



HAL
open science

Contrôle partagé adaptatif et élaboration de stratégies de conduite personnalisées pour le véhicule automatisé : une approche par apprentissage progressif

Mohamed Radjeb Oudainia

► To cite this version:

Mohamed Radjeb Oudainia. Contrôle partagé adaptatif et élaboration de stratégies de conduite personnalisées pour le véhicule automatisé : une approche par apprentissage progressif. Automatique / Robotique. Université Polytechnique Hauts-de-France, 2023. Français. NNT : 2023UPHF0038 . tel-04466406

HAL Id: tel-04466406

<https://theses.hal.science/tel-04466406v1>

Submitted on 19 Feb 2024

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.

Thèse de doctorat
Pour obtenir le grade de Docteur de
l'UNIVERSITE POLYTECHNIQUE HAUTS-DE-FRANCE
et de l'INSA HAUTS-DE-FRANCE
Spécialité : Automatique, productique

Présentée et soutenue par Mohamed Radjeb OUDAINIA.

Le 21/12/2023, à Valenciennes

Ecole doctorale :

Ecole Doctorale Polytechnique Hauts-de-France (ED PHF n°635)

Unité de recherche :

Laboratoire d'Automatique, de Mécanique et d'Informatique Industrielles et Humaines
(LAMIH-UMR CNRS 8201)

**Contrôle partagé adaptatif et élaboration de stratégies de conduite personnalisées
pour le véhicule automatisé : une approche par apprentissage progressif**

JURY

Président du jury

— Philippe Chevrel, Professeur des universités, Institut Mines-Telecom Atlantique Nantes.

Rapporteurs

— Olivier Sename, Professeur des universités, Université Grenoble Alpes.
— Reine Talj, Chargée de recherche CNRS HDR, Université Technologique de Compiègne.

Examineurs

— Naïma Ait Oufroukh-Mammar, Maître de Conférences HDR, Université d'Evry.
— Jimmy Lauber, Professeur des universités, UPHF-INSA.

Directeur de thèse

— Jean-Christophe Popieul, Professeur des universités, UPHF-INSA.

Co-encadrants

— Chouki Sentouh, Maître de Conférences HDR, UPHF-INSA.
— Anh-Tu Nguyen, Maître de Conférences, UPHF-INSA.

Résumé

La conduite autonome suscite un intérêt croissant auprès des constructeurs, des chercheurs, des autorités et du grand public en raison de ses promesses en matière de sécurité routière, de mobilité pour les personnes âgées et à mobilité réduite, d'efficacité énergétique et de réduction des émissions. Cependant, le déploiement complet de ces véhicules dépend de leur fiabilité dans toutes les situations, ce qui nécessite une supervision du conducteur. Cela soulève des questions cruciales sur l'interaction homme-machine, en particulier en ce qui concerne le partage de la commande et la résolution des conflits.

La thèse s'inscrit dans le cadre du projet ANR-CoCoVeIA (2019-2024) coordonné par le LAMIH (Coopération Conducteur-Véhicule Intelligent Autonome). Son objectif principal est d'incorporer des capacités d'auto-apprentissage dans les véhicules autonomes de niveau 2 pour améliorer leurs compétences en respectant les règles de sécurité routière. La thèse se concentre sur l'optimisation de l'interaction entre le système automatisé et le conducteur pour renforcer l'efficacité, améliorer les performances de conduite et favoriser l'acceptabilité du système.

Pour atteindre ces objectifs, une architecture de coopération auto-adaptative à plusieurs niveaux est proposée dans la première partie de la thèse. Cette architecture vise à adapter de manière optimale le comportement du véhicule autonome à un style de conduite préféré des conducteurs tout en garantissant une conduite sécuritaire et efficace. Une deuxième partie de la thèse se penche sur la personnalisation des systèmes d'assistance au changement de voie, utilisant une approche d'apprentissage basée sur la descente de gradient stochastique pour ajuster les paramètres en fonction des préférences du conducteur, en se basant sur la détection de ses intentions de changement de voie.

Pour résoudre les conflits entre le conducteur et le système de conduite autonome, la thèse explore trois approches de commande optimale robuste pour les systèmes linéaires à paramètres variants (LPV) représentés sous la forme floue Takagi-Sugeno (T-S). La première approche se concentre sur le contrôle partagé adaptatif en ajustant une fonction de coût multi-objectif en temps réel en fonction de la disponibilité du conducteur et de l'évaluation du risque. La deuxième approche introduit un modèle dynamique du conducteur, dont les paramètres sont identifiés en ligne, permettant une adaptation continue aux caractéristiques du conducteur. Ce modèle est utilisé pour développer un système de contrôle partagé adaptatif pour le maintien de voie en tenant compte de la dynamique des paramètres du système neuromusculaire du conducteur. La dernière approche vise à éliminer complètement les conflits entre le conducteur et le système de maintien de voie en combinant une fonction de coût adaptative avec un modèle dynamique du comportement du conducteur.

Pour la conception du contrôleur partagé LPV, les conditions de stabilité en boucle fermée du contrôle partagé adaptatif (LPV) pour les trois approches sont établies à l'aide de l'approche de stabilité de Lyapunov et formulées sous forme d'un problème d'optimisation d'inégalités matricielles linéaires (LMI) qui peuvent être résolues numériquement grâce à des algorithmes d'optimisation convexe. Des validations expérimentales et des expériences de test utilisateurs ont été menées au moyen du simulateur de conduite dynamique SHERPA-LAMIH pour évaluer l'acceptabilité de ces approches, démontrant ainsi leur efficacité pour améliorer la sécurité et le confort de conduite, et validant l'ensemble des approches proposées.

Mots clés : Véhicule automatisé, coopération conducteur-véhicule, contrôle partagé, commande robuste, dynamique véhicule, représentation T-S, commande LPV, optimisation multi-objectif, apprentissage progressif, modélisation conducteur, optimisation LMI.

Abstract

Autonomous driving technology is attracting increasing interest from automobile manufacturers, researchers, authorities, and the general public due to its promises in enhancing road safety, providing mobility for the elderly and individuals with reduced mobility, improving energy efficiency, and reducing emissions. However, the full deployment of these vehicles relies on their reliability in all situations, necessitating driver supervision. This raises critical questions about human-machine interaction, particularly concerning sharing control between the automated driving system and the driver, as well as conflict management.

The thesis is part of the ANR-CoCoVeIA project (2019-2024), coordinated by LAMIH (Cooperation Driver-Autonomous Intelligent Vehicle). The main objective of this project is to introduce self-learning capabilities into level 2 autonomous vehicles to enhance their skills while adhering to road safety rules. The thesis focuses specifically on managing interactions between the automated system and the driver, with the goal of improving its effectiveness, enhancing driving performance, and promoting the driver's acceptance of the system.

To achieve these goals, a multi-level evolutionary cooperation architecture is proposed in the first part of the thesis. This architecture aims to optimally adapt the behavior of the autonomous vehicle to a driver's preferred driving style while ensuring safe and efficient driving. The second part of the thesis delves into personalizing lane change assistance systems, using a stochastic gradient descent-based learning approach to adjust parameters based on the driver's preferences, relying on the detection of their lane change intentions.

To address conflicts between the driver and the autonomous driving system, the thesis explores three robust optimal control approaches for linear time-varying parameter systems (LPV) represented in the Takagi-Sugeno (T-S) fuzzy form. The first approach focuses on adaptive shared control by real-time adjustment of a multi-objective cost function based on driver availability and risk assessment. The second approach introduces a driver's dynamic model, with parameters identified online, allowing continuous adaptation to the driver's characteristics. This model is used to develop an adaptive shared control system for lane-keeping, taking into account the neuromuscular dynamics of the driver's parameters. The final approach aims to entirely eliminate conflicts between the driver and the lane-keeping system by combining an adaptive cost function with a dynamic driver behavior model.

For the design of the LPV shared controller, stability conditions for closed-loop adaptive shared control (LPV) for all three approaches are established using Lyapunov stability arguments and formulated as a linear matrix inequality (LMI) optimization problem that can be numerically solved using convex optimization algorithms. Experimental validations and user testing experiments were conducted using the SHERPA-LAMIH dynamic driving simulator to assess the acceptability of these approaches, demonstrating their effectiveness in improving safety and driving comfort and validating all of the proposed approaches.

Keywords : Automated vehicle, driver-vehicle cooperation, shared control, robust control, vehicle dynamics, T-S representation, LPV control, multi-objective optimization, progressive learning, driver modeling, LMI optimization.

Remerciements

Au début de la rédaction de cette section, je tiens à dédier cette thèse à la mémoire de mon père bien-aimé, Nouredine Oudainia, dont le départ soudain le 10 mai 2023 nous a profondément attristés. Que son âme repose en paix, et que Dieu l'accueille dans son vaste paradis. Il est essentiel pour moi d'exprimer ma gratitude envers Dieu, qui m'a accordé la force, le courage et la patience qui m'ont permis de mener à bien cette thèse jusqu'à la fin.

J'adresse également mes sincères et profonds remerciements à mon directeur de thèse, Jean-Christophe Popieul, et à mes encadrants Chouki Sentouh et Anh-Tu Nguyen pour m'avoir donné l'opportunité de découvrir le monde de la recherche. Leurs critiques constructives, leur patience inestimable et leurs qualités humaines exceptionnelles ont joué un rôle essentiel dans l'amélioration significative de mon travail au cours de cette période de thèse. Je tiens également à adresser mes remerciements à Jérôme Floris, dont l'expertise en simulation est inestimable, ainsi qu'à Philippe Simon, dont la gentillesse est inégalée. Leur disponibilité et leur précieuse assistance ont grandement contribué à la réussite de ce projet.

Un très grand merci à mes rapporteurs Olivier Sename et Reine Talj pour avoir accepté de réaliser une lecture attentive et pointue de ce manuscrit. Je remercie également très chaleureusement Philippe Chevrel, Naïma Ait Oufroukh et Jimmy Lauber d'avoir fait l'honneur de participer à mon jury de thèse.

Je tiens à exprimer ma gratitude envers tout le personnel du Laboratoire d'Automatique, Mécanique et Informatique Industrielle et Humaine (LAMIH UMR-CNRS 8201), où cette thèse a été réalisée. Leur contribution a grandement facilité mon travail en créant des conditions de travail exceptionnelles.

J'adresse également mes remerciements à mes amis et mes collègues du bureau, notamment Abdou, Fares, Yikai, Amel, Toufik, Gabriele, Daniel, Mohamed, Hossam, et bien d'autres pour les moments partagés.

Les mots me manquent pour exprimer la profonde gratitude que je ressens envers le dévouement et les sacrifices consentis par ma famille. C'est avec une grande émotion que je dédie ce travail à ma chère mère, Sadjia, à mes chères sœurs, Sarra, Nouha, et Nada, ainsi qu'à mon petit frère, Wail. Leur amour inconditionnel et leur soutien continu sont les forces qui m'ont poussé à persévérer et à surmonter les difficultés et les obstacles jusqu'à ce jour.

Je tiens à exprimer ma profonde gratitude envers ma merveilleuse épouse, Samah. Ta patience, ta compréhension et ta présence constante ont été les piliers de ma réussite. Merci d'avoir été à mes côtés à chaque étape de ce parcours.

Je tiens à exprimer ma gratitude envers toutes les personnes qui ont contribué, de près ou de loin, à cette réussite.

Table des matières

| | | |
|----------|---|-----------|
| 1 | Etat de l'art | 32 |
| 1.1 | Introduction | 33 |
| 1.2 | L'automatisation de la conduite automobile | 33 |
| 1.2.1 | Les systèmes avancés d'aide à la conduite (ADAS) | 34 |
| 1.2.2 | La taxonomie SAE des systèmes de conduite automatisée | 34 |
| 1.3 | Impact de l'automatisation de la conduite automobile sur le conducteur | 36 |
| 1.3.1 | Charge de travail mentale | 37 |
| 1.3.2 | Les transitions de contrôle | 39 |
| 1.3.3 | La conscience de la situation | 40 |
| 1.3.4 | La confiance | 40 |
| 1.4 | La coopération entre le conducteur et le véhicule automatisé | 41 |
| 1.4.1 | Vers une automatisation centrée sur l'humain | 41 |
| 1.4.2 | L'intégration de l'apprentissage automatique pour améliorer les interactions humain-véhicule | 43 |
| 1.4.3 | Modèles coopératifs pour l'interaction humain-système dans la conduite automatisée | 45 |
| 1.5 | Les projets en europe sur le développement de véhicules autonomes | 49 |
| 1.6 | Architecture hiérarchique pour la coopération conducteur-véhicule automatisé | 51 |
| 1.6.1 | L'activité de conduite automobile et sa décomposition hiérarchique | 51 |
| 1.6.2 | Les limitations des architectures de coopération existantes | 53 |
| 1.6.3 | Une architecture de coopération auto-adaptative entre le conducteur et le véhicule automatisé | 55 |
| 1.6.3.1 | Le niveau stratégique : | 55 |
| 1.6.3.2 | Le niveau tactique : | 55 |
| 1.6.3.3 | Le niveau opérationnel : | 57 |
| 1.7 | Cas d'usage traité dans le cadre de la thèse | 57 |
| 1.8 | Simulateur de conduite SHERPA-LAMIH | 58 |
| 1.9 | Conclusion | 58 |
| 2 | Prise de décision et planification de trajectoire personnalisées | 61 |
| 2.1 | Introduction | 62 |
| 2.2 | Etat de l'art | 62 |
| 2.3 | Contribution | 62 |
| 2.4 | La prise de décision sur la manœuvre | 64 |
| 2.4.1 | Etat de l'art | 64 |
| 2.4.2 | La prise de décision de changement de voie | 65 |
| 2.4.2.1 | Calcul du risque | 65 |
| 2.4.2.2 | Évaluation de la conformité légale | 66 |
| 2.4.2.3 | Condition d'apprentissage | 67 |
| 2.4.2.4 | Attribution des coûts | 68 |
| 2.4.2.5 | Sélection de la meilleure voie | 68 |

| | | |
|----------|--|-----------|
| 2.4.3 | Validation expérimentale | 68 |
| 2.5 | La planification de trajectoire | 69 |
| 2.5.1 | Etat de l'art | 70 |
| 2.5.2 | La planification de trajectoire latérale | 71 |
| 2.5.2.1 | Validation expérimentale | 72 |
| 2.5.3 | La planification de trajectoire longitudinale | 72 |
| 2.5.3.1 | Validation expérimentale | 74 |
| 2.6 | Détection de l'intention du conducteur | 75 |
| 2.6.1 | Etat de l'art | 75 |
| 2.6.2 | Détection d'intention au changement de voie | 76 |
| 2.6.3 | Validation expérimentale | 77 |
| 2.7 | L'algorithme d'apprentissage pour la personnalisation | 79 |
| 2.7.1 | État de l'art | 79 |
| 2.7.2 | L'approche de descente de gradient stochastique (SGD) dans les réseaux de neurones | 80 |
| 2.7.3 | Application de l'algorithme SGD pour la personnalisation des LCAS | 81 |
| 2.7.3.1 | Identification des paramètres du conducteur pour les changements de voie | 82 |
| 2.7.3.2 | Validation expérimentale | 85 |
| 2.7.4 | Le système de prise de décision pour l'apprentissage | 86 |
| 2.7.4.1 | Validation expérimentale | 91 |
| 2.8 | Conclusion | 92 |
| 3 | Contrôle partagé adaptatif basé sur une approche LPV avec fonction de coût multi-objectif | 95 |
| 3.1 | Introduction | 96 |
| 3.2 | Le contrôle partagé | 96 |
| 3.2.1 | Les définitions de contrôle partagé | 96 |
| 3.2.2 | Les modèles de contrôle partagé | 97 |
| 3.2.3 | Les stratégies de contrôle partagé dans la littérature pour résoudre les problèmes de conflit | 97 |
| 3.3 | Contribution | 100 |
| 3.4 | Superviseur de conduite pour la gestion du niveau de partage | 101 |
| 3.4.1 | Activité du conducteur (DA) | 101 |
| 3.4.1.1 | DA "Sous-charge" | 102 |
| 3.4.1.2 | DA "Charge normale" | 103 |
| 3.4.1.3 | DA "Surcharge" | 104 |
| 3.4.2 | Niveau d'assistance dynamique | 106 |
| 3.5 | Modélisation de la dynamique du système Véhicule-Route | 106 |
| 3.5.1 | Le système Véhicule-Route | 106 |
| 3.5.2 | Validation du Modèle Véhicule-Route sur SHERPA | 108 |
| 3.6 | Préliminaires sur la modélisation TS et l'étude de leur stabilité | 110 |
| 3.6.1 | Préliminaires sur la modélisation TS | 111 |
| 3.6.2 | Stabilité et stabilisation des systèmes TS | 113 |
| 3.6.2.1 | Stabilité d'un modèle TS | 113 |
| 3.6.2.2 | Stabilisation d'un modèle TS | 114 |
| 3.7 | La conception du contrôleur partagé adaptatif LPV-TS | 115 |
| 3.7.1 | Représentation TS du Modèle Véhicule-Route | 115 |
| 3.7.1.1 | Validation du modèle TS sur SHERPA | 116 |
| 3.7.2 | Conception du contrôleur partagé basée sur l'approche PDC | 116 |
| 3.7.3 | Analyse de la stabilité | 119 |
| 3.8 | Validation expérimentale | 119 |

| | | |
|----------|--|------------|
| 3.8.1 | Performance du contrôleur LKS en mode de conduite autonome | 120 |
| 3.8.2 | Performance du contrôle partagé adaptatif | 120 |
| 3.8.3 | Prise en compte du risque dans le contrôle partagé adaptatif | 122 |
| 3.8.4 | Expériences de test utilisateurs | 123 |
| 3.8.4.1 | Evaluation objective | 124 |
| 3.8.4.2 | Evaluation subjective | 125 |
| 3.9 | Conclusion | 126 |
| 4 | Contrôle partagé basé sur l'identification en ligne des paramètres d'un modèle de conducteur | 129 |
| 4.1 | Introduction | 130 |
| 4.2 | Les stratégies de contrôle partagé basées sur un modèle conducteur | 130 |
| 4.3 | Contribution | 132 |
| 4.4 | Dynamique Conducteur-Véhicule-Route | 133 |
| 4.4.1 | Dynamique Véhicule-Route | 133 |
| 4.4.2 | Etat de l'art sur les modèles conducteur | 133 |
| 4.4.2.1 | Le système visuel | 136 |
| 4.4.2.2 | Le système neuromusculaire | 138 |
| 4.4.2.3 | Un modèle conducteur simplifié | 138 |
| 4.4.3 | Modèle intégré LPV CVR | 139 |
| 4.5 | Identification en ligne des paramètres du conducteur | 140 |
| 4.5.1 | Processus d'identification en ligne des paramètres du conducteur à l'aide de l'approche MRIL | 140 |
| 4.5.2 | Validation du modèle conducteur proposé par simulation numérique et interactive sur le simulateur SHERPA | 142 |
| 4.5.2.1 | Comparaison entre l'approche d'identification proposée (MRIL) et l'approche RLS | 142 |
| 4.5.2.2 | Validation et analyse du modèle conducteur sur différents parcours | 143 |
| 4.5.3 | Validation du modèle CVR sur SHERPA | 144 |
| 4.6 | La conception du contrôleur partagé adaptatif basé sur la dynamique du conducteur | 145 |
| 4.6.1 | Représentation LPV-TS du Modèle augmenté Conducteur-Vehicule-Route | 146 |
| 4.6.1.1 | Validation du modèle augmenté LPV-TS sur SHERPA | 148 |
| 4.6.2 | Conception du contrôleur partagé basée sur l'approche PDC | 150 |
| 4.6.3 | Analyse de la stabilité | 151 |
| 4.7 | Validation expérimentale | 152 |
| 4.7.1 | Performance du contrôle partagé adaptatif | 152 |
| 4.7.2 | Evaluation objective | 154 |
| 4.8 | Conclusion | 155 |
| 5 | Contrôle partagé adaptatif LPV basé sur l'impédance du conducteur et une fonction de coût multi-objectif | 158 |
| 5.1 | Introduction | 159 |
| 5.2 | Contribution | 159 |
| 5.3 | Activité du conducteur & niveau d'assistance variable | 160 |
| 5.4 | Dynamique Conducteur-Véhicule-Route | 160 |
| 5.4.1 | Modèle d'interaction dynamique du conducteur | 161 |
| 5.4.2 | Modèle Intégré CVR | 162 |
| 5.5 | Approche d'identification en ligne de l'impédance du conducteur | 162 |
| 5.5.1 | Le processus d'identification en ligne de l'impédance du conducteur avec l'approche MRIL | 162 |
| 5.5.1.1 | Validation du modèle d'interaction dynamique du conducteur . . | 164 |
| 5.5.2 | Validation du modèle CVR | 166 |

| | | |
|---------|--|------------|
| 5.6 | Conception du contrôleur partagé haptique LPV basé sur l'impédance du conducteur | 166 |
| 5.6.1 | Représentation TS du Modèle Conducteur-Véhicule-Route | 168 |
| 5.6.1.1 | Validation du modèle augmenté TS | 169 |
| 5.6.2 | Conception du contrôleur PDC pour le contrôle partagé haptique LPV . . | 169 |
| 5.6.3 | Analyse de la stabilité | 173 |
| 5.7 | Validation expérimentale | 174 |
| 5.7.1 | Les performances du contrôle partagé LPV multi-objectif | 174 |
| 5.7.2 | Expériences de test utilisateur | 176 |
| 5.7.2.1 | Evaluation objective | 177 |
| 5.7.2.2 | Evaluation subjective | 177 |
| 5.8 | Conclusion | 179 |
| | Conclusion générale et Perspectives | 181 |
| | Conclusion générale | 181 |
| | Perspectives | 182 |
| | Références | 184 |

Table des figures

| | | |
|------|---|----|
| 1.1 | La taxonomie SAE des systèmes de conduite automatisée [SAE, 2021]. | 35 |
| 1.2 | Loi de Yerkes-Dodson adoptée dans le cadre de la conduite assistée [Nguyen et al., 2017]. | 39 |
| 1.3 | Les différentes étapes de traitement de l’information où la répartition des responsabilités entre l’humain et le système a lieu [Parasuraman et al., 2000]. | 42 |
| 1.4 | La ”H-Metaphor” du (cavalier-cheval) adaptée au contrôle partagé (conducteur-système) pour les véhicules automatisés [Flemisch et al., 2003]. | 46 |
| 1.5 | Modèle de coopération basée sur l’intention [Bauer et al., 2008]. | 47 |
| 1.6 | Cadre général pour la transition d’état dans la conduite automatisée [Lu et al., 2016]. | 48 |
| 1.7 | Apprentissage du processus de coopération pour la conduite automatisée [Vanderaegen, 2012]. | 49 |
| 1.8 | Illustration simplifiée des trois niveaux de performance des opérateurs humains compétents [Rasmussen, 1983]. | 51 |
| 1.9 | La structure hiérarchique de la tâche de conduite [Michon, 1985]. | 52 |
| 1.10 | Une architecture de coopération multi-niveaux entre le conducteur et un système de conduite automatisée [Benloucif et al., 2016]. | 53 |
| 1.11 | Une architecture de coopération multi-niveaux auto-adaptative entre le conducteur et le véhicule automatisé. | 56 |
| 1.12 | La prise de décision et la planification de trajectoire pour les véhicules intelligents dans les scénarios de changement de voie. | 58 |
| 1.13 | Le simulateur de conduite SHERPA-LAMIH. | 59 |
| 2.1 | Système de prise de décision et planification de trajectoires personnalisées. | 63 |
| 2.2 | La procédure de prise de décision pour effectuer un changement de voie. | 65 |
| 2.3 | Une illustration de la scène de conduite. | 66 |
| 2.4 | Scénario de changement de voie vers la gauche : évolution des fonctions de coût pour chaque voie et la prise de décision du système. | 68 |
| 2.5 | Scénario de changement de voie vers la droite : évolution des fonctions de coût pour chaque voie et la prise de décision du système. | 69 |
| 2.6 | L’impact de la valeur du seuil de décision de changement de voie à gauche ($\%TIV_1$) sur la décision prise par le système. | 70 |
| 2.7 | L’impact de la position cible (y_{r_1}) et du temps d’accomplissement de la manœuvre de changement de voie vers la gauche (T_{y_1}) sur la trajectoire planifiée. | 73 |
| 2.8 | L’impact de la durée de la manœuvre de changement de voie (T_{y_1}) sur le comportement longitudinal du véhicule. | 74 |
| 2.9 | Représentation de l’environnement pour la détection de l’intention. | 76 |
| 2.10 | Les performances du système de détection de l’intention de changement de voie. | 78 |
| 2.11 | Illustration d’un réseau de neurones. | 80 |
| 2.12 | L’algorithme de descente de gradient stochastique (SGD) est employé pour adapter les poids d’un réseau de neurones. | 81 |

| | | |
|------|--|-----|
| 2.13 | La représentation des paramètres du système d'aide au changement de voie sous la forme d'un réseau de neurones. | 82 |
| 2.14 | L'algorithme de descente de gradient stochastique (SGD) est utilisé pour ajuster les paramètres du système d'aide au changement de voie. | 83 |
| 2.15 | Aperçu de la méthode d'apprentissage SGD pour la prise de décision des manœuvres et la planification de trajectoires. | 85 |
| 2.16 | L'évolution des paramètres du système de prise de décision des manœuvres (DMSP) et de la planification de trajectoires (PPP) avant, pendant et après l'apprentissage par rapport à ceux des conducteurs pour le changement de voie vers la gauche. | 86 |
| 2.17 | L'évolution des paramètres du système de prise de décision des manœuvres (DMSP) et de la planification de trajectoires (PPP) avant, pendant et après l'apprentissage par rapport à ceux des conducteurs pour le changement de voie vers la droite. | 87 |
| 2.18 | La performance du système de prise de décision de changement de voie en mode automatique avant et après l'apprentissage, comparée à la décision du conducteur en mode manuel. | 87 |
| 2.19 | La performance du système de planification de trajectoires en mode automatique avant et après l'apprentissage, comparée à la trajectoire réalisée par le conducteur en mode manuel. | 88 |
| 2.20 | Le système de surveillance du conducteur de la société Continental Automotive basé sur un système de caméra. | 89 |
| 2.21 | L'algorithme de descente de gradient stochastique adaptatif (ASGD) est utilisé pour ajuster les paramètres du système d'aide au changement de voie en tenant compte de la décision d'apprentissage. | 90 |
| 2.22 | Aperçu de la méthode d'apprentissage ASGD pour la prise de décision des manœuvres et la planification de trajectoires. | 90 |
| 2.23 | L'évolution des paramètres du conducteur lors de la manœuvre de changement de voie vers la gauche, ainsi que les variations de la vitesse longitudinale du véhicule et la décision prise par le mécanisme de décision d'apprentissage. | 91 |
| 2.24 | L'évolution des paramètres du système de prise de décision des manœuvres (DMSP) et de la planification de trajectoires (PPP) pendant l'apprentissage par rapport à ceux du conducteur pour le changement de voie vers la gauche. | 92 |
| 3.1 | Le contrôle latéral partagé basé sur la planification de trajectoire [Benloucif et al., 2019a]. | 98 |
| 3.2 | Architecture de la stratégie de contrôle coopératif adaptée au style du conducteur [Rath et al., 2019]. | 99 |
| 3.3 | Le schéma de contrôle latéral partagé proposé dans [Mars et al., 2014]. | 99 |
| 3.4 | La Stratégie de Contrôle Partagé Adaptatif. | 100 |
| 3.5 | L'illustration de la relation entre l'activité et les performances du conducteur, ainsi que le niveau d'assistance requis. | 102 |
| 3.6 | Système de Surveillance du Conducteur (DMS). | 103 |
| 3.7 | Variation de l'activité du conducteur en fonction de la charge mentale (DS , HD), de la charge physique \mathcal{T}_{dN} ainsi que du risque. | 105 |
| 3.8 | La représentation du modèle de bicyclette. | 107 |
| 3.9 | Le circuit d'essai situé à Satory et les paramètres de courbure associés à ses virages. | 109 |
| 3.10 | Analyse comparative entre les sorties du modèle de véhicule proposé et les données recueillies sur SHERPA-LAMIH. | 109 |
| 3.11 | Écart entre les prédictions du modèle proposé et les données enregistrées sur SHERPA-LAMIH. | 110 |
| 3.12 | Analyse comparative entre les sorties du modèle TS de véhicule proposé et les données recueillies sur SHERPA-LAMIH. | 117 |

| | | |
|------|--|-----|
| 3.13 | Écart entre les prédictions du modèle TS proposé et les données enregistrées sur SHERPA-LAMIH. | 117 |
| 3.14 | Performances du système de maintien de voie (LKS) pour un scénario de vitesse variable. | 121 |
| 3.15 | Performance du système de maintien de voie (LKS) obtenue sur le simulateur SHERPA dans un scénario de perturbation due au vent latéral. | 121 |
| 3.16 | Les performances du contrôleur partagé avec et sans la fonction de coût adaptative lors d'un test d'évitement d'obstacles sur le simulateur SHERPA. | 122 |
| 3.17 | Scénario de changement de voie risqué et non risqué. | 122 |
| 3.18 | Performances du contrôle partagé pour un scénario de changement de voie risqué et non risqué. | 123 |
| 3.19 | Résultats de l'évaluation objective du contrôleur partagé avec une fonction de coût dynamique et constante pour un scénario d'évitement d'obstacles. | 125 |
| 3.20 | Résultats de l'évaluation subjective du contrôleur partagé avec une fonction de coût dynamique et constante pour un scénario d'évitement d'obstacles. | 126 |
| 3.21 | Résultats globaux des performances du contrôleur partagé conçu à l'aide d'une fonction de coût constante et dynamique pour un scénario d'évitement d'obstacles. | 127 |
| | | |
| 4.1 | Le jeu différentiel comme modèle du problème de contrôle partagé de la direction [Flad et al., 2017]. | 131 |
| 4.2 | Contrôle latéral LPV pour les systèmes avancés d'assistance à la conduite basé sur les performances du conducteur [Medero et al., 2022]. | 131 |
| 4.3 | Contrôle partagé basé sur la théorie de contrôle $H_2 - Preview$ [Saleh et al., 2013]. | 132 |
| 4.4 | Architecture du contrôle partagé basé sur l'identification en ligne des paramètres d'un modèle de conducteur. | 133 |
| 4.5 | Modèle conducteur à deux niveaux combinant des structures de contrôle anticipatoire en boucle ouverte et de contrôle compensatoire en boucle fermée [Donges, 1978]. | 134 |
| 4.6 | La structure du modèle conducteur [Sentouh et al., 2009]. | 135 |
| 4.7 | Modèle cybernétique du conducteur [Saleh et al., 2011]. | 135 |
| 4.8 | Modèle de conducteur basé sur un réseau de files d'attente (Queuing Network "QN") [Bi et al., 2015]. | 136 |
| 4.9 | Architecture du modèle de conducteur proposé. | 137 |
| 4.10 | Angles visuels pour les comportements anticipatifs et compensatoires [Sentouh et al., 2009]. | 137 |
| 4.11 | Architecture simplifiée du modèle de conducteur proposé. | 139 |
| 4.12 | Diagramme représentant l'approche d'identification en ligne des paramètres du conducteur (approche MRIL). | 141 |
| 4.13 | Architecture pour la comparaison des deux approches d'identification (RLS et MRIL). | 143 |
| 4.14 | Les résultats de l'identification paramétrique par les deux approches (RLS et MRIL). | 143 |
| 4.15 | La trajectoire et la courbure pour la piste d'autoroute et la piste de Satory. | 144 |
| 4.16 | Les résultats de l'approche d'identification en ligne des paramètres du conducteur sur la piste de Satory (a.1 et a.2) et sur la piste d'autoroute (b.1 et b.2) pour le test de maintien de voie sur le simulateur SHERPA. | 145 |
| 4.17 | Analyse comparative entre les sorties du modèle augmenté Conducteur-Véhicule-Route proposé et les données recueillies sur SHERPA-LAMIH. | 146 |
| 4.18 | Écart entre les prédictions du modèle augmenté Conducteur-Véhicule-Route proposé et les données enregistrées sur SHERPA-LAMIH. | 146 |
| 4.19 | Les résultats de l'identification en ligne des paramètres du modèle du conducteur ainsi que la variation de la vitesse du véhicule sur le simulateur SHERPA-LAMIH. | 149 |

| | | |
|------|---|-----|
| 4.20 | Comparaison entre les sorties du modèle augmenté LPV-TS du véhicule et les données obtenues à partir du simulateur SHERPA-LAMIH. | 149 |
| 4.21 | Écart entre les prédictions du modèle augmenté LPV-TS proposé et les données enregistrées sur SHERPA-LAMIH. | 150 |
| 4.22 | Les performances du contrôleur partagé basé sur les paramètres constants et dynamiques du conducteur lors d'un test d'évitement d'obstacles sur le simulateur SHERPA-LAMIH. | 153 |
| 4.23 | Les performances du contrôleur partagé basé sur les paramètres constants et dynamiques du conducteur lors d'un test d'évitement d'obstacles sur le simulateur SHERPA-LAMIH pour le premier conducteur. | 154 |
| 4.24 | Résultats de l'évaluation objective du contrôleur partagé basé sur les paramètres du conducteur constants et dynamiques, lors d'un test d'évitement d'obstacles sur le simulateur SHERPA. | 155 |
| 5.1 | La stratégie de contrôle partagé adaptatif multi-objectif et coopératif. | 159 |
| 5.2 | Modèle d'interaction dynamique du conducteur. | 161 |
| 5.3 | Schéma de l'approche d'identification en ligne de l'impédance du conducteur. | 163 |
| 5.4 | Les résultats de l'identification en ligne de paramètre du conducteur en utilisant le système LKS pour l'évitement d'obstacles sur le simulateur SHERPA. | 164 |
| 5.5 | Les résultats de l'identification en ligne de paramètre du conducteur en utilisant le système d'assistance DAE pour l'évitement d'obstacles sur le simulateur SHERPA. | 165 |
| 5.6 | Les résultats de l'identification en ligne des paramètres du conducteur en mode manuel et sans assistance pour l'évitement d'obstacles sur le simulateur SHERPA. | 165 |
| 5.7 | Les résultats de l'identification en ligne des paramètres du modèle du conducteur, ainsi que les variations de la vitesse du véhicule, dans le scénario de maintien de voie sur la piste de Satory. | 166 |
| 5.8 | Comparaison entre les sorties du modèle Conducteur-Véhicule-Route et les données obtenues à partir du simulateur SHERPA-LAMIH, dans le scénario de maintien de voie sur la piste de Satory. | 167 |
| 5.9 | Écart entre les prédictions du modèle Conducteur-Véhicule-Route proposé et les données enregistrées sur SHERPA-LAMIH, dans le scénario de maintien de voie sur piste de Satory. | 167 |
| 5.10 | Les résultats de l'identification en ligne de la rigidité (impédance) du conducteur, ainsi que les variations de la vitesse du véhicule, dans le scénario de changement de voie sur le simulateur SHERPA-LAMIH. | 170 |
| 5.11 | Analyse comparative entre les sorties du modèle augmenté de type TS et les données recueillies à partir du simulateur SHERPA-LAMIH, dans le contexte du scénario de changement de voie. | 170 |
| 5.12 | Différences entre les prédictions du modèle augmenté de type TS proposé et les données enregistrées sur le simulateur SHERPA-LAMIH dans le contexte du scénario de changement de voie. | 171 |
| 5.13 | Les trois situations de changement de voie (risquées et non risquées). | 174 |
| 5.14 | Les performances du contrôle partagé multi-objectif proposé dans des scénarios de changement de voie avec différentes situations de risque réalisés sur le simulateur SHERPA. | 175 |
| 5.15 | Les résultats de l'évaluation objective du contrôle partagé en utilisant quatre stratégies différentes dans le contexte d'un scénario d'évitement d'obstacles. | 177 |
| 5.16 | Les résultats de l'évaluation subjective du contrôle partagé en utilisant quatre stratégies différentes dans le contexte d'un scénario d'évitement d'obstacles. | 178 |
| 5.17 | Les résultats globaux des performances du contrôle partagé en utilisant quatre stratégies différentes dans le contexte d'un scénario d'évitement d'obstacles. | 178 |

Liste des tableaux

| | | |
|-----|--|-----|
| 1.1 | L'ADAS dans les véhicules utilitaires. | 37 |
| 2.1 | Les performances du système de détection pour les changements de voie réalisés vers la gauche (LCL) et vers la droite (LCR) dans les quatre scénarios. | 78 |
| 3.1 | La disponibilité des différents indicateurs d'activité du conducteur dans les trois régions. | 105 |
| 3.2 | Les valeurs numériques des paramètres du modèle du véhicule. | 120 |
| 4.1 | Les limites minimales et maximales de chaque paramètre pour chaque scénario. . | 148 |
| 4.2 | Les valeurs numériques des paramètres pour le modèle mathématique du véhicule SHERPA-LAMIH et du conducteur. | 153 |
| 5.1 | Les limites minimales et maximales de la rigidité du conducteur θ_s pour chaque scénario. | 169 |
| 5.2 | Les valeurs numériques des paramètres du modèle du véhicule et du conducteur. . | 174 |

Glossaire

Liste des abréviations

| Acronyme | Désignation |
|--------------------------|--|
| <i>ADAS</i> | Advanced Driver Assistance Systems |
| <i>LCAS</i> | Lane Change Assist System |
| <i>LKS</i> | Lane Keeping System |
| <i>ABS</i> | Anti-lock Braking System |
| <i>DAE</i> | Direction Assistée Electrique |
| <i>SAE</i> | Society of Automotive Engineers |
| <i>ACC</i> | Adaptive Cruise Control |
| <i>LKA</i> | Lane Keeping Assist |
| <i>DMS</i> | Decision Making System |
| <i>DMSP</i> | Decision Making System Parameters |
| <i>PPP</i> | Path Planing Parameters |
| <i>IDM</i> | Intelligent Driver Model |
| <i>TIV</i> | Time Inter-Vehicle |
| <i>DIV</i> | Distance Inter-Vehicle |
| <i>DLC_{int}</i> | Driver Lane Change Intention |
| <i>DR</i> | Detection Rate |
| <i>TBD</i> | Time Before Detection |
| <i>TDLC</i> | Time from Detection to Lane Crossing |
| <i>HMI</i> | Human Machine Interaction |
| <i>SGD</i> | Stochastic Gradient Descent |
| <i>ASGD</i> | Adaptive Stochastic Gradient Descent |
| <i>SHERPA</i> | Simulateur Hybride d'Etude et de Recherche Pour l'Automobile |
| <i>CVR</i> | Conducteur-Véhicule-Route |
| <i>LPV</i> | Linear parameter varying |
| <i>TS</i> | Takagi-Sugeno |
| <i>DS</i> | Driver State |
| <i>HD</i> | Hand Detection |
| <i>DA</i> | Driver Activity |
| <i>DiL</i> | Driver in the Loop |
| <i>LMI</i> | Linear Matrix Inequality |

Notations

| Symbole | Dénomination |
|-----------------|---|
| m | Masse totale de véhicule |
| I_z | Moment d'inertie de lacet du véhicule |
| l_f | Distance du centre de gravité à l'essieu avant |
| l_r | Distance du centre de gravité à l'essieu arrière |
| F_{yf} | Force latérale au niveau des roues avant |
| F_{yr} | Force latérale au niveau des roues arrière |
| f_w | Force latérale du vent |
| C_f | Coefficient de raideur des pneus avant |
| C_r | Coefficient de raideur des pneus arrière |
| B_s | Coefficient d'amortissement équivalent de la colonne de direction |
| J_s | Moment d'inertie équivalent du système de direction |
| R_s | Rapport de réduction de la direction |
| η_t | Largeur de contact du pneu |
| ρ_c | Courbure de la route |
| β | Angle de dérive au centre de gravité |
| r | Vitesse de lacet du véhicule |
| y_l | Ecart latéral du véhicule par rapport au centre de la voie |
| ψ_l | Angle de cap relatif |
| δ_d | Angle au volant |
| δ | Angle de braquage des roues avant |
| v_x | Vitesse longitudinale du véhicule |
| T_d | Couple du conducteur |
| T_a | Couple d'assistance |
| T_s | Couple d'auto-alignement |
| θ_{near} | Angle de compensation visuelle |
| θ_{far} | Angle d'anticipation visuelle |
| k_1 | Dynamique compensatoire du conducteur |
| k_2 | Dynamique anticipatoire du conducteur |
| k_3, θ_s | Dynamique de la raideur du conducteur |
| T_n | Constante de temps neuromusculaire |

Introduction générale

La sécurité des véhicules et des passagers reste un problème critique et récurrent tant pour les autorités publiques que les constructeurs et les équipementiers automobile. Parmi les moyens et technologies mises en œuvre, de nombreuses études montrent que le déploiement à grande échelle des systèmes avancés d'aide à la conduite (ADAS) puis des véhicules autonomes devrait largement contribuer à l'amélioration de la sécurité routière. Depuis maintenant une dizaine d'année, de nombreuses fonctions d'aide à la conduite ont été commercialisées et embarquées dans les véhicules. Des véhicules autonomes de niveau 2 et 3, selon la classification SAE (Society of Automotive Engineers), sont aussi déjà commercialisés. Toutefois ceux-ci ne sont pour l'instant capables de gérer que des situations relativement simples de contrôle latéral et longitudinal, principalement dans des situations autoroutières ou sur routes ouvertes. Malgré l'intégration croissante des ADAS et le développement des véhicules autonomes, le conducteur conservera encore pour longtemps un rôle central dans les tâches de conduite et de supervision et sera amené à interagir très souvent avec ces fonctions d'assistance. L'expérience a montré que ces systèmes soulèvent de nouvelles problématiques en termes de sécurité et d'acceptabilité pour le conducteur. En effet, dans un contexte où l'automatisation reste imparfaite, il est essentiel de s'assurer que ce nouveau type de mobilité tienne compte aussi bien des attentes du conducteur que des modifications prévisibles de la nature de la tâche et de l'activité de conduite de ce dernier. Le déploiement des véhicules automatisés ne sera vraiment efficace et accepté par les conducteurs que lorsqu'il correspondra aux besoins des conducteurs, de leurs aptitudes et capacités mais aussi lorsqu'ils apporteront des assistances adaptées grâce à un design centré sur l'humain. Il est donc nécessaire d'intégrer, dès la conception du système, la problématique des interactions avec le conducteur en résolvant les problèmes de partage de la commande entre le système de conduite automatisée et le conducteur et de la gestion de l'autorité, mais aussi la problématique liée à la personnalisation de ces systèmes.

