (voir tableau 3.3). La surface de réponse pour la deuxième version du modèle est représentée sur la figure 3.14.

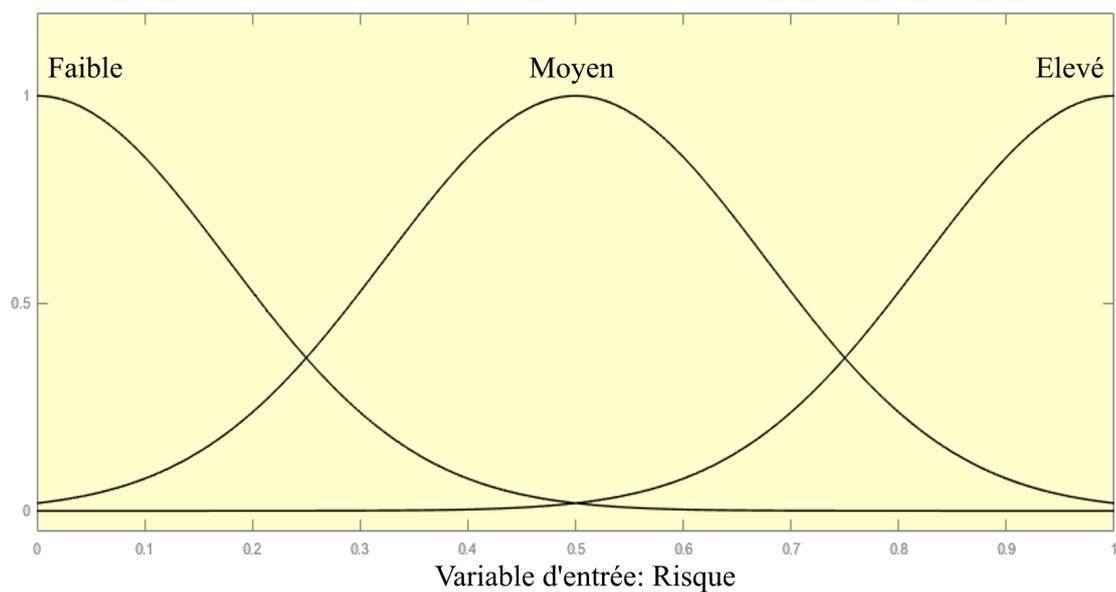


FIGURE 3.9 – Fonctions d'appartenance du risque.

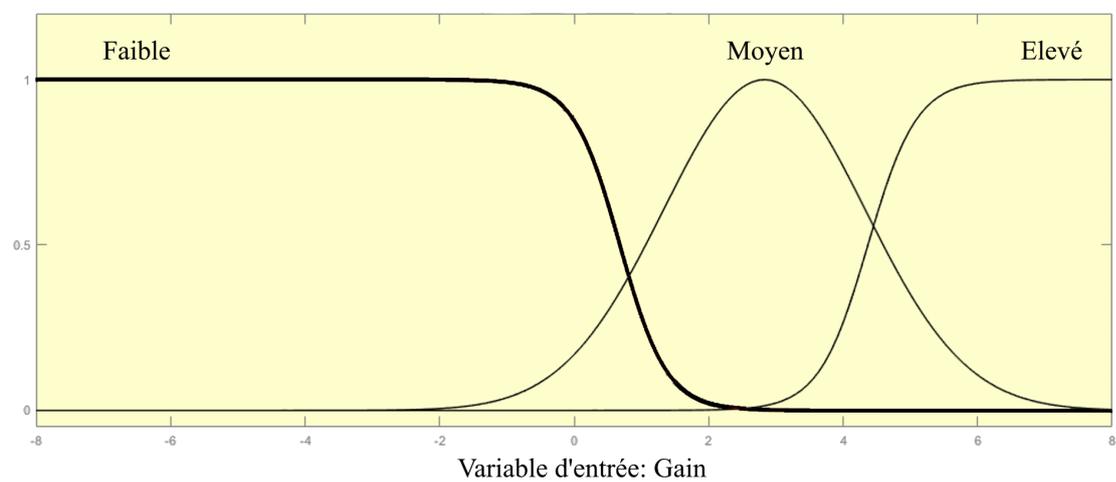


FIGURE 3.10 – Fonctions d'appartenance du gain.

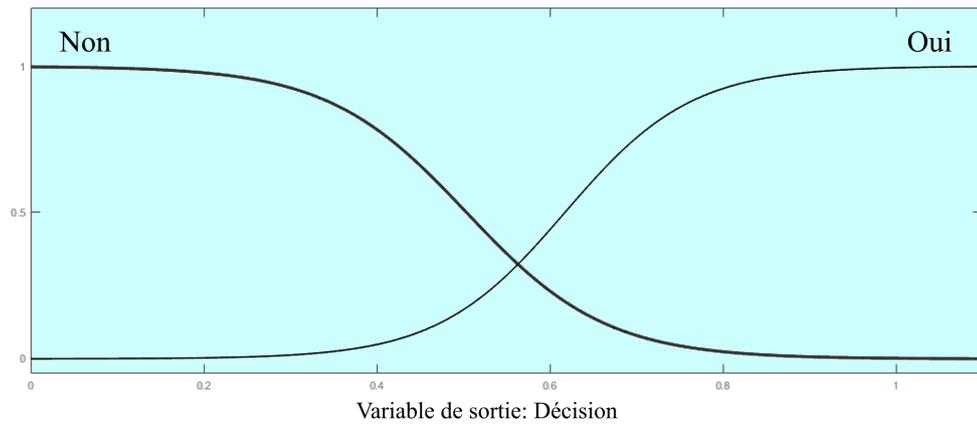


FIGURE 3.11 – Fonctions d'appartenance de défuzzification.

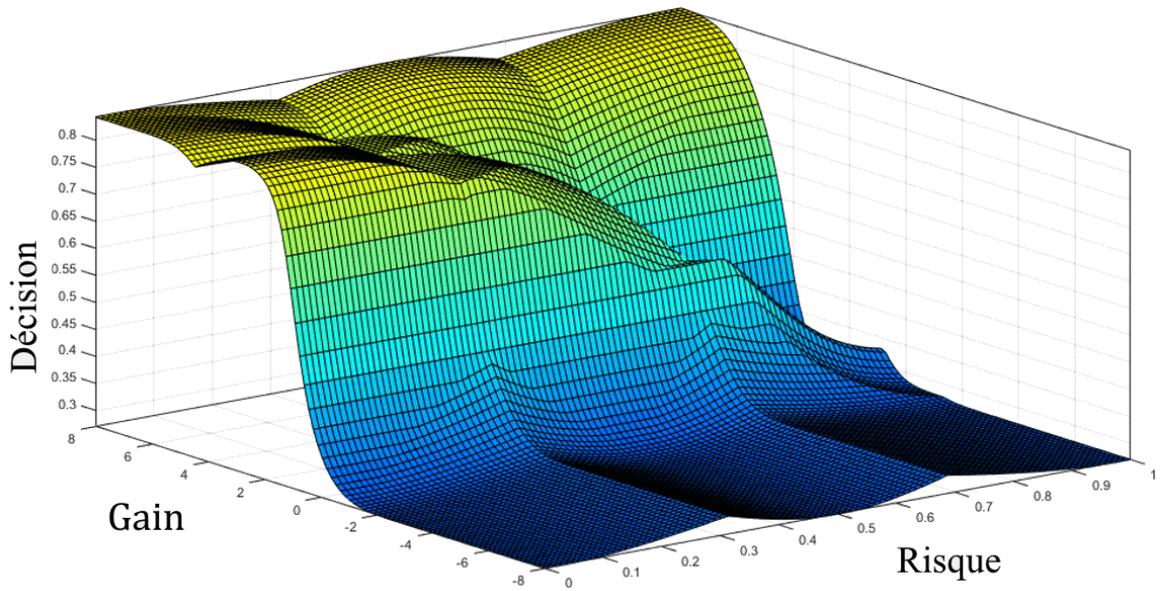


FIGURE 3.12 – Surface de sortie du modèle de logique floue.

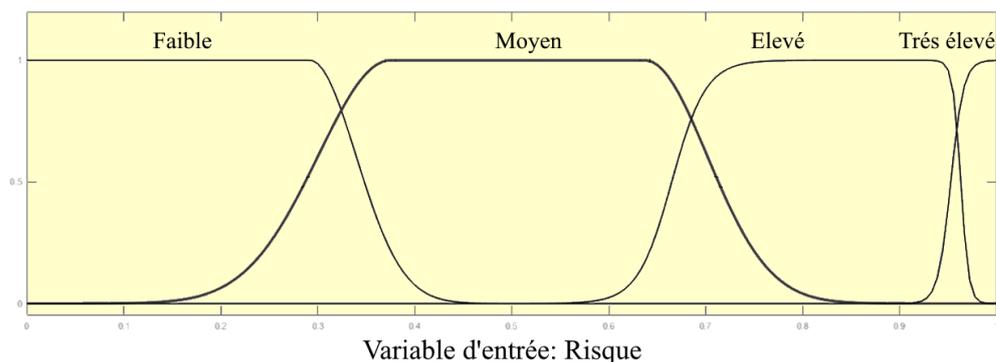


FIGURE 3.13 – Fonctions d’appartenance de fuzzification modifiées.