Problématique :

L'aspiration à une personnalisation accrue de l'expérience de conduite soulève des questions quant à la manière de concevoir et d'intégrer de manière transparente des systèmes personnalisables dans les véhicules autonomes. Comment garantir une interaction harmonieuse entre l'humain et le système automatisé tout en répondant aux attentes individuelles des conducteurs en matière de conduite, de confort, et de sécurité ? et comment gérer les conflits entre le système et le conducteur en contrôle partagé ?

Dans ce contexte complexe, cette thèse s'inscrit au sein du projet ANR_CoCoVeIA (2019-2024) (Coopération Conducteur-Véhicule Intelligent Autonome), coordonné par le LAMIH. L'objectif principal de ce projet est d'intégrer des capacités d'auto-apprentissage dans un système coopératif destiné aux véhicules autonomes de niveau 2. Cette démarche vise à améliorer les compétences des systèmes automatisés, en leur permettant d'apprendre de manière optimale à effectuer des manœuvres spécifiques tout en respectant les règles de circulation et de sécurité.

Cette thèse se concentre sur l'interaction progressive entre le système et le conducteur lors de

la conduite partagée ou manuelle, dans le but d'améliorer l'efficacité du système et de garantir une meilleure acceptation par le conducteur. Elle vise à atteindre les objectifs suivants :

- Favoriser le développement d'automatismes en imitant les comportements humains, tout en garantissant la sécurité. Cela implique l'intégration de capacités d'auto-apprentissage dans le système, lui permettant d'acquérir des réactions similaires à celles d'un conducteur expérimenté dans différentes situations de conduite.
- Gérer les conflits entre le système et le conducteur. Lorsque le système automatisé prend le contrôle de la conduite, il peut y avoir des moments où le conducteur et le système prennent des actions ou des décisions contradictoires. L'objectif essentiel est de développer des mécanismes pour résoudre ces conflits de manière sécurisée et efficace, en tenant compte à la fois de la sécurité et des préférences du conducteur.
- Permettre aux conducteurs de développer leur confiance envers le véhicule grâce à leur expérience de conduite. Le système coopératif devrait s'adapter aux préférences et aux habitudes de conduite de chaque conducteur, renforçant ainsi leur confiance dans le système automatisé.
- Personnaliser le fonctionnement des automatismes en fonction des préférences de chaque conducteur. Il est crucial de prendre en compte les préférences individuelles en matière de conduite, de confort et de sécurité, et d'adapter les fonctionnalités automatisées en conséquence pour optimiser l'expérience de conduite de chaque conducteur.

Afin de relever ces défis, une architecture auto-adaptative de la coopération entre l'humain et le véhicule a été élaborée, mettant en avant des niveaux stratégiques, tactiques et opérationnels cruciaux. Chaque niveau remplit un rôle spécifique dans la prise de décisions, la planification des manœuvres et l'exécution du contrôle, contribuant ainsi à renforcer la sécurité et l'efficacité de la conduite.

Les principales contributions de cette thèse sont les suivantes :

- Architecture de coopération auto-adaptative à plusieurs niveaux : Cette thèse présente une architecture visant à améliorer l'interaction entre le conducteur et le véhicule autonome de niveau 2. Cette architecture adapte le comportement du véhicule en fonction du style de conduite préféré du conducteur tout en garantissant la sécurité et l'efficacité de la conduite. Cette approche vise à optimiser l'interaction homme-machine et à renforcer l'acceptabilité du système.
- Personnalisation des systèmes d'assistance au changement de voie : La thèse développe une méthode d'apprentissage basée sur la descente de gradient stochastique (SGD) pour personnaliser les systèmes d'assistance au changement de voie en fonction des préférences du conducteur. Elle repose sur la détection des intentions de changement de voie du conducteur, ce qui contribue à améliorer l'efficacité de la conduite.
- Résolution des conflits conducteur-système autonome : La thèse explore trois approches de commande optimale robuste pour résoudre les conflits entre le conducteur et le système de conduite autonome. Ces approches utilisent des modèles linéaires à paramètres variants (LPV) représentés sous la forme floue Takagi-Sugeno (T-S) et adoptent des techniques de contrôle adaptatif afin d'assurer une conduite sûre et confortable. La première approche se concentre sur le contrôle partagé adaptatif en ajustant une fonction de coût multi-objectif en temps réel en fonction de la disponibilité du conducteur et de l'évaluation du risque. La deuxième approche introduit un modèle dynamique du conducteur, dont les paramètres sont identifiés en ligne grâce à une nouvelle méthode d'identification appelée MRIL (Model Reference Identification-based Lyapunov approach). Cette approche permet une adaptation continue aux spécificités individuelles du conducteur. La dynamique des paramètres neuromusculaires du modèle conducteur est utilisée pour développer un système de contrôle partagé adaptatif pour le maintien de voie. Enfin, la dernière ap-

proche vise à éliminer complètement les conflits entre le conducteur et le système de maintien de voie en combinant une fonction de coût adaptative et multi-objectif avec l'intégration d'un modèle dynamique du comportement du conducteur pour tenir compte de son impédance lors de l'interaction avec le volant, dans le but de personnaliser l'interaction conducteur-LKS.

- Conditions de stabilité et optimisation : La thèse établit des conditions de stabilité en boucle fermée pour le contrôle partagé adaptatif (LPV) à l'aide d'arguments de stabilité de Lyapunov. Elle formule ces conditions sous forme d'un problème d'optimisation d'inégalités matricielles linéaires (LMI), qui peuvent être résolues numériquement à l'aide d'algorithmes d'optimisation convexe. Cette étape est essentielle pour garantir la stabilité du système lors de l'interaction conducteur-système autonome.
- Validation expérimentale et acceptabilité : La thèse mène des validations expérimentales et des expériences de test utilisateurs à l'aide du simulateur de conduite dynamique SHERPA-LAMIH. Ces expérimentations visent à évaluer l'acceptabilité des approches proposées, démontrant ainsi leur efficacité pour améliorer la sécurité et le confort de conduite.

Organisation du mémoire

Ce rapport est composé de cinq chapitres :

Chapitre 1 : Etat de l'art

Ce chapitre a permis de dresser un état de l'art concernant la coopération entre le conducteur et les systèmes d'automatisation. Nous avons souligné l'importance cruciale de l'intégration des systèmes d'aide à la conduite avancés (ADAS) et de l'automatisation de la conduite automobile. De plus, nous avons examiné les répercussions de l'automatisation de la conduite sur le conducteur, mettant en évidence la nécessité de développer une approche centrée sur l'humain pour garantir son implication active dans le processus de conduite.

Nous avons également abordé la problématique de la non-personnalisation des systèmes d'assistance à la conduite et souligné son influence sur la coopération entre le conducteur et les systèmes d'automatisation. Afin de résoudre cette problématique, nous avons proposé une architecture de coopération auto-adaptative qui permettrait de mieux adapter les systèmes d'automatisation aux besoins et aux préférences individuelles des conducteurs.

En somme, ce chapitre met en évidence l'importance de développer des approches centrées sur l'humain et personnalisées pour assurer une coopération harmonieuse et efficace entre le conducteur et les systèmes d'automatisation, ouvrant ainsi la voie à des avancées prometteuses dans le domaine de la conduite automobile.

Chapitre 2 : Prise de décision et planification de trajectoire personnalisées

Le deuxième chapitre de la thèse se focalise sur la personnalisation des systèmes d'assistance au changement de voie (LCAS) dans les véhicules automatisés. Il explore comment prendre en compte le comportement et les caractéristiques individuelles de chaque conducteur dans le processus de prise de décision et de planification de trajectoire, en mettant l'accent sur le niveau tactique. La prise de décision du système repose sur des fonctions de coût adaptatives en temps réel qui tiennent compte du risque environnemental, des aspects juridiques, ainsi que d'un terme d'apprentissage. La planification de trajectoire s'appuie sur une planification polynomiale adaptative pour les mouvements latéraux.

Dans ce cadre, une approche d'apprentissage utilisant la descente de gradient stochastique (SDG) est mise en œuvre pour ajuster les paramètres du système en fonction des préférences du conducteur, en se basant sur la détection de ses intentions de changement de voie.

Des validations fonctionnelles ont été réalisées à l'aide du simulateur de conduite dynamique SHERPA-LAMIH pour évaluer l'efficacité de cette approche.

Chapitre 3 : Contrôle partagé adaptatif basé sur une approche LPV avec fonction de coût multi-objectif

Le troisième chapitre présente une nouvelle approche dynamique pour résoudre les conflits dans le contexte du contrôle partagé des systèmes de maintien de voie (LKS) des véhicules intelligents. La conception du contrôle partagé adaptatif repose sur l'ajustement en temps réel d'une fonction de coût multi-objectif, qui tient compte de la disponibilité et de l'activité du conducteur, ainsi que de l'évaluation du risque lié à la situation de conduite. L'intégration efficace de ces informations dans le processus de conception du contrôle partagé haptique pose plusieurs défis théoriques et techniques. Pour la conception du contrôleur partagé T-S LPV, les conditions de stabilité en boucle fermée du contrôle partagé adaptatif (LPV) sont établies en utilisant des arguments de stabilité de Lyapunov, formulées sous forme d'un problème d'optimisation d'inégalités matricielles linéaires (LMI) pouvant être résolues numériquement grâce à des algorithmes d'optimisation convexe.

Chapitre 4 : Contrôle partagé basé sur l'identification en ligne des paramètres d'un modèle de conducteur

Le quatrième chapitre se concentre sur l'introduction d'un modèle dynamique du conducteur, où ses paramètres sont identifiés en temps réel grâce à une nouvelle méthode d'identification basée sur le principe de stabilité de Lyapunov. Cette approche permet de définir un critère d'optimisation visant à minimiser la différence entre les valeurs prédites par le modèle et les mesures réelles. En ajustant itérativement les paramètres, le modèle s'adapte progressivement aux caractéristiques spécifiques du conducteur en temps réel. Par la suite, le modèle "conducteur-véhicule" augmenté, formulé dans le cadre T-S, est utilisé pour développer un système de contrôle partagé adaptatif LPV pour le maintien de voie. L'objectif de cette approche est d'atténuer les éventuels conflits entre les actions du conducteur et celles du système de maintien de voie (LKS) en prenant en compte l'estimation de l'impédance propre à chaque conducteur, en se basant sur la dynamique des paramètres du système neuromusculaire du conducteur.

Chapitre 5 : Contrôle partagé adaptatif LPV basé sur l'impédance du conducteur et une fonction de coût multi-objectif

En ce qui concerne le dernier chapitre, une approche est présentée visant à éliminer entièrement les conflits entre le conducteur et le système LKS en combinant les avantages des deux premières stratégies précédemment proposées. Cette approche intègre l'utilisation d'une fonction de coût adaptative multi-objectif et un modèle dynamique du comportement du conducteur dans le processus de conception du contrôle, ce qui permet de personnaliser davantage la solution en tenant compte de l'interaction du conducteur avec le LKS.

Des validations expérimentales et des tests utilisateurs ont été réalisés à l'aide du simulateur de conduite dynamique SHERPA-LAMIH pour évaluer l'acceptabilité de ces approches. Les résultats ont démontré leur efficacité dans l'amélioration de la sécurité et du confort de conduite, validant ainsi l'ensemble des approches proposées.

Conclusion générale et Perspectives

Pour conclure, le chapitre 6 comprend la conclusion générale du document ainsi que les perspectives de recherche future.

Liste des publications

Reuves internationales avec comité de lecture

- **M. R. Oudainia**, C. Sentouh, A. -T. Nguyen and J. -C. Popieul (2023, accepted), "Adaptive Cost Function-Based Shared Driving Control for Cooperative Lane-Keeping Systems With User-Test Experiments," in IEEE Transactions on Intelligent Vehicles, doi : 10.1109/TIV.2023.3317979.
- Perozzi, G. ; **Oudainia, M.R.** ; Sentouh, C. ; Popieul, J.-C. ; Rath, J.J (2023). Driver Assisted Lane Keeping with Conflict Management Using Robust Sliding Mode Controller. Sensors, 23, 4. <https://doi.org/10.3390/s23010004>
- **Oudainia M.R.**, Sentouh C, Nguyen A-T and Popieul J-C (2022), Online driver model parameter identification using the Lyapunov approach based shared control. Front. Control. Eng. 3 :1055915. doi : 10.3389/fcteg.2022.1055915

Conférences internationales avec actes et comité de lecture

- **M. R. Oudainia**, C. Sentouh, A. -T. Nguyen and J. -C. Popieul (2022), "Personalized Decision Making and Lateral Path Planning for Intelligent Vehicles in Lane Change Scenarios," 2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC), Macau, China, pp. 4302-4307.
- **M. R. Oudainia**, C. Sentouh, A. -T. Nguyen and J. -C. Popieul (2022), "Dynamic Conflict Mitigation for Cooperative Driving Control of Intelligent Vehicles," 2022 IEEE Intelligent Vehicles Symposium (IV), Aachen, Germany, pp. 1445-1452.

Présentation à une conférence nationale

- **Oudainia M.**, Sentouh C., Nguyen A., & Popieul J. (2023) "Prise de décision et planification latérale personnalisées pour les véhicules intelligents dans les scénarios de changement de voie", Les journées du Comité Technique Automatique et Transport Terrestre (CTATT), Mulhouse, France.
- **Oudainia M.**, Sentouh C., Nguyen A., & Popieul J. (2022). "Développement d'une stratégie de gestion dynamique des conflits en conduite partagée pour la conduite automatisée", Les journées du Comité Technique Automatique et Transport Terrestre (CTATT), Valenciennes, France.
- **Oudainia M.**, Sentouh C., Nguyen A., & Popieul J. (2021) "Coopération évolutive entre le conducteur et le véhicule automatisé basée sur une approche par apprentissage progressif", 7^{ème} Journée Régionale des Doctorants en Automatique (JRDA), UTC de Compiègne, France.

Livrables de projet et rapports techniques

- Floris J., Simon P., **Oudainia M.**, Wang Y., Sentouh C., Nguyen A., Debernard S., Popieul J. (2023). Spécifications des principes de coopération homme-machine et de commande, livrable L3.1, LAMIH, juillet. Projet ANR CoCoVeIA 2019-2024.
- **Oudainia M.**, Floris J., Simon P., Sentouh C., Nguyen A., Popieul J. (2023). Expérimentations préliminaires sur le contrôle partagé adaptatif, livrable L5.1, LAMIH, mai. Projet ANR CoCoVeIA 2019-2024.

Chapitre 1

Etat de l'art

Sommaire

| | | |
|------------|---|-----------|
| 1.1 | Introduction | 33 |
| 1.2 | L'automatisation de la conduite automobile | 33 |
| 1.2.1 | Les systèmes avancés d'aide à la conduite (ADAS) | 34 |
| 1.2.2 | La taxonomie SAE des systèmes de conduite automatisée | 34 |
| 1.3 | Impact de l'automatisation de la conduite automobile sur le conducteur | 36 |
| 1.3.1 | Charge de travail mentale | 37 |
| 1.3.2 | Les transitions de contrôle | 39 |
| 1.3.3 | La conscience de la situation | 40 |
| 1.3.4 | La confiance | 40 |
| 1.4 | La coopération entre le conducteur et le véhicule automatisé | 41 |
| 1.4.1 | Vers une automatisation centrée sur l'humain | 41 |
| 1.4.2 | L'intégration de l'apprentissage automatique pour améliorer les interactions humain-véhicule | 43 |
| 1.4.3 | Modèles coopératifs pour l'interaction humain-système dans la conduite automatisée | 45 |
| 1.5 | Les projets en europe sur le développement de véhicules autonomes | 49 |
| 1.6 | Architecture hiérarchique pour la coopération conducteur-véhicule automatisé | 51 |
| 1.6.1 | L'activité de conduite automobile et sa décomposition hiérarchique | 51 |
| 1.6.2 | Les limitations des architectures de coopération existantes | 53 |
| 1.6.3 | Une architecture de coopération auto-adaptative entre le conducteur et le véhicule automatisé | 55 |
| 1.7 | Cas d'usage traité dans le cadre de la thèse | 57 |
| 1.8 | Simulateur de conduite SHERPA-LAMIH | 58 |
| 1.9 | Conclusion | 58 |

1.1 Introduction

Le domaine de la conduite automobile est en constante évolution avec l'introduction croissante de systèmes avancés d'aide à la conduite et d'automatisation. Ces technologies promettent d'améliorer la sécurité, le confort et l'efficacité de la conduite, mais elles soulèvent également des questions importantes quant à la coopération entre humain et la machine.

Ce chapitre se concentre sur la coopération entre le conducteur et les systèmes d'automatisation, en mettant l'accent sur l'importance d'une interaction harmonieuse entre ces deux entités. Nous explorerons l'état de l'art de la coopération humain-véhicule, en examinant les différents niveaux de coopération, les défis associés et les solutions proposées.

Tout d'abord, nous examinerons les répercussions de l'automatisation de la conduite sur le conducteur. Il est essentiel de comprendre comment l'introduction de systèmes automatisés peut influencer l'activité du conducteur, sa perception de la sécurité et son niveau d'engagement dans la conduite. Nous discuterons également des limitations et des préoccupations liées à cette transition vers une conduite plus automatisée.

Ensuite, nous aborderons les architectures existantes de coopération humain-véhicule et les défis auxquels elles sont confrontées. Ces architectures ont pour objectif de permettre une interaction fluide entre le conducteur et les systèmes d'automatisation, mais elles présentent encore des limitations en termes de confiance mutuelle, de compréhension, de coordination des décisions et d'adaptation aux préférences individuelles.

Pour surmonter ces limitations, nous explorerons une approche auto-adaptative de la coopération humain-véhicule. Cette approche propose une répartition claire des rôles et des responsabilités entre le conducteur et les systèmes d'automatisation, en tenant compte des différentes étapes de prise de décision, de planification des manœuvres et d'exécution du contrôle. Une telle coopération peut améliorer la sécurité routière, réduire la fatigue du conducteur, augmenter l'efficacité de la conduite et offrir une expérience de conduite plus personnalisée et agréable.

1.2 L'automatisation de la conduite automobile

La conduite automobile est devenue un élément essentiel de la vie moderne, avec environ 81% des familles françaises possédant au moins une voiture en 2017, selon les données de l'Institut national de la statistique et de l'économie (INSEE). Cependant, malgré les efforts faits par les pouvoirs publics et les constructeurs automobiles, la conduite présente toujours un certain niveau de dangerosité.

Les statistiques de l'Organisation mondiale de la santé révèlent qu'environ 1,35 million de personnes décèdent chaque année dans le monde à la suite d'accidents de la route. De plus, entre 20 et 50 millions de personnes subissent des blessures non mortelles, dont beaucoup entraînent des handicaps. Les accidents de la route sont la principale cause de décès chez les enfants et les jeunes adultes âgés de 5 à 29 ans [OMS, 2018].

Des études antérieures [Treat et al., 1979] ont montré que les facteurs humains étaient responsables de 93% des accidents étudiés. Cela met en évidence l'importance des erreurs humaines dans les accidents de la route. Bien que des dispositifs de sécurité tels que les ceintures de sécurité et les airbags soient disponibles et puissent réduire le nombre de décès sur les routes, ils restent essentiellement passifs et ne peuvent pas prévenir les erreurs humaines qui se produisent lors de la conduite.

C'est pourquoi il y a un intérêt croissant pour le développement de systèmes d'assistance au conducteur ou de véhicules hautement automatisés afin d'améliorer la sécurité et le confort de conduite. Les systèmes avancés d'aide à la conduite (ADAS) jouent un rôle clé dans cette évolution. Ces systèmes utilisent de nombreux capteurs renseignant sur l'environnement du véhicule et la situation de conduite, tels que des caméras, des radars, des LIDARs, et des dispositifs de surveillance du conducteur pour détecter l'inattention et la diminution de la vigilance,

ainsi que d'autres technologies pour fournir des avertissements et une assistance au conducteur. L'assistance au maintien de voie, le freinage d'urgence automatique et la détection des angles morts en sont quelques exemples.

L'objectif ultime est de développer des véhicules entièrement autonomes capables de fonctionner sans intervention humaine. Cependant, cela nécessite des recherches approfondies et des avancées technologiques supplémentaires pour garantir la sécurité et la fiabilité de ces systèmes. En attendant, les systèmes ADAS continuent de jouer un rôle crucial dans la progression vers une conduite automatisée, en offrant des fonctionnalités d'assistance qui contribuent à réduire les risques d'accidents liés à l'erreur humaine.

1.2.1 Les systèmes avancés d'aide à la conduite (ADAS)

Le développement des ADAS a commencé il y a plus de 40 ans et les fonctions incluses dans ce type de systèmes sont généralement à l'intersection de la demande la plus urgente des conducteurs et des responsables de la sécurité et des possibilités technologiques du moment. Selon le résumé des recommandations ouvertes de sécurité 2019-2020 de la (Most Wanted List) [NTSB, 2018], l'élimination des distractions, la mise en œuvre d'une stratégie globale pour réduire les accidents liés à la vitesse, l'augmentation de la mise en œuvre des systèmes d'évitement des collisions dans tous les nouveaux véhicules routiers et la réduction des accidents liés à la fatigue figurent toutes dans le top 10 de la liste des améliorations les plus attendues en matière de sécurité des transports. En fait, toutes les exigences susmentionnées peuvent être prises en compte dans les systèmes d'aide à la conduite automobile. Dans ce cas, il est nécessaire de faire une présentation détaillée de l'ADAS sous différents aspects.

Les ADAS ont été introduits pour la première fois sur le marché des véhicules commerciaux avec le système de freinage antiblocage (ABS) à la fin des années 1970. Ils étaient d'abord disponibles sur les véhicules premium avant de se généraliser à toute la production [Gordon and Lidberg, 2015]. Le même scénario se reproduit pour l'ensemble des fonctions ADAS de ce type, initialement introduites comme des fonctionnalités de luxe pour les marques haut de gamme, avant d'être déployées sur la production de masse.

Au fil des années, grâce aux progrès technologiques et à la réduction des coûts des capteurs matériels, les systèmes d'aide à la conduite sont devenus des équipements standard et indispensables intégrés dans les véhicules actuels. Ils fournissent des informations essentielles sur l'environnement extérieur, avertissent les conducteurs en temps opportun, permettent un contrôle simplifié et offrent une assistance supplémentaire aux véhicules [Lu et al., 2005].

C'est le cas des systèmes d'aide à la conduite automatisée, qui ont connu un développement rapide depuis les années 2000, grâce aux concours et défis liés à la conduite automatisée, tels que le DARPA Urban Challenge en 2007 [Buehler et al., 2009], le VisLab Intercontinental Autonomous Challenge en 2010 [Broggi et al., 2010], le Grand Cooperative Driving Challenge en 2011 et en 2016 [Geiger et al., 2012, Englund et al., 2016], et d'autres événements similaires. Ces compétitions ont contribué à transformer les systèmes ADAS en des systèmes complexes et bien développés, combinant une architecture matérielle pour la perception et une conception logicielle pour le post-traitement [Galvani, 2019]. Ces systèmes ont été conçus pour améliorer le confort de conduite, modifier ou aider les comportements de conduite, tout en contribuant à éviter les accidents de la circulation pour assurer la sécurité des conducteurs [Ziebinski et al., 2016]. Cependant, il est important de noter que les véhicules autonomes, malgré ces avancées, sont encore en développement. Ils restent généralement réservés aux véhicules de gamme premium à ce jour.

1.2.2 La taxonomie SAE des systèmes de conduite automatisée

L'automatisation de la conduite s'est développée en partant de la facilitation du contrôle du véhicule par le conducteur jusqu'à la prise en charge complète des tâches de contrôle dans certaines conditions. Afin de mieux faire connaître les systèmes d'aide à la conduite automatisée

et de clarifier les responsabilités qui y sont liées, la taxonomie de la Society of Automotive Engineers (SAE) des systèmes de conduite automatisée [SAE, 2021], propose une classification en six niveaux pour mieux décrire les différentes capacités et responsabilités des systèmes d'automatisation de la conduite (voir Figure 1.1).




FIGURE 1.1 – La taxonomie SAE des systèmes de conduite automatisée [SAE, 2021].

- **Niveau 0 : Aucune automatisation (Conduite entièrement manuelle)**
 Au niveau 0, le conducteur est entièrement responsable de toutes les tâches de conduite, y compris la direction, l'accélération, le freinage et la surveillance de l'environnement. Aucun système d'assistance automatisé n'est actif.
- **Niveau 1 : Assistance à la conduite (Conduite assistée)**
 Au niveau 1, des systèmes d'assistance à la conduite sont présents pour soutenir le conducteur dans certaines opérations spécifiques. Par exemple, le régulateur de vitesse adaptatif peut ajuster automatiquement la vitesse du véhicule en fonction de la circulation, ou l'assistant de maintien de voie peut fournir une assistance à la direction pour maintenir le véhicule dans sa voie.
- **Niveau 2 : Automatisation partielle (Conduite semi-automatisée)**
 Au niveau 2, des systèmes avancés d'aide à la conduite (ADAS) prennent en charge plusieurs opérations de conduite simultanément, tels que la direction et l'accélération, mais le conducteur doit rester engagé et vigilant. Le conducteur doit toujours surveiller l'environnement et être prêt à reprendre le contrôle du véhicule si nécessaire.

— **Niveau 3 : Automatisation conditionnelle (Conduite conditionnellement automatisée)**

Au niveau 3, le véhicule peut gérer certaines tâches de conduite dans des conditions spécifiques, mais le conducteur doit être prêt à reprendre le contrôle lorsque le système le demande. Le conducteur peut se libérer des tâches de conduite et effectuer d'autres activités, mais doit rester attentif et prêt à reprendre la conduite lorsque le système le requiert.

— **Niveau 4 : Automatisation élevée (Conduite hautement automatisée)**

Au niveau 4, le véhicule est capable de prendre en charge toutes les tâches de conduite dans certaines conditions prédéfinies. Le conducteur peut se détacher complètement des tâches de conduite et ne pas être tenu de surveiller l'environnement en permanence. Cependant, le système est limité à des conditions spécifiques, comme une zone géographique délimitée ou des conditions météorologiques favorables.

— **Niveau 5 : Automatisation complète (Conduite entièrement automatisée)**

Au niveau 5, le véhicule est capable de prendre en charge toutes les tâches de conduite dans toutes les conditions et dans n'importe quel environnement. Aucune intervention humaine n'est requise, et les occupants du véhicule sont simplement des passagers.

Cette taxonomie SAE fournit une base de référence pour évaluer et communiquer les capacités des systèmes de conduite automatisée, ce qui est essentiel pour une compréhension commune et pour guider le développement et la réglementation de ces technologies.

La conduite autonome est encore un domaine en développement, et actuellement, seuls quelques instituts de recherche et entreprises sont capables de réaliser des véhicules autonomes jusqu'au niveau 3 de la taxonomie SAE (voir le tableau 1.1). La plupart des véhicules commerciaux disponibles sur le marché ne prennent en charge que des fonctions de conduite autonome de niveau 2 [Kuutti et al., 2020], ce qui signifie qu'ils offrent une assistance à la conduite humaine, mais nécessitent toujours la surveillance et l'intervention du conducteur.

Cependant, avec le développement rapide des systèmes avancés d'aide à la conduite, les marchés des véhicules commerciaux commencent à soutenir des approches de personnalisation des ADAS basées sur les préférences et les styles de conduite des utilisateurs [Hasenjäger and Wersing, 2017]. Cela signifie que les fonctionnalités des systèmes d'assistance à la conduite peuvent être adaptées aux besoins individuels des conducteurs, offrant ainsi une expérience de conduite plus personnalisée et confortable.

Ces avancées dans les ADAS et la personnalisation ouvrent la voie à une adoption plus répandue de la conduite autonome à l'avenir. Cependant, il reste encore des défis techniques, réglementaires et de sécurité à surmonter avant d'atteindre des niveaux plus élevés d'automatisation de la conduite et une intégration plus complète des véhicules autonomes sur les routes.

1.3 Impact de l'automatisation de la conduite automobile sur le conducteur

L'automatisation croissante dans le domaine des véhicules autonomes a un impact significatif sur le rôle et les responsabilités du conducteur. Actuellement, les niveaux d'automatisation se limitent principalement à une automatisation partielle, où le conducteur reste responsable de la tâche de conduite tout en déléguant certaines fonctions au système automatisé. Il est essentiel de comprendre les implications de cette évolution. Dans cette section, nous examinerons de manière approfondie l'impact de l'automatisation sur le conducteur, en mettant l'accent sur les compétences requises, la sécurité, la charge de travail mentale et la confiance.






| Marque | pays | Modèle | SAE | ADAS |
|---|-----------|----------------------|----------|---|
|  | USA | Model S (AUTOPilot) | Niveau 2 | Système de freinage d'urgence Système d'aide au stationnement Système d'aide au changement de voie Système d'avertissement de sortie de voie Régulateur de vitesse adaptatif |
|  | USA | Escape (Co-Pilot360) | Niveau 2 | Système de détection des angles morts Régulateur de vitesse adaptatif Système d'avertissement de sortie de voie Système d'aide au maintien de voie Système de freinage pré-collision Système de freinage post-collision |
|  | Allemagne | 7series(Pro) | Niveau 2 | Régulateur de vitesse adaptatif Système d'avertissement de collision Système d'avertissement de sortie de voie Système de freinage d'urgence Système d'aide au maintien de voie Système d'évitement des collisions latérales |
|  | Allemagne | A8 | Niveau 3 | Régulateur de vitesse adaptatif Système d'aide au virage Système d'aide au maintien de voie Système d'avertissement de sortie de voie Système d'évitement des collisions Système de reconnaissance des panneaux de signalisation |
|  | Chine | ES8(NIOpilot) | Niveau 2 | Pilote automatique en embouteillage Système d'aide au maintien de voie Système d'avertissement de collision Système de reconnaissance des panneaux de signalisation Système d'aide au stationnement |

TABLE 1.1 – L'ADAS dans les véhicules utilitaires.

1.3.1 Charge de travail mentale

L'esprit humain est limité dans sa capacité à traiter les informations perçues ([Kahneman, 1973], [Pashler, 1994]). Des études sur la performance des tâches doubles montrent que la performance humaine dans un scénario de tâche unique se détériore après l'introduction d'activités supplémentaires nécessitant plus de ressources ([Pashler, 1994], [Tombu and Jolicœur, 2003]).

Dans le domaine de la conduite, la distraction représente une manifestation de l'incapacité du conducteur à traiter plusieurs sources d'information à la fois ou pendant une durée prolongée. Dans leur approche tripartite de la distraction du conducteur, les auteurs dans [Strayer et al., 2011] ont décrit trois sources de distraction. Les distractions manuelles, visuelles et cognitives surviennent lorsque les mains des conducteurs ne sont pas sur le volant, leurs yeux ne sont pas fixés sur la route devant eux et leur attention est détournée de la tâche de conduite, respectivement.

Les recherches sur la distraction du conducteur montrent que le manque d'attention ralentit les réactions des conducteurs et nuit à leur contrôle volontaire du véhicule ([Hosking et al., 2009], [Ranney et al., 2005], [Rossi et al., 2012]). Par exemple, lorsqu'ils parlent au téléphone en mode mains libres, la distraction cognitive amène les conducteurs à maintenir une vitesse et une distance moins régulières par rapport au véhicule qui les précède ([Haigney et al., 2000], [Strayer and Drews, 2007]), rendant ainsi leur comportement moins prévisible pour les autres usagers de la route. La distraction cognitive est également associée à une exploration visuelle altérée de la route devant soi. Les auteurs dans [Biondi et al., 2015] ont fait conduire des participants dans un véhicule sur route tout en effectuant l'une des six tâches non liées à la conduite. Le par-

cours sélectionné pour l'étude présentait plusieurs situations dangereuses, allant d'intersections non signalées et contrôlées par des panneaux d'arrêt à des zones scolaires et des passages pour piétons. La charge cognitive croissante associée à la tâche secondaire détériorait l'exploration visuelle de l'environnement routier par les conducteurs, compromettant leur capacité à prévoir l'apparition de dangers sur la route [Strayer and Fisher, 2016]. Les auteurs dans [Taylor et al., 2013] ont obtenu des résultats similaires, avec une précision des conducteurs dans l'anticipation des dangers potentiels passant de 77 % en condition de non-distraction à 35 % en étant distraits. Des recherches récentes étudient l'effet que la conduite automatisée, et en particulier l'automatisation partielle, peut avoir sur la charge de travail du conducteur et sa capacité à rester engagé dans la tâche de surveillance étant donné le potentiel de surcharge mentale et de distraction qu'elle peut générer et ainsi compromettre la capacité humaine à prêter attention aux informations pertinentes de l'environnement routier [Lee et al., 2020].

La loi de Yerkes-Dodson [Yerkes and Dodson, 1908] définit une relation en forme de U inversé entre la charge de travail et la performance humaine, selon laquelle une performance optimale dans une tâche donnée est observée dans des conditions de charge de travail intermédiaire, tandis qu'une précision plus faible et des réponses plus lentes sont attendues dans les situations de sous-charge ou de surcharge. Cette loi a été adoptée dans le cadre de la conduite assistée (voir Figure 1.2) pour optimiser l'interaction entre le conducteur et les systèmes d'assistance [Nguyen et al., 2017].

Selon la Loi de Yerkes-Dodson, il existe une corrélation en forme de courbe en U inversé entre le niveau d'activation et les performances cognitives. Cela signifie que des niveaux d'activation modérés favorisent de meilleures performances, tandis que des niveaux trop faibles ou trop élevés peuvent entraîner une détérioration des performances.

Dans le contexte de la conduite assistée, cette loi est appliquée pour déterminer le niveau d'assistance approprié en fonction de l'état du conducteur et des conditions de conduite. L'objectif est d'ajuster l'assistance pour maintenir le conducteur dans une zone d'activation optimale, où il est suffisamment engagé et alerté pour réagir aux situations de conduite, tout en étant soutenu par les systèmes d'assistance pour améliorer sa performance et sa sécurité.

Ainsi, en utilisant la Loi de Yerkes-Dodson, les systèmes de conduite assistée peuvent adapter leur niveau d'assistance en temps réel en fonction du niveau d'activation du conducteur. Par exemple, dans des conditions de conduite simples et peu stimulantes, le niveau d'assistance peut être réduit pour permettre au conducteur de rester engagé et attentif. En revanche, dans des situations complexes ou stressantes, une assistance plus élevée peut être fournie pour aider le conducteur à gérer la charge cognitive et à prendre des décisions plus éclairées.

Dans le contexte de l'automatisation partielle, on suppose que lorsque le conducteur délègue le contrôle du véhicule au système, cela entraînera une phase de désengagement mental du conducteur. Pendant cette phase, le système prendra en charge la gestion de la vitesse et de la direction du véhicule, laissant ainsi à l'opérateur humain la tâche de supervision.

Les recherches menées par [Biondi et al., 2018] ont testé cette supposition avec des participants conduisant un véhicule semi-automatisé sur route ouverte. L'état du conducteur a été surveillé à l'aide de mesures auto-déclarées, comportementales et physiologiques. Pour étudier l'effet du mode de fonctionnement engagé sur la charge de travail et l'excitation du conducteur, les participants ont conduit à la fois en mode manuel et en mode semi-automatisé. Conformément à ce qui est établi par la loi de Yerkes-Dodson [Yerkes and Dodson, 1908], le fait de conduire un véhicule partiellement automatisé a réduit les niveaux d'activation physiologique des conducteurs et leur performance dans une tâche de détection a diminué pendant la conduite semi-automatisée. Les données d'observation recueillies dans les études menées par [Endsley, 2017], [Biondi et al., 2017], ainsi que [Banks et al., 2018], confirment cela. Après l'activation des systèmes semi-automatisés, les conducteurs ont effectivement été observés en train de devenir totalement "mains et pieds libres" et ne replaçaient leurs mains sur le volant qu'en réponse aux avertissements du système.




FIGURE 1.2 – Loi de Yerkes-Dodson adoptée dans le cadre de la conduite assistée [Nguyen et al., 2017].

1.3.2 Les transitions de contrôle

Une conséquence en termes de sécurité du désengagement du conducteur lors de la conduite semi-automatisée est que l'opérateur humain peut ne pas être prêt à reprendre le contrôle lors des transitions du système vers le conducteur. Une distinction peut être faite entre les transitions de contrôle planifiées et non planifiées. Les transitions planifiées se produisent lorsque le conducteur est informé de l'incapacité du système à gérer certaines situations routières ou de trafic - par exemple, solliciter le conducteur à reprendre le contrôle du véhicule en arrivant à la fin de l'automatisation. Les transitions non planifiées, en revanche, se produisent lorsque le système tombe en panne de manière inattendue ou lorsque le conducteur n'est pas suffisamment prévenu de la demande imminente de transition - par exemple, mauvaise qualité des marquages des voies et le système ne peut plus gérer le contrôle du véhicule.

Dans une étude menée par [Stanton et al., 1997], les auteurs ont noté que lors de l'automatisation de niveau 1, les conducteurs ne sont parvenus à reprendre le contrôle du véhicule après une défaillance de l'automatisation qu'environ un tiers du temps. D'autres études ont examiné les transitions de contrôle du système vers l'humain et mesuré le temps nécessaire aux conducteurs pour reprendre le contrôle du véhicule après une défaillance du système. Les recherches menées par [Gold et al., 2016], [Louw et al., 2015] et [Walch et al., 2015] indiquent que les messages d'avertissement doivent être présentés avec au moins un préavis de 2 à 3 secondes avant que le système ne se désengage complètement. Les auteurs dans [Naujoks and Neukum, 2014] soutiennent une autre hypothèse, montrant que les temps de reprise du conducteur sont d'environ 6 secondes, jusqu'à 3 fois plus longs que ce que suggèrent [Louw et al., 2015] et [Walch et al., 2015]. Les auteurs dans [Eriksson and Stanton, 2017] plaident en faveur d'une approche moins déterministe, plus adaptative, suggérant que des facteurs tels que le scénario routier, les caractéristiques du conducteur et la charge de travail, entre autres, devront être pris en compte lors de la conception des manœuvres de transition. Les résultats de leur étude, dans laquelle les participants devaient reprendre le contrôle du véhicule dans des scénarios de plus en plus

exigeants, montrent en effet que les temps de réponse à la reprise augmentent en fonction des exigences liées à la tâche secondaire. Malgré ces résultats offrant des indications importantes pour la conception des manœuvres de reprise, toutes ces études ont été réalisées dans des environnements simulés, les participants conduisant dans des scénarios hautement contrôlés. Ainsi, nous soutenons l'idée que les résultats concernant les temps de réponse à la reprise en main du contrôle du véhicule présentés dans ces études ne fournissent que des estimations conservatrices qui ne peuvent pas refléter pleinement ce qui se produirait dans des situations réelles.

1.3.3 La conscience de la situation

Lorsque l'utilisateur devient moins attentif lors de la conduite automatisée, on constate souvent une diminution de son niveau de surveillance du système automatisé et de sa conscience de son fonctionnement. L'auteur dans [Endsley, 1995] définit la conscience de la situation comme "la perception des éléments de l'environnement dans une période de temps et un espace donnés, la compréhension de leur signification et la projection de leur état dans un futur proche". Lorsque les conducteurs se désengagent de la tâche de conduite, on s'attend à ce qu'ils deviennent encore moins conscients non seulement du bon fonctionnement de l'automatisation, mais aussi des dangers potentiels pouvant survenir à l'extérieur du véhicule.

Dans une étude portant sur les opérateurs de vaisseaux spatiaux, les auteurs dans [Reichenbach et al., 2010] ont demandé aux participants d'interagir avec un système apparemment fiable. À mesure que les participants devenaient plus familiers avec l'automatisation au fil du temps, leurs performances en termes de surveillance du système et de détection des défaillances du système diminuaient, des résultats similaires sont mis en évidence dans [Bailey and Scerbo, 2007] et [Hoc, 2001].

Dans le domaine de la conduite automobile, des études menées par [Stanton and Young, 2005] et [Schleicher et al., 2011] sur l'interaction des conducteurs avec des systèmes automatisés de niveau 1 montrent des résultats similaires. Les auteurs dans [Stanton and Young, 2005] ont demandé aux conducteurs de conduire un véhicule simulé dans deux conditions : avec le régulateur de vitesse adaptatif (ACC) activé ou désactivé. Les informations sur le fonctionnement de l'ACC étaient présentées par un, deux ou trois messages d'avertissement (faible, moyen et fort) pour le retour d'information. La conduite avec l'ACC activé dans la condition de retour d'information moyen a permis aux conducteurs de maintenir une vitesse sûre, sans impact négatif sur leur capacité de surveillance. Cependant, lorsque la conduite était effectuée dans la condition de retour d'information fort, les niveaux plus élevés de charge mentale imposés par le système d'avertissement plus complexe ont appauvri la conscience du conducteur du trafic environnant. Des résultats similaires ont été obtenus par [Schleicher et al., 2011]. Les conducteurs ont conduit un véhicule simulé dans trois conditions : conduite manuelle, régulateur de vitesse classique et ACC. On a enregistré moins de violations de la limitation de vitesse avec une automatisation croissante. Cependant, par rapport à la conduite manuelle ou avec le régulateur de vitesse activé, l'activation de l'ACC a détérioré la conscience de la situation du conducteur et sa capacité à réagir rapidement aux dangers imminents.

1.3.4 La confiance

Les chercheurs s'accordent généralement à dire que la confiance dans l'automatisation est actuellement l'une des plus grandes menaces auxquelles l'industrie automobile est confrontée en termes d'acceptation de la technologie. Les auteurs dans [Lee and See, 2004] définissent la confiance comme "l'attitude selon laquelle un agent aidera à atteindre les objectifs d'un individu dans une situation caractérisée par l'incertitude et la vulnérabilité". Nous soutenons l'idée qu'une définition plus utile de la confiance est un modèle mental que l'utilisateur se fait des capacités opérationnelles de conduite automatisée en se basant sur des observations antérieures (ou de l'expérience). En tant que tel, il faut considérer la confiance comme un processus dynamique qui

évolue à mesure que l'expérience s'accumule.

Les recherches sur la confiance dans l'automatisation chez des participants n'ayant aucune expérience préalable du système automatisé indiquent que la complaisance des utilisateurs augmente avec le temps [Waytz et al., 2014]. Les auteurs [Lee and Moray, 1992] ont identifié une relation inverse entre la confiance et la surveillance, ce qui signifie que plus la confiance est élevée, moins le système est surveillé. Une revue des études empiriques menées par [De Winter et al., 2014] a montré que les conducteurs étaient plus susceptibles de s'engager dans des tâches secondaires lorsqu'ils étaient en mode de conduite automatisée. Ces résultats ont été corroborés par [Payre et al., 2016] suite à des études réalisées sur simulateur de conduite dans des conditions de conduite entièrement automatisée.

La littérature actuelle suggère qu'il existe deux tendances dangereuses en ce qui concerne la confiance dans les véhicules à conduite automatisée. La sous-confiance, qui pose une menace de rejet de la technologie, et la sur-confiance, qui peut conduire à une dépendance excessive. Comme l'ont noté [Miller et al., 2016], cette dernière présente des risques pour la sécurité dans des circonstances imprévisibles où l'automatisation n'est pas en mesure de fonctionner ou ne peut pas fonctionner comme prévu. Pour maintenir constamment la confiance dans le système de conduite automatisée, il est essentiel d'améliorer la coopération entre le système et l'opérateur humain. De plus, le système doit être en mesure de fournir des informations précises concernant son mode de fonctionnement. Les auteurs [Sarter and Woods, 1995] ont apporté des preuves empiriques montrant que les erreurs de mode engagé se produisaient principalement dans des situations limites en termes de temps, et que les opérateurs avaient parfois du mal à anticiper le comportement du système et le mode associé. Les erreurs de mode engagé se sont avérées être une source grave d'accidents.

Cependant, comme nous l'avons mentionné précédemment, le système de conduite automatisé et le conducteur doivent pouvoir coopérer de manière sûre et efficace dans l'environnement dynamique d'un véhicule en mouvement, d'où la nécessité de créer des architectures de fonctionnement qui définissent la nature et les lois régissant les interactions qui peuvent exister entre le conducteur et le système de conduite automatisée.

1.4 La coopération entre le conducteur et le véhicule automatisé

La coopération entre le conducteur et le véhicule automatisé est essentielle, comme le soulignent les niveaux actuels d'automatisation partielle. Dans cette section, nous mettons particulièrement l'accent sur la transition vers une automatisation centrée sur l'humain, et explorons le rôle potentiel de l'apprentissage automatique pour établir une coopération plus efficace entre le conducteur humain et son véhicule.

1.4.1 Vers une automatisation centrée sur l'humain

Les psychocognitivistes critiquent principalement la conduite automatisée en raison de sa prise en compte limitée de l'aspect humain qui intervient dans le processus d'automatisation [Inagaki and Sheridan, 2019]. Dans le cas des systèmes de conduite semi-automatisée, par exemple, le conducteur humain est tenu de surveiller le fonctionnement du système automatisé (niveau 2) et de reprendre rapidement le contrôle du véhicule (niveau 2 et niveau 3), quelles que soient les circonstances spécifiques, les scénarios routiers ou de circulation. En d'autres termes, on attend du conducteur humain qu'il agisse selon les instructions, indépendamment de la possibilité qu'il soit distrait, fatigué ou de toute autre manière désengagé de la tâche de surveillance. Une perspective alternative, centrée sur l'interaction humaine avec l'automatisation, est proposée dans l'étude fondamentale de Sheridan et Verplank (1978) [Sheridan and Verplank, 1978]. Leur modèle définit 10 niveaux distincts d'automatisation, où l'humain et le système prennent en charge différentes fonctions. Au niveau 1, le système n'offre aucune assistance : l'humain doit

prendre toutes les décisions et actions, tandis qu'au niveau 10, le système décide de tout, agit de manière autonome, en ignorant l'humain [Sheridan and Verplank, 1978]. Pour le niveau 5 ou inférieur, l'humain conserve l'autorité sur la décision finale. À l'inverse, pour le niveau 6 ou supérieur, le système exécuterait automatiquement sa propre décision, à moins que l'humain n'intervienne.

Ce modèle a ensuite été révisé par Parasuraman (2000) [Parasuraman et al., 2000], afin de prendre en compte les différentes étapes de traitement de l'information où la répartition des responsabilités entre l'humain et le système a lieu (voir Figure 1.3). Alors que le modèle original à dix niveaux se concentrait sur la sélection et l'exécution des réponses, il ne tenait pas compte des étapes préliminaires où l'information est acquise et intégrée. Un total de quatre étapes de traitement sont décrites [Parasuraman et al., 2000] : l'acquisition d'information, l'analyse d'information, la sélection de décision, la mise en œuvre de l'action. Les quatre étapes ont été développées à partir des phases de perception, de sélection de réponse et d'exécution de réponse décrites dans les modèles de traitement de l'information humaine ([Kahneman, 1973], [Pashler, 1994], [Tombu and Jolicœur, 2003], [Wickens, 2008]). Ces quatre étapes peuvent être automatisées, sur un processus continu de contrôle allant de l'automatisation faible à l'automatisation élevée (comme dans [Sheridan and Verplank, 1978]).




FIGURE 1.3 – Les différentes étapes de traitement de l'information où la répartition des responsabilités entre l'humain et le système a lieu [Parasuraman et al., 2000].

L'acquisition d'information s'applique à la détection de l'information et à l'enregistrement des entrées environnementales. À un faible niveau d'automatisation, cela peut impliquer l'utilisation de capteurs qui analysent l'environnement routier. Un système de détection hautement automatisé, en revanche, peut classer les objets routiers en fonction de leurs caractéristiques et de leurs dimensions (piétons, cyclistes, véhicules de passagers, camions, etc.).

L'analyse d'information du système concerne les fonctions cognitives telles que la mémoire de travail et le traitement inférentiel [Parasuraman et al., 2000]. Alors qu'un système faiblement automatisé peut fournir des informations sur la trajectoire des objets routiers, un système avec un niveau d'automatisation plus élevé dans ce domaine peut informer l'opérateur humain du potentiel de collision entre le véhicule et les autres usagers de la route.

La sélection des décisions est la capacité à prendre des décisions et à choisir des actions.

Dans le domaine de l'automatisation des véhicules, il s'agit de systèmes qui recommandent au conducteur humain d'effectuer certaines manœuvres importantes pour la sécurité (par exemple, freiner lorsque la distance de sécurité est inférieure à un seuil de sécurité).

La mise en œuvre de l'action fait référence à la capacité d'exécuter des actions spécifiques qui peuvent avoir été sélectionnées avec ou sans l'assistance des systèmes automatisés. Le régulateur de vitesse est un exemple de système faiblement automatisé, tandis que le régulateur de vitesse adaptatif, avec sa capacité à automatiser à la fois le maintien de la distance et la vitesse, est un système avec des fonctionnalités d'automatisation plus élevées.

L'un des avantages de l'utilisation d'une approche de l'automatisation centrée sur l'humain est sa capacité à considérer dès la conception du système automatisé les besoins de coopération avec l'humain. Selon ce modèle, la première étape du processus de conception consiste à identifier le niveau d'automatisation applicable au système à chacune des quatre étapes du traitement de l'information. L'étape suivante consiste à évaluer l'effet de chaque niveau d'automatisation sur les éléments liés à l'humain tels que la charge de travail, la confiance, la conscience de la situation et la dégradation des compétences.

Pour souligner l'importance de l'élément humain dans l'automatisation, [Parasuraman et al., 2000] définissent ceux-ci comme des critères d'évaluation primaires. Les auteurs décrivent également des critères d'évaluation secondaires, qui incluent la fiabilité de l'automatisation et les coûts des résultats de décision/action. Avec cette approche à l'esprit, il est possible de comprendre les causes profondes des récents accidents impliquant des véhicules automatisés et les erreurs de conception relatives. L'enquête menée par le National Transportation Safety Board sur l'accident mortel impliquant une Tesla Model S (en 2016) suggère que "la dépendance excessive du conducteur envers l'automatisation du véhicule a été favorisée par la conception opérationnelle de ce dernier, qui a permis au conducteur de se désengager de la conduite pendant de longues périodes et d'utiliser l'automatisation d'une manière incompatible avec les conseils et les préconisations du fabricant" ([NTSB, 2016]).

Dans le cadre théorique proposé par [Parasuraman et al., 2000], il s'agit d'un exemple d'automatisation maladroite à l'étape de l'exécution de l'action du traitement. Avant l'accident, le système conservait le contrôle total du fonctionnement du véhicule, mais il n'a pas réduit la vitesse du véhicule ni activé le frein d'urgence assisté (une défaillance de la perception). Avec le conducteur humain comptant sur les capacités du système, cela a favorisé le désengagement progressif du conducteur, ce qui a compromis sa conscience des conditions de circulation environnantes.

1.4.2 L'intégration de l'apprentissage automatique pour améliorer les interactions humain-véhicule

L'apprentissage automatique a été appliqué aux véhicules autonomes comme solution à plusieurs tâches, notamment des tâches de perception de l'environnement de bas niveau, telles que la détection des signaux ou la reconnaissance des piétons, et des processus cognitifs de haut niveau, tels que la planification d'itinéraires ou la gestion des dialogues conversationnels dans les systèmes d'infodivertissement embarqués. L'une des premières applications des réseaux neuronaux artificiels au problème du contrôle des véhicules était le système Autonomous Land Vehicle in a Neural Network (ALVINN) développé par Pomerleau en 1989, décrit pour la première fois dans [Pomerleau, 1988] et ultérieurement étendu dans [Pomerleau, 1997]. L'objectif de la coordination entre les systèmes automatisés et les occupants du véhicule nécessite l'application réussie de techniques d'apprentissage de l'intelligence artificielle, telles que l'apprentissage supervisé, l'apprentissage par imitation et l'apprentissage progressif.

L'apprentissage supervisé utilise des données étiquetées pour entraîner un système à accomplir une tâche spécifique, l'étiquetage étant traditionnellement effectué par annotation humaine. Cette méthode a été utilisée pour estimer le niveau cognitif de l'opérateur humain dans le temps [Al Mahi et al., 2017]. Cette capacité permet au véhicule de détecter l'émergence

du stress cognitif chez les conducteurs, d'augmenter leur niveau d'autonomie et de réduire les demandes d'attention du conducteur. L'apprentissage supervisé a également été utilisé pour enseigner à un robot des affordances sociales dans les interactions humaines quotidiennes à partir de vidéos étiquetées, et transférer les connaissances aux interactions humain-robot dans des scénarios inédits [Shu et al., 2017]. Cela pourrait permettre aux véhicules d'apprendre les préférences d'interaction des utilisateurs et leur comportement social en dehors du véhicule, qui pourraient être appliqués à des scénarios à l'intérieur du véhicule. Dans [Bojarski et al., 2016], les auteurs ont utilisé un réseau neuronal convolutif (CNN) pour créer un système de contrôle pour la direction d'un véhicule grâce à l'apprentissage supervisé.

L'apprentissage par imitation permet à un système automatisé d'apprendre à effectuer une tâche particulière à partir d'exemples ou de démonstrations. Les démonstrations sont généralement réalisées par une personne, puis encodées sous forme de paires (état-action) que le système utilise comme jeu de données pour dériver une politique qui reproduit le comportement démontré. Cette méthode a été utilisée pour permettre les interactions humain-ordinateur (IHO) avec des interfaces "enseigner et montrer", qui permettent aux utilisateurs de former des comportements complexes chez les robots [Saunders et al., 2015]. Appliquée à la conduite automatisée, cette approche peut être utilisée pour personnaliser les comportements de conduite automatisée afin de maximiser le confort de l'utilisateur. La réduction de la complexité de la génération de comportements de conduite personnalisés la rend plus accessible aux utilisateurs non techniques. Les auteurs dans [Tian et al., 2022] proposent une nouvelle approche personnalisée de planification et de contrôle pour le système d'assistance au changement de voie, qui peut apprendre efficacement une politique spécifique au conducteur basée sur la commande prédictive (MPC) via l'apprentissage par imitation à partir de quelques démonstrations de conducteurs. Cependant, il existe des limitations quant à l'application des techniques d'apprentissage par imitation. Les performances du système automatisé dans la tâche de conduite seront fondamentalement limitées aux performances de l'enseignant, et le système pourrait être incapable d'exécuter des tâches de conduite non enseignées [Argall et al., 2009]. Ces inconvénients limitent la généralisation des comportements enseignés et peuvent imposer une lourde charge à l'enseignant pour surveiller le véhicule. Une solution possible à ces lacunes de l'apprentissage par imitation est l'application d'un feedback constant de la part de l'enseignant (utilisateur du véhicule), ou de permettre l'exploration autonome sous la forme de l'apprentissage progressif.

L'apprentissage progressif, également connu sous le nom d'apprentissage par renforcement, est une approche où un système autonome apprend à prendre des décisions en interagissant avec son environnement, en effectuant des essais et en corrigeant ses erreurs pour maximiser une récompense donnée. Dans ce processus, le système réalise des actions dans un environnement donné, reçoit des récompenses ou des sanctions en fonction de la qualité de ses actions, puis ajuste ses stratégies pour maximiser les récompenses à l'avenir. Cela permet au système de découvrir progressivement les comportements optimaux qui conduisent à de meilleures performances. Le premier à suggérer l'apprentissage progressif pour la direction des véhicules était le travail réalisé par Yu [Yu and Sethi, 1995]. Yu a proposé un système de suivi de route basé sur le travail de Pomerleau [Pomerleau, 1988] et [Pomerleau, 1997], en utilisant l'apprentissage progressif pour concevoir un contrôleur. L'avantage de cette approche était la capacité à apprendre à partir d'expériences précédentes pour conduire dans de nouveaux environnements et à améliorer continuellement sa capacité de suivi de route grâce à l'apprentissage en ligne. Cela permettait au système de s'adapter et de s'améliorer en temps réel, en tirant parti des nouvelles informations et des nouvelles situations rencontrées sur la route.

Les applications de l'apprentissage progressif aux interactions humain-système ont été explorées avec succès sous la forme de mécanismes d'adaptation de comportement. Cela permettrait de détecter de petits signaux d'inconfort chez le partenaire humain et d'ajuster en retour les paramètres d'interaction d'un robot, tels que la rencontre du regard, la vitesse de mouvement et le timing [Mitsunaga et al., 2006]. La même technique peut être appliquée pour observer les

réactions de malaise des passagers du véhicule face aux comportements de conduite et optimiser le comportement de conduite pour le confort. Cette méthode est également utile pour guider l'apprentissage du système sur les conversations entre les passagers et leur assistant de véhicule autonome [Hinds et al., 2004]. Les comportements utilisateur de haut niveau peuvent être traduits en expressions communicatives de bas niveau, comme le démontrent [Hemminghaus and Kopp, 2017].

Bien que les résultats exploratoires mettent en évidence l'apprentissage progressif comme un domaine très prometteur pour la conduite autonome, il convient de noter que les applications de l'IHO et, plus spécifiquement, de l'interaction humain-véhicule en sont encore à un stade préliminaire. Un problème auquel les concepteurs de véhicules autonomes sont confrontés est la difficulté de sélectionner des représentations de comportement appropriées pour les interactions. Un autre inconvénient est que les méthodes d'apprentissage progressif en conduite automatisée doivent d'abord être formées dans des environnements sûrs, tels que des simulateurs de conduite réalistes, pour permettre l'exploration des comportements sans mettre en danger les passagers.

1.4.3 Modèles coopératifs pour l'interaction humain-système dans la conduite automatisée

Comme nous l'avons déjà vu auparavant, à la fois les systèmes de conduite automatisés et les conducteurs humains doivent apprendre à coopérer de manière sûre et efficace dans l'environnement dynamique d'un véhicule en mouvement, d'où la nécessité de créer des modèles qui définissent la nature et les lois régissant les interactions humain-système dans des conditions de conduite.

Un des modèles d'interaction les plus populaires entre le véhicule, le conducteur et l'automatisation dans la littérature est la "H-Metaphor" [Flemisch et al., 2003] (voir Figure 1.4). Ce modèle s'inspire des interactions coordonnées entre un cheval et son cavalier, et les transpose aux systèmes de conduite automatisée.

Dans ce modèle, le véhicule automatisé est conçu pour fonctionner de manière autonome dans des conditions routières générales, en évitant les obstacles et en maintenant une conduite sécurisée. Le rôle du conducteur humain se rapproche de celui d'un superviseur. Pendant la conduite automatisée, le conducteur peut s'engager dans d'autres activités, car il partage une interface de surveillance physique avec le véhicule automatisé. Cette interface permet au conducteur de rester constamment conscient de ce que fait le véhicule automatisé.

L'aspect essentiel de cette métaphore réside dans la communication entre le conducteur et le système automatisé. Lorsque le véhicule automatisé rencontre une situation inattendue, par exemple un obstacle imprévu ou une incertitude dans la direction à prendre, le conducteur doit intervenir. Cette communication peut prendre deux formes distinctes : une communication explicite, où le conducteur communique ses intentions de manière délibérée, par exemple en utilisant la parole ou en fournissant des commandes spécifiques au système, ou une communication implicite, où le conducteur transmet ses intentions par le biais d'actions, telles que des gestes manipulateurs, une exécution proactive des tâches ou même des signaux physiologiques.

Le véhicule peut également être conscient du degré d'engagement du conducteur et adapter son comportement d'interaction en conséquence. Plutôt qu'un cadre opérationnel pour le développement d'interactions coopératives humain-système, ce modèle présente une simplification du point de vue de la coopération. La "H-Metaphor" suppose également un certain nombre de choses sur l'intelligence du système automatisé et le modèle mental de l'utilisateur, comme par exemple que le véhicule doit avoir des comportements prévisibles et adaptés à la situation qui permettent à l'opérateur de détourner son attention de manière fiable. L'application des méthodes d'apprentissage montrent des promesses pour développer ces comportements, mais comme nous l'avons mentionné précédemment, la généralisation à différents scénarios est une tâche difficile.

Un modèle plus utile dans les restrictions actuelles de l'automatisation a été proposé dans




FIGURE 1.4 – La "H-Metaphor" du (cavalier-cheval) adaptée au contrôle partagé (conducteur-système) pour les véhicules automatisés [Flemisch et al., 2003].

[Hoc et al., 2009], une théorie qui catégorise la coopération dans la conduite automatisée en fonction du type d'activités de coopération. Ils définissent quatre modes de coopération : la perception, le contrôle mutuel, la délégation de fonction et le mode entièrement automatique. Ces modes de coopération ont été étudiés pour le régulateur de vitesse automatique (ACC) et les fonctions de sécurité latérale, telles que l'assistance au maintien de voie (LKA). Les résultats suggèrent que la coopération au niveau de la perception, comme dans les systèmes ACC et LKA actuels (niveaux SAE 1 et 2), tend à se faire à un niveau symbolique (c'est-à-dire que des messages d'avertissement sont fournis sans qu'aucune action ne soit entreprise). De même, dans les modes de coopération entièrement automatiques (niveaux SAE 4 et 5), les interactions peuvent se dérouler principalement au niveau symbolique, le système fournissant des mises à jour sporadiques sur les facteurs environnementaux ou les décisions de contrôle.

Les recherches menées sur l'ACC et sur le LKA ont montré que la coopération au niveau symbolique est moins efficace que l'action à la fois aux niveaux symbolique, perceptuel et de contrôle moteur des conducteurs ([Hoc et al., 2006], [Jordan et al., 2007]). Cela est conforme à l'exigence de la "H-Metaphor" d'une interface de surveillance partagée. En utilisant le cadre de [Hoc et al., 2009], les chercheurs en interaction automobile peuvent étudier comment développer des stratégies de coopération efficaces dans les modes de perception, de contrôle mutuel, de délégation de fonctions et d'automatisation complète. La coopération efficace est généralement mesurée par l'efficacité de la collaboration. L'efficacité est extrêmement critique dans le contexte de la conduite automatisée dans le but d'assurer la sécurité et de prendre des décisions en temps opportun. Cela nécessite des modèles qui soutiennent la formation d'un plan commun entre humain et le système de conduite automatisée.

Un tel modèle a été présenté comme une "coopération basée sur l'intention" dans [Bauer et al., 2008] (voir Figure 1.5). Une construction clé pour la coopération basée sur l'intention est

la modélisation de l'intention. Basé sur les connaissances de l'intention du partenaire humain et de l'activité actuelle, le système automatisé peut planifier ses propres actions pour atteindre un objectif commun. Par conséquent, le système a besoin de capacités pour percevoir et comprendre leur environnement, prendre des décisions, planifier, apprendre et réfléchir.




FIGURE 1.5 – Modèle de coopération basée sur l'intention [Bauer et al., 2008].

Les récents développements de l'inférence d'intention à l'aide de méthodes d'apprentissage automatique, telles que l'apprentissage progressif, montrent des promesses pour ce type de systèmes coopératifs intelligents. Cependant, la définition de l'intention est encore largement adaptée à des tâches particulières. Les systèmes de conduite automatisée doivent développer des techniques plus élaborées et évolutives pour la gestion de la communication implicite et explicite avec les conducteurs. Cela inclut la prise de décision dans les cas où la communication explicite et implicite ne se corroborent pas, par exemple lorsque le conducteur du véhicule automatisé indique à droite mais demande verbalement un virage à gauche, lorsque la politesse sociale dissimule une expression explicite de malaise face au comportement de conduite, ou lorsque les passagers délèguent certaines fonctions de contrôle au véhicule mais restent méfiants quant aux capacités du système.

Ce dernier problème, où l'autorité de contrôle est partagée entre le véhicule et le conducteur humain, est l'objet spécifique de nombreux modèles de coopération dans la littérature sur la conduite automatisée. Les auteurs dans [Abbink et al., 2012] ont présenté le concept d'autorité de contrôle dans la coopération humain-machine via l'interface haptique partagée avec retour de force sur le volant. Dans ce système, un couple supplémentaire activé par le contrôleur informe le conducteur que la position actuelle du volant diffère de celle que la machine estime être optimale, et en même temps, le conducteur peut imposer sa propre volonté en appliquant un couple accru pour corriger l'entrée de l'ADAS (voir [Mars et al., 2014], pour une extension du modèle [Abbink et al., 2012]).

Des travaux plus récents ont fait évoluer le concept d'autorité de contrôle vers un modèle d'"autorité partagée" qui inclut les points de vue du détenteur de l'initiative et de la cohérence des intentions [Nishimura et al., 2015]. Le modèle d'autorité partagée propose une méthode de contrôle de réglage de gain pour l'assistance au maintien de voie afin de permettre au conducteur de changer de voie en douceur. Cependant, le modèle d'autorité partagée présente encore des problèmes. Les conducteurs humains peuvent être confus si le degré de contrôle partagé change en fonction du contexte. Nous avons besoin de comprendre comment les conducteurs s'adaptent aux systèmes de contrôle partagé et pour déconstruire les correspondances adaptatives humaines des niveaux et des capacités d'automatisation afin de trouver les méthodes les plus efficaces pour apprendre les préférences individuelles des conducteurs et répondre à leurs besoins et objectifs.

Un pas dans cette direction a été proposé avec le cadre général pour les transitions dans la conduite automatisée présenté par [Lu et al., 2016] (voir Figure 1.6). Dans ce modèle, les auteurs définissent les états statiques des tâches de conduite principales entre l'automatisation et le conducteur avec un contrôle longitudinal et latéral spécifique, une surveillance du conducteur,

ainsi que les transitions d'un état de conduite à un autre. Dans ce modèle, les actionneurs du véhicule sont contrôlés par des commutateurs qui activent le contrôle automatisé et ajoutent des paramètres pour tenir compte de l'augmentation/réduction dynamique de l'entrée pendant les transitions et les périodes de contrôle partagé. Le niveau de surveillance du conducteur peut également moduler l'entrée du conducteur humain et tenir compte même de cas tels que la conduite distraite. Bien que la paramétrisation de ce modèle offre une certaine flexibilité aux changements de niveaux d'automatisation, elle ne tient pas compte du processus d'apprentissage que la collaboration entre le véhicule et le conducteur peut subir.




FIGURE 1.6 – Cadre général pour la transition d'état dans la conduite automatisée [Lu et al., 2016].

Un modèle basé sur l'apprentissage, où le système de conduite automatisée apprend à augmenter son autonomie en renforçant ses compétences et en gérant les limites du système, a été proposé par [Vanderhaegen, 2012]. Ce modèle basé sur l'IA (voir Figure 1.7) se concentre sur deux capacités, la capacité de coopération entre l'humain et le système et la capacité du système à apprendre lui-même à partir de ces actions collaboratives. [Vanderhaegen, 2012] propose un ajustement des paramètres d'apprentissage du système pour accélérer la convergence du taux de prédiction correcte dans un processus similaire à l'apprentissage par imitation. Le modèle pré-définit la coopération entre l'humain et l'IA et l'ajustement des paramètres d'apprentissage jusqu'à ce qu'il puisse être validé par le conducteur après plusieurs itérations. Les deux limitations de ce modèle sont la façon dont l'utilisateur peut valider l'apprentissage comme étant correct, en fonction de ses entrées, et la façon dont les systèmes de conduite automatisée peuvent intégrer les compétences d'apprentissage tout en maintenant la validation, c'est-à-dire garantir la prévisibilité d'un comportement correct dans toutes les conditions de conduite. Ce sont des limitations critiques qui nécessitent une recherche approfondie et une attention de l'ingénierie. Cependant, ces nouveaux modèles ont la capacité de produire des interactions collaboratives hautement personnalisées s'adaptant à la fois aux conditions de conduite dynamiques et au processus d'apprentissage de l'humain et du véhicule automatisé pour travailler ensemble.

En résumé, il est crucial de concevoir des systèmes capables de coopérer avec le conducteur en assurant en permanence une compréhension claire des actions du système, de ses limites et en offrant la possibilité de partager la tâche de conduite. Cela permet de maintenir le conducteur engagé et pleinement impliqué dans le processus.

En effet, plutôt que de déléguer entièrement la conduite au système automatisé, il est essentiel de maintenir le conducteur "dans la boucle". Cela signifie que le conducteur doit être continuellement informé et conscient des décisions prises par le système automatisé, ainsi que de ses performances et de ses limitations. Une communication bidirectionnelle transparente et efficace entre le système et le conducteur est nécessaire pour assurer cette compréhension mutuelle.

En partageant la conduite, le conducteur reste actif et prêt à intervenir si nécessaire. Il peut

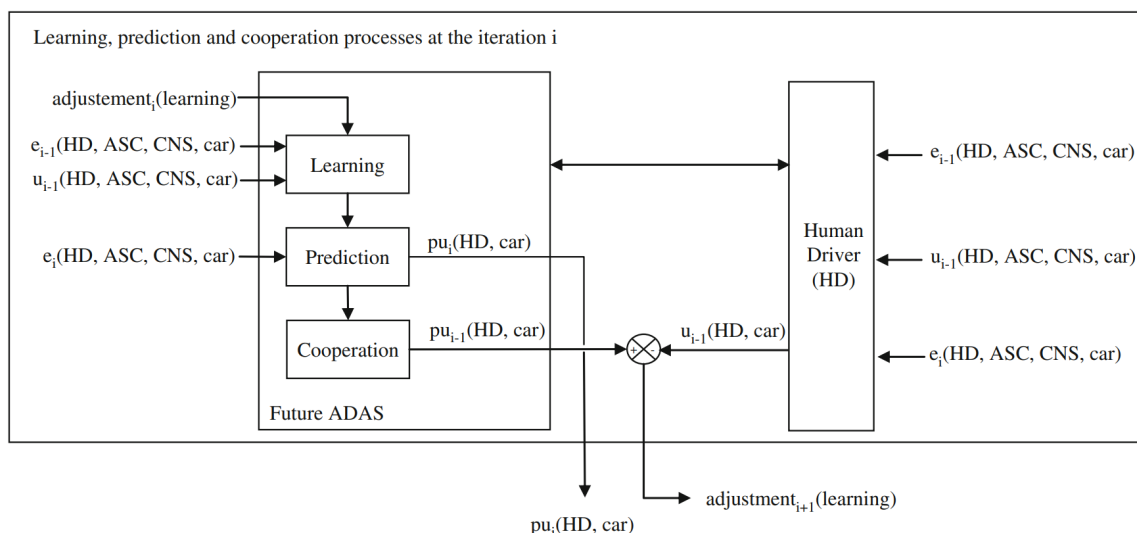


FIGURE 1.7 – Apprentissage du processus de coopération pour la conduite automatisée [Vanderhaegen, 2012].

continuer à surveiller activement l’environnement routier, à prendre des décisions contextuelles et à anticiper les situations imprévues. Cela permet de maintenir une répartition claire des rôles et des responsabilités entre le conducteur et le système automatisé.

La conception de ces systèmes coopératifs implique également la prise en compte des préférences individuelles du conducteur. Chaque conducteur a sa propre façon de conduire, ses habitudes et ses attentes. Les systèmes automatisés doivent donc être flexibles et personnalisables pour s’adapter aux préférences spécifiques de chaque conducteur, tout en respectant les limites de sécurité et de performance.

1.5 Les projets en europe sur le développement de véhicules autonomes

En Europe, plusieurs projets de recherche se sont consacrés au développement de véhicules autonomes tels que **HAVEit** [Hoeger et al., 2008] [Hoeger et al., 2011], **AdaptIVe** [Etemad, 2017], **Autopilot** [Lee et al., 2018], **BRAVE** [Kraetsch et al., 2021], et bien d’autres encore. Ces initiatives visent principalement à atteindre un niveau élevé d’automatisation, généralement de niveau 4, dans lequel le conducteur est tenu de reprendre le contrôle du véhicule dans des situations critiques, qu’elles soient d’ordre technique ou légal. Ce niveau d’automatisation s’inspire du modèle de l’aviation, dans lequel le pilote agit comme un ”superviseur” et n’intervient manuellement que lorsque des situations critiques se présentent.

Cependant, cette approche présente certains effets secondaires bien connus. Lorsque les conducteurs se trouvent dans des véhicules hautement automatisés, ils peuvent perdre conscience de la situation routière, ce qui peut entraîner un risque accru de distraction ou d’hypovigilance. De plus, il a été constaté que les compétences de conduite des conducteurs peuvent diminuer avec l’automatisation complète du véhicule. Afin de remédier à ces problèmes, il est important d’envisager des approches alternatives.

Une approche prometteuse à court terme consiste à maintenir le conducteur dans la boucle de contrôle, ce qui signifie qu’il demeure impliqué dans le processus de conduite malgré l’automatisation du véhicule. Cela offre également des opportunités pour le développement futur des véhicules autonomes. Un exemple de projet européen qui adopte cette approche est le projet **Au-**

toMate [Castellano et al., 2020], qui s'est déroulé de 2016 à 2019 et visait à développer, évaluer et démontrer le concept de la "TeamMate Car". Ce concept implique une collaboration entre le conducteur et l'automatisation pour assurer une conduite sécurisée et efficace. Les objectifs du projet incluaient une répartition flexible des tâches entre le conducteur et l'automatisation, la surveillance et l'anticipation des actions du conducteur, le développement de compétences expertes de conduite, la garantie de la sécurité des manœuvres et l'amélioration de l'interaction humain-machine. Le projet **ADAS&ME** [Anund and Nilsson, 2020], mené de 2015 à 2019, visait à développer des systèmes avancés d'aide à la conduite qui intègrent l'état du conducteur, le contexte environnemental et une interaction adaptative pour transférer automatiquement le contrôle entre le véhicule et le conducteur, assurant ainsi une utilisation plus sûre et plus efficace de la route pour tous les types de véhicules (voitures conventionnelles et électriques, camions, bus, motos). Le projet **i-DREAMS** (Driver and Road Environment Assessment and Monitoring System) [Pilkington-Cheney et al., 2021], mené de 2019 à 2022, visait à développer un système d'évaluation et de surveillance du conducteur et de l'environnement routier. Son objectif principal était d'améliorer la sécurité routière en identifiant les comportements dangereux de conduite, les facteurs de risque liés à l'environnement routier et en fournissant des informations en temps réel pour prévenir les accidents.

En complément, plusieurs projets financés par l'Agence Nationale de la Recherche (ANR) en France ont également mis en évidence les avantages du contrôle partagé entre le conducteur et le véhicule. Par exemple, le projet **PARTAGE** (2009-2012) coordonné par l'IRCCYN a mis en place des suggestions d'action pour réduire les risques de sortie de voie [Hoc et al., 2012]. D'autres projets, comme **ABV** (Automatisation Basse Vitesse) réalisé entre 2009 et 2013 et coordonné par l'IFSTTAR (Institut français des sciences et technologies des transports, de l'aménagement et des réseaux), ont élargi le concept de contrôle partagé au contrôle longitudinal sur autoroute dans des conditions de trafic dense [Sentouh et al., 2014].

Le projet **CoCoVeA** (Cooperation Conducteur - Vehicule Automatisé) (2013-2017) coordonné par le LAMIH, s'est concentré sur la gestion de l'autorité et la modulation du niveau d'automatisation en utilisant le contrôle partagé, atteignant ainsi le niveau 2 d'automatisation [Benloucif et al., 2016]. Son domaine d'application était la conduite sur autoroute à des vitesses légales. Des essais complets ont été réalisés à la fois sur simulateur et sur véhicule réel. Les résultats de ce projet ont démontré les avantages de partager la conduite entre le conducteur et l'automate, permettant à chacun de compléter l'action de l'autre sous forme d'une assistance bilatérale.

Bien que la validation du système dans une expérimentation sur simulateur ait montré son intérêt, elle a également révélé une limitation : dans des circonstances similaires, le conducteur devait toujours apporter les mêmes corrections. Le système n'était pas capable d'apprendre ni d'évoluer. Cependant, ces résultats ont permis de souligner l'importance du contrôle partagé pour une conduite efficace et sécurisée.

De manière similaire, le projet **AutoConduct** (2016-2020), coordonné par VeDeCoM, s'est penché sur les transitions entre les modes de conduite automatique et manuelle, aux niveaux 3 ou 4, en utilisant un contrôle partagé progressif sous la supervision d'un système avancé de surveillance du conducteur [Tattegrain et al., 2021]. Ce projet visait à étudier comment le conducteur et l'automate peuvent collaborer de manière fluide lors des changements entre les modes de conduite automatisée et manuelle. La surveillance avancée du conducteur était essentielle pour assurer la sécurité et permettre une transition en douceur entre les différents modes de conduite.

Cette thèse s'inscrit dans le cadre du projet **ANR-CoCoVeIA** (2019-2024) (Coopération Conducteur-Véhicule Intelligent Autonome), coordonné par le LAMIH, qui vise à intégrer des capacités d'auto-apprentissage dans un système coopératif destiné aux véhicules autonomes de niveau 2. L'objectif principal de ce projet est d'améliorer les compétences des systèmes automatisés en leur permettant d'apprendre de manière optimale à effectuer des manœuvres spécifiques

tout en respectant les règles de circulation et de sécurité.

1.6 Architecture hiérarchique pour la coopération conducteur-véhicule automatisé

L'objectif de cette partie est de proposer une architecture hiérarchique de coopération conducteur-véhicule automatisé qui permet de garantir une compréhension mutuelle et de prendre en compte les spécificités individuelles des conducteurs pour une meilleure confiance dans le système de conduite automatisé.

1.6.1 L'activité de conduite automobile et sa décomposition hiérarchique

L'activité de conduite automobile est définie par l'ensemble des processus nécessaires pour opérer un véhicule sur la route. Ces activités comprennent la détection, la reconnaissance et la classification des objets et des événements, les réponses appropriées à ces objets et événements, la planification des manœuvres, le contrôle de la dynamique longitudinale et latérale du véhicule, ainsi que l'amélioration de la visibilité.

[Donges, 1999] décrit la tâche de conduite comme une activité sensorimotrice axée sur un objectif, dans un modèle en trois couches comprenant la navigation, le guidage et le contrôle. Ces couches sont liées à différentes sous-tâches, qui peuvent à leur tour être classées selon différents niveaux de comportement humain [Donges, 1999]. Ces niveaux peuvent être expliqués en termes du modèle de Rasmussen [Rasmussen, 1983] (voir Figure 1.8). Il distingue le comportement basé sur les compétences, qui se produit automatiquement et permet l'exécution d'une activité secondaire, du comportement basé sur les règles, qui est nécessaire dans les situations fréquentes. Le comportement basé sur les connaissances est requis dans les situations complexes, qui n'ont pas été souvent vécues.