Avec cette deuxième version nous avons obtenu les résultats du tableau 3.4

		logique flou	
		Positif	Négatif
Décision réel	Positif	71,02 %	28,98 %
	Négatif	22,04 %	77,96 %

TABLE 3.2 – Matrice de confusion pour la logique floue (modèle modifié).

Gain \ Risque	Faible	Moyen	Élevé	Très élevé
	Faible	NON	NON	NON
Moyen	OUI	OUI	NON	NON
Élevé	OUI	OUI	OUI	NON

TABLE 3.3 – Tableau des règles du modèle de logique floue modifié

3.7 Arbre de décision

Les arbres de décision sont un algorithme populaire en apprentissage automatique utilisé pour résoudre des problèmes de classification et de régression. Ils peuvent être considérés comme un modèle graphique divisant les données en

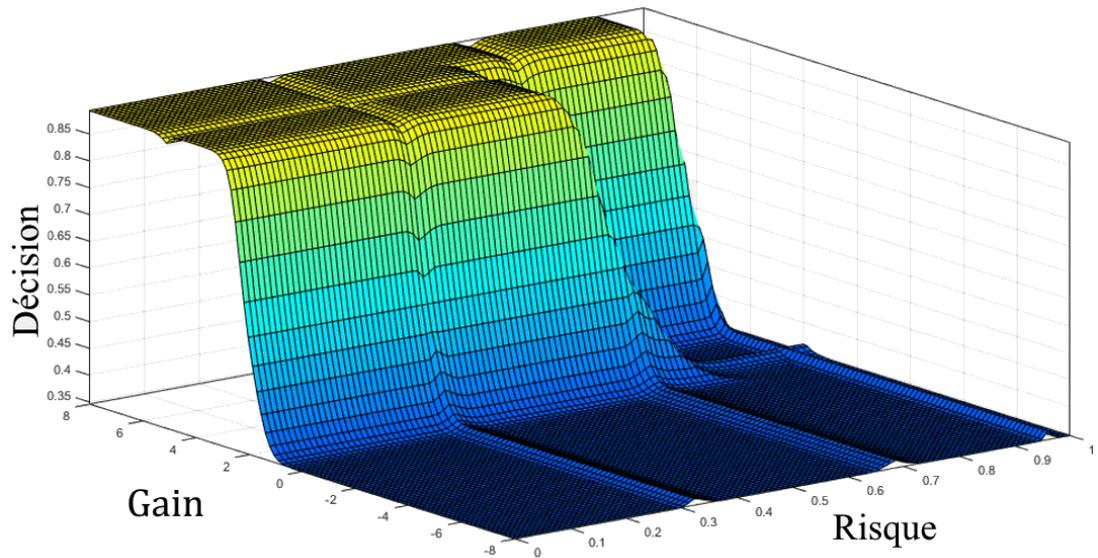


FIGURE 3.14 – Surface de sortie pour le modèle de logique floue modifié.

branches successives en fonction de tests logiques sur les caractéristiques d'entrée. Chaque nœud de la branche représente un test sur une caractéristique particulière, tandis que les feuilles représentent les prédictions finales. Les arbres de décision sont souvent utilisés pour leur simplicité et leur capacité à prendre en compte des interactions complexes entre les caractéristiques. Ils peuvent également être facilement visualisés et interprétés, ce qui les rend utiles pour expliquer les décisions prises par des algorithmes complexes. Lors de la construction d'un arbre de décision, l'algorithme commence par sélectionner la caractéristique la plus informative pour séparer les données en deux sous-ensembles. Ce processus est répété pour chaque sous-ensemble jusqu'à ce que les feuilles ne contiennent plus qu'une classe ou une valeur unique. Un arbre de décision commence généralement par un seul nœud, qui se ramifie en résultats possibles (figure 3.15). Chacun de ces résultats conduit à des nœuds supplémentaires, qui se ramifient vers d'autres possibilités. Cela lui donne une forme arborescente. Les nœuds représentent une équation logique qui compare une ou plusieurs entrées à des seuils qui seront appris par apprentissage. Les arbres de décision peuvent être utilisés seuls ou en combinaison avec d'autres algorithmes pour améliorer la précision. Les algorithmes de forêt aléatoire utilisent

CHAPITRE 3. ALGORITHMES DE PRISE DE DÉCISION ET VALIDATION

un grand nombre d'arbres de décision pour améliorer la précision et réduire la variance. Cependant, les arbres de décision ont également des inconvénients. L'un d'entre eux est qu'ils sont souvent sensibles aux fluctuations dans les données, ce qui peut entraîner des erreurs importantes dans les prédictions. De plus, ils peuvent être instables, ce qui signifie qu'une modification mineure dans les données peut entraîner une modification significative de l'arbre et de ses prédictions. Enfin, les arbres de décision peuvent facilement surapprendre les données d'entraînement, ce qui peut entraîner une performance inférieure sur les données de test.

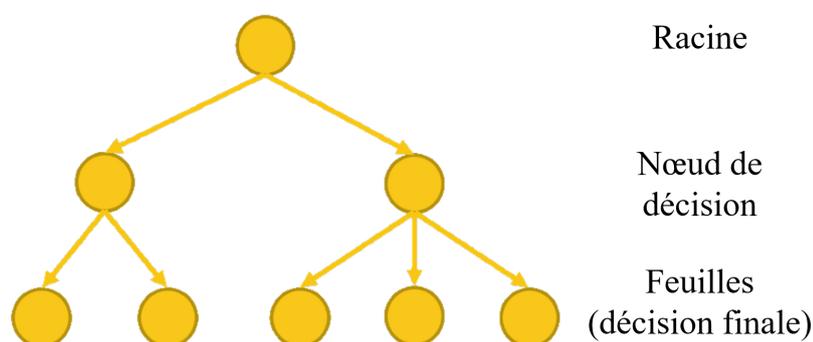


FIGURE 3.15 – Diagramme d'un arbre de décision

Pour développer cet algorithme, nous avons utilisé les outils implémentés sous MATLAB (Statistics and Machine Learning Toolbox), et nous avons scindé la base de données en deux (70% - 30%) pour effectuer une validation croisée. Il en résulte un arbre à 28 niveaux (figure 3.16), et la validation sur la base de données HighD est résumée sur la table 3.4.

		Arbre de décision	
		Positif	Négatif
Décision réel	Positif	75,53 %	24,47 %
	Négatif	21,64 %	78,36 %

TABLE 3.4 – Matrice de confusion pour l'arbre de décision.

Du tableau, nous pouvons voir que l'algorithme a un comportement cohérent

par rapport au comportement humain relevé sur la base de données avec un taux de vrais positifs et vrais négatifs de 75.53 et 78.36 respectivement. Ce résultat est supérieur comparé à la logique floue, ce qui est normal compte tenu du fait que l'arbre de décision ait été développé avec un algorithme d'apprentissage.

3.8 Réseau de neurones artificiels

Les réseaux de neurones artificiels (RNA) ou Artificial neural network (ANN) sont des algorithmes de traitement du signal largement utilisés dans l'apprentissage automatique pour la reconnaissance d'images, la génération de textes, la traduction automatique, etc. Ils fonctionnent en simulant le fonctionnement du système nerveux dans le cerveau humain, en connectant des nœuds appelés "neurones" pour transmettre des informations. Il peut prendre différentes formes selon le type des données qu'il traite et selon leur complexité et la méthode de traitement des données. Certains types de neurones étant plus adaptés à certaines tâches.

Les RNA sont formés en utilisant des données d'entraînement pour ajuster les poids des connexions entre les neurones. Ce processus d'entraînement permet d'améliorer les performances du modèle en minimisant l'erreur entre les prédictions du modèle et les vraies réponses. Après l'entraînement, le modèle peut être utilisé pour faire des prédictions sur de nouvelles données.

Les neurones sont généralement organisés en plusieurs couches (figure 3.17). Les neurones d'une couche se connectent aux neurones des couches précédentes et suivantes. La couche qui reçoit les données externes est la couche d'entrée. La couche qui produit le résultat final est la couche de sortie. Entre eux se trouvent une ou plusieurs couches cachées.

Les RNA sont souvent utilisés pour les tâches de classification, où ils prédisent une classe ou une catégorie pour un exemple donné. Les modèles de classification sont souvent utilisés pour les tâches telles que la reconnaissance d'images, la reconnaissance de la parole, etc. Les RNA peuvent également être utilisés pour les tâches de régression, où ils prédisent une valeur numérique continue.