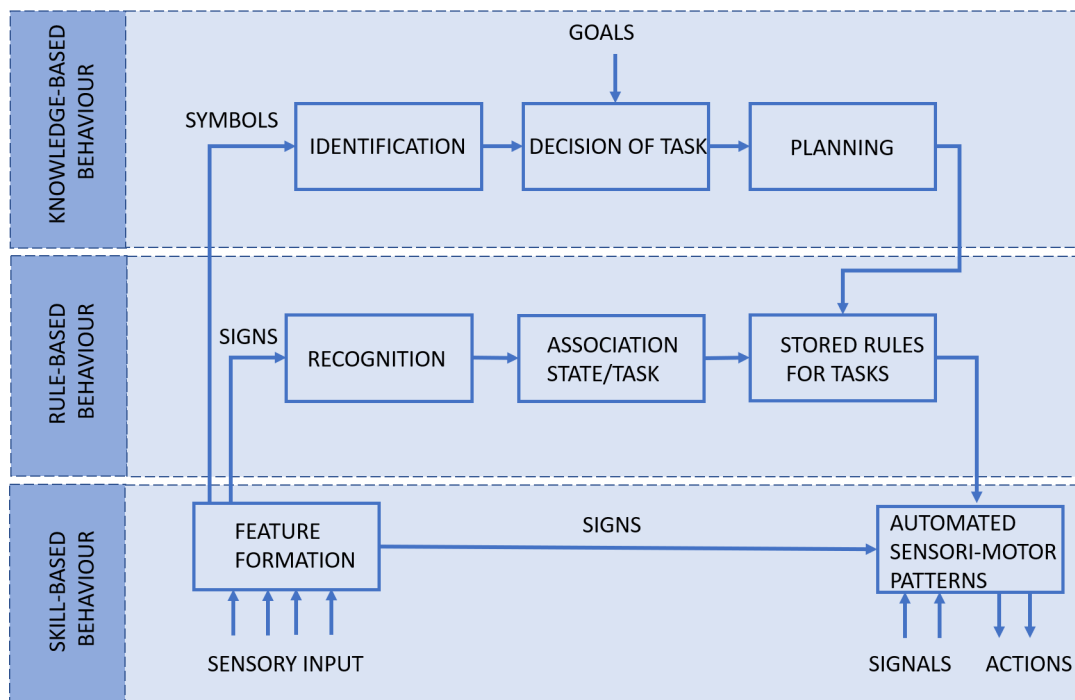


FIGURE 1.8 – Illustration simplifiée des trois niveaux de performance des opérateurs humains compétents [Rasmussen, 1983].

La première couche de ce modèle cognitif est le niveau de navigation, qui peut être considéré comme un comportement basé sur les connaissances et n'est pas interprété comme une tâche dynamique, mais comme un processus de planification [Donges, 1999]. La tâche de conduite dynamique se compose des deux niveaux suivants, le guidage et le contrôle. Le niveau de guidage décrit la sélection des manœuvres pendant la tâche de conduite, tandis que le niveau de contrôle ou de stabilisation englobe le contrôle de la dynamique longitudinale et latérale du véhicule. L'état actuel du véhicule est perçu par le conducteur, ce qui lui permet de sélectionner et d'appliquer les manœuvres appropriées par le biais d'actions motrices. Selon l'expérience du conducteur, son état et la situation de conduite, les deux niveaux de la tâche de conduite peuvent nécessiter un comportement basé sur les règles ou basé sur les compétences.

Michon dans [Michon, 1985] (voir Figure 1.9) propose un modèle similaire, qui classe les niveaux selon les efforts stratégiques, tactiques et opérationnels du conducteur. L'effort stratégique comprend la planification de la destination et des itinéraires, tandis que l'effort tactique implique, par exemple, les manœuvres de dépassement et de changement de voie. L'effort opérationnel comprend les réactions au freinage et au braquage pour stabiliser le véhicule.

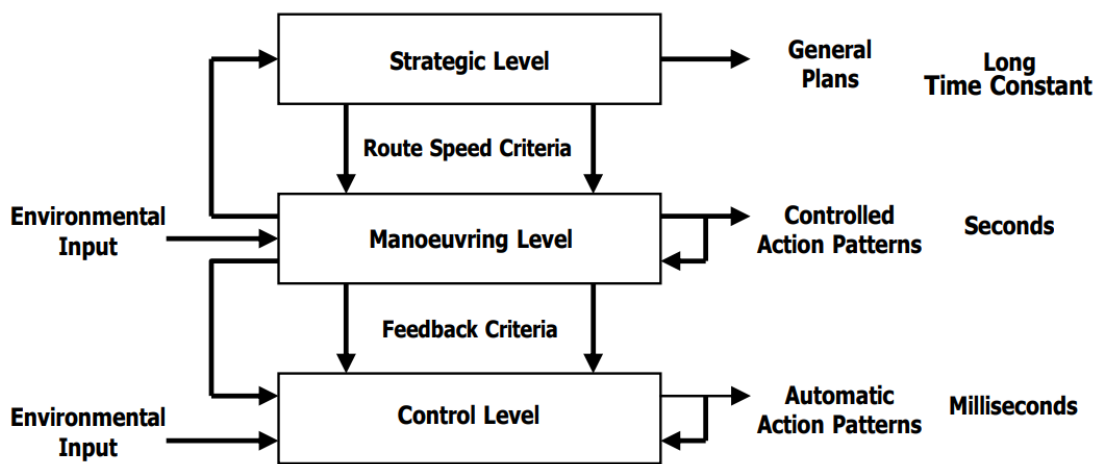


FIGURE 1.9 – La structure hiérarchique de la tâche de conduite [Michon, 1985].

Selon [Fastenmeier and Gstalter, 2007], les tâches de navigation, de guidage et de contrôle peuvent être regroupées dans la catégorie des "tâches de conduite de base", qui se produisent dans un large éventail de situations de trafic.

Groeger [Groeger, 2000] décrit le comportement du conducteur comme étant orienté vers un objectif, les conducteurs pouvant avoir plusieurs objectifs (sécurité, vitesse, économie, etc.). Ces objectifs peuvent être en conflit à tout moment, il est donc nécessaire que les conducteurs évaluent les situations et planifient leur conduite de manière adéquate [Young et al., 2011].

Dans le cadre du projet ANR-CoCoVeA (2013-2017), le travail décrit dans l'article de Benloucif et al. [Benloucif et al., 2016] (voir Figure 1.10) élargit ces modèles à un modèle en quatre couches qui divise le niveau de guidage en un niveau de planification des manœuvres et un niveau de planification des trajectoires. Ce modèle constitue une base très appropriée pour la conception d'une automatisation centrée sur l'humain. L'interaction entre le conducteur et le système au niveau tactique est assurée par le biais de l'IHM (Interface humain-Machine) et du module de détection des intentions du conducteur. Au niveau opérationnel, l'interaction est haptique et se fait par l'intermédiaire du volant et la pédale d'accélération à retour d'effort. Afin de garantir la coopération au niveau tactique, un mécanisme de gestion des conflits est mis en place. Ainsi, lorsqu'un conflit de décision est détecté, le module de décision des manœuvres procède à un arbitrage pour déterminer lequel a l'autorité sur la décision. Au niveau opérationnel, une stratégie

de contrôle qui favorise une transition fluide et continue entre le conducteur et l'automatisation est utilisée.




FIGURE 1.10 – Une architecture de coopération multi-niveaux entre le conducteur et un système de conduite automatisée [Benloucif et al., 2016].

Cependant, il est important de noter que malgré les avantages de ces architectures pour la coopération entre le conducteur et l'automatisation, elles présentent une limitation majeure : l'absence d'apprentissage automatique dans le système. Le système ne s'adapte pas et ne progresse pas avec le temps, ce qui constitue une opportunité importante à explorer pour améliorer encore la coopération entre l'humain et la machine.

1.6.2 Les limitations des architectures de coopération existantes

Dans cette section, nous examinerons en détail les limitations des architectures existantes pour assurer une coopération efficace entre le conducteur et le véhicule automatisé, notamment le manque de confiance et de compréhension mutuelle, le risque accru d'erreurs humaines, les difficultés liées aux transitions entre les modes de fonctionnement, la surcharge cognitive, la dépendance excessive, l'adaptation limitée aux préférences individuelles et la diminution de l'efficacité de la collaboration. En identifiant ces limitations, nous pourrions mieux comprendre les défis auxquels sont confrontés les systèmes de coopération humain-véhicule actuels et proposer des solutions pour les surmonter.

Dans la coopération entre l'humain et la machine, il est crucial que la machine conduise le véhicule de manière similaire à un conducteur humain afin de créer une expérience de conduite détendue pour les passagers, y compris le conducteur lui-même [Nguyen et al., 2017]. Cependant, si le fonctionnement de la machine ne correspond pas au comportement attendu par le conducteur, des conflits entre les actions de la machine et les attentes du conducteur peuvent survenir, pouvant potentiellement conduire à des accidents mortels. Par exemple, lors d'un changement automatique de voie, un conducteur prudent peut se sentir tendu si la machine tourne le volant trop rapidement en laissant une courte distance de sécurité par rapport au véhicule qui le précède, tandis qu'un conducteur caractérisé par une conduite plus sportive peut s'impatienter si le changement automatique de voie prend trop de temps [Yu et al., 2018]. Des études ont

révélé que certaines fonctionnalités de conduite automatique sont moins efficaces qu'un conducteur humain, ce qui a conduit les testeurs à annuler les changements automatiques de voie par mesure de sécurité [Barry, 2019].

Ces exemples mettent en évidence la nécessité d'une personnalisation dans la coopération humain-machine [Okamoto and Tsiotras, 2019]. Plus le comportement de conduite de la machine est proche à celui du conducteur en termes de décision, d'anticipation et de trajectoires, moins il y aura de conflits et d'interférences négatives entre les deux agents. Cependant, les architectures existantes présentent certaines limitations qui peuvent entraver une coopération harmonieuse entre l'humain et le véhicule.

- **Manque de confiance et de compréhension mutuelle** : Les conducteurs peuvent avoir du mal à faire confiance aux systèmes automatisés, en particulier lorsqu'ils ne comprennent pas pleinement leur fonctionnement ou lorsqu'ils perçoivent un manque de transparence dans les décisions prises par le système. Cela peut entraîner une méfiance et une réticence à coopérer pleinement avec le système.
- **Risque d'erreur humaine** : Si les systèmes automatisés ne sont pas conçus pour prendre en compte les différences inter et intra-individuelles dans la capacité des conducteurs à interagir avec eux, cela peut augmenter le risque d'erreurs humaines. Les conducteurs qui ont plus de difficultés à comprendre et à utiliser les fonctionnalités des systèmes autonomes peuvent commettre des erreurs de conduite qui pourraient être évitées si les systèmes étaient adaptés à leurs besoins.
- **Temps de transition entre les modes de fonctionnement** : Comme nous l'avons mentionné précédemment, lorsqu'un système automatisé passe du mode entièrement automatisé au mode de contrôle manuel, ou vice versa, il peut y avoir un temps de transition qui peut causer des désagréments ou des perturbations engendrant ainsi un sentiment d'insécurité chez le conducteur.
- **Surcharge cognitive** : Les systèmes automatisés peuvent fournir une quantité importante d'informations et de notifications au conducteur, ce qui peut entraîner une surcharge cognitive. Les conducteurs peuvent se sentir submergés par les informations et avoir du mal à prendre des décisions efficaces et rapides.
- **Dépendance excessive** : Certains conducteurs peuvent développer une dépendance excessive aux systèmes automatisés, ce qui peut entraîner une diminution de leur vigilance et de leurs compétences de conduite. Cela peut poser des problèmes lorsque le système ne peut pas gérer certaines situations ou lorsque le conducteur doit reprendre le contrôle en cas de défaillance du système.
- **Adaptation limitée aux préférences individuelles** : Les systèmes automatisés peuvent ne pas être suffisamment adaptés aux préférences individuelles des conducteurs. Par exemple, certains conducteurs peuvent préférer une conduite plus agressive ou plus douce, mais les systèmes automatisés peuvent ne pas être en mesure de s'ajuster de manière optimale à ces préférences individuelles.
- **Diminution de l'efficacité de la coopération** : Si les interactions entre les conducteurs humains et les systèmes autonomes ne sont pas adaptées aux préférences et aux caractéristiques individuelles des utilisateurs, cela peut entraîner une diminution de l'efficacité de la coopération. Les conducteurs peuvent avoir du mal à comprendre les instructions des systèmes autonomes ou à s'adapter aux modes de conduite qui ne sont pas conformes à leurs préférences.

Ces défis soulignent la nécessité d'une architecture de coopération humain-véhicule auto-adaptative qui surmonte ces limitations et améliore l'efficacité, l'acceptabilité et la sécurité des systèmes d'aide à la conduite.

1.6.3 Une architecture de coopération auto-adaptative entre le conducteur et le véhicule automatisé

Dans cette partie, nous présentons une architecture de coopération humain-véhicule auto-adaptative qui vise à améliorer le contrôle partagé haptique dans les systèmes automatisés. Cette architecture, illustrée dans la Figure 1.11, présente une approche innovante en matière de coopération en prenant en compte plusieurs aspects essentiels. Elle offre la possibilité d'établir une stratégie de coopération pour les véhicules coopératifs auto-adaptatifs, en particulier en adaptant les décisions et les trajectoires en fonction des préférences du conducteur. De plus, elle intègre la conception de systèmes conscients de leurs propres limites. En outre, cette approche aborde des problématiques critiques telles que la gestion de l'interaction des véhicules autonomes avec les autres usagers de la route, les algorithmes de prédiction et de planification de trajectoires, les méthodes de prise de décision, ainsi que l'apprentissage continu et évolutif pour personnaliser le système en fonction des préférences et des besoins spécifiques de chaque conducteur.

En adoptant cette architecture de coopération humain-véhicule auto-adaptative, nous pouvons surmonter les limitations actuelles et créer des systèmes d'aide à la conduite plus efficaces, personnalisés et acceptés par les conducteurs. Comme ça a été souligné précédemment, la coopération doit être assurée dans chaque niveau de l'activité de conduite afin d'assurer la gestion des interactions entre le conducteur et le système de conduite automatisée.

L'architecture de coopération proposée dans cette thèse considère alors les trois niveaux : stratégique, tactique et opérationnel. Chaque niveau joue un rôle spécifique dans la coopération entre humain et le véhicule automatisé, et contribue à améliorer l'efficacité et la sécurité de la conduite.

1.6.3.1 Le niveau stratégique :

Au niveau stratégique, le module de planification de l'itinéraire et du plan stratégique permet de calculer un itinéraire en fonction de critères spécifiques. Ce module intègre également des fonctionnalités avancées, telles que la transmission d'informations provenant du plan stratégique, qui sont utilisées pour prendre des décisions concernant les manœuvres. Cela garantit une coordination efficace entre le conducteur et le système automatisé. Il convient de noter que la thèse ne se focalise pas sur cette partie, car les défis ne résident pas dans les aspects automatiques, mais plutôt dans l'optimisation, notamment dans le contexte de la recherche opérationnelle et de l'informatique.

1.6.3.2 Le niveau tactique :

Au niveau tactique de notre architecture de coopération humain-véhicule auto-adaptative, plusieurs modules sont implémentés pour faciliter la coopération entre le conducteur et le système automatisé.

Le premier module qui gère l'évaluation de l'état du conducteur "Driver Assessment" joue un rôle crucial dans la gestion de l'autorité et des interférences. Il surveille en permanence l'état du conducteur, évaluant son niveau d'attention et de fatigue. Ces informations sont prises en compte lors de la prise de décision concernant l'autorité du contrôle et pour ajuster les actions de l'automatisation en fonction de l'état du conducteur. Ainsi, le système peut s'adapter en conséquence pour garantir la sécurité et l'efficacité de la conduite.

Le module suivant estime l'intention du conducteur "Driver Intention". Il utilise différentes sources d'informations, telles que les actions du conducteur, l'état du véhicule et l'environnement proche du véhicule, pour inférer les intentions de manœuvres du conducteur. En analysant ces informations, le système peut anticiper les actions prévues par le conducteur, ce qui facilite la coopération entre le conducteur et l'automatisation. Cela permet également d'ajuster les actions de l'automatisation pour répondre aux besoins du conducteur.

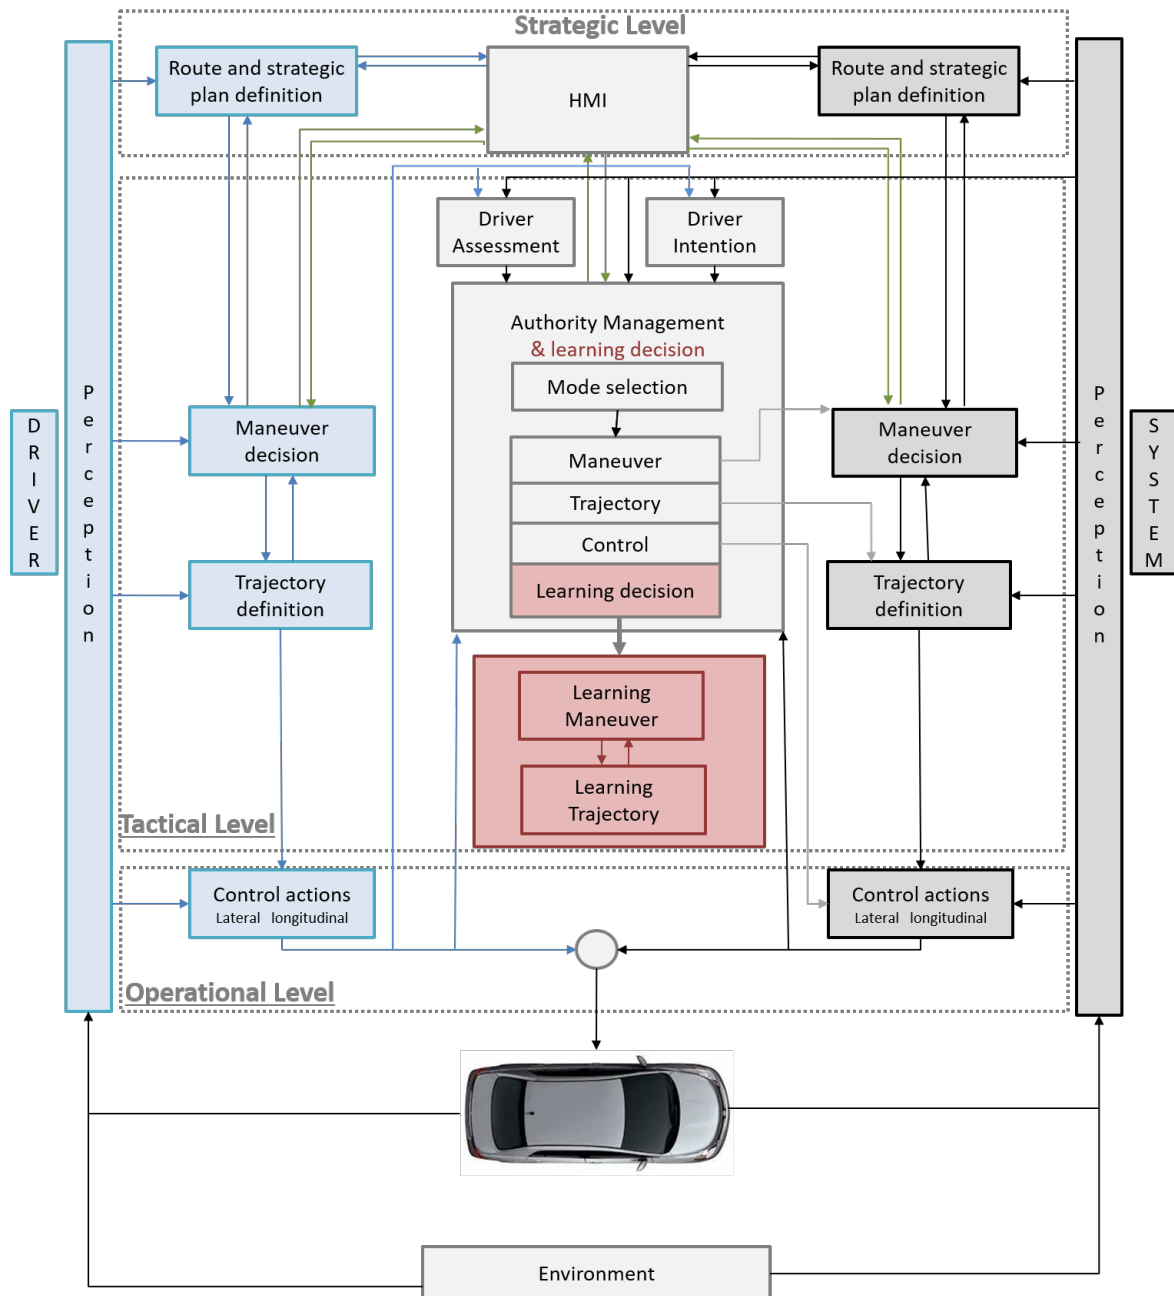


FIGURE 1.11 – Une architecture de coopération multi-niveaux auto-adaptative entre le conducteur et le véhicule automatisé.

Le module de décision des manœuvres "Maneuver decision" est responsable de l'analyse des informations disponibles pour prendre des décisions concernant les manœuvres à exécuter. Toutefois, en cas de détection d'une intention contradictoire du conducteur, un processus d'arbitrage est déclenché. L'arbitrage consiste à déterminer quelle entité, du conducteur ou de l'automatisation, a l'autorité de prendre la décision finale en fonction de la situation spécifique. Cela permet de résoudre les conflits potentiels et de garantir une prise de décision cohérente et sécurisée.

Le module de définition de la trajectoire "Trajectory definition" est responsable de la génération des trajectoires spécifiques à la manœuvre sélectionnée. Il utilise les informations sur la manœuvre prévue, les caractéristiques du véhicule et les contraintes environnementales pour calculer la trajectoire optimale à suivre. Ces trajectoires guident les actions de contrôle pour réaliser la

manœuvre de manière sûre et efficace, en prenant en compte les intentions du conducteur et les conditions de conduite.

Le module de gestion de l'autorité "Authority Management" joue un rôle central dans la sélection du mode de fonctionnement du système. Il prend en compte les niveaux d'automatisation disponibles (0, 1, 2) ainsi que les modes de transition de sécurité et le mode d'urgence. Ce module définit les conditions de transition qui régulent le mode actif du système, déterminant ainsi le niveau d'automatisation approprié. De plus, il assure la coordination entre les niveaux tactique et opérationnel de l'architecture et adapte l'interface humain-machine (IHM) en fonction du mode de fonctionnement actuel.

En outre, notre architecture intègre également un apprentissage progressif et itératif de la manœuvre "Learning Maneuver" et de la trajectoire "Learning Trajectory". Ce processus d'apprentissage se base sur les décisions et les trajectoires réalisées par le conducteur en mode de conduite manuelle ou partagée afin d'améliorer les performances du système en s'adaptant aux préférences et aux comportements spécifiques du conducteur. Une décision est prise concernant la validation de l'apprentissage "Learning decision" en prenant en compte l'état du conducteur, le respect du code de la route et le niveau de risque associé à la manœuvre. Cette approche permet d'améliorer constamment les performances du système en s'adaptant aux préférences et aux comportements du conducteur, tout en garantissant la sécurité et la conformité.

1.6.3.3 Le niveau opérationnel :

Au niveau opérationnel, le module d'exécution du contrôle "Control actions" est responsable de l'implémentation pratique du contrôle du véhicule. Il utilise des contrôleurs pour diriger le véhicule et gérer sa vitesse permettant de garantir une conduite sûre et fluide. Les actions de contrôle sont coordonnées avec les décisions prises au niveau tactique, en tenant compte des intentions du conducteur, des conditions de conduite et des contraintes environnementales. Cette coordination et cette interaction harmonieuse entre humain et le système automatisé contribuent à une meilleure coopération et à une conduite plus sûre.

En adoptant cette architecture de coopération humain-véhicule auto-adaptative, nous pouvons relever les défis actuels et améliorer l'efficacité, l'acceptabilité et la sécurité des systèmes de conduite automatisés. Cette approche permet de personnaliser les fonctionnalités des systèmes automatisés en fonction des préférences et des besoins individuels des conducteurs, offrant ainsi une expérience de conduite optimale. De plus, elle renforce la coopération entre humain et le système automatisé, favorisant une meilleure acceptation et utilisation des fonctionnalités d'assistance à la conduite.

1.7 Cas d'usage traité dans le cadre de la thèse

Avec le développement rapide des ADAS, la conduite des véhicules devient de plus en plus automatisée. Parmi ces systèmes, les systèmes d'assistance au changement de voie (LCAS) sont conçus pour aider le conducteur à choisir les manœuvres de changement de voie. Ces systèmes fournissent des informations et des conseils au conducteur pour faciliter ses décisions.

Cependant, lorsque le système va au-delà de l'information et exécute lui-même les manœuvres planifiées, le problème devient complexe. Les décisions prises par le système doivent être fiables et sécurisées afin de garantir la sécurité et le confort des passagers du véhicule, ainsi que des autres usagers de la route. Il est essentiel que le système prenne en compte les aspects sécurité, tels que la détection des véhicules environnants, l'évaluation des distances de sécurité et la prise en compte des règles liées au code de la route.

De plus, malgré la conscience du conducteur des décisions prises par le système et de la trajectoire prévue du véhicule, il est possible que sa confiance et son acceptabilité vis-à-vis du système restent limitées. Chaque conducteur a ses propres préférences en termes de décisions

de conduite et de trajectoires (voir Figure 1.12), ce qui peut susciter une certaine méfiance à l'égard d'un système automatisé prenant des décisions à sa place. Il est donc essentiel de prendre en compte les attentes et les préférences individuelles des conducteurs lors de la conception de ces systèmes d'assistance au changement de voie.




FIGURE 1.12 – La prise de décision et la planification de trajectoire pour les véhicules intelligents dans les scénarios de changement de voie.

Pour faire face à ces défis, nous envisageons de développer un système d'assistance au changement de voie en utilisant l'architecture de coopération auto-adaptative précédemment proposée (voir Figure 1.11). Ce système sera centré sur l'humain et sera adaptatif, prenant en considération les préférences individuelles des conducteurs, tout en garantissant la sécurité globale sur la route.

1.8 Simulateur de conduite SHERPA-LAMIH

Les recherches menées et la validation des algorithmes ont été réalisées sur le simulateur de conduite SHERPA-LAMIH, qui est un dispositif avancé utilisé pour des projets de recherche impliquant le développement et le prototypage de systèmes coopératifs d'aide à la conduite. Le simulateur a été installé au Laboratoire d'Automatique, de Mécanique et d'Informatique Industrielles et Humaines (LAMIH) en septembre 1997, dans le cadre d'un partenariat avec le constructeur PSA Peugeot Citroën, qui est maintenant devenu Stellantis (voir la Figure 1.13).

Ce simulateur a été utilisé dans de nombreuses études visant à améliorer la sécurité routière. Il permet de simuler différentes situations de conduite, y compris des situations potentiellement dangereuses, telles que la conduite monotone, les dépassements sur autoroute, et les comportements biomécaniques du conducteur en situation de pré-crash. Il permet également de détecter des états dangereux pour le conducteur, comme l'hypovigilance ou la distraction, et d'estimer la charge de travail du conducteur.

Le simulateur utilise le logiciel de simulation automobile SCANeR développé par la société AV Simulation, qui offre un environnement de simulation réaliste prenant en compte la dynamique du véhicule et une variété de paramètres tels que la météo, l'adhérence et l'état de surface de la route. Il offre également la possibilité d'utiliser deux environnements de développement, à savoir RTmaps (INTEMPORA) et Matlab/Simulink. Il dispose d'une bibliothèque de modèles dynamiques de véhicule très réalistes comme le modèle CALLAS.

1.9 Conclusion

En conclusion, ce chapitre a mis en évidence l'importance de la coopération entre le conducteur et les systèmes d'automatisation dans le domaine de la conduite automobile. La conception centrée sur l'humain des systèmes avancés d'aide à la conduite et de l'automatisation de la conduite est cruciale pour améliorer la sécurité et l'efficacité de la conduite.



FIGURE 1.13 – Le simulateur de conduite SHERPA-LAMIH.

Cependant, les architectures existantes présentent des limitations en termes de confiance mutuelle, de compréhension, de surcharge cognitive et d'adaptation aux préférences individuelles. Pour surmonter ces limitations, une architecture auto-adaptative de la coopération humain-véhicule a été proposée, mettant l'accent sur la gestion des interactions aux niveaux stratégique, tactique et opérationnel.

Cette architecture permet de mieux adapter les systèmes d'automatisation aux besoins et aux préférences individuelles des conducteurs, tout en garantissant une coopération harmonieuse et efficace. Chaque niveau joue un rôle spécifique dans la prise de décision, la planification des manœuvres et l'exécution du contrôle, contribuant ainsi à améliorer la sécurité et l'efficacité de la conduite.

Il est donc essentiel de développer une automatisation centrée sur l'humain et personnalisée pour assurer une coopération efficace entre le conducteur et les systèmes automatisés.

Dans le chapitre suivant, nous allons explorer en détail comment cette nouvelle approche peut être appliquée pour personnaliser les systèmes d'assistance au changement de voie (LCAS), offrant ainsi une expérience de conduite plus adaptée et sécurisée.

Chapitre 2

Prise de décision et planification de trajectoire personnalisées

Sommaire

| | | |
|------------|--|-----------|
| 2.1 | Introduction | 62 |
| 2.2 | Etat de l'art | 62 |
| 2.3 | Contribution | 62 |
| 2.4 | La prise de décision sur la manœuvre | 64 |
| 2.4.1 | Etat de l'art | 64 |
| 2.4.2 | La prise de décision de changement de voie | 65 |
| 2.4.3 | Validation expérimentale | 68 |
| 2.5 | La planification de trajectoire | 69 |
| 2.5.1 | Etat de l'art | 70 |
| 2.5.2 | La planification de trajectoire latérale | 71 |
| 2.5.3 | La planification de trajectoire longitudinale | 72 |
| 2.6 | Détection de l'intention du conducteur | 75 |
| 2.6.1 | Etat de l'art | 75 |
| 2.6.2 | Détection d'intention au changement de voie | 76 |
| 2.6.3 | Validation expérimentale | 77 |
| 2.7 | L'algorithme d'apprentissage pour la personnalisation | 79 |
| 2.7.1 | État de l'art | 79 |
| 2.7.2 | L'approche de descente de gradient stochastique (SGD) dans les réseaux de neurones | 80 |
| 2.7.3 | Application de l'algorithme SGD pour la personnalisation des LCAS | 81 |
| 2.7.4 | Le système de prise de décision pour l'apprentissage | 86 |
| 2.8 | Conclusion | 92 |

2.1 Introduction

Dans le chapitre précédent, nous avons mis en évidence l'importance cruciale de la coopération entre le conducteur et les systèmes d'automatisation pour améliorer la sécurité et l'efficacité de la conduite automobile. Cependant, nous avons également identifié des limitations majeures dans les architectures existantes, notamment en termes de confiance mutuelle, de compréhension, de surcharge cognitive et d'adaptation aux préférences individuelles. Pour surmonter ces limitations, nous avons proposé une approche de coopération auto-adaptative entre l'humain et le véhicule, en mettant en avant les niveaux stratégique, tactique et opérationnel comme éléments clés.

Dans ce nouveau chapitre, nous allons explorer en profondeur comment cette approche innovante peut être appliquée pour personnaliser les systèmes d'assistance au changement de voie (LCAS) dans les véhicules intelligents. Nous verrons comment tenir compte du comportement et des caractéristiques individuelles de chaque conducteur dans la prise de décision et la planification de trajectoire en mode de conduite manuelle, en nous concentrant particulièrement sur le niveau tactique.

2.2 Etat de l'art

De nombreuses approches axées sur la personnalisation et l'adaptation des systèmes avancés d'aide à la conduite ont été proposées dans la littérature [Hasenjäger and Wersing, 2017]. Les auteurs de [Benloucif et al., 2019a, Benloucif et al., 2017] ont proposé une approche qui prédit la trajectoire du conducteur en fonction du couple appliqué au volant à l'aide d'un modèle de vitesse et de taux de lacet constants CTRV "Constant Turn Rate and Velocity". Dans [Han et al., 2021], les auteurs ont prédit la trajectoire du conducteur en utilisant le réseau LSTM (Long-Short-Term-Memory) et l'observateur d'état étendu pour adapter la trajectoire suivie par le système en contrôle partagé. Dans [Noto et al., 2011, Noto et al., 2012], un système d'assistance à l'évitement d'obstacles est proposé sur la base du champ de potentiel personnalisé, où la représentation des sentiments de risque du conducteur a été identifiée à l'aide de données individuelles de conduite. Cependant, comme les données de conduite ont été collectées à l'avance, le comportement du système reste fixe après l'apprentissage. Pour garantir la sécurité et personnaliser les décisions du système, une méthode basée sur des fonctions d'utilité a été employée dans [Nilsson et al., 2016], qui permet de comparer plusieurs critères pondérés pour évaluer et classer différentes décisions. Dans [Butakov and Ioannou, 2014], une approche combinée entre un modèle cinématique de changement de voie sinusoïdal et un modèle stochastique est utilisée, ce qui permet d'ajuster les paramètres du modèle cinématique au style de conduite individuel. Un classifieur de type SVM (Support Vector Machine) est utilisé dans [Vallon et al., 2017] pour modéliser le mécanisme de décision de changement de voie personnalisé de certains conducteurs. L'utilisation de réseaux de neurones dans [Zhu et al., 2020] et de la méthode de régression de séries temporelles multidimensionnelles [Yang et al., 2021] pour la personnalisation des LCAS a été proposée. L'efficacité de ces techniques repose entièrement sur les données sur lesquelles sont effectués les apprentissages, celles-ci devant majoritairement être disponibles au préalable (apprentissage hors ligne). Elles souffrent également du fait qu'il est difficile d'étudier les performances aux limites du fonctionnement du système ou de prédire le comportement du système face à des situations inconnues.

2.3 Contribution

Ce chapitre présente un système novateur conçu pour améliorer la prise de décision et la planification des trajectoires dans des scénarios de changement de voie. Le système global proposé (voir le schéma fonctionnel dans la Figure 2.1) intègre des mécanismes avancés pour comprendre

les actions entreprises par un conducteur lorsqu'il effectue des changements de voie en mode de conduite manuelle, en utilisant un système de détection d'intention. De plus, le système intègre une fonctionnalité d'auto-apprentissage dans le système d'assistance au changement de voie, permettant ainsi de personnaliser les fonctionnalités d'automatisation en fonction des préférences de chaque conducteur. Ce système présente plusieurs avantages par rapport à d'autres méthodes existantes précédemment citées. Tout d'abord, il résout le défi de la disponibilité préalable des données nécessaires à l'apprentissage, car il fonctionne de manière itérative et progressive, collectant des données en ligne à partir des comportements réels des conducteurs. Cela signifie qu'il peut continuer à s'améliorer au fil du temps sans avoir besoin d'une base de données préexistantes. De plus, il est capable de s'adapter à des situations en temps réel, ce qui le rend très flexible et adaptatif.

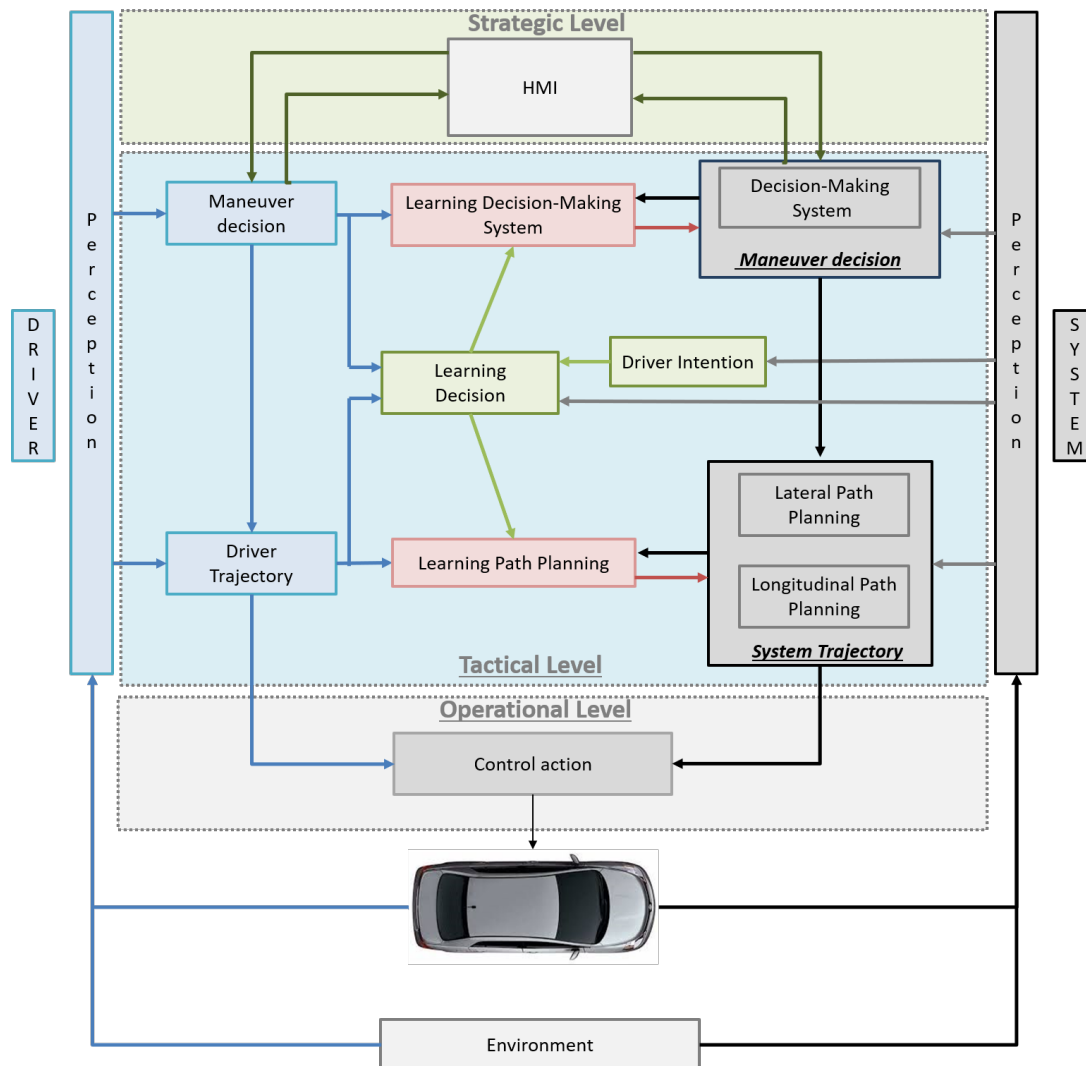


FIGURE 2.1 – Système de prise de décision et planification de trajectoires personnalisées.

Pour renforcer davantage ce processus d'apprentissage, un système de validation a été développé. Cette étape de validation prend en considération plusieurs facteurs essentiels, notamment l'état du conducteur, le respect du code de la route et le niveau de risque associé à la manœuvre effectuée par le conducteur. En intégrant ces aspects, le système garantit une fiabilité et une précision accrues dans l'apprentissage et l'ajustement des comportements de conduite automatisée.

En résumé, ce système représente une contribution significative dans le domaine de l'assistance à la conduite. Il exploite l'auto-apprentissage pour adapter automatiquement les fonctionnalités d'automatisation en fonction des préférences individuelles des conducteurs, tout en assurant la sécurité et l'efficacité dans les situations de changement de voie sur la route.

2.4 La prise de décision sur la manœuvre

Pour les véhicules autonomes (AV), le module de prise de décision joue un rôle crucial car il fait le lien entre le module de perception de l'environnement et le module de contrôle du mouvement. Les performances de conduite des AV sont fortement influencées par le module de prise de décision. Un algorithme de prise de décision fiable et réalisable peut améliorer les performances des AV, notamment en matière de sécurité, de confort, d'efficacité et d'économie de carburant [Lin et al., 2018, Hang et al., 2021, Hang et al., 2017, Ma et al., 2021]. Par conséquent, la recherche sur les algorithmes de prise de décision pour les AV est devenue un sujet brûlant ces dernières années.

2.4.1 Etat de l'art

Les algorithmes de prise de décision pour les véhicules autonomes (AV) sont conçus pour résoudre divers scénarios de conduite tels que les changements de voie, l'évitement de collision, et bien d'autres. Le changement de voie est un scénario de conduite typique, courant et potentiellement dangereux, utilisé pour tester les performances des AV [Schubert, 2011, Hang et al., 2020, Mouhagir et al., 2019]. De nombreuses études ont été menées sur la prise de décision du changement de voie des AV, en utilisant différentes approches.

Parmi ces approches, certaines sont basées sur les fonctions d'utilité pour gagner en flexibilité et gérer des scénarios complexes [Wei et al., 2010]. D'autres utilisent l'apprentissage basé sur les données, notamment SVM (Support Vector Machine) [Zhang et al., 2017], les machines d'apprentissage extrême (ELM) [Huang et al., 2006], l'apprentissage par renforcement (RL) [Peters et al., 2013] et les réseaux neuronaux profonds (DNN) [Costilla-Reyes et al., 2017]. Les modèles de réseaux neuronaux convolutifs (CNN) sont mis en place pour détecter, reconnaître et abstraire des informations dans la scène routière en entrée, permettant ainsi de simuler des décisions de changement de voie similaires à celles prises par les conducteurs humains pour les AV [Li et al., 2018]. Certains algorithmes combinent même les SVM avec l'optimisation des paramètres bayésiens pour traiter la prise de décision du changement de voie des AV [Liu et al., 2019]. Dans [Xu et al., 2018], un processus de décision markovien (MDP) est associé à l'apprentissage par renforcement pour résoudre les problèmes de prise de décision séquentielle liés au changement de voie.

Cependant, ces approches suscitent certaines critiques. L'une des principales préoccupations concerne leur dépendance excessive aux données. Ces approches nécessitent une quantité importante de données d'entraînement pour construire des modèles de prise de décision efficaces, ce qui peut être coûteux et chronophage.

De plus, peu d'algorithmes existants prennent en compte les caractéristiques spécifiques des conducteurs dans le processus de prise de décision. Les différents conducteurs ont des préférences de conduite variées. Ces différentes caractéristiques peuvent entraîner des résultats de prise de décision différents. La contribution de ce travail réside dans la structuration du module de prise de décision basée sur une évaluation multicritère de la situation, en intégrant un critère de personnalisation progressif du fonctionnement selon les préférences de chaque conducteur. Cela permettrait d'améliorer la pertinence des décisions prises par les véhicules autonomes en fonction des préférences individuelles des utilisateurs.

L'algorithme visant à ajuster les paramètres du système de prise de décision sera introduit ultérieurement dans ce chapitre. Cette approche d'adaptation personnalisée permettra de mettre

en œuvre une décision répondant aux préférences individuelles des conducteurs et offrant ainsi une expérience de conduite optimisée en fonction de différents critères tels que la sécurité et l'efficacité.

2.4.2 La prise de décision de changement de voie

Dans le contexte de la prise de décision concernant le changement de voie, nous devons choisir parmi les différentes voies disponibles (gauche, centre, droite), qui sont respectivement désignées par les indices (1, 0, -1).

La prise de décision de changement de voie se fait en évaluant le risque, la conformité légale et la condition d'apprentissage pour chaque voie disponible (voir Figure 2.2). Ces critères sont pondérés et utilisés pour calculer un coût global pour chaque voie. La voie avec le coût le plus faible est sélectionnée comme la meilleure voie pour effectuer le changement de voie. Cette approche permet de prendre en compte divers facteurs et de prendre des décisions basées sur des critères objectifs et des préférences individuelles du conducteur.

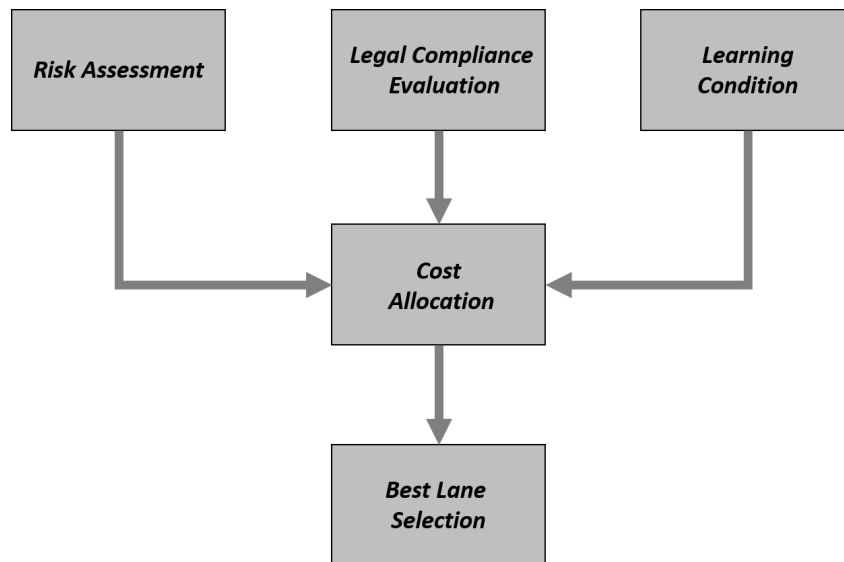


FIGURE 2.2 – La procédure de prise de décision pour effectuer un changement de voie.

2.4.2.1 Calcul du risque

Le risque est évalué en utilisant la mesure du temps inter-véhiculaire (TIV). Le TIV représente la durée estimée avant qu'une collision ou un conflit potentiel ne se produise entre le véhicule ego et les autres véhicules sur une voie donnée [Glaser et al., 2010]. Le TIV est calculé en utilisant la distance inter-véhiculaire (DIV) et la vitesse du véhicule ego. La DIV est la distance entre le véhicule ego et le véhicule le plus proche sur la voie considérée.

$$TIV = \frac{DIV}{v_{ego}} \quad (2.1)$$

Les valeurs de TIV sont calculées pour chaque paire de véhicules dans le champ de vision du véhicule et pour chaque voie disponible, comme illustré dans la Figure 2.3.

Le TIV est normalisé ($\%TIV$) par rapport au TIV maximum (TIV_{max}), qui est déterminé en utilisant la distance inter-véhiculaire maximale perceptible par le système (DIV_{max}) et la vitesse du véhicule ego.




FIGURE 2.3 – Une illustration de la scène de conduite.

$$\begin{cases} TIV_{\max} = \frac{DIV_{\max}}{v_{ego}} \\ \%TIV = \frac{TIV}{TIV_{\max}} \end{cases} \quad (2.2)$$

Le risque est alors calculé comme suit :

$$Risque = 1 - \%TIV \quad (2.3)$$

Cela permet d'obtenir une mesure de risque relative pour chaque voie où le coût du risque pour chaque voie $i \in -1, 0, 1$ est calculé comme suit :

$$C_{i,risque} = Risque(F_i, E_i) + Risque(E_i, L_i) \quad (2.4)$$

2.4.2.2 Évaluation de la conformité légale

La conformité légale est évaluée en fonction des marquages de chaque voie. Une caméra de détection des marquages est utilisée pour identifier le type de marquage de la voie considérée.

Si le marquage est discontinu, cela indique une possibilité de changement de voie autorisé, et le coût de conformité légale est de 0. Si le marquage est continu ou s'il n'y a pas de voie adjacente à gauche/droite, cela indique une impossibilité de changer de voie, et le coût de conformité légale est de 1. Cette évaluation de la conformité légale permet de prendre en compte les règles de circulation et de respecter le code de la route.

Le coût de conformité légale pour chaque voie $i \in 1, 0, -1$ est défini comme suit :

$$C_{i,legal} = Marquage_{voie_i} \quad (2.5)$$

où $Marquage_{voie_i}$ est une variable binaire qui indique le type de marquage de la voie.

2.4.2.3 Condition d'apprentissage

La condition d'apprentissage est évaluée en utilisant la métrique TIV, qui représente l'espace ou le temps inter-véhiculaire désiré par le conducteur avant d'effectuer un changement de voie. Cette condition varie en fonction du type de changement de voie (vers la gauche ou vers la droite) et dépend des TIV normalisés entre le véhicule ego et les autres véhicules sur la voie actuelle ou sur la voie adjacente. Si la condition d'apprentissage est satisfaite, cela signifie qu'il y a suffisamment d'espace pour effectuer le changement de voie sans risque de collision. Sinon, la condition n'est pas satisfaite et le changement de voie ne doit pas être effectué. La condition d'apprentissage permet de prendre en compte les préférences du conducteur et ses connaissances sur l'environnement de conduite.

Pour le changement de voie vers la gauche, la condition d'apprentissage ($C_{\%TIV_1}$) est déterminée en utilisant le rapport ($\%TIV_{EL(0)}$) du temps inter-véhiculaire entre le véhicule ego et le véhicule leader de la voie actuelle sur le temps inter-véhiculaire maximal. La condition est satisfaite si ce rapport est inférieur ou égal à un seuil de pourcentage $\%TIV_1$. Ce seuil représente l'espace désiré par le conducteur avant le changement de voie vers la gauche.

Pour résumer, la condition d'apprentissage pour un changement de voie vers la gauche est comme suit :

$$C_{\%TIV_1} = \left(\%TIV_{EL(0)} \leq \%TIV_1 \right) \quad (2.6)$$

avec :

$$\%TIV_{EL(0)} = \frac{TIV_{EL(0)}}{TIV_{max}} \quad (2.7)$$

Pour le changement de voie vers la droite, la condition d'apprentissage est déterminée en utilisant le rapport ($\%TIV_{FE(-1)}$) du temps inter-véhiculaire entre le véhicule ego et le véhicule suivant dans la voie de droite sur le temps inter-véhiculaire maximal. La condition est satisfaite si ce rapport est supérieur ou égal à un seuil de pourcentage $\%TIV_{-1}$, ce qui indique qu'il y a suffisamment d'espace pour que le véhicule ego puisse se déplacer dans la voie de droite sans risque de collision. Ce seuil représente l'espace désiré par le conducteur avant le changement de voie vers la droite.

Pour résumer, la condition d'apprentissage pour un changement de voie vers la droite est comme suit :

$$C_{\%TIV_{-1}} = \left(\%TIV_{FE(-1)} \geq \%TIV_{-1} \right) \quad (2.8)$$

avec :

$$\%TIV_{FE(-1)} = \frac{TIV_{FE(-1)}}{TIV_{max}} \quad (2.9)$$

Pour le maintien de la voie, la condition d'apprentissage est toujours non satisfaite

$$C_{\%TIV_0} = 0 \quad (2.10)$$

Le coût d'apprentissage pour chaque voie $i \in -1, 0, 1$ est calculé comme suit :

$$C_{i,apprentissage} = C_{\%TIV_i} \quad (2.11)$$

où $C_{\%TIV_i}$ est une variable binaire qui indique la condition d'apprentissage, c'est-à-dire si elle est valide ou non.

Les seuils ($\%TIV_1, \%TIV_{-1}$) pour le changement de voie vers la gauche et la droite sont calculés et ajustés en fonction des mécanismes d'apprentissage présentés dans ce chapitre afin de personnaliser le système de prise de décision pour chaque conducteur.

2.4.2.4 Attribution des coûts

Les coûts de risque, de conformité légale et d'apprentissage sont pondérés par des poids correspondants ($w_{risque}, w_{legal}, w_{apprentissage}$). Ces poids permettent d'accorder une importance relative à chaque critère dans la prise de décision. Les coûts de risque, de conformité légale et d'apprentissage sont calculés pour chaque voie et contribuent à la détermination du coût total pour chaque voie. Le coût total C_i est une mesure globale de la qualité de chaque voie en termes de risque, de conformité légale et de condition d'apprentissage.

$$C_i = \omega_{risque}C_{i,risque} + \omega_{legal}C_{i,legal} - \omega_{apprentissage}C_{i,apprentissage} \quad (2.12)$$

2.4.2.5 Sélection de la meilleure voie

Le système de prise de décision (DMS) choisit la voie avec le coût le plus faible, c'est-à-dire la voie qui présente le risque le plus faible, la plus grande conformité légale et la meilleure condition d'apprentissage. La sélection de la meilleure voie permet de déterminer la voie la plus appropriée pour effectuer le changement de voie en minimisant le risque et en respectant les règles de circulation.

$$DMS = Index\{\min(C_i)\} \quad (2.13)$$

Cette approche permet de prendre en compte divers facteurs et de prendre des décisions basées sur des critères objectifs et des préférences individuelles du conducteur.

2.4.3 Validation expérimentale

Pour valider expérimentalement le système de prise de décision pour le changement de voie, nous avons exécuté un scénario de dépassement sur une autoroute à deux voies avec circulation à sens unique en utilisant le simulateur SHERPA. Les résultats de cette expérimentation sont illustrés dans les Figures 2.4 et 2.5 respectivement. Dans ces graphiques, l'ego-véhicule est représenté en bleu, tandis que le véhicule leader à dépasser est en gris.




FIGURE 2.4 – Scénario de changement de voie vers la gauche : évolution des fonctions de coût pour chaque voie et la prise de décision du système.

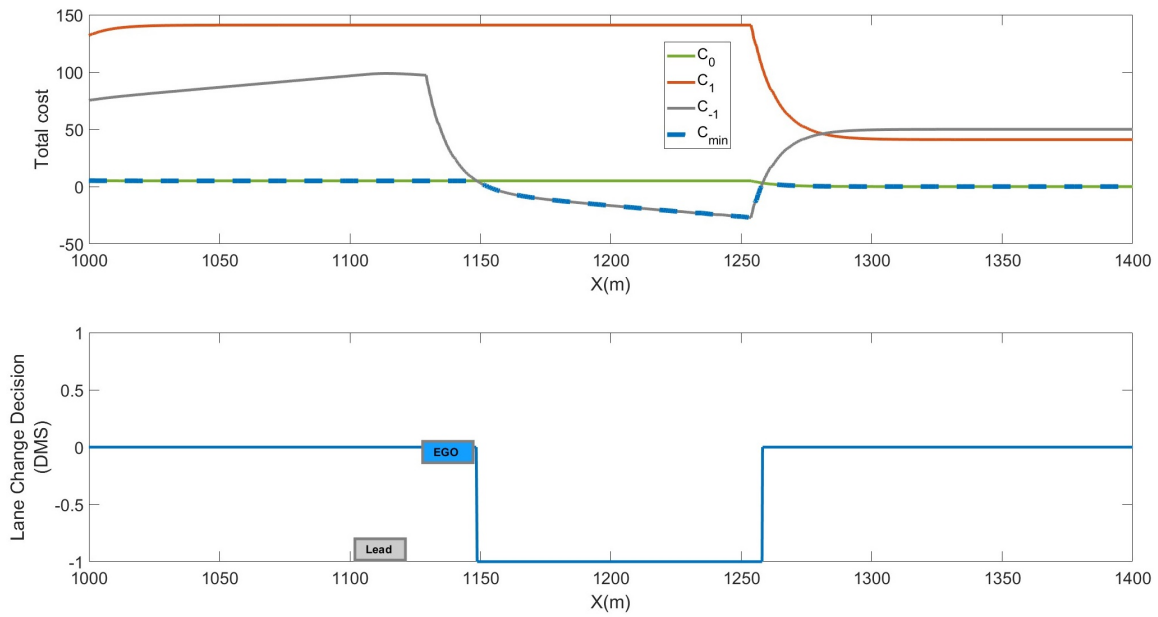


FIGURE 2.5 – Scénario de changement de voie vers la droite : évolution des fonctions de coût pour chaque voie et la prise de décision du système.

La Figure 2.4 montre l'évolution des fonctions de coût pour chaque voie (voie gauche C_1 , voie actuelle C_0 , voie droite C_{-1}) lors du scénario de changement de voie vers la gauche. Ces fonctions de coût représentent l'évaluation de la pertinence d'un changement de voie pour chaque voie disponible. La décision finale du système est basée sur la fonction de coût la plus faible, représentée par C_{min} . Dans ce scénario, on observe que la fonction de coût la plus faible se situe dans la voie gauche, ce qui indique une décision de changement de voie vers la gauche.

De même, la Figure 2.5 présente l'évolution des fonctions de coût pour chaque voie lors du scénario de changement de voie vers la droite. Encore une fois, la fonction de coût la plus faible se situe dans la voie correspondante au changement de voie vers la droite, ce qui confirme la décision prise par le système.

En ce qui concerne le seuil de décision de changement de voie, la Figure 2.6 présente l'impact du seuil $\%TIV_1$ (pour le changement de voie vers la gauche) sur la décision finale du système. On peut observer que lorsque le seuil est plus bas, le système prend des décisions de changement de voie avec une distance plus courte par rapport au véhicule leader. À l'inverse, un seuil plus élevé conduit à des décisions de changement de voie avec une distance plus grande par rapport au véhicule leader. Ce seuil peut être ajusté en fonction des préférences et du style de conduite du conducteur.

En résumé, la validation expérimentale du système de prise de décision de changement de voie a montré que le système est capable de choisir la voie optimale par rapport à un critère intégrant des fonctions de coût calculées pour chaque voie. De plus, l'adaptation du seuil de décision permet de personnaliser les décisions de changement de voie en fonction des préférences individuelles du conducteur.

2.5 La planification de trajectoire

Dans les travaux de recherche liés à la conduite automatisée des véhicules, la planification de trajectoire est l'un des domaines de recherche les plus importants. L'objectif ultime de la planification de trajectoire est de générer un chemin qui assure des décisions de conduite, telles que le changement de voie, de manière efficace et sécurisée.




FIGURE 2.6 – L’impact de la valeur du seuil de décision de changement de voie à gauche ($\%TIV_1$) sur la décision prise par le système.

La planification de trajectoire joue un rôle essentiel dans les systèmes de conduite autonome, car elle permet au véhicule de naviguer de manière autonome dans son environnement tout en évitant les obstacles, respectant les règles de circulation et prenant en compte les préférences du conducteur.

2.5.1 Etat de l’art

L’utilisation de l’apprentissage automatique a ouvert de nouvelles perspectives dans le domaine de la planification de trajectoire et du contrôle pour les véhicules autonomes. Des chercheurs tels que Butakov et Ioannou [Butakov and Ioannou, 2014] ont développé une approche novatrice de planification de trajectoire personnalisée en se basant sur un modèle de courbe sinusoïdale, ajustant ainsi la durée de la trajectoire à l’aide d’un modèle de mélange gaussien. De même, Zhu et al. [Zhu et al., 2020] ont récemment proposé un cadre d’apprentissage combiné pour la tâche de changement de voie en utilisant le modèle GRU (Gated recurrent unit). Ces méthodes se distinguent par leur capacité à optimiser une récompense ou un coût pour générer une trajectoire optimale, en prenant en compte les préférences personnelles de conduite du conducteur, comme le confort, la sécurité, l’efficacité et l’effort physique et mental.

Pour parvenir à ces solutions de planification de trajectoire personnalisées, certaines études ont utilisé la méthode d’entropie maximale [Kuderer et al., 2015, Zhou et al., 2017, Chen et al., 2019], permettant d’apprendre une fonction de coût exprimée sous forme d’une somme pondérée de caractéristiques. Cette approche, basée sur des courbes polynomiales, permet de générer des trajectoires continues, essentielles pour les mouvements fluides des véhicules autonomes. En outre, elle présente l’avantage de demander moins de ressources de calcul, ce qui la rend idéale pour les systèmes en temps réel ou embarqués.

Cependant, la personnalisation de la fonction de coût pour des actions spécifiques au conducteur reste complexe [Kuderer et al., 2015], et les méthodes manuelles d’ajustement des paramètres de coût [Koga et al., 2016, Koga et al., 2015] sont fastidieuses. Des approches comme celle développée par Yang et al. [Yang et al., 2019] ont été proposées pour ajuster automatiquement les poids de la fonction de coût en utilisant des indices statistiques reflétant les caractéristiques

individuelles de conduite. Cependant, une grande quantité de données est nécessaire pour cette méthode.

Dans le cadre de notre travail, nous avons opté pour une approche de planification de trajectoire basée sur des fonctions polynomiales [Takahashi et al., 1989]. Cette méthode offre des avantages indéniables en termes de simplicité et de facilité de manipulation mathématique des polynômes. Elle simplifie le développement des systèmes de contrôle tout en permettant la génération de trajectoires continues, garantissant la stabilité et le confort des véhicules autonomes. La possibilité d’ajustement des paramètres du polynôme, tels que le temps de la manœuvre et la position cible, offre un contrôle précis de la courbure de la trajectoire, permettant ainsi une adaptation personnalisée du comportement du véhicule en fonction des spécifications de la tâche et des préférences du conducteur.

En ce qui concerne l’adaptation du comportement longitudinal, nous avons utilisé le modèle du conducteur intelligent (Intelligent Driver Model, IDM) [Treiber et al., 2000] comme référence. Ce modèle se distingue par sa formulation mathématique simple, qui permet de reproduire un comportement réaliste de suivi des véhicules. Lors d’un changement de voie, notre système se concentre sur la modification de la cible ou du véhicule à suivre, ce qui lui permet de s’adapter efficacement à la tâche spécifique et au comportement individuel du conducteur.

L’algorithme d’adaptation des paramètres du système de planification de trajectoire sera présenté à la fin du chapitre. Cette approche d’adaptation personnalisée permettra de mettre en œuvre une planification de trajectoire sur mesure, répondant aux préférences individuelles des conducteurs.

2.5.2 La planification de trajectoire latérale

La planification de la trajectoire latérale basée sur les primitives de trajectoire polynomiales est une approche couramment utilisée pour générer des trajectoires lisses et confortables pour le véhicule [Takahashi et al., 1989].

Dans cette approche, on utilise des polynômes du cinquième ordre pour décrire la trajectoire latérale du véhicule. Ces polynômes permettent de générer des trajectoires lisses et confortables en contrôlant le jerk (la dérivée de l’accélération) et en assurant la continuité des vitesses, des accélérations et des courbures.

Pour commencer, on définit l’état initial du mouvement latéral, qui comprend la position latérale (y_{r_0}), la vitesse (\dot{y}_{r_0}) et l’accélération (\ddot{y}_{r_0}) dans le référentiel de la route à l’instant initial. Ensuite, on fixe l’état final de la trajectoire latérale, qui sera atteint lorsque le véhicule se déplace parallèlement à la route avec une vitesse et une accélération latérales nulles. L’état final est défini par la position latérale cible (y_{r_f}) et le temps de réalisation de la manœuvre (T_y), qui correspond au temps nécessaire pour atteindre la position cible.

Pour générer la trajectoire latérale, on utilise un polynôme du cinquième ordre, qui est défini par les coefficients a_0 , a_1 , a_2 , a_3 , a_4 et a_5 . Ces coefficients sont déterminés en résolvant un système d’équations linéaires qui satisfait les six conditions limites : les positions, les vitesses et les accélérations initiales et finales. Les équations du polynôme permettent de calculer la position latérale ($y_r(t)$), la vitesse ($\dot{y}_r(t)$) et l’accélération ($\ddot{y}_r(t)$) à chaque instant dans le temps.

$$\begin{cases} y_r(t) = a_0 + a_1t + a_2t^2 + a_3t^3 + a_4t^4 + a_5t^5 \\ \dot{y}_r(t) = a_1 + 2a_2t + 3a_3t^2 + 4a_4t^3 + 5a_5t^4 \\ \ddot{y}_r(t) = 2a_2 + 6a_3t + 12a_4t^2 + 20a_5t^3 \end{cases} \quad (2.14)$$

Le système d’équations linéaires est construit en utilisant une matrice A dépendant du temps de réalisation de la manœuvre T_y . Cette matrice est de taille 6×6 et est construite en fonction des puissances de T_y . Une fois le système d’équations linéaires résolu, les coefficients du polynôme sont obtenus.

$$\begin{bmatrix} a_0 \\ a_1 \\ a_2 \\ a_3 \\ a_4 \\ a_5 \end{bmatrix} = A \begin{bmatrix} y_{r_0} \\ \dot{y}_{r_0} \\ \ddot{y}_{r_0} \\ y_{r_f} \\ \dot{y}_{r_f} \\ \ddot{y}_{r_f} \end{bmatrix} \quad (2.15)$$

$$A = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 2 & 0 & 0 & 0 \\ 0 & T_y & T_y^2 & T_y^3 & T_y^4 & T_y^5 \\ 0 & 1 & 2T_y & 3T_y^2 & 4T_y^3 & 5T_y^4 \\ 0 & 0 & 2 & 6T_y & 12T_y^2 & 20T_y^3 \end{bmatrix}$$

La planification de trajectoire latérale basée sur les primitives de trajectoire polynomiales offre une flexibilité dans la personnalisation de la trajectoire en fonction des préférences du conducteur ou des caractéristiques spécifiques de la situation de conduite. Par exemple, en ajustant les paramètres de temps de réalisation de la manœuvre (T_y) et de position cible (y_{r_f}), on peut obtenir des trajectoires avec différents niveaux de dynamisme ou de prudence.

En effet, les paramètres de la trajectoire pour les changements de voie à gauche et à droite peuvent être personnalisés en utilisant les paramètres T_{y_1} , $y_{r_{f_1}}$ pour les changements de voie à gauche et les paramètres $T_{y_{-1}}$, $y_{r_{f_{-1}}}$ pour les changements de voie à droite.

En ajustant ces paramètres, on peut modifier la durée, la courbure et la trajectoire latérale du véhicule pendant les manœuvres de changement de voie, ce qui permet d'adapter le comportement du véhicule à différentes situations de conduite et aux préférences individuelles du conducteur.

2.5.2.1 Validation expérimentale

La validation expérimentale de l'approche polynomiale pour la planification de trajectoire latérale lors des changements de voie a été réalisée en ajustant les paramètres de la trajectoire, tels que la position cible (y_{r_1}) et le temps d'accomplissement de la manœuvre de changement de voie vers la gauche (T_{y_1}) sur le simulateur SHERPA.

Dans la Figure 2.7, nous pouvons observer les résultats obtenus pour différents réglages de ces paramètres lors d'un changement de voie vers la gauche. Il est clair qu'une valeur faible de T_{y_1} conduit à un changement de voie latéral rapide, tandis qu'une valeur plus grande se traduit par un changement de voie plus lent et progressif. De plus, en ajustant la position cible (y_{r_1}), nous obtenons des trajectoires planifiées avec des positions finales différentes.

En ajustant ces paramètres (y_{r_1} , T_{y_1}) pour le changement de voie à gauche, ($y_{r_{-1}}$, $T_{y_{-1}}$) pour le changement de voie à droite, selon les préférences de chaque conducteur, il est possible de personnaliser la trajectoire planifiée lors des changements de voie, ce qui permet d'obtenir des comportements de conduite adaptés à chaque conducteur.

2.5.3 La planification de trajectoire longitudinale

Selon la sortie du système de prise de décision, le comportement longitudinal est adapté en utilisant le modèle du conducteur intelligent (Intelligent Driver Model, IDM) [Treiber et al., 2000] comme référence. IDM est un modèle relativement simple par rapport à certains modèles de trafic plus complexes, ce qui le rend facile à implémenter et à calculer. Malgré cette simplicité, il parvient à capturer des aspects importants du comportement longitudinal de la conduite du conducteur.




FIGURE 2.7 – L’impact de la position cible (y_{r_1}) et du temps d’accomplissement de la manœuvre de changement de voie vers la gauche (T_{y_1}) sur la trajectoire planifiée.

Pour chaque voie $i \in -1, 0, 1$, l’accélération longitudinale du véhicule est calculée selon les équations suivantes :

$$a_{x_i} = a \left(1 - \left(v_{ego}/v_d \right)^2 - \left(D/DIV_{t_i}^* \right)^2 \right) \quad (2.16)$$

où a représente la capacité d’accélération maximale du véhicule, v_{ego} est la vitesse actuelle du véhicule ego, v_d est la vitesse désirée par le conducteur (ou éventuellement la limite de vitesse de la voie), D est la distance de sécurité désirée et $DIV_{t_i}^*$ est la distance inter-véhiculaire de transition pour chaque voie.

Pour suivre une distance de sécurité avec le véhicule leader, un régulateur rétroactif est utilisé avec l’équation suivante :

$$D = D_0 + T v_{ego} \quad (2.17)$$

Ici, T est le délai constant désiré (le TIV désiré) et D_0 est une petite constante positive qui garantit une distance de sécurité même lorsque le véhicule est à l’arrêt.

La manœuvre de changement de voie ("LC") vers le véhicule cible ou la vitesse limite dans la voie cible peut être considérée comme un comportement de transition visant à établir une nouvelle distance de sécurité stable avec le véhicule cible ou la vitesse limite dans la voie cible, afin de garantir une transition en douceur et un comportement confortable. La distance inter-véhiculaire de transition désirée $DIV_{t_i}^*$ est calculée selon l’équation suivante :

$$DIV_{t_i}^*(t) = DIV_{EL_0}^* - \left(DIV_{EL_0}^* - DIV_{EL_i}^*(t) \right) \left(1 - e^{-t/\tau} \right) \quad (2.18)$$

avec $t \in [0, T_{y_i}]$

Dans cette équation, $DIV_{EL_i}^*$ représente la distance inter-véhiculaire entre le véhicule ego et le véhicule leader de chaque voie, évaluée au moment initial ($t = 0$). La trajectoire de transition de la distance inter-véhiculaire ($DIV_{t_i}^*$) évolue au fil du temps (t) pour atteindre la valeur désirée pour la manœuvre de changement de voie. $t = 0$ correspond à l’instant où le système décide

de changer de voie. La durée de la manœuvre de changement de voie est définie par T_{y_i} , qui correspond au temps nécessaire pour accomplir la transition. Après T_{y_i} , le système contrôle l'intervalle de temps souhaité par rapport au nouveau véhicule devant lui. Le paramètre τ est une constante de réglage.

La durée de la manœuvre de changement de voie peut varier en fonction de la direction du changement de voie. T_{y_1} représente le temps nécessaire pour accomplir la transition lors d'un changement de voie vers la gauche, tandis que $T_{y_{-1}}$ représente le temps nécessaire pour accomplir la transition lors d'un changement de voie vers la droite. Ces durées peuvent être adaptées selon les préférences individuelles du conducteur.

L'ajustement de ces durées permet de contrôler la façon dont le véhicule effectue la transition d'une voie à une autre. Par exemple, si un conducteur préfère une transition plus rapide lors d'un changement de voie vers la gauche, il peut réduire la valeur de T_{y_1} . À l'inverse, s'il souhaite une transition plus lente lors d'un changement de voie vers la droite, il peut augmenter la valeur de $T_{y_{-1}}$.

En ajustant ces durées de manière appropriée, le conducteur peut optimiser le confort, la sécurité et l'efficacité de la manœuvre de changement de voie, en tenant compte des conditions de circulation et de ses propres préférences.

2.5.3.1 Validation expérimentale

En observant la Figure 2.8 et en comparant les résultats pour les différentes durées de manœuvre, plusieurs observations peuvent être faites.




FIGURE 2.8 – L'impact de la durée de la manœuvre de changement de voie (T_{y_1}) sur le comportement longitudinal du véhicule.

Tout d'abord, pendant la phase de suivi du véhicule à une vitesse de 15 m/s entre $t \in [0, 10s]$, l'ego véhicule maintient une distance inter-véhiculaire désirée avec le véhicule qui le précède en respectant le temps d'inter-distance souhaité. Cette phase initiale montre que le véhicule suit correctement le véhicule leader et ajuste son accélération en fonction de la distance et de la vitesse. Ensuite, à $t = 10s$, la manœuvre de changement de voie vers la gauche est initiée. La trajectoire désirée du véhicule devient alors la trajectoire de la voie de gauche. On observe que

différentes trajectoires de transition de distance inter-véhiculaire sont générées en fonction des différentes durées de manœuvre choisies ($T_{y_1} = 7s$, $T_{y_1} = 5s$, $T_{y_1} = 3s$, $T_{y_1} = 1s$).

En analysant les résultats, il est clair que la durée de la manœuvre (T_{y_1}) a un impact significatif sur le comportement longitudinal du véhicule. Une durée plus courte ($T_{y_1} = 1s$) correspond à un conducteur caractérisé par une conduite plus sportive ou très dynamique dans la manœuvre, ce qui se traduit par des valeurs élevées d'accélération et de jerk. En revanche, une durée plus longue ($T_{y_1} = 7s$) correspond à un conducteur caractérisé par une conduite plus souple et calme, où les valeurs d'accélération et de jerk sont plus faibles.

Les résultats obtenus démontrent clairement que la durée de la manœuvre de changement de voie a une influence significative sur le comportement longitudinal du véhicule. Cette variable permet d'ajuster le style de conduite et la dynamique du véhicule pendant la manœuvre de changement de voie, en fonction des préférences individuelles de chaque conducteur.

En adaptant la durée de la manœuvre de changement de voie selon les préférences du conducteur, il est possible de moduler la dynamique de la manœuvre (plus sportive ou plus calme). Une durée plus courte peut être choisie par les conducteurs avec un style de conduite plus sportif ou souhaitant réaliser une manœuvre plus rapide, tandis qu'une durée plus longue peut être préférée par les conducteurs avec un style de conduite plus souple ou ceux qui privilégient une transition en douceur.

Cette capacité d'ajuster la durée de la manœuvre de changement de voie permet de personnaliser le comportement du véhicule en fonction des préférences individuelles des conducteurs. Cela contribue à améliorer le confort, la sécurité et la satisfaction de conduite, en offrant une expérience de conduite plus adaptée aux attentes et au style de conduite de chaque conducteur.

2.6 Détection de l'intention du conducteur

Selon le schéma fonctionnel de la personnalisation de LCAS (voir la Figure 2.1), la détection de l'intention du conducteur joue un rôle essentiel. Elle nous permet de comprendre les actions entreprises par un conducteur lorsqu'il effectue des changements de voie en conduite manuelle. Cette section explicite le processus de détection de l'intention du conducteur lors de ces changements de voie.

2.6.1 Etat de l'art

Dans la littérature, le terme "détection d'intention" est utilisé pour désigner un domaine de recherche qui vise à anticiper les comportements des conducteurs sur la route. Ce domaine englobe différentes terminologies telles que la reconnaissance ou l'identification de comportement, la prédiction ou l'estimation d'action. De nombreuses études ont été menées dans ce domaine pour prédire les manœuvres de changement de voie sur les autoroutes, généralement avec une anticipation d'environ 2 secondes avant leur occurrence [Ortiz et al., 2012, Houenou et al., 2013, Lawitzky et al., 2013].

Les méthodes couramment utilisées pour la prédiction d'intention comprennent les SVM (Support Vector Machine), les Réseaux de Neurones Artificiels (ANN), les Réseaux Bayésiens (BN), le Classificateur Bayésien (BC) et le Raisonnement à partir de Cas (CBR) [Kumar et al., 2013, Dogan et al., 2011, Liu et al., 2014, Kasper et al., 2012, Hou et al., 2013, Schlechtriemen et al., 2014, Graf et al., 2013, Bonnin et al., 2014]. Ces approches ont démontré leur capacité à reconnaître et à prédire les manœuvres de changement de voie, offrant des performances allant jusqu'à 79% de précision dans la détection de véhicules sur les voies adjacentes s'insérant dans la voie du véhicule égo [Graf et al., 2013].

L'Administration nationale de la sécurité routière américaine (NHTSA) rapporte qu'en moyenne, il faut 1,5 seconde pour qu'un véhicule franchisse les marquages de voie et entre dans la voie adjacente après avoir initié une manœuvre de changement de voie [Fitch et al., 2009].

Par conséquent, il est extrêmement avantageux qu'un système de reconnaissance d'intention de changement de voie puisse identifier l'intention du conducteur d'un véhicule de changer de voie au moins 1,5 seconde avant l'occurrence de la manœuvre.

Cependant, de nombreuses approches existantes reposent sur des données d'entraînement, nécessitent un apprentissage continu en ligne ou imposent une charge numérique importante, ce qui les rend difficiles à vérifier ou inappropriées pour une implémentation en temps réel sur un ordinateur de véhicule. C'est pourquoi il est nécessaire de développer des mécanismes de prédiction d'intention plus simples et moins dépendants de l'apprentissage afin de réduire la nécessité de données d'entraînement et de ressources de calcul numérique. Pour ce faire, cette section aborde le problème de la reconnaissance de l'intention de manœuvre du conducteur en utilisant un système basé sur des règles simples. Les systèmes basés sur des règles présentent plusieurs avantages, tels que la traçabilité et la facilité de mise en œuvre. Ils offrent également une vue d'ensemble claire et une compréhension du modèle du système.

Un système basé sur des règles permet une représentation naturelle du comportement de conduite sur autoroute, car les autoroutes sont des environnements structurés avec des règles de circulation relativement simples et faciles à respecter. Ainsi, il est possible d'utiliser des règles simples pour détecter l'intention du conducteur en se basant sur des variables telles que la vitesse latérale et la position par rapport à la route. Ces variables sont mesurées en termes de distance par rapport aux limites de voie gauche et droite.

En utilisant ces règles simples, il devient possible de reconnaître l'intention de changement de voie du conducteur sans avoir besoin de données d'entraînement complexes ou de ressources computationnelles élevées. Cela permet une implémentation plus facile et une meilleure compréhension du système de reconnaissance d'intention de manœuvre du conducteur.

2.6.2 Détection d'intention au changement de voie

La détection d'intention de changement de voie est un élément essentiel pour la personnalisation du système d'aide au changement de voie au niveau tactique. Dans ce paragraphe, nous présentons un mécanisme basé sur des règles permettant de détecter l'intention du conducteur dans la manœuvre de changement de voie en utilisant la dynamique du véhicule en mode de conduite manuelle.

La Figure 2.9 illustre la représentation de l'environnement pour la détection de l'intention.

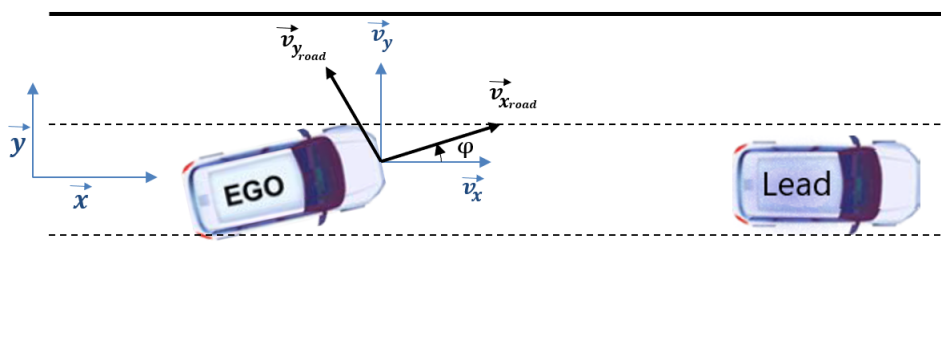


FIGURE 2.9 – Représentation de l'environnement pour la détection de l'intention.

Lorsqu'un conducteur souhaite effectuer un changement de voie, il effectue un mouvement latéral vers la voie cible adjacente. Ainsi, pour reconnaître son intention, nous nous appuyons sur deux indices de mouvement latéral : la vitesse latérale dans le référentiel de la route et la position latérale par rapport aux limites de voie.

La vitesse latérale dans le référentiel de la route est calculée à partir de la vitesse longitudinale du véhicule (v_x), la vitesse latérale du véhicule (v_y) et l'erreur de cap (φ), qui mesure la différence entre le cap du véhicule et le cap de la route. Cette mesure permet d'éviter les fausses détections dans les virages et d'adapter la détection d'intention à la variation de la vitesse du véhicule.

Pour un changement de voie vers la gauche, l'intention peut être détectée si la vitesse latérale dans le référentiel de la route ($v_{y_{road}}$) est supérieure ou égale à un seuil (α_{v_y}) et si la position latérale (y_c) est supérieure ou égale à un autre seuil (β_{y_c})

$$DLCL_{int} = (v_{y_{road}} \geq \alpha_{v_y}) \wedge (y_c \geq \beta_{y_c}) \quad (2.19)$$

De même, pour un changement de voie vers la droite, l'intention peut être détectée si la vitesse latérale dans le référentiel de la route ($v_{y_{road}}$) est inférieure ou égale à un seuil négatif ($-\alpha_{v_y}$) et si la position latérale (y_c) est inférieure ou égale à un autre seuil négatif ($-\beta_{y_c}$).

$$DLCR_{int} = (-v_{y_{road}} \geq \alpha_{v_y}) \wedge (-y_c \geq \beta_{y_c}) \quad (2.20)$$

Ce mécanisme de détection d'intention repose sur des règles simples et utilise les indices de mouvement latéral pour reconnaître l'intention du conducteur dans la manœuvre de changement de voie.

2.6.3 Validation expérimentale

Des tests ont été menés pour évaluer l'efficacité du mécanisme proposé pour la détection de l'intention de changement de voie sur le simulateur SHERPA. Ces tests ont été réalisés lors d'une phase de conduite manuelle impliquant la participation de 6 sujets. Quatre scénarios différents ont été utilisés, correspondant à des vitesses de 70 km/h, 90 km/h, 110 km/h et une vitesse variable. Chaque sujet a effectué 5 changements de voie vers la gauche et 5 changements de voie vers la droite pour chaque scénario, totalisant ainsi 240 changements de voie réalisés lors des essais.