Les RNA ont de nombreux avantages par rapport aux autres algorithmes d'apprentissage automatique. Ils peuvent gérer des données complexes et non structurées, telles que les images et les sons, et peuvent capturer des relations complexes

CHAPITRE 3. ALGORITHMES DE PRISE DE DÉCISION ET VALIDATION

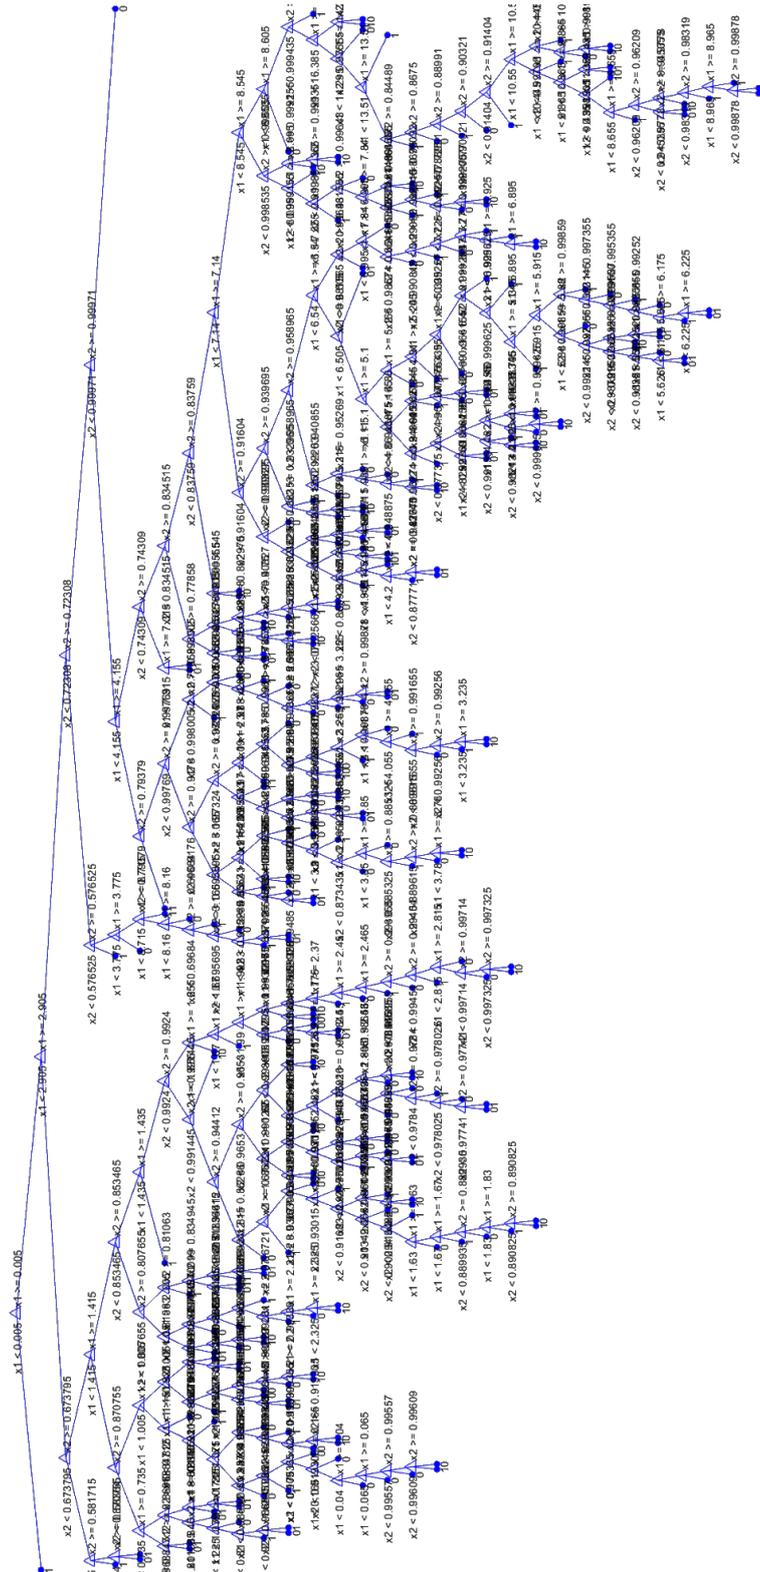


FIGURE 3.16 – Arbre de décision résultant de l'apprentissage.

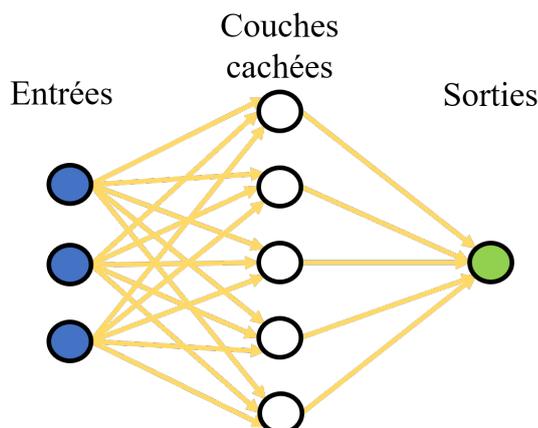


FIGURE 3.17 – Diagramme d'un réseau de neurones perceptron multicouches

entre les entrées et les sorties. De plus, les RNA peuvent être utilisés pour la génération de nouveaux contenus, tels que les images et les textes, en utilisant la technique de génération par modèle.

Malgré leurs nombreux avantages, les RNA ont également quelques défauts. Tout d'abord, ils nécessitent souvent beaucoup de données pour fonctionner correctement et peuvent être très longs à entraîner. De plus, les RNA peuvent être sujets à des problèmes d'overfitting, où le modèle se surapprend aux données d'entraînement et ne fonctionne pas bien sur de nouvelles données. Il est donc important de disposer d'un ensemble de données de validation pour évaluer les performances du modèle pendant l'entraînement. En outre, les RNA peuvent manquer de transparence, ce qui peut rendre difficile de comprendre les décisions prises par le modèle et de déterminer la façon dont il arrive à ses prédictions.

Dans notre cas, nous l'avons utilisé comme un algorithme de décision qui prend le risque et le gain en entrée et donne une décision binaire en sortie. Le réseau sélectionné comporte trois couches, avec 5 neurones dans les deux premières couches, et deux dans la dernière, et la fonction d'activation des neurones est "softmax". Les résultats obtenus sont compilés dans le tableau 3.5.

Nous avons testé plusieurs architectures et paramètres pour le réseau et avons conclu qu'il n'est pas nécessaire d'avoir plus de couches cachées et neurones par couche, car cela n'améliore pas les résultats.

		ANN	
		Positif	Négatif
Décision réel	Positif	75,84 %	24,16 %
	Négatif	21,50 %	78,50 %

TABLE 3.5 – Matrice de confusion pour le réseau de neurones artificiels.

Les taux de vrais positifs et vrais négatifs sont très proche des taux obtenus avec l'arbre de décision, la petite différence est négligeable. Cela nous amène à penser qu'il est difficile d'obtenir de meilleurs résultats avec un seul learner. Une piste envisageable pour améliorer le résultat est d'utiliser des modèles multi-learner tel que la forêt d'arbres décisionnels (Random Forest).

3.9 Forêt d'arbres décisionnels

Les forêt d'arbres décisionnels ou forêts aléatoires sont un type d'algorithme d'apprentissage automatique développée pour résoudre les problèmes de classification et de régression. Ils sont considérés comme l'un des algorithmes les plus performants dans ce domaine en raison de leur robustesse aux données bruitées et de leur capacité à gérer les variables numériques et catégoriques. Les forêts aléatoires sont basées sur l'idée de construire un grand nombre d'arbres de décision indépendants, appelés "arbres d'ensemble". Chaque arbre est formé en sélectionnant aléatoirement un sous-ensemble des données d'entraînement et en choisissant aléatoirement un sous-ensemble des caractéristiques pour construire l'arbre. Le résultat final est la moyenne des prédictions de chaque arbre, ou peut également être un algorithme de vote, ce qui permet d'obtenir une meilleure prédiction que ce que pourrait offrir un seul arbre (figure 3.18). Les forêts aléatoires peuvent être utilisées pour mesurer l'importance des caractéristiques en comparant les performances de prédiction avec et sans la caractéristique spécifique. Cela permet aux utilisateurs de mieux comprendre les relations entre les caractéristiques et la variable cible, ce qui peut être très utile pour la prise de décision. De plus, les forêts aléatoires sont également considérées comme étant relativement peu sensibles aux valeurs

3.9. FORÊT D'ARBRES DÉCISIONNELS

aberrantes, car elles utilisent la moyenne des prédictions de plusieurs arbres pour faire une prédiction, ce qui réduit l'impact des données aberrantes. Cependant, les forêts aléatoires ont également des défauts. L'un des plus importants est la complexité accrue par rapport aux arbres de décision simples, ce qui peut entraîner une complexité accrue. De plus, leur interprétation peut être difficile en raison de la complexité de l'arbre final, car il est difficile de déterminer comment chaque caractéristique a contribué à la prédiction.

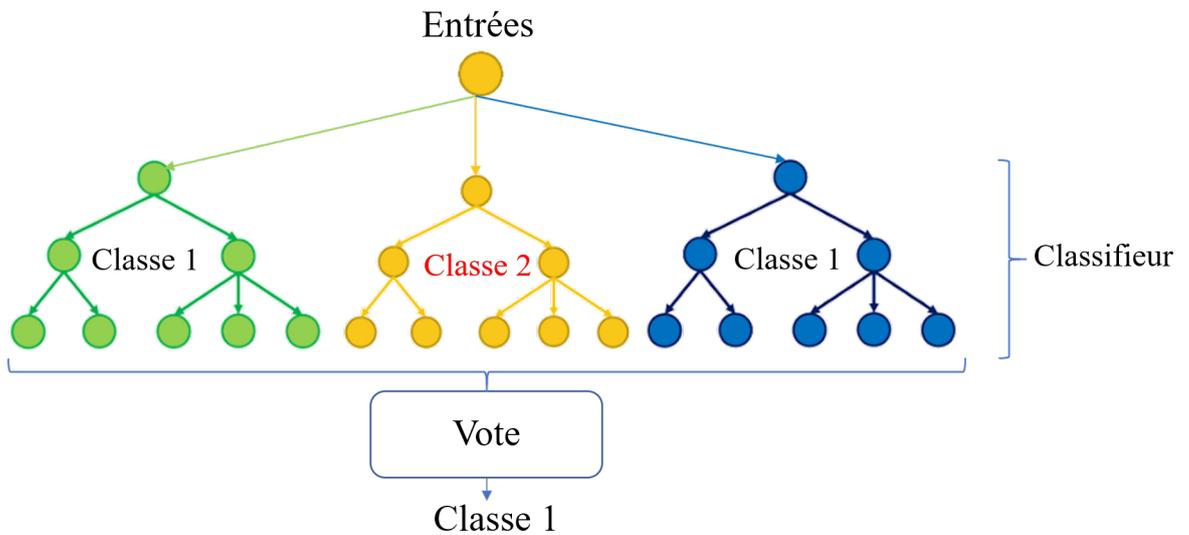


FIGURE 3.18 – Diagramme d'une forêt d'arbres décisionnels

Dans notre cas, nous avons développé un modèle avec 30 arbres de décision, et entraîné sur les échantillons HighD et les résultats sur l'ensemble de validation sont présentés dans le tableau 3.6.

		Random Forest	
		Positif	Négatif
Décision réel	Positif	87,3 %	12,7 %
	Négatif	20,7 %	79,3 %

TABLE 3.6 – Matrice de confusion pour la forêt d'arbres décisionnels.

Comme attendu, l'utilisation de modèle multi learner a permis d'améliorer les performances avec un gain de 11,46 points pour les vrais positifs et 0.8 point pour les vrais négatifs. Cela s'explique par le fait d'avoir plusieurs learner dans notre modèle permet de mieux représenter la diversité des conducteurs dans la base de données qui ont des styles de conduite différents et de ce fait, très difficile à apprendre pour un seul learner.

3.10 Validation sur simulateur

Les simulateurs de conduite pour véhicules automatisés sont des outils très utiles pour les ingénieurs travaillant sur le développement de systèmes de conduite automatisée. Ils permettent de tester les algorithmes de conduite et de navigation dans un environnement sûr et contrôlé, avant de les déployer sur des véhicules réels.

Les simulateurs peuvent reproduire des situations de conduite réelles, comme les conditions météorologiques, les obstacles, les piétons et les autres véhicules. Par exemple, un simulateur peut reproduire une situation de conduite enneigée pour tester comment le système de conduite automatisée réagit aux conditions difficiles. Les ingénieurs peuvent également utiliser des données de capteurs réels pour les intégrer dans le simulateur, de cette manière ils peuvent tester comment le système réagit aux données de capteurs réelles.

Les simulateurs peuvent également être utilisés pour simuler des défaillances dans les systèmes de conduite automatisée, pour tester comment ils réagissent et pour identifier les améliorations possibles. Par exemple, un ingénieur peut simuler une défaillance dans un capteur de vision, pour voir comment le système de conduite automatisée réagit et pour identifier les améliorations possibles.

Il existe plusieurs simulateurs de conduite automatisés qui peuvent différer, notamment en termes de :

- Capacités de simulation : certains simulateurs peuvent simuler des scénarios de conduite plus réalistes et plus complexes que d'autres, en prenant en compte des facteurs tels que la météo, les conditions de circulation, les piétons, etc.
- Niveaux d'automatisation pris en charge : certains simulateurs peuvent si-

muler des véhicules automatisés à différents niveaux d’automatisation, de la conduite assistée à la conduite automatisée complète, tandis que d’autres peuvent se concentrer sur des niveaux spécifiques d’automatisation.

- Modèles de véhicules : chaque simulateur peut avoir une sélection différente de modèles de véhicules disponibles pour la simulation, avec des caractéristiques et des comportements différents.
- Plateforme matérielle allant des simulateurs logiciels simples aux simulateurs de conduite hautement immersifs en réalité virtuelle, ou bien encore des simulateurs HiL (Hardware-in-the-loop simulation) qui permettent de tester le fonctionnelle ou encore l’architecture système.
- Outils d’analyse et de visualisation : les simulateurs peuvent offrir des fonctionnalités différentes pour l’analyse et la visualisation des résultats de la simulation, comme des outils de suivi des performances, des indicateurs de sécurité, des visualisations 3D, etc.
- Plateformes de développement : certains simulateurs peuvent être développés sur des plateformes de développement spécifiques, comme MATLAB ou Unreal Engine, ce qui peut influencer les capacités et les fonctionnalités disponibles.

Pour valider le comportement des différents algorithmes, nous souhaitons un simulateur de conduite pour reproduire les situations auxquelles le véhicule sera confronté sur l’autoroute et devra prendre la décision de changer de voie ou non. L’intérêt de valider nos algorithmes sur un simulateur est de pouvoir tester des situations auxquelles les conducteurs n’ont pas été confrontés, et pouvoir quantifier le niveau de risque pris par les différents algorithmes. Nous présentons certains simulateurs ci-dessous.

3.10.1 CARLA

CARLA (Car Learning to Act) [DRC⁺17] est un simulateur de conduite pour véhicules automatisés open-source développé par une communauté de chercheurs issus de l’Intel Labs, du Toyota Research Institute ainsi que du Computer Vision Center de Barcelone. Il a été créé pour fournir un environnement de simulation réaliste pour les tests et le développement de systèmes de conduite automatisée.

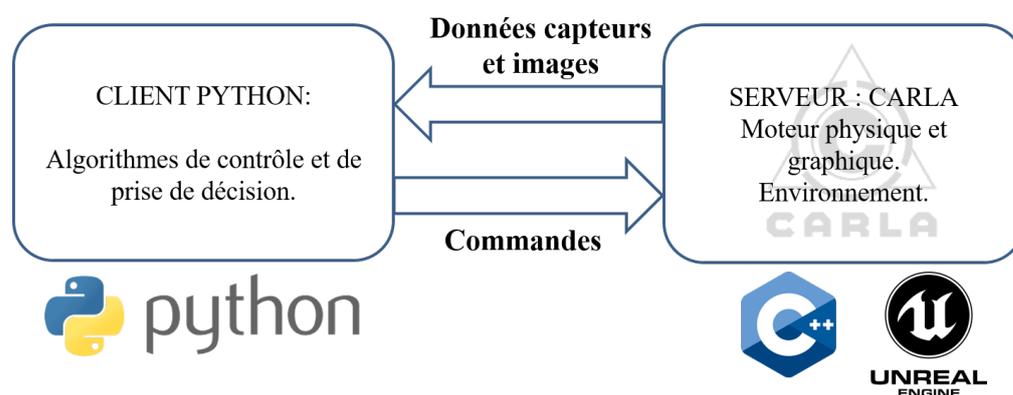


FIGURE 3.19 – Architecture "Serveur-Client" de CARLA.

CARLA est conçu pour simuler des environnements urbains réalistes, avec des routes, des bâtiments, des arbres, des piétons et d'autres véhicules. Il prend en charge les capteurs couramment utilisés dans les systèmes de conduite automatisée, tels que la vision par ordinateur, la lidar, le radar et les capteurs GPS. Il fournit également un ensemble complet d'outils de simulation de scénarios de conduite personnalisés, y compris la génération de trafic, la modélisation des véhicules et des piétons, ainsi que la simulation des conditions météorologiques et de la luminosité.

CARLA utilise le moteur de jeu Unreal Engine pour simuler l'environnement physique, ce qui permet de reproduire de manière réaliste les propriétés visuelles et les effets de lumière. Il est également équipé d'un moteur de physique pour simuler les lois de la physique de la conduite. Cette combinaison de technologies permet de reproduire de manière réaliste les conditions de conduite pour les tests de conduite automatisée.

En termes de flexibilité, CARLA est compatible avec les frameworks de machine learning populaires tels que TensorFlow et PyTorch via des scripts python (figure 3.20). Cela permet aux utilisateurs de facilement intégrer des modèles d'apprentissage automatique pour les tests dans le simulateur. Il est également open-source et est disponible sur GitHub, ce qui permet aux développeurs de l'utiliser et de le personnaliser selon leurs besoins.

Parmi les inconvénients de CARLA, que nous pouvons relever que ce dernier est gourmand en ressources processeur et graphique du fait de ses graphismes réalistes.

Sa configuration reste complexe par rapport à certains de ses concurrents ainsi que la création de scénarios de tests.

3.10.2 Matlab Driving Simulator

Le simulateur de conduite Matlab est un outil de simulation de véhicules automatisés développé par MathWorks, utilisant l'environnement de simulation et de modélisation de systèmes multi-domaine Simulink. Il est intégré à la Toolbox "Automated Driving" [Mat], et est conçu pour aider les ingénieurs et les chercheurs dans l'évaluation et la validation des systèmes de conduite automatisée avant leur déploiement sur des véhicules réels.

Le simulateur de conduite Matlab permet de simuler des véhicules automatisés en utilisant des modèles de véhicules physiques et des modèles de capteurs pour représenter les capteurs utilisés dans les systèmes de conduite automatisée tels que les caméras, les lidars, les radars et les capteurs GPS. Il offre également un grand nombre de scénarios de conduite incluant des routes, des intersections et des situations de circulation, ainsi que des modèles de piétons et d'autres véhicules.

Le simulateur de conduite Matlab est également intégré à d'autres outils de développement de MathWorks, tels que Stateflow pour la modélisation de systèmes à états et SimDriveline pour la modélisation de systèmes de transmission de véhicules. Il offre également une interface de programmation d'application (API) pour intégrer des modèles de conduite automatisée développés en dehors de Matlab, tels que des modèles d'apprentissage automatique entraînés avec TensorFlow ou PyTorch.