Les tests ont été réalisés sur une route à deux voies avec circulation à sens unique, où la largeur d'une voie était de 3,5 mètres. L'objectif de ces essais était de recueillir des données réelles sur les performances du mécanisme de détection de l'intention de changement de voie dans des conditions de conduite réelles. Les résultats de ces tests seront ensuite analysés pour évaluer l'efficacité et la précision du mécanisme, ainsi que sa capacité à détecter correctement l'intention de changement de voie dans différentes situations de conduite.

Afin d'évaluer la performance de reconnaissance de l'intention de changement de voie, plusieurs métriques ont été utilisées pour mesurer l'efficacité et la précision du mécanisme de détection :

DR_m : Le taux de détection moyen pour les changements de voie.

TBD_m : Les retards de détection moyens, qui mesurent le temps écoulé entre le moment où l'intention de changement de voie se manifeste et le moment où le système la détecte.

$TDLC_m$: Les temps moyens entre la détection et le franchissement de la ligne, qui quantifient la durée entre la détection de l'intention et le moment où le conducteur effectue effectivement le changement de voie.

Les performances du système de détection pour les changements de voie réalisés vers la gauche et vers la droite dans les quatre scénarios sont présentées dans le Tableau 2.1.

Les résultats présentés dans le tableau démontrent une performance élevée du système de détection de l'intention de changement de voie, avec un taux de détection de 100% dans tous les scénarios. Cela signifie que le système a identifié correctement l'intention de changement de voie pour chaque essai.

En ce qui concerne les retards de détection moyens (TBD_m), ils varient légèrement d'un scénario à l'autre, allant de 0,26s à 0,61s. Cependant, ces retards restent dans une plage raisonnable compte tenu de la complexité de la tâche. Les temps moyens entre la détection et le

| LC | Scénario | $TDLC_m$ | DR_m | TBD_m |
|-----|----------|----------|--------|---------|
| LCL | S1 | 1.76 s | 100% | 0.61 s |
| | S2 | 1.71 s | 100% | 0.48 s |
| | S3 | 1.62 s | 100% | 0.45 s |
| | S4 | 1.74 s | 100% | 0.53 s |
| LCR | S1 | 2.18 s | 100% | 0.37 s |
| | S2 | 1.83 s | 100% | 0.26 s |
| | S3 | 1.97 s | 100% | 0.27 s |
| | S4 | 2.05 s | 100% | 0.31 s |

TABLE 2.1 – Les performances du système de détection pour les changements de voie réalisés vers la gauche (LCL) et vers la droite (LCR) dans les quatre scénarios.

franchissement de la ligne ($TDLC_m$) varie également, allant de 1,62s à 2,18s. Ces résultats suggèrent que le système est capable de détecter l'intention de changement de voie avec une anticipation raisonnable. Globalement, les résultats indiquent une bonne prédiction de l'intention de changement de voie avec des délais raisonnables.

Afin de mettre en évidence la robustesse du système de détection, la Figure 2.10 présente la détection de l'intention de changement de voie en mode de conduite manuelle pour le sujet 1 dans le quatrième scénario. Les décisions (1, 0, -1) correspondent respectivement à la détection d'un changement de voie vers la gauche, le maintien de la voie et un changement de voie vers la droite.




FIGURE 2.10 – Les performances du système de détection de l'intention de changement de voie.

Cette figure met en évidence les 10 changements de voie réalisés par le conducteur (5 vers la gauche et 5 vers la droite) avec une vitesse variable et une courbure de route variable. Le système de détection parvient à détecter l'intention du conducteur de changement de voie avant que celui-ci ne franchisse la ligne, ce qui témoigne de la robustesse du mécanisme face aux variations de vitesse, de courbure de route et de profils de conducteur.

2.7 L’algorithme d’apprentissage pour la personnalisation

L’automatisation centrée sur l’humain représente une approche essentielle pour réduire les risques de désaccord entre l’humain et la machine, favorisant ainsi une meilleure coopération et de ce fait une meilleure acceptabilité de ces systèmes [Muslim and Itoh, 2019]. Cependant, ces systèmes, présentent des limites lorsqu’il s’agit de s’adapter aux préférences et aux styles de conduite individuels. Ce constat a ouvert la voie à un domaine de recherche en plein essor axé sur la personnalisation des systèmes de conduite automatisée.

2.7.1 État de l’art

Les systèmes de conduite automatisée conçus pour un conducteur idéaliste peuvent être trop prudents pour certains conducteurs, car ils ne prennent pas en compte les différences inter-individuelles en termes de styles de conduite et de préférences. Pour remédier à cela, des chercheurs ont développé des modèles de conducteur personnalisés [Basu et al., 2017], [Butakov and Ioannou, 2014], [Tian et al., 2022], qui permettent aux systèmes de conduite automatisée de s’adapter aux caractéristiques spécifiques de chaque conducteur.

Plusieurs modèles de conducteur ont été proposés en fonction des besoins spécifiques et des applications variées [Plöchl and Edelmann, 2007], [Salvucci, 2006], [Li et al., 2016]. Cependant, ces dernières années, avec l’augmentation massive des données disponibles, les méthodes basées sur les données sont devenues populaires pour concevoir des systèmes de conduite automatisée qui imitent le comportement humain [Lu et al., 2019], [Sama et al., 2020], [Do et al., 2017], [Vallon et al., 2017], [Li et al., 2018].

Dans certaines études, les comportements de conduite ont été extraits de conducteurs humains experts à l’aide de méthodes basées sur l’apprentissage profond, comme la reconnaissance des formes et le traitement des données massives [Sama et al., 2020]. Ces comportements ont ensuite été appliqués à des véhicules autonomes, permettant ainsi de reproduire avec succès des comportements de conduite proactifs, c’est-à-dire des comportements qui anticipent et réagissent de manière proactive aux changements de l’environnement routier.

Une autre approche couramment utilisée est les SVM (Support Vector Machine), qui a été développée pour capturer le comportement de prise de décision lors des changements de voie des conducteurs humains [Vallon et al., 2017]. Les SVM sont des algorithmes d’apprentissage supervisé largement utilisés qui sont efficaces pour classer et catégoriser des données complexes, comme les comportements de conduite.

Une tâche d’apprentissage est généralement transformée en un problème d’optimisation visant à minimiser une fonction objectif en sélectionnant les paramètres optimaux. Les différents algorithmes d’optimisation suivent un processus similaire. Tout d’abord, le modèle calcule la sortie et l’objectif d’optimisation en utilisant les paramètres initiaux. Ensuite, ces paramètres du modèle sont ajustés itérativement pour réduire la valeur de la fonction objectif. Ce processus est répété jusqu’à ce qu’un modèle approprié soit obtenu, correspondant à une réduction significative de la fonction de perte.

Cependant, les différents algorithmes d’optimisation ont des avantages et des inconvénients en fonction des architectures et des fonctions de perte utilisées [Gauriau et al., 2015]. L’algorithme Adaptive Gradient (AdaGrad) met à jour les paramètres en fonction de l’accumulation des carrés des gradients. Bien qu’il converge rapidement pour les fonctions convexes, il peut être beaucoup moins efficace sur certains modèles [Lydia and Francis, 2019]. Le Root Mean Squared Propagation (RMSProp), une variante d’AdaGrad, est une méthode efficace et populaire pour l’optimisation des paramètres [Xu et al., 2021] mais elle peut également présenter des limitations dans certaines situations [Rakshitha and Naveen, 2022].

La méthode d’optimisation couramment utilisée dans l’apprentissage profond, en particulier dans les réseaux de neurones, est la descente de gradient stochastique (SGD) [Sweke et al., 2020]. Cette méthode met à jour les paramètres en fonction du gradient de la fonction objectif.

L'avantage notable de la SGD est que le temps de calcul nécessaire pour chaque mise à jour ne croît pas de manière significative, même avec un grand ensemble d'entraînement [Bottou et al., 1991, Lecun et al., 1998, Zinkevich et al., 2010].

Dans les réseaux de neurones, le processus d'apprentissage consiste à ajuster les paramètres du modèle (poids et biais) pour que le réseau puisse approximer de manière précise la fonction cible qui lie les entrées aux sorties souhaitées. La descente de gradient stochastique est utilisée pour mettre à jour ces paramètres de manière itérative et progressive en utilisant des échantillons aléatoires du jeu de données d'entraînement.

Dans notre cas, nous souhaitons adapter l'approche de descente de gradient stochastique (SGD) utilisée dans les réseaux de neurones pour ajuster les paramètres du système d'aide au changement de voie en fonction des préférences de chaque conducteur.

2.7.2 L'approche de descente de gradient stochastique (SGD) dans les réseaux de neurones

La phase d'apprentissage est une étape essentielle lors de l'utilisation des réseaux de neurones pour résoudre divers problèmes tels que la classification, la reconnaissance de formes et la prédiction. Pendant cette phase, les poids du réseau de neurones sont ajustés à l'aide d'un mécanisme d'apprentissage afin de minimiser l'erreur de prédiction sur les données d'entraînement.

Pour illustrer ce concept, la Figure 2.11 présente un exemple de réseau de neurones appelé perceptron, utilisé pour résoudre des problèmes de classification binaire. Ce réseau prend en entrée un vecteur d'attributs (par exemple, les pixels d'une image) et produit une sortie qui indique la classe prédite pour cet exemple (par exemple, 0 ou 1 pour une image binaire). Les poids du réseau de neurones w sont représentés par les flèches entre les neurones.




FIGURE 2.11 – Illustration d'un réseau de neurones.

L'objectif de l'apprentissage d'un neurone artificiel est de trouver les poids qui minimisent l'erreur de prédiction sur les données d'entraînement. Pour ce faire, une fonction d'erreur est utilisée pour mesurer l'écart entre la sortie du neurone $y_n = wx$ et la sortie désirée y pour chaque exemple d'entraînement.

La fonction d'erreur la plus couramment utilisée est la fonction d'erreur quadratique, qui mesure l'écart quadratique entre la sortie du neurone et la sortie désirée :

$$\mathfrak{S}(w) = \frac{1}{2} (wx - y)^2 \quad (2.21)$$

En utilisant l'approche de la descente de gradient stochastique (SGD), où les poids du neurone sont ajustés en utilisant les dérivées partielles de la fonction d'erreur par rapport à chaque poids.

$$\Delta w = -\alpha \frac{\partial \mathfrak{S}(w)}{\partial w} \quad (2.22)$$

où α est le taux d'apprentissage, et

$$\frac{\partial \mathfrak{S}(w)}{\partial w} = x (wx - y) \quad (2.23)$$

Ensuite, les poids du neurone sont ajustés en soustrayant une petite fraction de ces dérivées partielles à chaque poids, en utilisant un taux d'apprentissage fixe. Ces dérivées partielles reflètent la pente de la fonction d'erreur par rapport à chaque poids, indiquant ainsi la direction et l'amplitude du changement nécessaire pour réduire l'erreur de prédiction.

$$w_{k+1} = w_k - \alpha \frac{\partial \mathfrak{J}(w)}{\partial w} \quad (2.24)$$

Ce processus est répété pour chaque exemple d'entraînement, en effectuant plusieurs passes sur l'ensemble des exemples, jusqu'à ce que la fonction d'erreur converge vers un minimum local.

Le résumé de l'algorithme SGD utilisé pour l'adaptation des poids des réseaux de neurones est présenté dans la Figure 2.12

Algorithme 1: SGD pour l'ajustement des poids du réseau de neurones

Donnée: x, y

Initialisation: w_0, α

Pour chaque itération i

• **La fonction du coût :**

$$\mathfrak{J}(w) \leftarrow \frac{1}{2}(wx - y)^2$$

• **Le gradient :**

$$\frac{\partial \mathfrak{J}(w)}{\partial w} \leftarrow x(wx - y)$$

• **L'algorithme SGD :**

$$w \leftarrow w - \alpha \frac{\partial \mathfrak{J}(w)}{\partial w}$$

Fin

FIGURE 2.12 – L'algorithme de descente de gradient stochastique (SGD) est employé pour adapter les poids d'un réseau de neurones.

2.7.3 Application de l'algorithme SGD pour la personnalisation des LCAS

Dans le contexte des systèmes d'aide au changement de voie, cette approche de la descente de gradient stochastique peut être adaptée pour ajuster les poids du neurone afin de minimiser l'erreur entre les paramètres du système et ceux observés sur le conducteur. Le neurone peut être schématisé comme un perceptron, un modèle linéaire qui combine les entrées pondérées par des poids pour produire une sortie. Les poids du réseau représentent les paramètres du système, et l'objectif est d'apprendre à reproduire le comportement du conducteur (voir Figure 2.13). On peut alors utiliser la même approche de descente de gradient stochastique pour ajuster les poids du neurone de manière à minimiser l'erreur de prédiction entre la sortie du neurone (les paramètres du système) et la sortie désirée (les paramètres moyens observés sur un conducteur) pour chaque changement de voie i . Cela permet d'apprendre à reproduire le comportement du conducteur dans des situations similaires, et donc de concevoir des systèmes de contrôle plus efficaces et plus intuitifs pour les conducteurs humains.

Les paramètres du système P_s et les paramètres moyens du conducteur P_{D_m} sont comparés en utilisant l'erreur quadratique des paramètres.

$$\mathfrak{J}(P_s) = \frac{1}{2}(P_s - P_{D_m})^2 \quad (2.25)$$




FIGURE 2.13 – La représentation des paramètres du système d’aide au changement de voie sous la forme d’un réseau de neurones.

Pour chaque itération de changement de voie i , la sortie du neurone est calculée, et les dérivées partielles de l’erreur par rapport à chaque poids (paramètre) du neurone sont calculées.

$$\Delta P_s = -\alpha \frac{\partial \mathfrak{S}(P_s)}{\partial P_s} \quad (2.26)$$

avec α étant le taux d’apprentissage, et

$$\frac{\partial \mathfrak{S}(P_s)}{\partial P_s} = (P_s - P_{D_m}) \quad (2.27)$$

Ensuite, les poids du neurone sont ajustés en soustrayant une petite fraction de ces dérivées partielles à chaque poids, en utilisant un taux d’apprentissage fixe. Ce processus est répété pour chaque changement de voie réalisé, jusqu’à ce que la fonction d’erreur converge vers un minimum local.

$$P_s(i+1) = P_s(i) - \alpha \frac{\partial \mathfrak{S}(P_s)}{\partial P_s} \quad (2.28)$$

En résumé, dans le contexte des systèmes d’aide au changement de voie, l’approche SGD peut être adaptée pour ajuster les paramètres du système afin de reproduire le comportement du conducteur. Sachant que les paramètres du système à adapter pour le changement de voie à gauche P_{s_1} et le changement de voie à droite $P_{s_{-1}}$ sont :

$$P_{s_1} = \begin{bmatrix} \%TIV_1 \\ T_{y_1} \\ y_{r_1} \end{bmatrix}, \quad P_{s_{-1}} = \begin{bmatrix} \%TIV_{-1} \\ T_{y_{-1}} \\ y_{r_{-1}} \end{bmatrix} \quad (2.29)$$

Avec les paramètres à adapter pour le système de prise de décision (DMSP) et pour la planification de trajectoire (PPP) sont les suivants :

$$DMSP = \begin{bmatrix} \%TIV_1 \\ \%TIV_{-1} \end{bmatrix}, \quad PPP = \begin{bmatrix} T_{y_1} \\ T_{y_{-1}} \\ y_{r_1} \\ y_{r_{-1}} \end{bmatrix} \quad (2.30)$$

Le résumé de l’algorithme SGD utilisé pour l’adaptation des paramètres du système d’aide au changement de voie est présenté dans la Figure 2.14.

2.7.3.1 Identification des paramètres du conducteur pour les changements de voie

Afin d’intégrer l’apprentissage dans la prise de décision et la planification de trajectoire, il est essentiel de capturer les paramètres du conducteur lorsqu’il conduit en mode manuel pour effectuer un changement de voie. Pour ce faire, nous devons identifier et reconnaître six paramètres spécifiques du conducteur pour un changement de voie complet vers la gauche (P_{D_1}) et vers la droite ($P_{D_{-1}}$).

Algorithme 2: SGD pour le système d'aide au changement de voie

Entrée: P_D, i

Sortie: P_s, P_{D_m}

Initialisation: P_{s_0}, P_{D_m}, α

Pour chaque nouveau changement de voie i

- **Les paramètres moyens du conducteur :** $P_{D_m} \leftarrow \frac{1}{2}(P_{D_m} + P_D)$
- **La fonction du coût :** $\mathfrak{J}(P_s) \leftarrow \frac{1}{2}(P_s - P_{D_m})^2$
- **Le gradient :** $\frac{\partial \mathfrak{J}(P_s)}{\partial P_s} \leftarrow (P_s - P_{D_m})$
- **L'algorithme SGD :** $P_s \leftarrow P_s - \alpha \frac{\partial \mathfrak{J}(P_s)}{\partial P_s}$

Fin

FIGURE 2.14 – L'algorithme de descente de gradient stochastique (SGD) est utilisé pour ajuster les paramètres du système d'aide au changement de voie.

Les paramètres du conducteur pour un changement de voie à gauche sont définis comme suit :

$$P_{D_1} = \begin{bmatrix} \%TIV_{D_1} \\ T_{y_{D_1}} \\ y_{r_{D_1}} \end{bmatrix} \quad (2.31)$$

où : $\%TIV_{D_1}$ représente le temps inter-véhiculaire entre le véhicule ego et le véhicule leader de la même voie, normalisé par le temps inter-véhiculaire maximal détecté au démarrage de la manœuvre de changement de voie à gauche. $T_{y_{D_1}}$ est le temps nécessaire pour que le véhicule effectue le changement de voie vers la gauche. $y_{r_{D_1}}$ indique la position latérale du véhicule ego lorsque la fin du changement de voie à gauche est détectée.

De manière similaire, pour un changement de voie à droite, les paramètres du conducteur sont donnés par :

$$P_{D_{-1}} = \begin{bmatrix} \%TIV_{D_{-1}} \\ T_{y_{D_{-1}}} \\ y_{r_{D_{-1}}} \end{bmatrix} \quad (2.32)$$

où : $\%TIV_{D_{-1}}$ représente le temps inter-véhiculaire entre le véhicule ego et le véhicule suiveur dans la voie de droite, normalisé par le temps inter-véhiculaire maximal détecté lorsque le début de la manœuvre de changement de voie à droite est repéré. $T_{y_{D_{-1}}}$ est le temps nécessaire pour que le véhicule effectue le changement de voie vers la droite. $y_{r_{D_{-1}}}$ indique la position latérale du véhicule ego lorsque la fin du changement de voie à droite est détectée.

Pour déterminer le moment où le conducteur a l'intention de changer la voie vers la gauche ($DLCL_{int}$) ou vers la droite ($DLCR_{int}$) en mode de conduite manuel (voir la section 2.6), nous utilisons les conditions suivantes :

Pour un changement de voie à gauche :

$$C_L = ((DLCL_{int}(t) - DLCL_{int}(t - \tau_2)) > 0) \wedge (v_{y_{road}}(t) > 0) \quad (2.33)$$

$$EC_L = ((DLCL_{\text{int}}(t) - DLCL_{\text{int}}(t - \tau_2)) < 0) \wedge (v_{y_{\text{road}}}(t) > 0) \quad (2.34)$$

Pour un changement de voie à droite :

$$C_R = ((DLCR_{\text{int}}(t) - DLCR_{\text{int}}(t - \tau_2)) > 0) \wedge (v_{y_{\text{road}}}(t) < 0) \quad (2.35)$$

$$EC_R = ((DLCR_{\text{int}}(t) - DLCR_{\text{int}}(t - \tau_2)) < 0) \wedge (v_{y_{\text{road}}}(t) < 0) \quad (2.36)$$

Les conditions (C_L, EC_L) représentent le début et la fin de la manœuvre de changement de voie à gauche respectivement, tandis que les conditions (C_R, EC_R) représentent le début et la fin de la manœuvre de changement de voie à droite. Dans ces équations, $DLCL_{\text{int}}(t)$ et $DLCR_{\text{int}}(t)$ représentent les signaux de détection d'intention du conducteur pour changer de voie vers la gauche et vers la droite, respectivement. $v_{y_{\text{road}}}(t)$ est la vitesse latérale du véhicule par rapport à la route, et τ_2 est une petite constante de temps positive.

Une fois que les conditions (C_L, EC_L) ou (C_R, EC_R) sont vérifiées, nous pouvons obtenir les paramètres caractérisant le conducteur pour la manœuvre de changement de voie vers la gauche ou vers la droite, respectivement, de la manière suivante :

Pour le changement de voie à gauche :

$$\begin{cases} \%TIV_{D_1} = \%TIV_{(EL(0))}(t_{C_L}) \\ y_{r_{D_1}} = y_{ego}(t_{EC_L}) \\ T_{y_{D_1}} = t_{EC_L} - t_{C_L} \end{cases} \quad (2.37)$$

Pour le changement de voie à droite :

$$\begin{cases} \%TIV_{D_{-1}} = \%TIV_{(FE(-1))}(t_{C_R}) \\ y_{r_{D_{-1}}} = y_{ego}(t_{EC_R}) \\ T_{y_{D_{-1}}} = t_{EC_R} - t_{C_R} \end{cases} \quad (2.38)$$

Dans ces équations, t_{C_L} et t_{EC_L} représentent les instants de début et de fin de la manœuvre de changement de voie à gauche (les instants où les conditions (C_L, EC_L) sont vérifiées, respectivement). De même, t_{C_R} et t_{EC_R} représentent les instants de début et de fin de la manœuvre de changement de voie à droite (les instants où les conditions (C_R, EC_R) sont vérifiées, respectivement). $\%TIV_{(EL(0))}(t_{C_L})$ et $\%TIV_{(FE(-1))}(t_{C_R})$ sont les temps inter-véhiculaire entre le véhicule ego et les véhicules devant lui (pour un changement de voie à gauche) et derrière lui à droite (pour un changement de voie à droite), respectivement, normalisés par les temps inter-véhiculaire maximal détecté lorsque le début de la manœuvre est repéré. $y_{ego}(t_{EC_L})$ et $y_{ego}(t_{EC_R})$ indiquent la position latérale du véhicule ego lorsque la fin de la manœuvre de changement de voie est détectée, pour un changement de voie à gauche et à droite, respectivement. $T_{y_{D_1}}$ et $T_{y_{D_{-1}}}$ représentent le temps total nécessaire pour que le conducteur effectue la manœuvre de changement de voie vers la gauche et vers la droite, respectivement.

La Figure 2.15 montre un aperçu de la méthode d'apprentissage pour la décision de manœuvre et la planification de trajectoire. Au début du processus, nous utilisons les paramètres du système DMSP pour la prise de décision et ceux du PPP pour la planification de trajectoire, afin de déterminer la manœuvre et la trajectoire appropriées. Si nous détectons une intention de changement de voie du conducteur, nous calculons les paramètres DMSP et PPP du conducteur et utilisons l'algorithme SGD pour les adapter et obtenir de nouveaux paramètres DMSP et PPP pour le système. Ces nouveaux paramètres seront ensuite utilisés pour la prochaine manœuvre de changement de voie. En résumé, lorsque le conducteur manifeste son intention de changer la voie, nous ajustons les paramètres du système en fonction de ses actions et de ses préférences, ce qui permet de personnaliser davantage le comportement du système de conduite autonome en réponse aux préférences individuelles du conducteur.

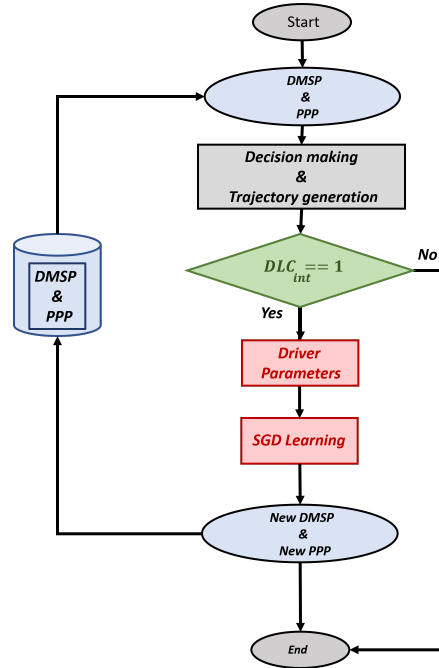


FIGURE 2.15 – Aperçu de la méthode d’apprentissage SGD pour la prise de décision des manœuvres et la planification de trajectoires.

2.7.3.2 Validation expérimentale

La validation expérimentale de l’approche de planification de trajectoires personnalisées proposée, a été réalisée en utilisant le simulateur dynamique interactif SHERPA sur une piste d’essai de type autoroute à deux voies d’une longueur de 4 km et d’une largeur de voie de 3,5 m. Cette piste permet de reproduire des conditions réalistes de conduite et de tester la performance du système de prise de décision sur les manœuvres et de planification de trajectoires personnalisées. Cela permet de démontrer l’efficacité et l’amélioration du système suite à l’apprentissage.

L’approche a été testée pour un scénario de dépassement de douze véhicules. Les quatre premiers dépassements ont été effectués en mode de conduite automatique où le conducteur n’intervient pas dans le contrôle du véhicule, puis les quatre suivants ont été réalisés en mode de conduite manuelle où le processus d’apprentissage est activé. Enfin, les quatre derniers dépassements ont été effectués à nouveau en mode de conduite automatique, afin de comparer le comportement du système avant et après l’apprentissage par rapport à celui du conducteur. Le taux d’apprentissage $\alpha = 0.5$ et les paramètres initiaux de l’algorithme d’apprentissage, qui représentent les performances du système LCAS avant l’apprentissage $P_s(0)$ sont les suivants :

$$P_s(0) = \begin{bmatrix} \%TIV_1 = 1 \\ \%TIV_{-1} = 1 \\ T_{y_1} = 7s \\ T_{y_{-1}} = 7s \\ y_{r_1} = 3.5m \\ y_{r_{-1}} = 0m \end{bmatrix} \quad (2.39)$$

Les Figures 2.16 et 2.17 montrent l’évolution de paramètres DMSP et PPP pour les changements de voie vers la gauche et vers la droite. Avant l’apprentissage, les valeurs des paramètres du système sont initialement différentes de celles du conducteur. Cependant, au fur et à mesure que l’algorithme d’apprentissage progresse, les valeurs convergent ou se rapprochent des valeurs

du conducteur, montrant ainsi une amélioration des performances du système pour se rapprocher du comportement souhaité.




FIGURE 2.16 – L'évolution des paramètres du système de prise de décision des manœuvres (DMSP) et de la planification de trajectoires (PPP) avant, pendant et après l'apprentissage par rapport à ceux des conducteurs pour le changement de voie vers la gauche.

En ce qui concerne les performances du système de prise de décision de changement de voie et du système de planification de trajectoires, les résultats sont présentés dans les Figures 2.18 et 2.19 respectivement.

Avant l'apprentissage (en mode manuel), le système de décision de changement de voie prend des décisions de manière anticipée par rapport à celles du conducteur, ce qui peut conduire à des actions moins réactives et moins sûres. Cependant, après l'apprentissage, le système de décision s'aligne davantage sur les décisions du conducteur, montrant une évolution de la prise de décision pour se rapprocher du comportement naturel du conducteur.

De même, le système de planification de trajectoire montre une évolution après l'apprentissage. Avant celui-ci, la trajectoire planifiée par le système pouvait être moins adaptée et moins précise par rapport à celle du conducteur en mode manuel. Cependant, après l'apprentissage, la trajectoire planifiée par le système converge vers celle du conducteur, démontrant ainsi une meilleure reproduction du comportement du conducteur et probablement une meilleure adéquation aux préférences de ce dernier.

2.7.4 Le système de prise de décision pour l'apprentissage

Lorsque l'on utilise l'apprentissage pour personnaliser un système de conduite autonome, il est essentiel de prendre en compte les risques potentiels liés à l'apprentissage de mauvais comportements du conducteur. Pour éviter cela, un système de prise de décision de l'apprentissage et de supervision est conçu pour contrôler et guider l'apprentissage afin de s'assurer que seuls les comportements souhaitables du conducteur sont appris et adoptés par le système.

Ce système peut déterminer quelles actions ou comportements sont considérés comme sécuritaires et adéquats, et il peut intervenir pour corriger les décisions du système si elles ne corres-




FIGURE 2.17 – L'évolution des paramètres du système de prise de décision des manœuvres (DMSP) et de la planification de trajectoires (PPP) avant, pendant et après l'apprentissage par rapport à ceux des conducteurs pour le changement de voie vers la droite.




FIGURE 2.18 – La performance du système de prise de décision de changement de voie en mode automatique avant et après l'apprentissage, comparée à la décision du conducteur en mode manuel.

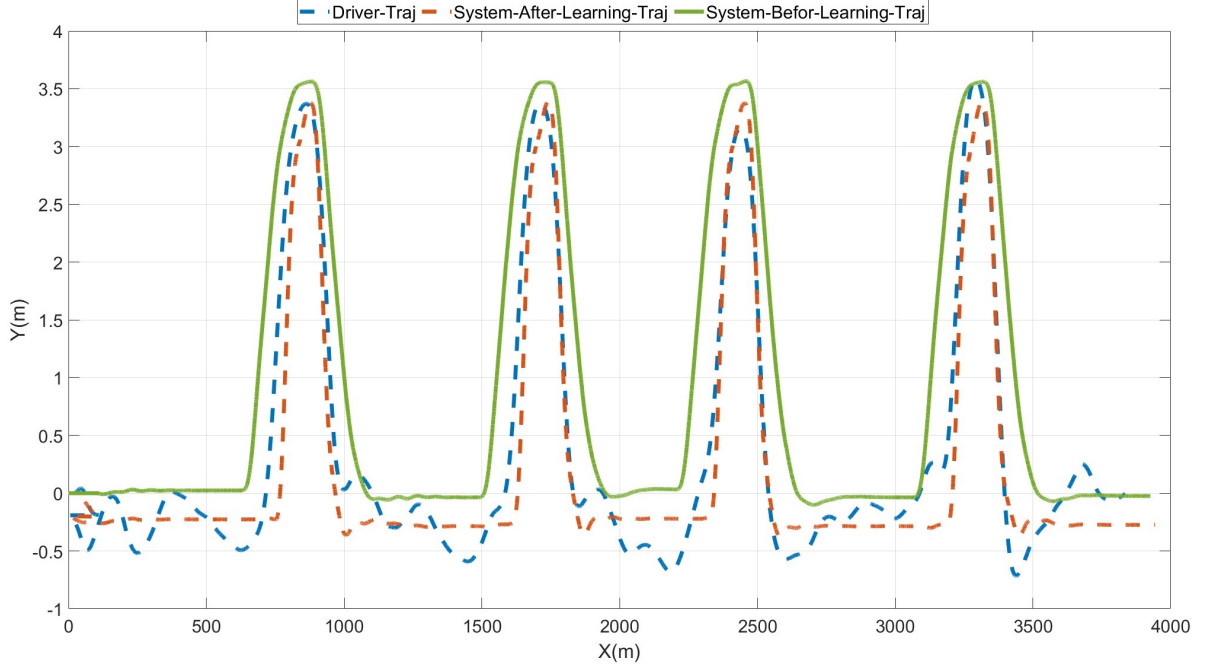


FIGURE 2.19 – La performance du système de planification de trajectoires en mode automatique avant et après l’apprentissage, comparée à la trajectoire réalisée par le conducteur en mode manuel.

pondent pas aux comportements souhaitables du conducteur.

Par exemple, si le système de conduite autonome apprend des comportements risqués ou dangereux du conducteur lors de l’apprentissage, le système de prise de décision et de supervision peut intervenir pour corriger ces comportements et éviter qu’ils ne soient adoptés par le système.

Nous proposons un système basé sur des règles pour prendre des décisions en tenant compte du respect du code de la route, de l’état du conducteur (fatigue, endormissement), et du risque associé à la manœuvre réalisée. Ce système de prise de décision vise à superviser l’apprentissage du système de conduite autonome afin de s’assurer qu’il n’apprend que les comportements souhaitables du conducteur.

Nous définissons la décision d’apprentissage, ρ_i (ρ_1 pour les changements de voie à gauche et ρ_{-1} pour les changements de voie à droite). Cette décision est basée sur des conditions qui évaluent les paramètres du conducteur, respectent les règles de conduite et surveillent l’état du conducteur à l’aide de caméras.

$$\rho_i = C_{P_{D_i}} \wedge C_{legal_i} \wedge C_{DS} \quad (2.40)$$

où :

$C_{P_{D_i}}$: est la condition qui évalue la dangerosité de la manœuvre en comparant les paramètres du conducteur pour un changement de voie avec un intervalle de sécurité prédéfini $[P_{D_{i_{min}}}, P_{D_{i_{max}}}]$. Cela permet de vérifier si les paramètres du conducteur sont compatibles avec une manœuvre sûre.

C_{legal_i} : est la condition qui vérifie si le conducteur respecte le code de la route, par exemple en comparant la vitesse actuelle du véhicule avec la limite de vitesse autorisée ($v_{ego} \leq v_{lim}$) et en vérifiant si le marquage de voie est discontinu ($Marquage_{voie_i} = 0$). Cela garantit que le changement de voie est effectué en accord avec les règles de conduite.

C_{DS} : est la condition qui représente l’état du conducteur, en vérifiant si le système de surveillance du conducteur indique qu’il est en état de conduire ($DS = 1$). Cela évite que le

système n'apprend des comportements inappropriés si le conducteur n'est pas en mesure de conduire de manière optimale (problème de vigilance ou d'attention).

Pour évaluer cet indicateur, un système de surveillance du conducteur fourni par la société Continental Automotive est utilisé (voir Figure 2.20). Le niveau de somnolence du conducteur peut être catégorisé en trois classes distinctes par ce système, à savoir vigilant, somnolent et endormi. De même, le niveau d'inattention renvoyé par le système indique si le conducteur concentre son attention visuelle sur la route ou non.

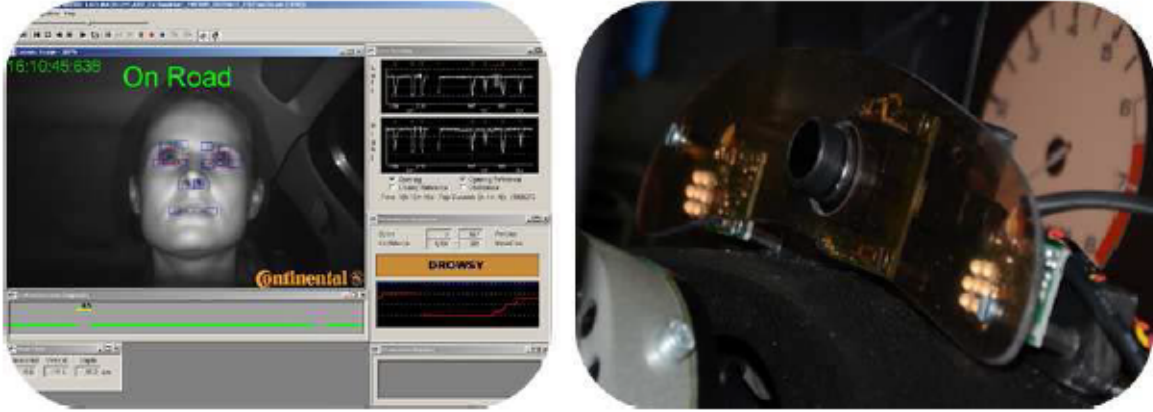


FIGURE 2.20 – Le système de surveillance du conducteur de la société Continental Automotive basé sur un système de caméra.

L'état du conducteur, noté \mathcal{DS} , peut être directement obtenu à partir du système de surveillance du conducteur et normalisé pour simplifier son utilisation, c'est-à-dire $0 \leq \mathcal{DS} \leq 1$, dans lequel la valeur maximale de \mathcal{DS} indique un conducteur vigilant et attentif.

Après avoir déterminé le mécanisme de décision de l'apprentissage, nous adaptons le calcul des paramètres moyens du conducteur utilisé dans l'apprentissage en fonction de la décision de l'apprentissage comme suit :

$$P_{D_m} = \frac{1}{1 + \rho} (P_{D_m} + \rho P_D) \quad (2.41)$$

De plus, l'algorithme d'apprentissage SGD pour le changement de voie devient ASGD (Adaptive Stochastic Gradient Descent) où le taux d'apprentissage devient adaptatif selon la décision d'apprentissage ρ , calculé de la manière suivante :

$$\alpha(\rho) = \alpha\rho \quad (2.42)$$

Le mécanisme d'adaptation des paramètres du système d'aide au changement de voie en utilisant ASGD devient :

$$P_s(i+1) = P_s(i) - \alpha(\rho) \frac{\partial \mathfrak{S}(P_s)}{\partial P_s} \quad (2.43)$$

Ainsi, en utilisant ce système de prise de décision basé sur des règles et en adaptant le taux d'apprentissage en fonction de la décision de l'apprentissage, nous veillons à ce que l'apprentissage du système de conduite automatisée se déroule de manière sécurisée, responsable et conforme aux comportements souhaitables du conducteur. Cela contribue à créer un système de conduite automatisée personnalisé, sécurisé et respectueux des règles de conduite.

Le résumé de l'algorithme ASGD, utilisé pour ajuster les paramètres du système d'aide au changement de voie en intégrant la décision de l'apprentissage dans le processus, est présenté dans la Figure 2.21.

Algorithme 3: ASGD pour le système d'aide au changement de voie avec la décision d'apprentissage

Entrée: P_D, i, ρ

Sortie: P_s, P_{D_m}

Initialisation: P_{s_0}, P_{D_m}, α

Pour chaque nouveau changement de voie i

- Les paramètres moyens du conducteur : $P_{D_m} \leftarrow \frac{1}{(1+\rho)}(P_{D_m} + \rho P_D)$
- La fonction du coût : $\mathfrak{J}(P_s) \leftarrow \frac{1}{2}(P_s - P_{D_m})^2$
- Le gradient : $\frac{\partial \mathfrak{J}(P_s)}{\partial P_s} \leftarrow (P_s - P_{D_m})$
- Le taux d'apprentissage adaptatif : $\alpha(\rho) \leftarrow \alpha \rho$
- L'algorithme ASGD : $P_s \leftarrow P_s - \alpha(\rho) \frac{\partial \mathfrak{J}(P_s)}{\partial P_s}$

Fin

FIGURE 2.21 – L'algorithme de descente de gradient stochastique adaptatif (ASGD) est utilisé pour ajuster les paramètres du système d'aide au changement de voie en tenant compte de la décision d'apprentissage.

La Figure 2.22 montre un aperçu de la méthode d'apprentissage pour la décision de manœuvres et la planification de trajectoires en intégrant la décision de l'apprentissage dans le process.

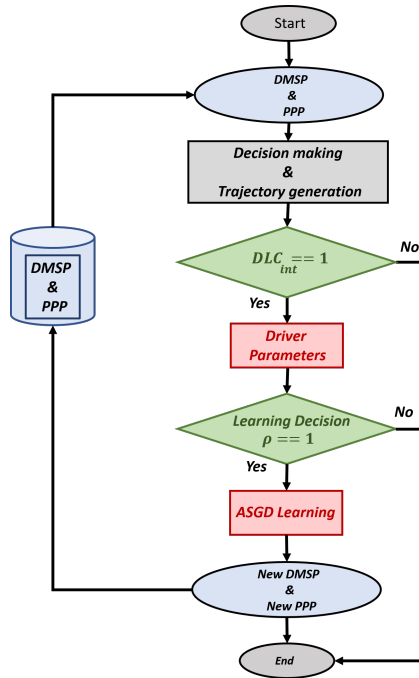


FIGURE 2.22 – Aperçu de la méthode d'apprentissage ASGD pour la prise de décision des manœuvres et la planification de trajectoires.

Au début du processus, nous utilisons les paramètres du système DMSP pour la prise de décision et ceux du PPP pour la planification de trajectoires, afin de déterminer la manœuvre et la trajectoire appropriées. Cependant, lorsque nous détectons une intention de changement de voie du conducteur, nous adoptons une approche d'apprentissage pour adapter les paramètres

du système. Pour ce faire, nous calculons les paramètres DMSP et PPP du conducteur. Ensuite, nous utilisons le mécanisme de décision d'apprentissage pour adapter et autoriser l'algorithme ASGD à ajuster ces paramètres et obtenir de nouveaux paramètres DMSP et PPP pour le système. Ces nouveaux paramètres adaptés sont alors utilisés pour la prochaine manœuvre de changement de voie.