En utilisant le simulateur de conduite Matlab, les ingénieurs et les chercheurs peuvent simuler des scénarios de conduite réalistes et reproduire des situations de conduite difficiles, ce qui permet d'évaluer les performances des systèmes de conduite automatisée dans des conditions réelles. En outre, en utilisant l'API, il est possible d'intégrer des modèles d'apprentissage automatique pour améliorer les performances des systèmes de conduite automatisée.

Cependant malgré ses qualités, les ressources et la documentation pour l'usage de ce dernier restent très limitées. Le recours obligatoire à Simulink le rend moins flexible, et le modèle se retrouve chargé très vite.

CHAPITRE 3. ALGORITHMES DE PRISE DE DÉCISION ET VALIDATION



FIGURE 3.20 – Exemple d’interface du Simulateur de conduite de Matlab. Modèle Simulink (haut-gauche). Vue caméra embarqué (haut-droite). Vue extérieure (bas-gauche). Vue aérienne (bas-droit)

3.10.3 CarMaker

CarMaker est un outil de simulation de véhicules automatisés développé par IPG Automotive (figure 3.21) [car], une entreprise allemande spécialisée dans les outils de développement pour l’industrie automobile. Il est utilisé pour simuler les systèmes de conduite automatisée dans des environnements virtuels réalistes, permettant aux ingénieurs et aux chercheurs de tester et de valider les systèmes avant leur déploiement sur des véhicules réels.

CarMaker est basé sur la plateforme de simulation de véhicules IPG CarMaker, qui a été développée au cours des 20 dernières années. Il utilise une combinaison de modèles physiques, de modèles de capteurs et de modèles de conduite pour simuler les véhicules automatisés dans des environnements virtuels réalistes. Il peut simuler des véhicules automatisés à différents niveaux d’automatisation, de la conduite assistée à la conduite automatisée complète.

Le logiciel CarMaker comprend une variété de modèles de véhicules, de modèles

3.10. VALIDATION SUR SIMULATEUR

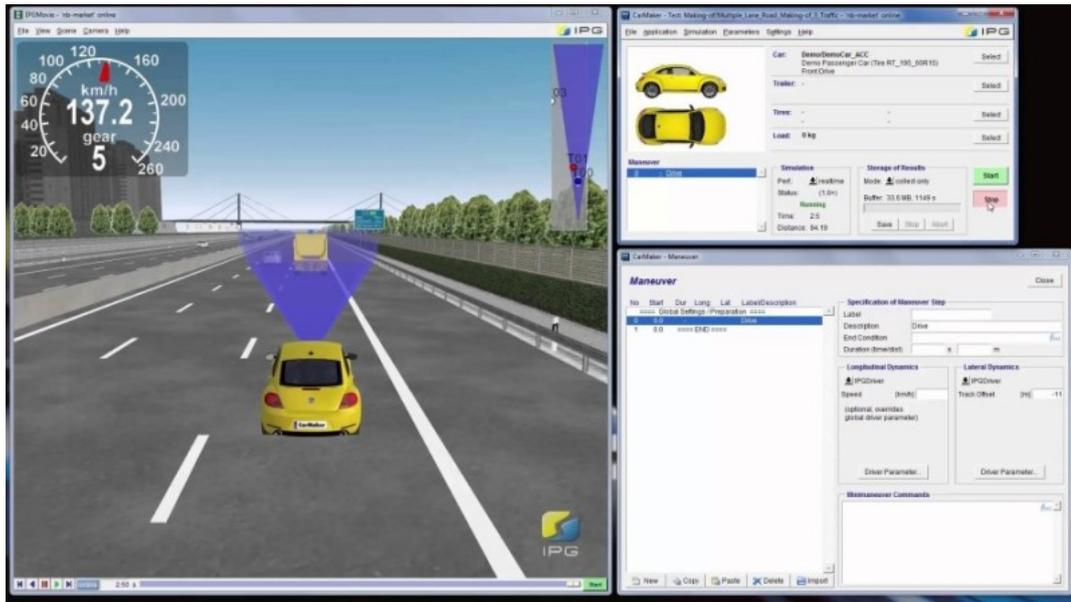


FIGURE 3.21 – Exemple de l'interface du simulateur CarMaker

de capteurs, de modèles de conduite, de modèles de circulation et d'outils de visualisation et d'analyse. Il permet également de simuler des situations de conduite difficiles telles que des conditions météorologiques extrêmes, des situations de circulation chaotiques et des erreurs de capteurs.

Les modèles de véhicules dans CarMaker sont basés sur des données réelles recueillies auprès de fabricants d'automobiles. Les modèles de capteurs incluent des capteurs de vision, de radar et de lidar, qui peuvent être configurés pour simuler des erreurs ou des limites de performance. Les modèles de conduite incluent des modèles de comportement de conduite humaine et des modèles de contrôle de véhicule automatisé.

Les modèles de circulation incluent des modèles de trafic, de signalisation routière et de piétons, qui peuvent être utilisés pour simuler des scénarios de conduite réalistes. Les outils de visualisation et d'analyse permettent aux utilisateurs de visualiser les résultats de la simulation et de les analyser pour identifier les domaines d'amélioration potentiels.

Malgré tout, ce dernier a une faiblesse qui est son coût. Contrairement à CARLA qui est gratuit et open source, et la toolbox "Automated driving" qui

est intégrée à Matlab qui est d'ores et déjà utilisé dans la majorité des laboratoires.

3.10.4 Développement d'un simulateur de conduite

Notre choix de développer un simulateur de conduite sur mesure est guidé par plusieurs motivations essentielles. Tout d'abord, nous avons identifié un besoin de flexibilité en termes de temps de simulation. Contrairement aux simulateurs existants qui opèrent en temps réel, notre simulateur permet des exécutions plus rapides en éliminant les contraintes de temps réel. Cela signifie que nous pouvons exécuter une simulation à une vitesse accélérée, ce qui est particulièrement utile pour l'itération rapide lors du développement et du test des algorithmes de conduite.

De plus, nous avons souhaité la possibilité de tester simultanément plusieurs algorithmes de prise de décision sur un même scénario. Notre simulateur permet l'intégration et l'évaluation côte à côte de plusieurs algorithmes différents, facilitant ainsi des comparaisons précises et une compréhension approfondie de leurs performances respectives. Le simulateur que nous avons développé est divisé en deux composantes interconnectées :

- un générateur de scénarios et un simulateur de conduite. Le générateur de scénarios permet de fixer les conditions initiales de la simulation, en modifiant des variables telles que la position longitudinale des véhicules, les vitesses, les limites de vitesse et la présence de véhicules sur la voie cible. L'utilisation d'algorithmes de génération contrôlée nous permet de couvrir un large spectre de situations de conduite, nous avons créé un total de 3740 scénarios différents pour couvrir un large éventail de situations de conduite.
- Le simulateur de conduite lui-même calcule les trajectoires des quatre véhicules dans la simulation, en utilisant un modèle bicyclette cinématique pour modéliser leurs mouvements avec une période d'échantillonnage de 0.1 seconde. Les vitesses des véhicules autres que l'ego-véhicule sont constantes tout au long de la simulation, avec une dynamique latérale nulle. Seul l'ego-véhicule est contrôlé pour adapter sa vitesse au véhicule devant lui et pour changer de voie si l'algorithme de prise de décision le décide (figure 3.23).

3.10. VALIDATION SUR SIMULATEUR

Pour la représentation visuelle de la simulation, nous avons choisi une approche pragmatique. Une vue aérienne fournit une perspective globale du scénario, tandis que les véhicules sont représentés sous forme de rectangles à l'échelle. Bien que simple, cette visualisation offre une compréhension claire de la situation sans alourdir les ressources de traitement (figure 3.22).

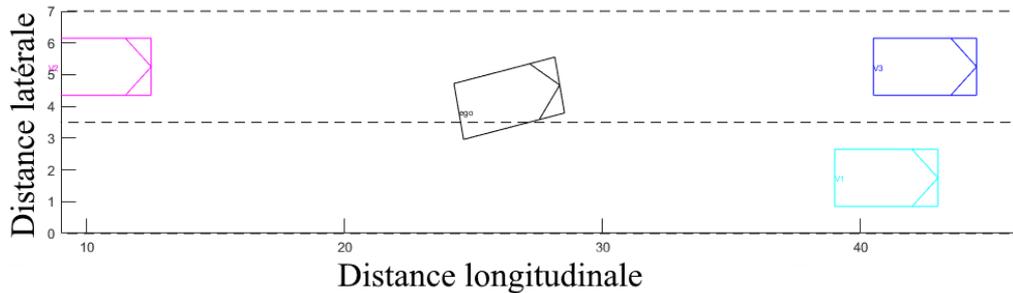


FIGURE 3.22 – Représentation graphique du simulateur de conduite.

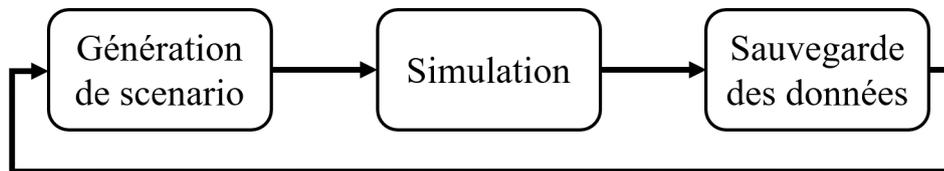


FIGURE 3.23 – Schéma du simulateur de conduite.

Nous avons testé les quatre algorithmes de prise de décision, chacun étant évalué sur les 3740 scénarios générés et simulateur. En testant les algorithmes en parallèle, nous avons pu réduire considérablement le temps nécessaire pour exécuter les tests. Le tableau 3.7 représente le taux de décisions positives et négatives par les différents algorithmes sur l'ensemble des scénarios générés.

Afin d'obtenir une représentation du risque pris par les algorithmes, nous avons tracé la figure 3.24 qui représente l'histogramme du pourcentage de manœuvre effectuée avec un risque supérieur au niveau de la barre pour tous les algorithmes.

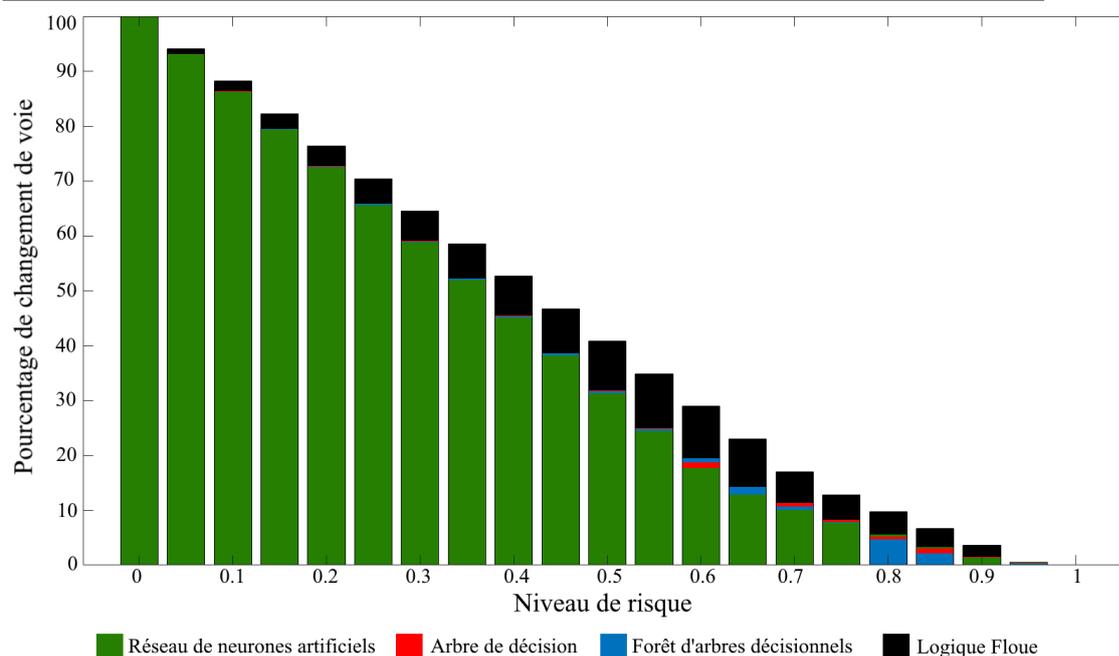


FIGURE 3.24 – Histogramme du niveau de risque pris par chaque algorithme.

3.11 Étude des résultats

À la lumière de l'ensemble des résultats compilés dans les sections précédentes, il en ressort que les algorithmes sont divisés en deux catégories. D'un côté l'algorithme de logique floue qui repose sur un réglage empirique, de l'autre le réseau de neurones, l'arbre de décision, et la forêt d'arbres décisionnels qui reposent sur un apprentissage automatique à partir d'un jeu de données. Cela se traduit par des performances sensiblement différentes. Nous remarquons que les algorithmes basés sur l'apprentissage dépassent les résultats obtenus avec les algorithmes de logique floue lorsque le critère d'évaluation est la fidélité des décisions par rapport à la base de données HighD, et donc la fidélité au comportement humain. Ce qui est normal et attendu sachant que ces algorithmes ont appris à partir d'échantillons de la même base de données qui est utilisée pour les évaluer, avec le meilleur résultat obtenu avec la forêt d'arbres décisionnels (tableau 3.8).

Bien entendu, il serait impossible d'obtenir un algorithme avec des taux de faux négatifs et de faux positifs nuls. En effet, notre base de données est constituée de dé-

3.11. ÉTUDE DES RÉSULTATS

	Positif	Négatif
Arbre de décision	37,06 %	62,93 %
Forêt d'arbres décisionnels	36,07 %	63,93 %
Réseau de neurones artificiels	36,58 %	63,42 %
Logique floue	33,11 %	66,89 %

TABLE 3.7 – Taux de décision positif et négatif pour chaque algorithme testé sur simulateur.

	Taux de vrais positifs	Taux de vrais négatifs
Logique Floue	71,02 %	77,96 %
Arbre de décision	75,53 %	78,36 %
Réseau de neurones artificiels	75,84 %	78,50 %
Forêt d'arbres décisionnels	87,3 %	79,3 %

TABLE 3.8 – Tableau récapitulatif des taux de vrais positifs et vrais négatifs pour chaque algorithme

cisions prises par des humains, et les décisions humaines ne sont pas déterministes. De plus, les différents échantillons utilisés ne présentent pas le même conducteur, ce qui entraîne des différences de comportement. Aussi, les conditions de conduite ne sont pas prises en compte, le comportement peut être différent la nuit ou par temps de pluie, et enfin, il peut y avoir certains conducteurs dans la base de données qui ont eu des comportements très dangereux à certains moments, mais qui ne sont pas statistiquement significative, et qui sont noyés au milieu d'autres échantillons au comportement plus classique, et n'est donc pas appris par les modèles développés.

Pour les résultats obtenus avec le simulateur de conduite, deux remarques intéressantes sont à noter : premièrement, le tableau montre que les algorithmes se comportent de manière très similaire, avec des taux de décisions positives et négatives proches, avec une différence notable pour la logique floue. Ceci s'explique encore par le fait que les trois premiers algorithmes sont basés sur l'apprentissage alors que le dernier est paramétré manuellement. Deuxièmement, le tableau nous renseigne sur la similitude de comportement entre les algorithmes, mais ne nous renseigne pas sur le niveau de risque pris lors des manœuvres. Pour cela, il faut regarder les histogrammes de la figure 3.24. On remarque la même tendance pour tous les algorithmes, mais aussi que la logique floue prend plus de risque que les

autres algorithmes, ce qui montre que ces derniers sont non seulement plus proches du comportement humain, mais qu'ils prennent également moins de risque au sein du simulateur.

On peut également remarquer que le taux de changement de voie pour un risque supérieur ou égal à 0,95 est inférieur à 0,67% pour tous les algorithmes avec un minimum établi à 0,45% pour la forêt aléatoire. Nous concluons donc que la forêt aléatoire est celle ayant obtenu les meilleurs résultats parmi ceux comparés.

Conclusion

Ce chapitre a été consacré à la méthodologie de prise de décision dans son ensemble. Nous avons présenté l'organigramme de prise de décision, avec les 3 étapes : prédiction de trajectoire, calcul du gain et du risque avec définition du moment optimal, et finalement, calcul de la décision finale.

Pour la brique finale, nous en avons proposé quatre : arbre de décision, forêt aléatoire, réseau de neurones artificiels et logique floue. Ces quatre algorithmes ont été paramétrés soit empiriquement (logique floue), soit par apprentissage automatique et ont été validés sur des échantillons de changement de voies issues de la base de données HighD, avec une seconde validation sur simulateur en générant des scénarios aléatoires pour tester leurs comportements. Des deux validations, il ressort que la forêt aléatoire a les meilleures performances des 4 algorithmes. Non seulement, elle est la plus proche du comportement humain, mais c'est également l'algorithme qui prend le moins de risque.

Chapitre 4

Conclusion générale

Les travaux de cette thèse portent sur l'étude du comportement des conducteurs lors des manœuvres de changement de voies sur autoroutes et voies rapides. Le but étant le comprendre dans l'optique de reproduire ce comportement par un algorithme dans le cadre de conduite automatisée, ou du moins de s'en approcher au maximum.

Dans le cadre de la thèse, nous nous sommes intéressés aux manœuvres de changement de voie, nous avons développé une méthode d'évaluation du risque spécifique à ces dernières. Elle est basée sur les échantillons extraits de la base de données MOOVE de VEDECOM, cette dernière offre l'avantage de contenir un grand nombre de manœuvres comparé aux alternatives. Cette échelle du risque prend en compte la vitesse relative et la distance entre l'ego et les véhicules sur la voie cible, et repose sur un constat simple : plus il existe de manœuvres réalisées dans des conditions plus risquées, moins le risque est élevé. En partant de ce postulat nous avons tracé des histogrammes bivariants normés sur quatre intervalles de vitesses qui donne une valeur du risque entre 0 (risque faible) et 1 (risque absolu). L'étape suivante est la prise de décision, à cet effet nous avons développé un algorithme en 3 étapes :

- Prédiction de trajectoire des véhicules sur la voie cible dans le but de déterminer le meilleur instant pour changer de voie.
- Calcul du risque et également d'un autre indicateur que nous avons développé qui est le gain. Il représente le gain potentiel que pourrait représenter

les manœuvres.

- L’algorithme de prise de décision finale. À l’issue de cette étape, nous obtenons une sortie binaire qui correspond à la décision de changer de voie ou non.