2.7.4.1 Validation expérimentale

Pour vérifier l'efficacité du mécanisme de prise de décision pour l'apprentissage et son rôle d'adaptation du mécanisme d'apprentissage, un conducteur a effectué une série de cinq changements de voie en mode de conduite manuelle à l'aide du simulateur SHERPA. Ces manœuvres de changement de voie ont été réalisées dans des conditions contrôlées afin d'évaluer la capacité du système à prendre des décisions adéquates et à ajuster son processus d'apprentissage en réponse aux comportements du conducteur.

La Figure 2.23 illustre l'évolution des paramètres du conducteur pour la manœuvre de changement de voie à gauche. Ces paramètres incluent : i) le temps intervéhiculaire normalisé entre le véhicule ego et le véhicule leader de la même voie ($\%TIV_{1D}$), ii) la position latérale cible du conducteur (y_{1D}), iii) le temps de réalisation de la manœuvre de changement de voie du conducteur (T_{y1D}) et iv) la variation de la vitesse par rapport à la vitesse limite ($v_{lim} = 22m/s$) de la voie.




FIGURE 2.23 – L'évolution des paramètres du conducteur lors de la manœuvre de changement de voie vers la gauche, ainsi que les variations de la vitesse longitudinale du véhicule et la décision prise par le mécanisme de décision d'apprentissage.

La Figure 2.23 indique également les décisions prises par le mécanisme proposé lors des différentes phases du test. À deux instants spécifiques, soit $t = 138s$ et $t = 170s$, le système a décidé de ne pas apprendre. Cela s'est produit car le conducteur n'a pas respecté la vitesse

limite de la voie à ces moments précis. De plus, à l'instant $t = 248s$, le système a également choisi de ne pas apprendre, en raison d'une manœuvre jugée dangereuse par le système, où le temps intervéhiculaire était trop faible par rapport au véhicule leader.




FIGURE 2.24 – L'évolution des paramètres du système de prise de décision des manœuvres (DMSP) et de la planification de trajectoires (PPP) pendant l'apprentissage par rapport à ceux du conducteur pour le changement de voie vers la gauche.

En examinant la Figure 2.24 et en prenant en compte les décisions prises par le système d'apprentissage, nous pouvons observer que les paramètres du système convergent vers les paramètres moyens du conducteur uniquement lors des deux premiers changements de voie. Dans ces cas-là, la décision du système était positive (OK), indiquant que le comportement du conducteur était sûr et conforme aux règles de conduite.

En revanche, lors des trois derniers changements de voie, le système a choisi de ne pas apprendre, car ses décisions étaient négatives (non). Cela signifie que le comportement du conducteur n'était pas conforme aux normes de sécurité ou qu'il y avait des situations potentiellement dangereuses.

Ces résultats démontrent que le système d'apprentissage est capable de s'adapter en temps réel en prenant en compte le respect du code de la route et la sécurité des manœuvres. En utilisant les décisions du mécanisme décisionnel de l'apprentissage, le système peut ajuster son processus d'apprentissage pour ne prendre en compte que les comportements sûrs et appropriés du conducteur, ce qui améliore la sécurité globale du système de conduite.

2.8 Conclusion

Dans ce chapitre, nous avons présenté un nouveau système destiné à la prise de décision sur les manœuvres et à la planification de trajectoires personnalisées dans des situations de changement de voie. L'approche proposée est basée sur des fonctions de coût adaptatives qui prennent en compte le risque, les aspects légaux et les préférences du conducteur lors de la prise de décision pour effectuer des manœuvres de changement de voie. De plus, une méthode polynomiale adaptative de planification de trajectoires basée sur l'apprentissage des préférences

paramétriques liées à la manœuvre a été également proposée. Nous avons utilisé une approche de descente de gradient stochastique pour ajuster les paramètres du système en fonction des préférences du conducteur en mode de conduite manuelle, en se basant sur ses intentions de changement de voie.

L'approche proposée a été évaluée fonctionnellement de manière expérimentale en utilisant un simulateur de véhicule interactif dans des situations de conduite réelles impliquant des dépassements. Les résultats obtenus ont clairement démontré l'efficacité de la stratégie proposée pour la personnalisation des prises de décisions et des trajectoires planifiées pour les systèmes d'aide au changement de voie (LCAS). En utilisant les décisions prises par le mécanisme d'apprentissage de la prise de décision et grâce à l'algorithme de descente de gradient stochastique adaptatif (ASGD), le système peut ajuster son processus d'apprentissage pour ne considérer que les comportements sûrs et appropriés du conducteur, ce qui améliore la sécurité globale du système de conduite. Ces résultats démontrent que le système d'apprentissage est capable de s'adapter en temps réel tout en prenant en compte le respect du code de la route et la sécurité des manœuvres.

Cependant, il est essentiel de noter que dans ce chapitre, notre attention a été principalement axée sur la sécurité au niveau tactique, en tenant compte des contraintes liées au code de la route et au système de surveillance du conducteur. Nous n'avons pas encore abordé le niveau opérationnel.

Dans le prochain chapitre, nous développerons une nouvelle stratégie de contrôle partagé, axée sur l'humain, qui tiendra compte des contraintes de sécurité tout en gérant les non-linéarités liées à la variation de la vitesse longitudinale du véhicule et le niveau de partage fourni par un superviseur de conduite. Notre objectif sera également de minimiser les conflits au niveau de l'actionneur entre le système automatisé et le conducteur, visant ainsi à offrir une expérience de conduite plus fluide et sécurisée.

Chapitre 3

Contrôle partagé adaptatif basé sur une approche LPV avec fonction de coût multi-objectif

Sommaire

| | | |
|------------|---|------------|
| 3.1 | Introduction | 96 |
| 3.2 | Le contrôle partagé | 96 |
| 3.2.1 | Les définitions de contrôle partagé | 96 |
| 3.2.2 | Les modèles de contrôle partagé | 97 |
| 3.2.3 | Les stratégies de contrôle partagé dans la littérature pour résoudre les problèmes de conflit | 97 |
| 3.3 | Contribution | 100 |
| 3.4 | Superviseur de conduite pour la gestion du niveau de partage | 101 |
| 3.4.1 | Activité du conducteur (DA) | 101 |
| 3.4.2 | Niveau d'assistance dynamique | 106 |
| 3.5 | Modélisation de la dynamique du système Véhicule-Route | 106 |
| 3.5.1 | Le système Véhicule-Route | 106 |
| 3.5.2 | Validation du Modèle Véhicule-Route sur SHERPA | 108 |
| 3.6 | Préliminaires sur la modélisation TS et l'étude de leur stabilité | 110 |
| 3.6.1 | Préliminaires sur la modélisation TS | 111 |
| 3.6.2 | Stabilité et stabilisation des systèmes TS | 113 |
| 3.7 | La conception du contrôleur partagé adaptatif LPV-TS | 115 |
| 3.7.1 | Représentation TS du Modèle Véhicule-Route | 115 |
| 3.7.2 | Conception du contrôleur partagé basée sur l'approche PDC | 116 |
| 3.7.3 | Analyse de la stabilité | 119 |
| 3.8 | Validation expérimentale | 119 |
| 3.8.1 | Performance du contrôleur LKS en mode de conduite autonome | 120 |
| 3.8.2 | Performance du contrôle partagé adaptatif | 120 |
| 3.8.3 | Prise en compte du risque dans le contrôle partagé adaptatif | 122 |
| 3.8.4 | Expériences de test utilisateurs | 123 |
| 3.9 | Conclusion | 126 |

3.1 Introduction

Dans le chapitre précédent, nous avons exploré la personnalisation des prises de décision sur les manoeuvres et des trajectoires planifiées au niveau tactique pour la conduite automatisée. Nous nous sommes focalisés principalement sur les aspects sécurité au niveau tactique. Jusqu'à présent, le niveau opérationnel n'a pas été exploré.

Comme nous l'avons mentionné dans le chapitre 1, l'interaction conducteur-véhicule automatisé au niveau opérationnel (voir Figure 1.11 de l'architecture proposée) doit être gérée afin de résoudre les problèmes de conflits au volant entre le conducteur et le système de conduite autonome.

Le présent chapitre se focalise sur la conception d'une nouvelle stratégie de gestion dynamique des conflits, visant à résoudre les défis liés au contrôle de la conduite partagée dans les systèmes de maintien de voie (LKS) des véhicules automatisés.

Basé sur le concept d'une approche de contrôle centrée sur l'humain, le LKS que nous proposons tient compte en temps réel de l'activité et de la disponibilité du conducteur, ainsi que du contexte environnant, afin d'adapter le niveau d'assistance en fonction de la situation de conduite. La conception du contrôleur partagé adaptatif repose sur une fonction de coût dynamique, dont l'ajustement est déterminé en fonction du niveau d'assistance fourni par un superviseur de conduite.

Pour relever le défi des non-linéarités liées à la variation en temps réel de la vitesse du véhicule et du niveau d'assistance, nous exploitons la technique de commande linéaire à paramètres variants (LPV). En utilisant la théorie de stabilité de Lyapunov, nous formulons les conditions de conception du contrôle sous forme de contraintes d'inégalités matricielles linéaires (LMI), qui peuvent être résolues efficacement à l'aide de techniques de programmation semi-définie.

En complément, nous avons mené des expériences de test utilisateurs pour évaluer l'acceptabilité du système par les conducteurs. Ces tests ont été réalisés en utilisant le simulateur de conduite dynamique SHERPA, présenté dans le chapitre précédent. L'objectif était de démontrer l'efficacité du contrôle partagé adaptatif que nous proposons dans ce chapitre. Les résultats principaux de ce chapitre font l'objet de la publication [Oudainia et al., 2023].

3.2 Le contrôle partagé

La détermination de la manière dont les compétences des conducteurs et des véhicules automatisés peuvent être harmonieusement combinées pour une coopération optimale au niveau opérationnel reste un défi [Flad et al., 2014]. Une approche attrayante pour atteindre une telle interaction conducteur-automatisation est le contrôle partagé, un concept hérité du domaine de la coopération homme-machine, avec diverses applications en robotique (par exemple, les robots médicaux opérés sous guidage haptique [Xiong et al., 2017]).

3.2.1 Les définitions de contrôle partagé

Le contrôle partagé a été défini pour la première fois par Sheridan et Verplank [Sheridan and Verplank, 1978] comme *"le cas où à la fois l'automatisation et l'humain travaillent sur la même tâche et en même temps"*. D'autres définitions introduisent une hiérarchie de sous-tâches : dans le contrôle partagé, *"le système distant peut exercer un contrôle sur certains aspects de la tâche tandis que l'opérateur humain conserve un accès aux forces et mouvements de bas niveau"* [Griffin et al., 2005], ou *"le robot peut contrôler les fonctions de bas niveau tandis que l'opérateur humain conserve le contrôle de haut niveau"* [O'Malley et al., 2006]. Abbink, dans [Abbink et al., 2018], définit la commande partagée comme suit : *"En commande partagée, les humains et les robots interagissent de manière congruente dans un cycle de perception-action pour effectuer une tâche dynamique, qu'un individu humain ou un robot pourrait exécuter individuellement dans*

des circonstances idéales”. Cette définition exclut l’automatisation complète (où il n’y a pas d’humain) ou le contrôle manuel (où il n’y a pas d’automatisation).

3.2.2 Les modèles de contrôle partagé

La littérature explore deux modèles de contrôle partagé, chacun reposant sur des mécanismes distincts pour partager la tâche de conduite [Abbink and Mulder, 2010, Li et al., 2017c]. Ces modèles sont dénommés le ”contrôle partagé couplé” et le ”contrôle partagé non couplé”. Dans les deux cas, on suppose qu’il existe une interface de contrôle, telle qu’un volant, une pédale d’accélérateur ou une pédale de frein, associée à un actionneur électronique représentant l’automatisation.

Le contrôle partagé couplé, appelé également ”contrôle partagé direct”, est pertinent pour les systèmes de guidage haptique [Abbink and Mulder, 2010, Li et al., 2017c]. Dans ce contexte, le système automatisé et le conducteur interagissent en utilisant une rétroaction de force, avec une liaison mécanique entre l’interface de contrôle et le système de guidage. Cela signifie que les actions de contrôle du conducteur sont immédiatement transférées au véhicule, donnant l’autorité finale à l’opérateur humain s’il applique une force suffisante. L’actionneur sert à communiquer l’intention d’automatisation au conducteur, mais il applique également des actions de contrôle au système de guidage dans le but de soutenir le conducteur, de réduire la charge de travail et l’effort de contrôle.

Le contrôle partagé non couplé est également connu sous le nom de ”Blended Shared Control” [Abbink and Mulder, 2010, Katzourakis et al., 2011, Hamdan et al., 2021] ou de contrôle partagé indirect [Li et al., 2017c, Li et al., 2017b, Li et al., 2017a], s’applique principalement aux systèmes ”drive-by-wire”, où l’interface de contrôle et le système de guidage ne sont pas mécaniquement liés. Dans ce cas, un contrôleur intermédiaire prend en charge le traitement des commandes du conducteur, tandis que l’autorité finale est attribuée à l’automatisation. Néanmoins, en situations normales, le système se comporte comme s’il était couplé. La rétroaction haptique est toujours nécessaire pour communiquer l’intention d’automatisation au conducteur, et l’interaction se déroule virtuellement en combinant les commandes du conducteur et de l’automatisation, réduisant ainsi les conflits potentiels à l’interface de contrôle.

La thèse dont il est question se concentre principalement sur le contrôle partagé haptique (couplé) dans le contexte de la tâche de maintien de voie. Dans ce cas, le conducteur interagit avec le système d’automatisation en utilisant un volant motorisé. Ce volant est directement connecté aux pneus avant du véhicule par l’intermédiaire de la colonne de direction.

3.2.3 Les stratégies de contrôle partagé dans la littérature pour résoudre les problèmes de conflit

La coopération entre le conducteur et le système d’automatisation soulève des questions sur le transfert d’autorité et de responsabilité entre eux. Dans les systèmes ADAS traditionnels, la plupart des décisions sont prises par le système, limitant ainsi le rôle du conducteur à une simple supervision. Cela peut entraîner une certaine dépendance à l’égard du système, une perte de compétences de conduite et une perte de confiance dans les capacités du système.

Les approches Driver-in-the-Loop (DiL) sont proposées pour résoudre ces problèmes. Les stratégies DiL basées sur la coopération entre le conducteur et le système ADAS ont pour but de permettre au conducteur de garder le contrôle de la conduite tout en bénéficiant des avantages de l’assistance à la conduite. Les avantages potentiels incluent une meilleure sécurité, une réduction de la charge de travail du conducteur, une amélioration du confort de conduite, etc. La coopération entre le conducteur et le système ADAS soulève également des questions de sécurité liées aux conflits potentiels entre le conducteur et le système. Pour minimiser ces conflits, les approches DiL proposent des stratégies de partage d’autorité entre le conducteur

et le système ADAS. Ces stratégies ont pour but de prendre en compte les compétences et les capacités de chaque partie pour déterminer la meilleure répartition des tâches.

Dans la littérature, plusieurs stratégies de contrôle pour résoudre les problèmes de conflit sont proposées. Dans [Benloucif et al., 2019a], l’auteur présente un nouveau cadre pour le contrôle latéral partagé dans la conduite sur autoroute en utilisant la planification de trajectoire (voir Figure 3.1). L’idée centrale de ce travail est de prendre en compte le couple de direction du conducteur au niveau de la planification de trajectoire afin d’ajuster la trajectoire souhaitée du système de manière à mieux correspondre à l’intention du conducteur. Cette adaptation permet au système de converger vers la position souhaitée par le conducteur, facilitant ainsi des changements de voie plus fluides avec moins d’effort et de couples conflictuels.

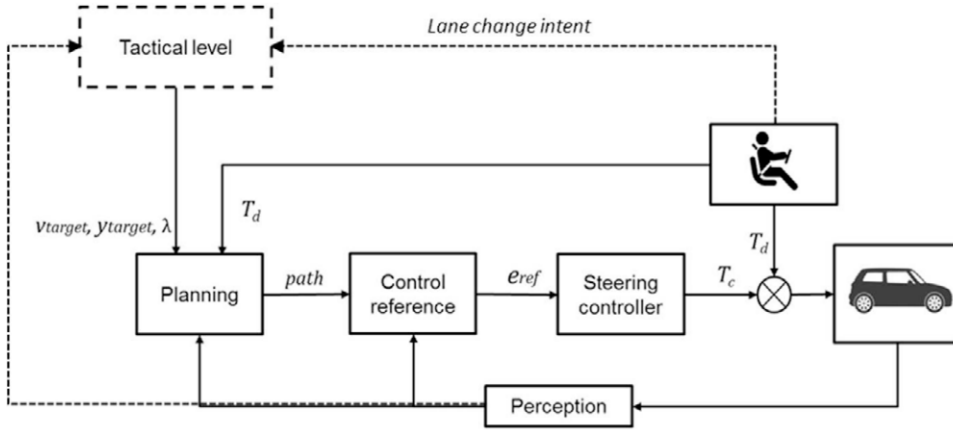


FIGURE 3.1 – Le contrôle latéral partagé basé sur la planification de trajectoire [Benloucif et al., 2019a].

Les auteurs de [Huang et al., 2019] ont proposé un cadre coopératif développé en utilisant la programmation dynamique adaptative basée sur les données et un modèle d’itération d’apprentissage basé sur la théorie classique du petit gain. La modification du niveau d’autorité haptique est utilisée dans [Abbink and Mulder, 2010] pour définir une commande haptique partagée, permettant au conducteur de modifier plus ou moins aisément la position du volant en fonction de la criticité de la situation de conduite.

Certaines applications de conduite intègrent un module de contrôle partagé au niveau tactique qui est distinct du niveau d’action plus bas. Par exemple, dans [Sentouh et al., 2013], une loi de décision tactique est établie entre le conducteur et le système automatisé pour sélectionner lequel des contrôleurs de bas niveau doit avoir plus d’autorité, en fonction de la différence de couple entre les commandes du conducteur et de l’automatisation.

Dans [Rath et al., 2019], une approche robuste de contrôle coopératif est formulée pour concevoir un système d’assistance au maintien de voie personnalisé avec adaptation au style du conducteur lors de la navigation sur une piste à forte ou faible courbure (voir Figure 3.2). En utilisant le style de conduite identifié, une fonction de modulation en forme de U basée sur l’activité du conducteur déterminée par l’état du conducteur et l’implication du couple exercé par le conducteur est proposée pour adapter le couple d’assistance. Le couple d’assistance est généré sur la base d’une commande par mode glissant d’ordre supérieur.

Dans [Mars et al., 2014] (voir Figure 3.3), un automate fournit un couple optimal de commande requis pour le suivi de voie, pondéré par un pourcentage $\alpha\%$ (un niveau de partage), tandis que le conducteur contribue avec le pourcentage restant, soit $100 - \alpha\%$, lorsque cela est en accord avec l’action de l’assistance. La même stratégie a été également utilisée dans [Saleh, 2012].




FIGURE 3.2 – Architecture de la stratégie de contrôle coopératif adaptée au style du conducteur [Rath et al., 2019].

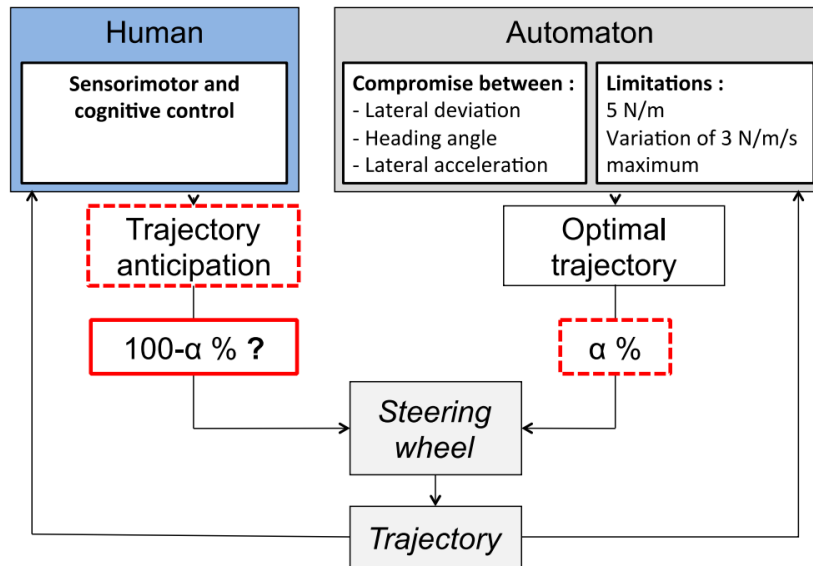


FIGURE 3.3 – Le schéma de contrôle latéral partagé proposé dans [Mars et al., 2014].

Dans [Sentouh et al., 2013, Sentouh et al., 2018], les auteurs ont démontré que le contrôle latéral du véhicule peut être partagé de manière dynamique, dans laquelle le produit des couples conducteur-système de maintien de voie est pris comme indicateur de partition pour favoriser l'action du conducteur sur celle du système. Basée sur une approche de commande floue LPV TS conçue pour le système conducteur-véhicule et pour représenter le conflit conducteur-ADAS dans le critère quadratique, l'approche de pondération est utilisée dans [Nguyen et al., 2017] pour gérer le compromis entre la performance de suivi de voie et le ratio d'interférence négative du système à l'aide d'un algorithme de prise de décision situé au niveau du contrôle tactique.

Dans [Pano et al., 2020], une méthode basée sur l'approche H_2/H_∞ est également exposée pour élaborer un système de contrôle partagé haptique. Cette méthode implique la configuration hors ligne des plages des gains du contrôleur en utilisant divers niveaux de partage de contrôle. Cette stratégie de contrôle partagé haptique a été adaptée dans [Pano et al., 2022] pour assurer

les transitions entre les deux modes de fonctionnement (manuel et autonome). Cette stratégie est intéressante car elle utilise explicitement le niveau de partage entre le conducteur humain et l'assistance dans le réglage de la commande. Cependant dans cette approche locale, la stabilité globale du système n'est pas démontrée.

Les approches de contrôle partagé existantes font face à des défis en termes de stabilité et d'allocation de l'autorité de conduite. La méthode de sommation pondérée $u = (1 - \rho)u_d + \rho u_c$, qui répartit les entrées de contrôle entre le conducteur et l'automatisation, présente des limitations quant à la garantie de la stabilité globale du système. De plus, l'allocation de la responsabilité de conduite avec les conducteurs humains demeure une problématique complexe. Pour répondre à ces défis, il est impératif de développer une nouvelle stratégie d'interaction humain-machine (HMI) qui autorise une transition progressive et continue du contrôle du véhicule entre le conducteur et le système, tout en garantissant la sécurité et la stabilité.

3.3 Contribution

Dans cette première approche, nous étudions le concept de contrôle centré sur l'humain pour concevoir un contrôle partagé LPV adaptatif pour LKS basé sur le couple d'entrée de braquage en tant que signal de commande, en mettant l'accent sur la minimisation du conflit entre le conducteur et le LKS.

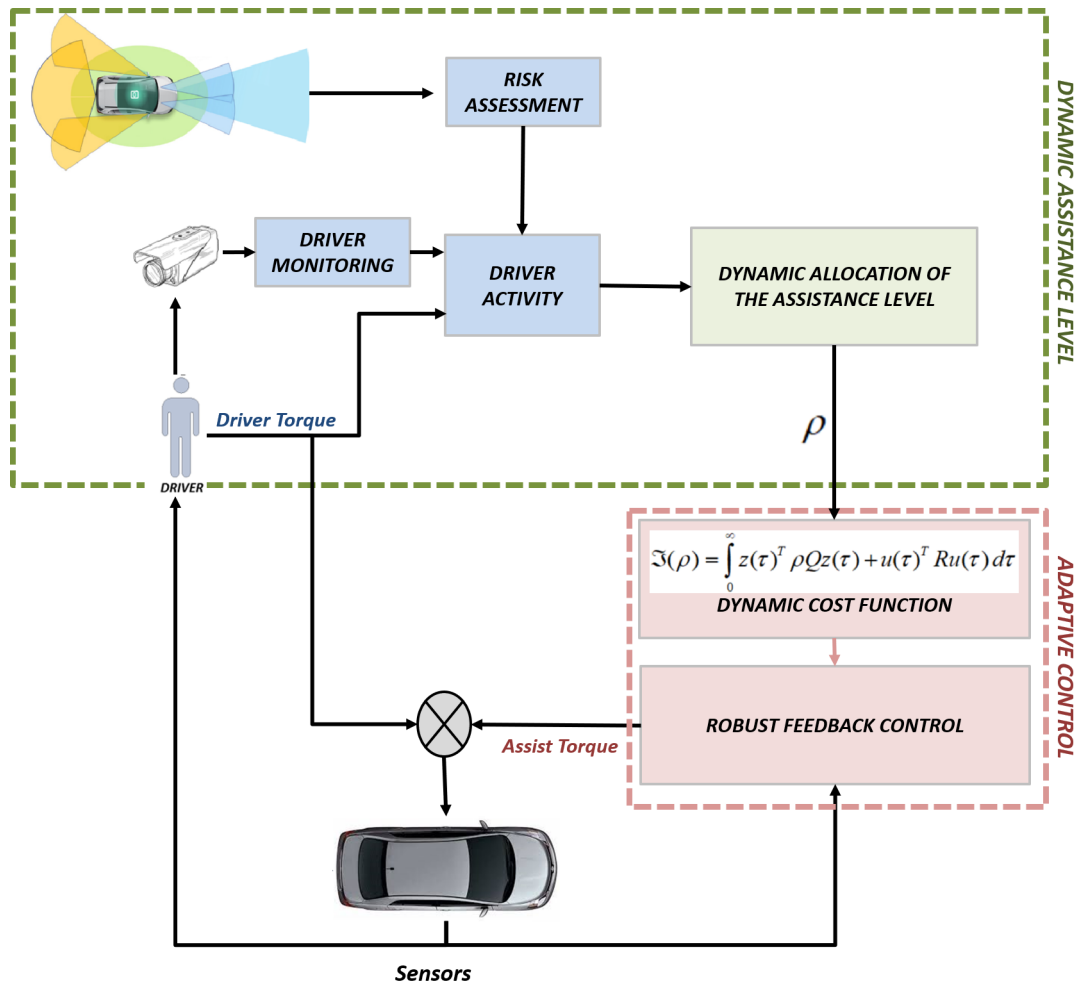


FIGURE 3.4 – La Stratégie de Contrôle Partagé Adaptatif.

La nouvelle stratégie de contrôle partagé adaptatif proposée dans ce chapitre, telle qu’illustrée dans la Figure 3.4, est capable de traiter le conflit conducteur-LKS de manière dynamique. Elle est basée sur le principe d’ajustement de l’objectif de la fonction de coût en fonction du risque environnant, de la disponibilité et de l’activité du conducteur. L’intégration efficace de ces informations concernant le conducteur et la situation de conduite, directement dans le processus de conception du contrôle partagé haptique présente, plusieurs défis théoriques et techniques et la littérature ouverte contient très peu de travaux sur ce sujet.

Les principales contributions de ce travail peuvent être résumées comme suit :

- Une méthode pour caractériser l’activité de conduite en ligne du conducteur en fonction de ses charges physiques et mentales est présentée. Une telle caractérisation est essentielle pour construire une fonction de coût multi-objectif pour la conception de la commande partagée. En prenant en compte les informations en temps réel sur la disponibilité et l’activité du conducteur, ainsi que les conditions de circulation, cette fonction de coût adaptative permet une gestion efficace des conflits entre le conducteur et le système de maintien de voie.
- Un cadre de commande polytopique LPV est utilisé pour prendre en compte la variation dynamique non seulement de la vitesse du véhicule, mais surtout du paramètre reflétant le niveau de partage de la commande, qui est impliqué dans la fonction de coût adaptative. Les conditions de conception sont exprimées en termes de contraintes d’inégalités matricielles linéaires (LMI), où la fonction de coût peut être minimisée via une optimisation convexe.
- Enfin, des expériences de test utilisateurs ont été menées à l’aide du simulateur de conduite dynamique SHERPA pour étudier l’acceptabilité des conducteurs envers le système de contrôle partagé adaptatif proposé. Ces expériences ont permis de démontrer l’efficacité de cette approche pour améliorer la sécurité et le confort de conduite.

3.4 Superviseur de conduite pour la gestion du niveau de partage

Cette section vise à présenter les différents blocs du superviseur de conduite illustrés dans la Figure 3.4 (la partie supérieure en vert). Nous commencerons par l’activité du conducteur et irons jusqu’au calcul du niveau d’assistance dynamique.

3.4.1 Activité du conducteur (DA)

Les capacités du conducteur dépendent fortement de son état physiologique et psychologique. Des recherches antérieures ont examiné les effets de la charge cognitive (physique et mentale) d’un conducteur humain sur sa capacité à effectuer une tâche de conduite donnée, ainsi que la relation entre la fatigue du conducteur et un environnement routier monotone [Zhao and Rong, 2012]. De plus, le niveau d’assistance requis a déjà été souligné comme devant être adapté aux performances du conducteur en fonction de la charge cognitive [Sentouh et al., 2018, Benloucif et al., 2019b]. La relation entre la charge cognitive et la performance de la tâche de conduite peut être représentée par la célèbre courbe en forme de U [Nguyen et al., 2017], où la charge du conducteur peut être classée en trois types : sous-charge, charge normale et surcharge, comme indiqué dans la Figure 3.5.

Les travaux de recherche sur la conduite automatisée se concentrent souvent sur la partie droite de la courbe liée à la fatigue active (situation de surcharge). La partie gauche de la courbe concerne la fatigue passive du conducteur liée à sa sous-charge cognitive, qui est également capable de dégrader les performances du conducteur [McWilliams and Ward, 2021]. En effet, une tâche peu exigeante réduit encore les ressources attentionnelles, ce qui peut entraîner des changements dans les performances du conducteur caractérisés par une diminution de la vigilance.




FIGURE 3.5 – L’illustration de la relation entre l’activité et les performances du conducteur, ainsi que le niveau d’assistance requis.

De nombreuses études expérimentales ont été consacrées à l’identification d’indicateurs capables de caractériser la fatigue passive et active du conducteur. Ces indicateurs peuvent être classés en deux grands groupes, souvent désignés dans la littérature comme issus des méthodes ”directes” et ”indirectes” [Boverie and Giralt, 2008], en fonction de la mesure effectuée sur le conducteur lui-même pour la charge mentale (par exemple, les clignements des yeux, les mouvements de tête, etc.) ou sur le véhicule pour la charge physique (par exemple, l’angle du volant, le couple de direction, la position latérale sur la route, etc.). Un consensus s’est peu à peu dégagé selon lequel un diagnostic fiable de l’état du conducteur devrait être basé sur une combinaison des deux méthodes grâce à une fusion de données (”fusion de données conducteur et conduite”) [Liu et al., 2016, Sentouh et al., 2018, Kashevnik et al., 2021].

Dans cette sous-section, nous proposons un modèle de l’activité du conducteur (DA) qui se compose de trois parties, une partie ”Sous-charge” qui représente la partie mentale du conducteur, une partie ”Charge normale” qui représente la partie mentale et physique du conducteur, et une partie ”Surcharge” qui inclut, en plus de l’état mental et physique du conducteur, l’évaluation des risques liés à la situation de conduite.

3.4.1.1 DA ”Sous-charge”

Pour évaluer l’orientation du regard et les clignements des yeux du conducteur afin d’identifier la somnolence et l’inattention du conducteur, un système de surveillance du conducteur (Driver Monitoring) de la société Continental Automotive est utilisé (voir Figure 3.6). Le niveau d’éveil du conducteur est catégorisé par ce système en trois classes distinctes, à savoir vigilant, somnolent

et endormi. De même, le niveau d'inattention indique si le regard du conducteur est concentré sur la route ou non.



FIGURE 3.6 – Système de Surveillance du Conducteur (DMS).

Afin de permettre une bonne représentation de l'activité du conducteur, les informations de surveillance du conducteur ont été combinées avec la détection des mains sur le volant. L'activité du conducteur DA dans la région "Sous-charge" est définie comme suit :

$$DA_U = 1 - \exp^{-(\sigma_1 \times DS \times HD)^{\sigma_2}} \quad (3.1)$$

avec DS étant l'état du conducteur. Cette information est obtenue directement à partir du système de surveillance du conducteur et puis normalisée pour simplifier son utilisation, c'est-à-dire $0 \leq DS \leq 1$, dans lequel une valeur accrue de DS indique un conducteur vigilant et attentif. HD désigne la détection des mains du conducteur sur le volant à partir d'un capteur de détection des mains $HD \in \{0, 1\}$ où 0 signifie mains libres et 1 signifie mains sur le volant. L'expression (3.1) est proposée pour identifier les situations dans lesquelles le conducteur pourrait être considéré comme étant en sous-charge ou dans un scénario où il n'a pas besoin d'assistance. Cela est crucial car chaque faible variation de couple d'entrée ne signifie pas nécessairement un besoin d'assistance. Par exemple, lors de la conduite en ligne droite sur une route dégagée, de légères fluctuations de couple sont typiques et n'indiquent pas nécessairement un manque de conscience du conducteur. Une telle situation de conduite n'est pas représentée dans la caractérisation de l'assistance au conducteur dans [Nguyen et al., 2017].

3.4.1.2 DA "Charge normale"

Dans ce travail, la charge physique est quantifiée par le couple mesuré par le conducteur sur le volant. Ainsi, une variable non linéaire représentant l'activité du conducteur DA dans la région "Charge normale" est définie comme suit :

$$DA_N = 1 - \exp^{-(\sigma_1 \times \mathcal{T}_{dN} \times DS \times HD)^{\sigma_2}} \quad (3.2)$$

où la charge physique du conducteur est normalisée par le couple exercé par le conducteur sur le volant comme suit : $\mathcal{T}_{dN} = \left| \frac{T_d}{T_{d\max}} \right|$, où $T_{d\max}$ est le couple maximal requis par le conducteur pour la tâche de direction, moyenné sur différents conducteurs. L'expression (3.2) représente un scénario de conduite typique dans lequel l'activité du conducteur se situe dans une plage attendue. Elle sert de référence pour évaluer le comportement de conduite normal sans nécessité d'une assistance supplémentaire.

3.4.1.3 DA "Surcharge"

Comme mentionné précédemment, dans la région "Surcharge", l'évaluation des risques est également prise en compte. Dans ce travail, l'évaluation du risque de dépassement est prise en compte dans le processus d'arbitrage du superviseur de conduite.

Dans ce contexte, le risque d'une manœuvre peut être exprimé comme le risque de collision frontale et arrière avec le véhicule leader et le véhicule suiveur respectivement. Pour évaluer le risque, nous considérons la métrique temps-inter-véhicule (TIV) du véhicule Ego au véhicule adjacent comme utilisé dans [Oudainia et al., 2022b].

$$\begin{aligned} Risk &= \frac{\mathcal{TIV}_{\max} - \mathcal{TIV}}{\mathcal{TIV}_{\max}} \\ \mathcal{TIV} &= \frac{\mathcal{D}}{v_{ego}}, \quad \mathcal{TIV}_{\max} = \frac{\mathcal{D}_{\max}}{v_{ego}} \end{aligned} \quad (3.3)$$

où \mathcal{D} est l'espace entre deux véhicules et \mathcal{D}_{\max} est la distance maximale qui peut être détectée par le système de perception du véhicule. L'activité du conducteur DA dans la région "Surcharge" est définie comme suit :

$$DA_O = 1 - \exp^{-(\sigma_1 \times \mathcal{DS} \times \mathcal{HD} \times Risk)^{\sigma_2}} \quad (3.4)$$

L'expression (3.4) s'applique spécifiquement aux situations où le conducteur peut être en surcharge ou confronté à des conditions de conduite exigeantes. Cette expression aide à identifier quand le conducteur peut avoir besoin d'assistance en raison d'une charge de travail accrue, par exemple, lors de manœuvres d'urgence. La fonction d'activité du conducteur joue un rôle clé pour le contrôleur de conduite partagée entre le conducteur et l'automatisation proposé. Cette fonction détermine le niveau d'implication du conducteur dans le processus de contrôle du véhicule par rapport à l'automatisation. L'utilisation d'une fonction *exponentielle* pour modéliser l'activité du conducteur dans les équations (3.1), (3.2) et (3.4) permet d'éviter des changements brusques et soudains entre deux états discrets (0 et 1) qui pourraient entraîner un comportement instable ou inapproprié du système. Le paramètre de réglage σ_1 est utilisé pour représenter l'implication du conducteur dans les tâches de conduite, tandis que σ_2 représente le degré d'influence des différents indicateurs sur la variable d'activité du conducteur (DA). Les paramètres du modèle σ_1 et σ_2 sont utilisés comme dans [Nguyen et al., 2017]. À partir des équations (3.1), (3.2) et (3.4), la variable DA représentant l'activité du conducteur dans les trois régions de fonctionnement peut être exprimée comme suit :

$$DA = \frac{1}{3} (DA_U + DA_N + DA_O) \quad (3.5)$$

La continuité de (3.5) est assurée par la charge mentale (\mathcal{DS} , \mathcal{HD}), qui est commune aux trois régions. L'activité du conducteur est divisée en trois catégories ("Sous-charge" (DA_U), "Charge normale" (DA_N) et "Surcharge" (DA_O)). Les indicateurs de charge mentale (\mathcal{DS} , \mathcal{HD}) sont utilisés pour caractériser la (DA_U) et la (DA_N). En plus de ceux-ci, l'indicateur physique \mathcal{T}_{dN} est utilisé pour caractériser la (DA_N). Dans le cas de la "Surcharge", l'activité du conducteur est caractérisée par les indicateurs de charge mentale (\mathcal{DS} , \mathcal{HD}) et l'indicateur de risque $Risk$. L'activité globale du conducteur, notée DA , est calculée dans l'équation (3.5) comme une moyenne des trois variables DA_U , DA_N et DA_O . La considération de la moyenne de ces valeurs de DA crée une métrique composite qui tient compte de divers scénarios de conduite et atténue les fluctuations potentielles ou les valeurs aberrantes dans les sorties individuelles des expressions. Pour récapituler, le tableau 3.1 illustre la disponibilité des différents indicateurs d'activité du conducteur dans les trois régions :

La Figure 3.7 montre l'évolution de l'activité du conducteur dans les trois régions dans différentes situations en fonction des différents indicateurs (\mathcal{DS} , \mathcal{HD} , \mathcal{T}_{dN} , $Risk$).

TABLE 3.1 – La disponibilité des différents indicateurs d’activité du conducteur dans les trois régions.

| Activité du Conducteur / Indicateurs | DS | HD | \mathcal{T}_{dN} | $Risk$ |
|--------------------------------------|------|------|--------------------|--------|
| DA_U | ✓ | ✓ | – | – |
| DA_N | ✓ | ✓ | ✓ | – |
| DA_O | ✓ | ✓ | – | ✓ |
| DA | ✓ | ✓ | ✓ | ✓ |




FIGURE 3.7 – Variation de l’activité du conducteur en fonction de la charge mentale (DS , HD), de la charge physique \mathcal{T}_{dN} ainsi que du risque.

- Lorsque le système de surveillance du conducteur indique que le conducteur n’est pas disponible ($DS = 0$), cela signifie que le conducteur n’est pas en état d’intervenir dans la tâche de conduite. Par conséquent, la DA est nulle entre 0 et 10 secondes.
- Lorsque le conducteur est disponible ($DS = 1$) et qu’il a les mains sur le volant ($HD = 1$), mais qu’il ne fait pas d’effort physique (c’est-à-dire que $\mathcal{T}_{dN} = 0$), la DA varie dans la plage de la région ”Sous-charge” entre 10 et 20 secondes. Cela signifie que le conducteur est dans un état de faible activité, ce qui peut être considéré comme normal dans certaines situations de conduite.
- Lorsque le conducteur est disponible ($DS = 1$) et qu’il a les mains sur le volant ($HD = 1$), et que la situation de conduite est considérée comme non risquée ($Risk = 0$), et qu’il est physiquement actif, la DA varie dans la plage de la région ”Charge normale” entre 21 et 35 secondes. Cela signifie que le conducteur est dans un état d’activité normale, qui est considéré comme souhaitable en conduite manuelle ou partagée.
- Enfin, lorsque le conducteur est disponible ($DS = 1$) et qu’il a les mains sur le volant ($HD = 1$), et que la situation de conduite est considérée comme risquée ($Risk \neq 0$), la DA varie dans la plage de la région ”Surcharge” entre 35 et 50 secondes. Cela signifie que le

conducteur est dans un état d'activité élevé, qui peut être considéré comme souhaitable dans certaines situations de conduite à risque, mais qui peut également entraîner une fatigue mentale si elle est maintenue pendant une longue période.