Les quatre algorithmes choisis peuvent être classés en 2 catégories : les algorithmes d’apprentissage d’un côté et la logique floue de l’autre. Arbre de décision, forêt d’arbres décisionnels et réseaux de neurones composent la gamme des algorithmes d’apprentissage. Ces derniers ont appris sur la base de données HighD qui nous a permis de réaliser une extraction de données des échantillons positifs de changement de voie, mais également ce que nous considérons comme échantillons négatifs.

Pour valider et comparer les performances de l’ensemble des algorithmes, deux approches ont été utilisées. La première a été de tester les algorithmes sur la base de données HighD, des matrices de confusions ont été dressées et ont mis en évidence des résultats supérieurs pour les algorithmes d’apprentissage comparés à la logique floue, ce qui est normal et attendu. Les meilleurs résultats étant obtenus par la forêt d’arbres décisionnels avec des scores de vrais positifs et vrai négatifs de respectivement 87,3% et 79,3%. Il est selon nous très compliqué d’espérer un meilleur mimétisme du comportement humain pour plusieurs raisons : la prise de décision d’un humain n’est pas forcément déterministe. la prise de décision d’un humain n’est pas forcément déterministe. Aussi, les conditions de conduite ne sont pas prises en compte. La nuit ou la pluie peut engendrer des différences de comportement. Et certains conducteurs qui ont eu des comportements très dangereux à certains moments. Mais qui n’est pas statistiquement significatif. La seconde validation effectuée fut sur un simulateur que nous avons développé et qui génère des scénarios de manière aléatoire en faisant varier plusieurs paramètres et de tester le comportement de chaque algorithme sur les mêmes scénarios. Il en résulte que sur l’ensemble des algorithmes et des scénarios, nous n’avons enregistré aucune collision. Nous avons remarqué également que l’algorithme de logique flou est celui qui prend le plus de risque parmi ceux testés, celui prenant le moins étant la forêt d’arbres décisionnels. Nous pouvons conclure que ce dernier est celui qui présente les meilleurs résultats aussi bien sur simulateur que sur base de données.

À l’issue de cette thèse, les travaux présentés ont donné des résultats promet-

teurs. Il reste cependant plusieurs axes d'améliorations que nous avons identifiées et listées ci-dessous :

- Compléter la validation des algorithmes avec une validation expérimentale sur véhicule, et ce, en environnement contrôlé tel qu'une piste fermée, et par la suite, sur route ouverte.
- Évaluer le ressenti de passager au sein de véhicules embarquant les algorithmes présentés lors des manœuvres de changement. Cette évaluation se fera au moyen de questionnaires et permettra de mesurer l'acceptabilité des personnes aux algorithmes développés.
- Développer la méthode d'extraction de données pour discriminer les manœuvres prudentes des manœuvres « agressives », et ainsi pouvoir offrir deux modes de conduite aux algorithmes.
- Tirer parti de la communication entre véhicules (V2V), d'une part pour améliorer la prédiction de trajectoire, mais également pour informer les autres véhicules de l'intention de changer de voie.

Bibliographie

- [ADSH12] Georges S Aoude, Vishnu R Desaraju, Lauren H Stephens, and Jonathan P How. Driver behavior classification at intersections and validation on large naturalistic data set. *IEEE Transactions on Intelligent Transportation Systems*, 13(2) :724–736, 2012.
- [AN09] Samer Ammoun and Fawzi Nashashibi. Real time trajectory prediction for collision risk estimation between vehicles. In *2009 IEEE 5th International Conference on Intelligent Computer Communication and Processing*, pages 417–422. IEEE, 2009.
- [BBJM20] Abdelmoudjib Benterki, Moussa Boukhnifer, Vincent Judalet, and Choubeila Maaoui. Artificial intelligence for vehicle behavior anticipation : Hybrid approach based on maneuver classification and trajectory prediction. *IEEE Access*, 8 :56992–57002, 2020.
- [BBK05] Adrian Broadhurst, Simon Baker, and Takeo Kanade. Monte carlo road safety reasoning. In *IEEE Proceedings. Intelligent Vehicles Symposium, 2005.*, pages 319–324. IEEE, 2005.
- [BCS10] Mattias Brännström, Erik Coelingh, and Jonas Sjöberg. Model-based threat assessment for avoiding arbitrary vehicle collisions. *IEEE Transactions on Intelligent Transportation Systems*, 11(3) :658–669, 2010.
- [BCSG16] Esmail Balal, Ruey Long Cheu, and Thompson Sarkodie-Gyan. A binary decision model for discretionary lane changing move based on fuzzy inference system. *Transportation Research Part C : Emerging Technologies*, 67 :47–61, 2016.

- [BDGB17] L Bonic, A De Galizia, and A Bracquemond. Identification of real world driving scenarios for the functional safety of autonomous vehicles. In *EVS30 Symposium Stuttgart*, pages 369–376, 2017.
- [BED08] Holger Berndt, Jorg Emmert, and Klaus Dietmayer. Continuous driver intention recognition with hidden markov models. In *2008 11th International IEEE Conference on Intelligent Transportation Systems*, pages 1189–1194. IEEE, 2008.
- [Boa98] Transportation Research Board. National automated highway system research program : A review : A review–special report 253. 1998.
- [BSW05] Thorsten Brandt, Thomas Sattel, and Jörg Wallaschek. On automatic collision avoidance systems. *SAE transactions*, pages 431–440, 2005.
- [car] Carmaker. <https://ipg-automotive.com/en/products-solutions/software/carmaker/>. Consulté le : 25-10-2022.
- [Chr09] Tay Christopher. *Analysis of dynamic scenes : Application to driving assistance*. PhD thesis, Institut National Polytechnique de Grenoble-INPG, 2009.
- [DMM⁺11] Helgo Dyckmanns, Richard Matthaei, Markus Maurer, Bernd Lichte, Jan Effertz, and Dirk Stüker. Object tracking in urban intersections based on active use of a priori knowledge : Active interacting multi model filter. In *2011 IEEE Intelligent Vehicles Symposium (IV)*, pages 625–630. IEEE, 2011.
- [DRC⁺17] Alexey Dosovitskiy, German Ros, Felipe Codevilla, Antonio Lopez, and Vladlen Koltun. CARLA : An open urban driving simulator. In *Proceedings of the 1st Annual Conference on Robot Learning*, pages 1–16, 2017.
- [DWWB13] Chenxi Ding, Wuhong Wang, Xiao Wang, and Martin Baumann. A neural network model for driver’s lane-changing trajectory prediction in urban traffic flow. *Mathematical Problems in Engineering*, 2013, 2013.

- [EP08] Andreas Eidehall and Lars Petersson. Statistical threat assessment for general road scenes using monte carlo sampling. *IEEE Transactions on intelligent transportation systems*, 9(1) :137–147, 2008.
- [FM91] Robert E Fenton and Robert J Mayhan. Automated highway studies at the ohio state university-an overview. *IEEE transactions on Vehicular Technology*, 40(1) :100–113, 1991.
- [FRR⁺12] Flavio Farroni, Michele Russo, Riccardo Russo, Mario Terzo, and Francesco Timpone. On the influence of anti-roll stiffness on vehicle stability and proposal of an innovative semi-active magnetorheological fluid anti-roll bar. In *RAAD 2012 : 21th International Workshop on Robotics in Alpe-Adria-Danube Region, 10-13 September 2012 : Naples, Italy : Proceedings*, page 318. ESA, 2012.
- [Gip81] Peter G Gipps. A behavioural car-following model for computer simulation. *Transportation Research Part B : Methodological*, 15(2) :105–111, 1981.
- [Hid05] Peter Hidas. Modelling vehicle interactions in microscopic simulation of merging and weaving. *Transportation Research Part C : Emerging Technologies*, 13(1) :37–62, 2005.
- [HSK06] Jrg Hillenbrand, Andreas M Spieker, and Kristian Kroschel. A multi-level collision mitigation approach—its situation assessment, decision making, and performance tradeoffs. *IEEE Transactions on intelligent transportation systems*, 7(4) :528–540, 2006.
- [ILCD00] Scott Ikenaga, Frank L Lewis, Javier Campos, and Leo Davis. Active suspension control of ground vehicle based on a full-vehicle model. In *Proceedings of the 2000 American Control Conference. ACC (IEEE Cat. No. 00CH36334)*, volume 6, pages 4019–4024. IEEE, 2000.
- [JDVHR11] Joshua Joseph, Finale Doshi-Velez, Albert S Huang, and Nicholas Roy. A bayesian nonparametric approach to modeling motion patterns. *Autonomous Robots*, 31(4) :383–400, 2011.
- [KBKE18a] Robert Krajewski, Julian Bock, Laurent Kloeker, and Lutz Eckstein. The highd dataset : A drone dataset of naturalistic vehicle trajectories on german highways for validation of highly automated driving

- systems. In *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, pages 2118–2125, 2018.
- [KBKE18b] Robert Krajewski, Julian Bock, Laurent Kloeker, and Lutz Eckstein. The highd dataset : A drone dataset of naturalistic vehicle trajectories on german highways for validation of highly automated driving systems. In *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, pages 2118–2125. IEEE, 2018.
- [KHW⁺10] Eugen Käfer, Christoph Hermes, Christian Wöhler, Helge Ritter, and Franz Kummert. Recognition of situation classes at road intersections. In *2010 IEEE international conference on robotics and automation*, pages 3960–3965. IEEE, 2010.
- [KPSB15] Jason Kong, Mark Pfeiffer, Georg Schildbach, and Francesco Borrelli. Kinematic and dynamic vehicle models for autonomous driving control design. In *2015 IEEE intelligent vehicles symposium (IV)*, pages 1094–1099. IEEE, 2015.
- [KTH07] Arne Kesting, Martin Treiber, and Dirk Helbing. General lane-changing model mobil for car-following models. *Transportation Research Record*, 1999(1) :86–94, 2007.
- [LAP⁺13] Andreas Lawitzky, Daniel Althoff, Christoph F Passenberg, Georg Tanzmeister, Dirk Wollherr, and Martin Buss. Interactive scene prediction for automotive applications. In *2013 IEEE Intelligent Vehicles Symposium (IV)*, pages 1028–1033. IEEE, 2013.
- [LPP⁺11] Christian Laugier, Igor E Paromtchik, Mathias Perrollaz, Mao Yong, John-David Yoder, Christopher Tay, Kamel Mekhnacha, and Amaury Nègre. Probabilistic analysis of dynamic scenes and collision risks assessment to improve driving safety. *IEEE Intelligent Transportation Systems Magazine*, 3(4) :4–19, 2011.
- [LVL14] Stéphanie Lefèvre, Dizan Vasquez, and Christian Laugier. A survey on motion prediction and risk assessment for intelligent vehicles. *robotics journal*, 1, 1 : 1, 2014.

- [Mat] Matlab automated driving toolbox. https://www.mathworks.com/help/driving/index.html?s_tid=CRUX_lftnav. Consulté le : 25-10-2022.
- [MCNF17] Mustafa Mukadam, Akansel Cosgun, Alireza Nakhaei, and Kikuo Fujimura. Tactical decision making for lane changing with deep reinforcement learning. 2017.
- [MH02] Ronald Miller and Qingfeng Huang. An adaptive peer-to-peer collision warning system. In *Vehicular Technology Conference. IEEE 55th Vehicular Technology Conference. VTC Spring 2002 (Cat. No. 02CH37367)*, volume 1, pages 317–321. IEEE, 2002.
- [Moh19] Haradhan Mohajan. The second industrial revolution has brought modern social and economic developments. 2019.
- [MS05] Hiren M Mandalia and Mandalia Dario D Salvucci. Using support vector machines for lane-change detection. In *Proceedings of the human factors and ergonomics society annual meeting*, volume 49, pages 1965–1969. SAGE Publications Sage CA : Los Angeles, CA, 2005.
- [NGS] Us department of transportation – ngsim – next generation simulation. <https://ops.fhwa.dot.gov/trafficanalysistools/ngsim.htm>. Consulté le : 25-10-2022.
- [Oer97] Ch Oertel. On modeling contact and friction calculation of tyre response on uneven roads. *Vehicle System Dynamics*, 27(S1) :289–302, 1997.
- [OFKG11] Michaël Garcia Ortiz, Jannik Fritsch, Franz Kummert, and Alexander Gepperth. Behavior prediction at multiple time-scales in inner-city scenarios. In *2011 IEEE Intelligent Vehicles Symposium (IV)*, pages 1068–1073. IEEE, 2011.
- [PTAA07] Aris Polychronopoulos, Manolis Tsogas, Angelos J Amditis, and Luisa Andreone. Sensor fusion for predicting vehicles’ path for collision avoidance systems. *IEEE Transactions on Intelligent Transportation Systems*, 8(3) :549–562, 2007.
- [PWHR11] Rob Palin, David Ward, Ibrahim Habli, and Roger Rivett. Iso 26262 safety cases : Compliance and assurance. 2011.

- [Qia17] Xiangjun Qian. *Model predictive control for autonomous and cooperative driving*. PhD thesis, Ph. D. Thesis, PSL Research University, France, 2017.
- [RCXH13] Mizanur Rahman, Mashrur Chowdhury, Yuanchang Xie, and Yiming He. Review of microscopic lane-changing models and future research opportunities. *IEEE transactions on intelligent transportation systems*, 14(4) :1942–1956, 2013.
- [SKvA12] Wouter J Schakel, Victor L Knoop, and Bart van Arem. Integrated lane change model with relaxation and synchronization. *Transportation Research Record*, 2316(1) :47–57, 2012.
- [SRW08] Robin Schubert, Eric Richter, and Gerd Wanielik. Comparison and evaluation of advanced motion models for vehicle tracking. In *2008 11th international conference on information fusion*, pages 1–6. IEEE, 2008.
- [TF14] Quan Tran and Jonas Firl. Online maneuver recognition and multimodal trajectory prediction for intersection assistance using non-parametric regression. In *2014 IEEE intelligent vehicles symposium proceedings*, pages 918–923. IEEE, 2014.
- [VPS06] Harini Veeraraghavan, Nikos Papanikolopoulos, and Paul Schrater. Deterministic sampling-based switching kalman filtering for vehicle tracking. In *2006 IEEE Intelligent Transportation Systems Conference*, pages 1340–1345. IEEE, 2006.
- [WB08] Michael T Wolf and Joel W Burdick. Artificial potential functions for highway driving with collision avoidance. In *2008 IEEE International Conference on Robotics and Automation*, pages 3731–3736. IEEE, 2008.
- [Zad65] Lotfi A Zadeh. Fuzzy sets. *Information and control*, 8(3) :338–353, 1965.
- [ZCZZ10] Li Zhang, Shangshu Cai, Yunlong Zhang, and Min Zhang. Comparison of lane changing algorithms between ngsim and corsim. In *2010 IEEE 71st Vehicular Technology Conference*, pages 1–6. IEEE, 2010.

Titre : Estimation et analyse de risque de collision pour un véhicule autonome

Mots clés : Véhicule automatisé, évaluation du risque, prise de décision.

Résumé : L'un des domaines qui a vu les plus grandes évolutions ces dernières années dans l'industrie automobile est certainement ADAS (Advanced Driver-Assistance Systems), toutes ces technologies visent à améliorer la sécurité routière et le confort des conducteurs et des passagers. Le véhicule automatisé doit être capable de réaliser plusieurs tâches simultanément. La perception qui consiste à construire une carte l'environnement. La prise de décision décide de la trajectoire optimale à suivre en temps réel. La conduite automatisée s'appuie sur le contrôle des organes du véhicule (moteur, freins, direction, etc.) afin de suivre une trajectoire donnée par le module de décision. Le travail de cette thèse s'inscrit dans le développement d'algorithmes pour la prise de décision, et plus précisément pour les manœuvres de changement de voie sur autoroute et voies rapides. L'étude commence par un point sur les travaux réalisés concernant l'analyse des risques pour les véhicules automatisés, également sur les différents algorithmes pour la prise de décision pour le changement de voie. Une métrique pour évaluer le risque lors des manœuvres de changement de voie est

développée. Cette métrique est construite à partir de la base de données MOOVE de l'Institut VEDECOM pour la conduite en conditions réelles. Sur la base de l'échelle de risque proposée, une méthodologie de prise de décision pour le changement de voie est développée. Elle repose sur 3 étapes successives : prédiction de trajectoires des véhicules environnants, évaluations des risques à partir des trajectoires prédites et choix du moment optimal pour commencer la manœuvre, et finalement algorithme de prise de décision qui, en se basant sur la valeur du risque et du gain décide de réaliser la manœuvre de changement de voie ou non. Quatre algorithmes ont été proposés, Arbre de décision, forêt d'arbres décisionnels, logique floue et réseau de neurones. Les quatre algorithmes ont été validés de deux méthodes. La première est une validation sur la base de données HighD en comparant les décisions des algorithmes aux décisions humaines. La seconde est une validation sur simulateur pour évaluer les niveaux de risque pris par les algorithmes. De ces deux validations il en ressort que la forêt d'arbres décisionnels est l'algorithme qui obtient les meilleures performances.

Title : Detection and analysis of collision risk for autonomous vehicle

Keywords : Automated vehicle, risk assessment, decision making.

Abstract : One of the areas that has seen the greatest developments in recent years in the automotive industry is certainly ADAS (Advanced Driver-Assistance Systems), all these technologies aim to improve road safety and comfort of drivers and passengers. The autonomous vehicle must be able to perform several tasks simultaneously. The perception which consists in building a map of the environment. The decision making process decide the optimal trajectory to follow in real time. The automated driving is based on the control of the vehicle's organs (engine, brakes, steering, etc.) in order to follow a trajectory given by the decision module. The work of this thesis is part of the development of algorithms for decision making, and more precisely for lane change maneuvers on highways and expressways. The study starts with a review of the work done on risk analysis for autonomous vehicles, and also on the different algorithms for lane change decision making. A metric to evaluate the risk during lane change maneuvers is developed. This

metric is built from the MOOVE database of the VEDECOM Institute for driving in real conditions. Based on the proposed risk scale, a decision-making methodology for lane change is developed. It is based on 3 successive steps : prediction of trajectories of surrounding vehicles, risk assessment from the predicted trajectories and choice of the optimal moment to start the maneuver, and finally decision making algorithm which, based on the value of risk and gain, decides to perform the lane change maneuver or not. Four algorithms have been proposed, Decision Tree, random Forest, Fuzzy Logic and Neural Network. The four algorithms have been validated in two ways. The first one is a validation on the HighD database by comparing the decisions of the algorithms to human decisions. The second is a validation on a simulator to evaluate the risk levels taken by the algorithms. From these two validations, it appears that the random forest is the algorithm that obtains the best performances.