3.4.2 Niveau d'assistance dynamique

En utilisant la DA de la relation (3.5), et en fixant les valeurs des paramètres λ_1 , λ_2 et λ_3 à 3.6, 0.5 et 0.1 respectivement, le niveau d'assistance ρ fourni par le superviseur de conduite est calculé en utilisant la formule suivante :

$$\rho = (\lambda_1 \cdot DA_U \cdot (DA - \lambda_2)^2 + \lambda_3) + (1 - DA_U) \quad (3.6)$$

Les paramètres de ρ dans l'équation (3.6) sont choisis de manière à représenter la fonction en forme de U qui caractérise le besoin d'assistance du conducteur, comme illustré dans la Figure 3.5. Le niveau maximal d'assistance $\rho_{max} = 1$ correspond aux situations où l'activité du conducteur est soit $DA=0$, soit $DA=1$. En revanche, un niveau minimal d'assistance, fixé à $\rho_{min} = 0.1$, est nécessaire pour éviter les conflits entre le conducteur et le système d'automatisation lorsque l'activité du conducteur est $DA=0.5$.

Le niveau d'assistance est conditionné aussi par l'activité du conducteur dans la région "Sous-charge" (DA_U). Le but de cette condition est de donner l'autorité au système si le conducteur est hors de la boucle de conduite. Dans le cas où le conducteur est dans la boucle de conduite, l'autorité est partagée entre le système et le conducteur en fonction de DA pour minimiser le conflit, ce qui conduit à la minimisation de la charge physique de direction du conducteur. Lorsque l'action de direction du conducteur conduit à une situation de conduite risquée, la DA est déplacée vers la région de "surcharge" et l'autorité est donc donnée au système.

3.5 Modélisation de la dynamique du système Véhicule-Route

La conception du contrôleur intégrant le conducteur dans la boucle pour le contrôle coopératif est effectué dans ce travail pour le maintien de voie, l'évitement d'obstacles et les manœuvres de changement de voie. Pour une conception efficace du contrôleur coopératif, le modèle intégré Véhicule-Route est discuté dans cette section.

3.5.1 Le système Véhicule-Route

Le modèle bicyclette est un modèle simplifié couramment utilisé pour représenter les mouvements latéral et de lacet d'un véhicule (Figure 3.8). Il est largement utilisé dans la conception et la simulation de systèmes de contrôle de véhicules, tels que les systèmes de contrôle de la stabilité latérale des véhicules, de suivi de trajectoires et de la direction assistée [Rajamani, 2011].

Pour la conduite sur autoroute, il est commun de formuler deux hypothèses afin de simplifier le modèle :

1. La route est considérée comme plane et uniforme, sans dévers ni pente.
2. Le mouvement de translation se réduit à deux degrés de liberté : le mouvement vertical est négligé, et seuls les mouvements longitudinal et latéral sont pris en compte.
3. L'angle de braquage (δ) est petit.

Les forces latérales des pneus sont essentielles pour modéliser les mouvements latéral et de lacet du véhicule. Ces forces dépendent des propriétés des pneus et des caractéristiques de la surface de la route. En utilisant le modèle bicyclette, la dynamique latérale du véhicule résultante de l'interaction entre les pneus et la surface de la route peut être représentée. Les forces latérales générées par les pneumatiques d'un véhicule automobile peuvent être exprimées comme suit :




FIGURE 3.8 – La représentation du modèle de bicyclette.

$$F_{yf} = 2C_f\alpha_f, \quad F_{yr} = 2C_r\alpha_r$$

où α_f et α_r sont les angles de dérive latérale des pneumatiques avant et arrière respectivement et C_f et C_r sont les raideurs latérales des pneus avant et arrière respectivement.

Les angles de dérive latérale des pneumatiques avant et arrière sont donnés comme suit :

$$\alpha_f = \delta - \beta - \frac{l_f r}{v_x}, \quad \alpha_r = \frac{l_r r}{v_x} - \beta$$

où δ est l'angle de braquage, v_x est la vitesses longitudinale, r est la vitesse de lacet du véhicule, β est l'angle de dérive au centre de gravité, l_f et l_r sont les distances entre le centre de gravité du véhicule et l'essieu avant et arrière respectivement.

Les dynamiques des mouvements latéral et de lacet peuvent alors être exprimées comme suit [Sentouh et al., 2018] :

$$\begin{cases} \dot{\beta} = -\frac{2(C_f+C_r)}{mv_x}\beta + \left(\frac{2(C_rl_r-C_fl_f)}{mv_x^2} - 1\right)r + \frac{2C_f}{mv_x}\delta + \frac{1}{mv_x}f_w \\ \dot{r} = \frac{2(C_rl_r-C_fl_f)}{I_z}\beta + \frac{-2(C_rl_r^2+C_fl_f^2)}{v_x I_z}r + \frac{2C_fl_f}{I_z}\delta + \frac{l_w}{I_z}f_w \end{cases} \quad (3.7)$$

où m est la masse du véhicule, I_z est le moment d'inertie vertical du véhicule, et f_w est la force latérale du vent ayant pour centre d'impact une distance l_w du centre de gravité.

Pour le suivi de voie, l'erreur de position du véhicule par rapport au centre de voie y_L et l'erreur de cap ψ_L à une distance devant le véhicule l_s sont pris en compte dans la conception du contrôle. Les dynamiques de ces variables sont données comme suit [Sentouh et al., 2018] :

$$\begin{cases} \dot{\psi}_L = r - \rho_c v_x \\ \dot{y}_L = \beta v_x + l_s r + \psi_L v_x \end{cases} \quad (3.8)$$

où ρ_c est la courbure de la route.

Pour représenter l'interaction haptique entre le conducteur humain et le véhicule, la dynamique de la colonne de direction est représentée comme suit [Sentouh et al., 2018] :

$$J_s \ddot{\delta}_d = -B_s \dot{\delta}_d + T_d + T_a - T_s \quad (3.9)$$

où δ_d est l'angle de braquage au volant, J_s est le moment d'inertie équivalent du système de direction, et B_s est son coefficient d'amortissement équivalent. T_d est le couple de commande du conducteur, et T_a est le couple de commande du système d'assistance.

Le couple d'auto-alignement T_s est exprimé comme suit :

$$T_s = \frac{-2C_f \eta_t}{R_s} \beta + \frac{-2l_f C_f \eta_t}{R_s v_x} r + \frac{2C_f \eta_t}{R_s^2} \delta$$

où η_t est la largeur de contact du pneu. R_s est le rapport de réduction entre l'angle de braquage au volant δ_d et l'angle de braquage des roues avant δ . Dans cette représentation, l'action du conducteur représentée par son couple T_d est considérée comme une entrée connue du système.

À partir des dynamiques (3.7), (3.8) et (3.9), le modèle véhicule-route peut être formulé comme suit :

$$\dot{x} = Ax + Bu + Ed \quad (3.10)$$

où $x = [\beta \ r \ \psi_L \ y_L \ \delta_d \ \dot{\delta}_d]^T$ est le vecteur d'état, $u = T_c = T_a + T_d$ est l'entrée de contrôle, $d = [f_w, \rho_c]$ est le vecteur de perturbations, et

$$A = \begin{bmatrix} a_{11} & a_{12} & 0 & 0 & a_{15} & 0 \\ a_{21} & a_{22} & 0 & 0 & a_{25} & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ v_x & l_s & v_x & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ a_{61} & a_{62} & 0 & 0 & a_{65} & a_{66} \end{bmatrix},$$

$$B = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & b_6 \end{bmatrix}^T,$$

$$E = \begin{bmatrix} e_1 & e_2 & 0 & 0 & 0 & 0 \\ 0 & 0 & -v_x & 0 & 0 & 0 \end{bmatrix}^T.$$

avec :

$$a_{11} = -\frac{2(C_f + C_r)}{m v_x}, \quad a_{12} = \frac{2(C_r l_r - C_f l_f)}{m v_x^2} - 1, \quad a_{15} = \frac{2C_f}{m v_x R_s}, \quad a_{21} = \frac{2(C_r l_r - C_f l_f)}{I_z},$$

$$a_{22} = -\frac{2(C_r l_r^2 + C_f l_f^2)}{v_x I_z}, \quad a_{25} = \frac{2C_f l_f}{I_z R_s}, \quad a_{61} = \frac{2C_f \eta_t}{J_s R_s}, \quad a_{62} = \frac{2C_f l_f \eta_t}{v_x J_s R_s},$$

$$a_{65} = -\frac{2C_f \eta_t}{J_s R_s^2}, \quad a_{66} = -\frac{B_s}{J_s}, \quad b_6 = \frac{1}{J_s}, \quad e_1 = \frac{1}{m v_x}, \quad e_2 = \frac{l_w}{I_z}$$

3.5.2 Validation du Modèle Véhicule-Route sur SHERPA

Pour exploiter le modèle de véhicule défini par l'équation (3.10) en vue de créer des contrôleurs adéquats à intégrer, il est impératif de s'assurer de la validité de ce modèle. À cet effet, une étape cruciale consiste à le valider en confrontant ses prédictions avec des mesures réelles obtenues grâce au simulateur dynamique SHERPA-LAMIH.

Ce modèle est soumis à des essais de validation. Plus précisément, il est soumis à l'influence du couple conducteur mesuré (comme illustré dans la Figure 3.10) lors de la simulation d'un parcours effectué sur la piste de Satory (comme montré dans la Figure 3.9). Cette reproduction du parcours dans le simulateur implique la mise en œuvre de phases d'accélération et de décélération soigneusement planifiées. Ces phases visent à solliciter le système de manière diversifiée, permettant ainsi de mettre en évidence ses différentes réponses et modes de fonctionnement.

Les résultats obtenus à partir de ces essais de validation sont présentés dans la Figure 3.10. Cette figure compare les prédictions du modèle avec les mesures réelles obtenues sur simulateur




FIGURE 3.9 – Le circuit d’essai situé à Satory et les paramètres de courbure associés à ses virages.

de conduite dans des situations de conduite réalistes. Les écarts entre les sorties du modèles et les mesures sont représentés dans la Figure 3.11, qui illustre bien la précision du modèle dans diverses situations.

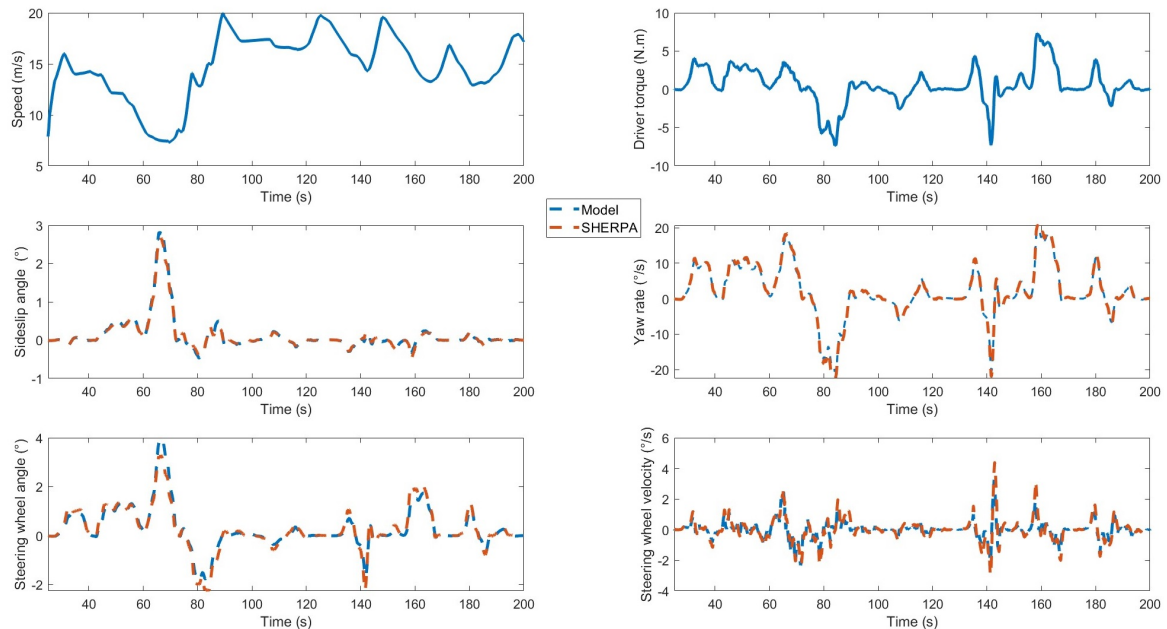


FIGURE 3.10 – Analyse comparative entre les sorties du modèle de véhicule proposé et les données recueillies sur SHERPA-LAMIH.

L’analyse de ces résultats met en lumière la capacité du modèle véhicule-route que nous avons sélectionné à reproduire, de manière fidèle, la dynamique latérale du véhicule. Cette concordance




FIGURE 3.11 – Écart entre les prédictions du modèle proposé et les données enregistrées sur SHERPA-LAMIH.

entre les prédictions du modèle et les comportements observés du véhicule témoigne de la qualité du modèle à capturer avec pertinence les caractéristiques globales de la dynamique latérale du véhicule. En conséquence, ce modèle validé peut être utilisé en toute confiance pour élaborer des lois de commande pour le maintien de voie du véhicule.

3.6 Préliminaires sur la modélisation TS et l'étude de leur stabilité

La théorie des ensembles flous a été annoncée par Lotfi Zadeh dans les années soixante [Zadeh, 1965] et constitue un puissant outil pour la représentation de classes d'objets physiques ambiguës. Cette approche découle de la capacité de l'homme à décider et à agir de manière intelligente en se basant sur ses compétences d'observation et sa tendance naturelle à catégoriser et classer les objets et les expériences. Dans le domaine de l'automatisation, elle a été introduite comme un outil permettant à un expert de mettre méthodiquement en œuvre ses connaissances et son expertise pour contrôler des systèmes physiques complexes ou difficiles à modéliser. Le premier article sur le contrôle flou a été publié en 1975 par [Mamdani and Assilian, 1975], jetant les bases et les principes de l'application de la logique floue à la conception de contrôle. L'application réussie du contrôle flou dans le métro de Sendai au Japon a rendu cette approche célèbre et a suscité l'intérêt de nombreux chercheurs, dont les contributions relatives à ce domaine continuent de croître à ce jour. L'un des avantages historiques de cette approche est qu'elle ne nécessite pas de modèle mathématique pour la conception du contrôle, ce qui la rend attrayante lorsque l'on traite des systèmes physiques difficiles à modéliser ou donnant des modèles mathématiques complexes [Takagi and Sugeno, 1985]. Cependant, la nature heuristique de l'approche est moins attrayante lorsqu'il s'agit d'applications pour lesquelles une certaine garantie de robustesse et une preuve de stabilité de la conception du contrôle sont cruciales. Pour rompre avec la nature heuristique de l'approche du contrôle flou, [Tanaka and Sugeno, 1992] ont proposé une approche alternative basée sur un modèle tout en conservant la même philosophie de la conception de la logique floue. L'approche résultante présentait une grande similitude dans

sa formulation mathématique avec les modèles à paramètres linéaires variant (LPV) [Sala et al., 2005], permettant l'utilisation d'outils théoriques de base du contrôle automatique tels que la théorie de Lyapunov et la formulation LMI (Linear Matrix Inequalities).

Au cours des dernières décennies, les modèles de Takagi-Sugeno (TS) ont été largement utilisés pour la représentation de systèmes non linéaires. Caractérisée par un ensemble de règles floues "If-Then" avec des parties conséquentes étant des représentations linéaires locales, l'approche de modélisation floue TS peut représenter un système non linéaire par une combinaison convexe de modèles linéaires [Tanaka et al., 1998, Sala and Arino, 2009]. La transition du modèle non linéaire à la représentation TS peut être effectuée par linéarisation autour de plusieurs points de fonctionnement [Johansen et al., 2000] ou l'utilisation de l'approche des secteurs non linéaires [Ohtake et al., 2003, Tanaka and Wang, 2004].

L'étude de la stabilité ou de la stabilisation des modèles TS repose généralement sur le choix d'une fonction de Lyapunov candidate. En imposant un comportement dissipatif à cette fonction, nous aboutissons souvent à des conditions de stabilité sous forme d'inégalités matricielles linéaires [Tanaka and Wang, 2004]. Une fois que ces conditions sont établies, des algorithmes d'optimisation convexe sont utilisés pour résoudre le problème semi-défini ainsi formulé [Gahinet et al., 1994, Boyd et al., 1994].

3.6.1 Préliminaires sur la modélisation TS

La modélisation Takagi-Sugeno est une méthode qui permet de représenter des systèmes dynamiques non linéaires en utilisant une somme de modèles locaux linéaires. Elle est particulièrement utile pour simplifier la représentation des systèmes complexes et non linéaires tout en préservant leur comportement global. La représentation d'un système dynamique non linéaire peut être exprimée sous forme du système d'équations suivant :

$$\begin{cases} \dot{x}(t) = A(z)x(t) + B(z)u(t) \\ y(t) = C(z)x(t) + D(z)u(t) \end{cases} \quad (3.11)$$

où $x(t) \in R^{n_x}$ est le vecteur d'état, $u(t) \in R^m$ est le vecteur d'entrée de contrôle, $y(t) \in R^{n_y}$ est le vecteur de sortie mesurée, $z(t) \in R^r$ est le vecteur de prémisse qui contient les paramètres variant (non-linéarités), qui peuvent dépendre ou non des variables d'état ou de perturbations externes. Les matrices $A(z) \in R^{n_x \times n_x}$, $B(z) \in R^{n_x \times m}$, $C(z) \in R^{n_y \times n_x}$, et $D(z) \in R^{n_y \times m}$ peuvent dépendre ou non de z . La variable z reste dans un ensemble compact \mathcal{D}_z de la forme :

$$\mathcal{D}_z = \{z \in R^r : \underline{z}_i \leq z_i \leq \bar{z}_i, i = 1, 2, \dots, r\} \quad (3.12)$$

où z_i représente la i -ème composante du vecteur z , et z_i , \bar{z}_i sont les bornes minimales et maximales respectivement. En utilisant l'approche des secteurs non linéaires [Wang and Tanaka, 2004], les termes dépendant de l'état z_i peuvent être réécrits de manière convexe pour $z \in \mathcal{D}_z$ comme suit :

$$z_i = w_i^0 \underline{z}_i + w_i^1 \bar{z}_i \quad (3.13)$$

$$w_i^0 = \frac{\bar{z}_i - z_i}{\bar{z}_i - \underline{z}_i}, w_i^1 = 1 - w_i^0 \quad (3.14)$$

Le système (3.11) est alors représenté par les $n_r = 2^r$ règles floues "If-Then" suivantes :

Rule_i : if (z_1 is M_{i_1}) and (z_2 is M_{i_2}) ... and (z_r is M_{i_r})

Then

$$\begin{cases} \dot{x}(t) = A_i x(t) + B_i u(t) \\ y(t) = C_i x(t) + D_i u(t) \end{cases} \quad (3.15)$$

où $A_i \in R^{n_x \times n_x}$, $B_i \in R^{n_x \times m}$, $C_i \in R^{n_y \times n_x}$, et $D_i \in R^{n_y \times m}$ sont les matrices constantes du i -ème sous-modèle linéaire. $M_{i_j} \in [0, 1]$ sont les fonctions d'appartenance des sous-ensembles flous des prémisses. L'interprétation des règles floues (*Rule_i*) dicte que l'opérateur « Et » est considéré comme un opérateur de produit. En conséquence, nous définissons pour chaque sous-modèle local (3.15) un niveau d'appartenance au modèle global en utilisant des fonctions d'appartenance normalisées (MFs) définies à partir de (3.14) de la manière suivante :

$$h_i(z) = \prod_{i=1}^r w_i^{i_p} \quad (3.16)$$

où l'indice $i_p \in \{0, 1\}$. En utilisant la somme pondérée pour le calcul du modèle TS global, le système non linéaire (3.15) peut être réécrit sous forme polytopique comme suit :

$$\begin{cases} \dot{x}(t) = \sum_{i=1}^{n_r} h_i(z) (A_i x(t) + B_i u(t)) \\ y(t) = \sum_{i=1}^{n_r} h_i(z) (C_i x(t) + D_i u(t)) \end{cases} \quad (3.17)$$

Notez que les fonctions d'appartenance vérifient la propriété de somme convexe :

$$0 \leq h_i(z) \leq 1, \quad \forall i \in I_{n_r}, \quad \sum_{i=1}^{n_r} h_i(z) = 1, \quad \forall z \in \mathcal{D}_z \quad (3.18)$$

Exemple : Considérons le modèle non linéaire suivant :

$$\dot{x}(t) = \begin{pmatrix} 0 & \cos^2(x_2) \\ -2 & \frac{1}{1+x_1^2} \end{pmatrix} x(t) + \begin{pmatrix} \cos^2(x_2) \\ 3 \end{pmatrix} u(t) \quad (3.19)$$

En considérant le vecteur $z = [z_1, z_2]$ comme prémisses, où :

$$z_1 = \cos^2(x_2), \quad z_2 = \frac{1}{1+x_1^2}$$

Notez que pour $x_1 \in [-1, 1]$ et $x_2 \in [-\pi, \pi]$, nous avons $z \in \mathcal{D}_z$ avec :

$$\mathcal{D}_z = \left\{ z \in R^2 : 0 \leq z_1 \leq 1, \quad 0.5 \leq z_2 \leq 1 \right\} \quad (3.20)$$

En utilisant l'approche des secteurs non linéaires [Wang and Tanaka, 2004], les termes dépendant de l'état z_i peuvent être réécrits de manière convexe pour $z \in \mathcal{D}_z$ comme suit :

$$\begin{aligned} z_1 &= w_1^0 \cdot 0 + w_1^1 \cdot 1 \\ z_2 &= w_2^0 \cdot 0.5 + w_2^1 \cdot 1 \end{aligned} \quad (3.21)$$

où :

$$\begin{aligned} w_1^0 &= 1 - z_1, \quad w_1^1 = z_1 \\ w_2^0 &= \frac{1-z_2}{0.5}, \quad w_2^1 = 1 - w_2^0 \end{aligned} \quad (3.22)$$

En triant toutes les combinaisons possibles, les fonctions d'appartenance normalisées sont obtenues conformément à l'équation (3.16) avec :

$$h_1 = w_1^0 \cdot w_2^0, \quad h_2 = w_1^1 \cdot w_2^0, \quad h_3 = w_1^0 \cdot w_2^1, \quad h_4 = w_1^1 \cdot w_2^1$$

Le système non linéaire (3.19) peut ensuite être représenté exactement par le modèle flou TS (3.17) avec $2^2 = 4$ sommets. À titre d'illustration, les matrices du modèle flou TS (3.17) sont données par :

$$\begin{aligned} A_1 &= \begin{pmatrix} 0 & 0 \\ -2 & 0.5 \end{pmatrix}, \quad A_2 = \begin{pmatrix} 0 & 1 \\ -2 & 0.5 \end{pmatrix}, \quad A_3 = \begin{pmatrix} 0 & 0 \\ -2 & 1 \end{pmatrix}, \quad A_4 = \begin{pmatrix} 0 & 1 \\ -2 & 1 \end{pmatrix}, \\ B_1 &= \begin{pmatrix} 0 \\ 3 \end{pmatrix}, \quad B_2 = \begin{pmatrix} 1 \\ 3 \end{pmatrix}, \quad B_3 = \begin{pmatrix} 0 \\ 3 \end{pmatrix}, \quad B_4 = \begin{pmatrix} 1 \\ 3 \end{pmatrix} \end{aligned}$$

3.6.2 Stabilité et stabilisation des systèmes TS

Comme évoqué précédemment, le modèle TS est une agrégation convexe de sous-systèmes linéaires. Il convient de souligner que la stabilité de l'ensemble global ne découle pas nécessairement de la stabilité de chaque sous-système individuellement [Tanaka et al., 1998]. Pour analyser la stabilité d'un modèle TS, la méthode de Lyapunov est couramment utilisée. Dans ce manuscrit, la fonction de Lyapunov adoptée a la forme suivante :

$$V(x) = x^T P x, \quad P > 0 \quad (3.23)$$

De plus, voici quelques lemmes utiles pour l'étude de la stabilité d'un modèle TS.

Lemme 1. [Boyd et al., 1994] : Considérons la matrice $M = \begin{bmatrix} M_{11} & M_{12} \\ M_{12}^T & M_{22} \end{bmatrix}$ avec M_{11} et M_{22} comme des matrices carrées. On peut énoncer :

$$M < 0 \Leftrightarrow \begin{cases} M_{11} < 0 \\ M_{11} - M_{12} M_{22}^{-1} M_{12}^T < 0 \end{cases} \Leftrightarrow \begin{cases} M_{22} < 0 \\ M_{22} - M_{12} M_{11}^{-1} M_{12}^T < 0 \end{cases} \quad (3.24)$$

Ces équivalences sont connues sous le nom de complément de Schur, et elles permettent de transformer une contrainte quadratique en une contrainte LMI.

Lemme 2. (Congruence) [Boyd et al., 1994] : Étant donnée une matrice $P = P^T$ et une matrice à rang complet Q , on peut affirmer que si $P > 0$, alors $QPQ^T > 0$.

Lemme 3. [Boyd et al., 1994] : Soit Υ_i des matrices de dimensions appropriées, alors la condition suivante doit être vérifiée pour chaque $i = 1, 2, \dots, n_r$:

$$\sum_{i=1}^{n_r} h_i \Upsilon_i < 0 \quad (3.25)$$

Cela signifie que $\Upsilon_i < 0$ pour tout $i = 1, 2, \dots, n_r$.

Lemme 4. [Boyd et al., 1994] : Soit Υ_{ij} des matrices de dimensions appropriées.

$$\sum_{i=1}^{n_r} \sum_{j=1}^{n_r} h_i h_j \Upsilon_{ij} < 0 \quad (3.26)$$

Pour que l'équation (3.26) soit satisfaite, les conditions suivantes doivent être remplies pour tout $i = 1, 2, \dots, n_r$, $j = 1, 2, \dots, n_r$, et $i \neq j$:

$$\begin{aligned} \Upsilon_{ij} &< 0 \\ \frac{2}{n_r-1} \Upsilon_{ii} + \Upsilon_{ij} + \Upsilon_{ji} &< 0 \end{aligned} \quad (3.27)$$

3.6.2.1 Stabilité d'un modèle TS

Considérons le système autonome TS suivant :

$$\dot{x}(t) = \sum_{i=1}^{n_r} h_i A_i x(t) \quad (3.28)$$

Le modèle TS non commandé (3.28) est quadratiquement stable si la fonction de Lyapunov (3.23) décroît et tend vers zéro lorsque $t \rightarrow \infty$ pour toutes les trajectoires $x(t)$. La dérivée de (3.23) le long des trajectoires du modèle non commandé (3.28) est :

$$\dot{V}(x) = x^T \left(\left(\sum_{i=1}^{n_r} h_i A_i^T \right) P \right) x + x^T \left(P \left(\sum_{i=1}^{n_r} h_i A_i \right) \right) x \quad (3.29)$$

Le théorème suivant énonce les conditions de stabilité des systèmes en boucle ouverte obtenues à partir de la théorie de la stabilité de Lyapunov :

Théorème : Le système flou continu (3.28) avec $u(t) = 0$ est globalement asymptotiquement stable s'il existe une matrice P définie positive commune telle que le problème LMI suivant soit réalisable :

$$A_i^T P + P A_i < 0, \quad i = 1, 2, \dots, n_r \quad (3.30)$$

Cela signifie qu'une matrice P commune doit exister pour tous les sous-systèmes.

3.6.2.2 Stabilisation d'un modèle TS

Pour stabiliser un système TS en utilisant une rétroaction d'état, plusieurs lois de commande peuvent être utilisées, parmi lesquelles la rétroaction linéaire $u = Kx$. Une solution plus générale est le schéma de commande PDC (Parallel Distributed Compensation) [Wang et al., 1996]. Le PDC est composé de rétroactions d'état linéaires combinées en utilisant les fonctions non linéaires $h_i(z)$ du modèle.

$$u = \sum_{i=1}^{n_r} h_i(z) K_i x \quad (3.31)$$

En conséquence, en introduisant l'équation (3.31) dans le modèle TS (3.17), on obtient la boucle fermée suivante :

$$\dot{x} = \sum_{i=1}^{n_r} h_i(z) \left(A_i + B_i \sum_{j=1}^{n_r} h_j(z) K_j \right) x \quad (3.32)$$

Finalement, le système en boucle fermée est composé de n_r^2 modèles linéaires :

$$\dot{x} = \sum_{i=1}^{n_r} \sum_{j=1}^{n_r} h_i(z) h_j(z) (A_i + B_i K_j) x \quad (3.33)$$

Poursuivant avec la stabilité quadratique, (3.23) donne pour la dérivée de la fonction de Lyapunov le long des trajectoires de (3.33) :

$$\dot{V}(x) = \sum_{i=1}^{n_r} \sum_{j=1}^{n_r} h_i(z) h_j(z) x^T (A_i + B_i K_j)^T P + P (A_i + B_i K_j) x \quad (3.34)$$

Ainsi, $\dot{V}(x) < 0$ est assuré si :

$$\sum_{i=1}^{n_r} \sum_{j=1}^{n_r} h_i(z) h_j(z) x^T \left(A_i^T P + P A_i + P B_i K_j + K_j^T B_i^T P \right) x < 0 \quad (3.35)$$

Il convient également de noter que, en raison de la quantité $P B_i K_j$, cette expression n'est pas une LMI. Pour l'exprimer avec des conditions LMI, le changement de variables suivant peut être effectué : $X = P^{-1}$, $M_i = K_i X$, pour $i = 1, 2, \dots, n_r$, et avec la propriété de congruence par rapport à la matrice de rang complet X , (3.35) est équivalente à :

$$\sum_{i=1}^{n_r} \sum_{j=1}^{n_r} h_i(z) h_j(z) \left(X A_i^T + A_i X + B_i M_j + M_j^T B_i^T \right) < 0 \quad (3.36)$$

Théorème : Le modèle TS continu (3.32) avec la loi de commande PDC (3.31) est globalement asymptotiquement stable (GAS) s'il existe des matrices $X > 0$, et M_i , $i = 1, 2, \dots, n_r$, telles que, avec Υ_{ij} défini comme $\Upsilon_{ij} = X A_i^T + A_i X + M_j^T B_i + B_i M_j$, les conditions de (3.27) sont satisfaites. De plus, si les conditions sont remplies, les gains PDC sont :

$$K_i = M_i X^{-1}, \quad i = 1, 2, \dots, n_r \quad (3.37)$$

Notez que dans le cas où $B_i = B$ pour $i = 1, 2, \dots, n_r$, alors l'inégalité (3.36) est équivalente à :

$$\sum_{i=1}^{n_r} h_i(z) \left(X A_i^T + A_i X + B M_i + M_i^T B^T \right) < 0 \quad (3.38)$$

3.7 La conception du contrôleur partagé adaptatif LPV-TS

Pour faire face aux non-linéarités liées à la variation en temps réel de la vitesse du véhicule et du niveau d'assistance, la forme floue T-S est utilisée pour la conception du contrôleur. Les conditions de conception sont formulées en termes de contraintes d'inégalités matricielles linéaires (LMI), ce qui permet de minimiser la fonction de coût par le biais d'une optimisation convexe.

En résumé, cette section décrit la conception du contrôleur partagé adaptatif pour le système flou T-S de l'équation (3.10). Le problème de contrôle partagé est ensuite résolu à l'aide de contraintes LMI, suivi d'une analyse de stabilité dans la dernière partie.

3.7.1 Représentation TS du Modèle Véhicule-Route

Il est à noter que les matrices A et E dans (3.10) dépendent des termes mesurés, identifiés et bornés suivants :

$$\left\{ v_x, \frac{1}{v_x}, \frac{1}{v_x^2} \right\}$$

$$v_{\min} \leq v_x \leq v_{\max}$$

Dans le but de réduire la complexité et le caractère conservatif de la méthode de contrôle proposée dans [Wang and Tanaka, 2004], un changement de paramètre est effectué. Bien qu'un modèle T-S flou exact des dynamiques du véhicule (3.10) puisse être obtenu avec 8 sous-systèmes linéaires, cela entraîne une charge numérique importante pour une implémentation en temps réel et des résultats de contrôle conservatifs. Par conséquent, une approche basée sur le développement de Taylor est utilisé pour simplifier la représentation TS.

Le changement de paramètre réduit le nombre de sous-systèmes et la charge de calcul, sans sacrifier la précision des résultats de contrôle. Cette approche a montré son efficacité pour améliorer les performances du système de contrôle et réduire le caractère conservatif des résultats de contrôle. En utilisant l'approche des secteurs non-linéaires, la méthode de contrôle proposée est capable d'atteindre le niveau de performance de contrôle souhaité avec une complexité de calcul significativement réduite.

$$\frac{1}{v_x} = \frac{1}{v_0} + \frac{1}{v_1} \alpha, \quad \alpha_{v_{\min}} \leq \alpha \leq \alpha_{v_{\max}} \quad (3.39)$$

$$\text{avec : } v_0 = \frac{2v_{\min}v_{\max}}{v_{\min}+v_{\max}}, \quad v_1 = \frac{2v_{\min}v_{\max}}{v_{\min}-v_{\max}}.$$

De (3.39), nous obtenons :

$$v_x = v_0 \left(1 + \frac{v_0}{v_1} \alpha \right)^{-1}, \quad \frac{1}{v_x^2} = \frac{1}{v_0^2} \left(1 + \frac{v_0}{v_1} \alpha \right)^2$$

Notez que le nouveau paramètre α peut être utilisé pour représenter la variation de v_x entre ses bornes inférieure et supérieure, c'est-à-dire $\alpha_{v_{\min}} = -1$ et $\alpha_{v_{\max}} = 1$. Ensuite, une approximation

de la série de Taylor du premier ordre est utilisée pour exploiter la forte relation entre les termes dépendant de la vitesse :

$$v_x \approx v_0(1 - \frac{v_0}{v_1}\alpha), \quad \frac{1}{v_x^2} \approx \frac{1}{v_0^2}(1 + 2\frac{v_0}{v_1}\alpha) \quad (3.40)$$

Remarquons que v_x , $\frac{1}{v_x}$ et $\frac{1}{v_x^2}$ dans (3.39)-(3.40) dépendent linéairement du nouveau paramètre α . En substituant ces expressions dans (3.10), nous obtenons un modèle de véhicule dont les matrices d'espace d'état ne dépendent que du paramètre variant $\{\alpha\}$. En utilisant l'approche des secteurs non linéaires [Wang and Tanaka, 2004], on obtient la représentation T-S floue à 2 règles suivante à partir de (3.10) :

$$\sum_{\alpha} : \left\{ \dot{x} = \sum_{i=1}^2 h_i(\alpha)(A_i x + E_i d) + Bu \right. \quad (3.41)$$

où les matrices d'espace d'état des deux sous-modèles linéaires sont données par :

$$\begin{aligned} \sum_{\alpha_1} : A(\alpha_{v_{\min}}), \quad B, \quad E(\alpha_{v_{\min}}), \\ \sum_{\alpha_2} : A(\alpha_{v_{\max}}), \quad B, \quad E(\alpha_{v_{\max}}) \end{aligned} \quad (3.42)$$

Les fonctions d'appartenance vérifiant les propriétés de sommes convexes sont représentées comme suit :

$$h_1(\alpha) = \frac{1 - \alpha}{2}, \quad h_2(\alpha) = 1 - h_1(\alpha) \quad (3.43)$$

3.7.1.1 Validation du modèle TS sur SHERPA

Le processus de validation du modèle TS (3.41) en utilisant le simulateur SHERPA-LAMIH suit les mêmes étapes que celles appliquées pour valider le modèle de véhicule dans la section précédente (3.5.2). Pour ce faire, les entrées du modèle TS sont constituées de la vitesse longitudinale du véhicule ainsi que du couple généré par le conducteur mesuré sur le volant. Ces deux variables sont essentielles pour simuler le comportement du véhicule.

Les résultats obtenus de cette phase de validation sont présentés dans la Figure 3.12.

Cette figure expose la comparaison entre les prédictions du modèle TS et les données réelles mesurées sur le simulateur. Les courbes superposées permettent d'évaluer la représentation TS du modèle véhicule-route par rapport au comportement réel du véhicule simulé par le simulateur SHERPA.

Pour évaluer plus précisément la performance du modèle TS, les erreurs de validation sont détaillées dans la Figure 3.13. Cette représentation met en évidence les écarts entre les prédictions du modèle et les valeurs mesurées, contribuant ainsi à une meilleure compréhension de la précision du modèle.

En examinant ces résultats, il est clair que le modèle TS reproduit fidèlement la dynamique du modèle de véhicule utilisé dans simulateur SHERPA-LAMIH.

Ce modèle TS sera employé pour élaborer un contrôleur optimal LPV adaptatif pour le contrôle partagé de la direction du véhicule tout en minimisant les conflits potentiels entre les actions du conducteur au volant et celles du LKS.

3.7.2 Conception du contrôleur partagé basée sur l'approche PDC

Tout d'abord, le vecteur de performance du système TS (3.41), qui représente la performance en termes de maintien de voie et de confort est défini comme suit :

$$z = \mathcal{C}x = \left[\beta \quad r \quad \psi_L \quad y_L \quad \dot{\delta}_d \right]^T \quad (3.44)$$

Dans ce travail, nous proposons une solution de contrôle qui a pour objectif de minimiser la fonction de coût suivante :

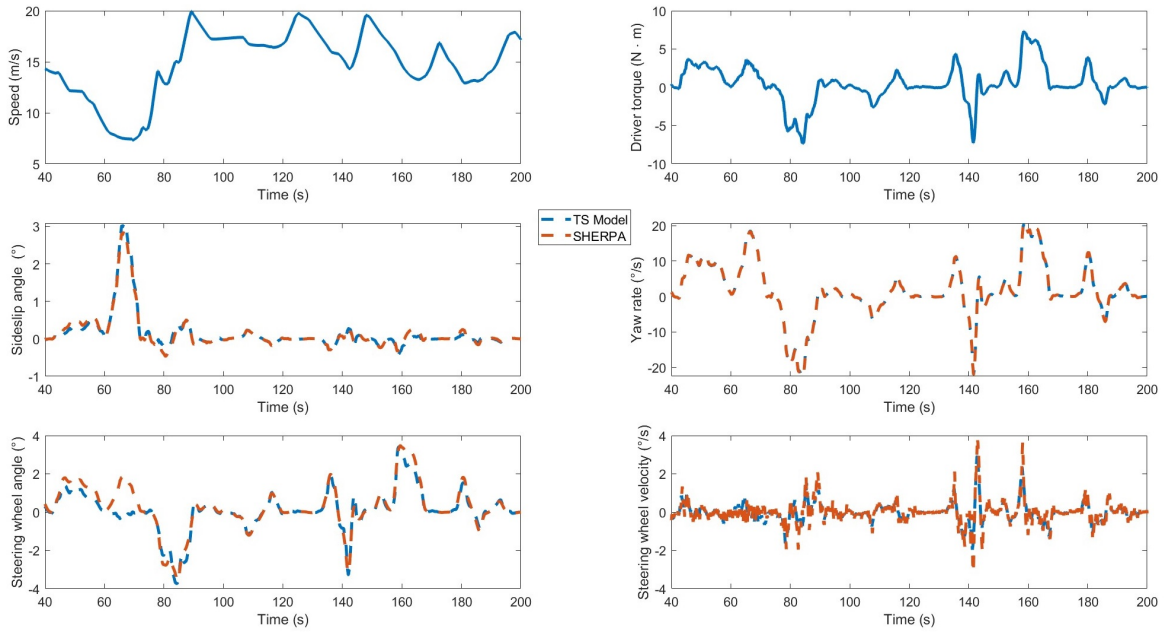


FIGURE 3.12 – Analyse comparative entre les sorties du modèle TS de véhicule proposé et les données recueillies sur SHERPA-LAMIH.




FIGURE 3.13 – Écart entre les prédictions du modèle TS proposé et les données enregistrées sur SHERPA-LAMIH.

$$\mathcal{J}(\rho) = \int_0^{\infty} (z^T(\tau)\rho Q z(\tau) + u^T(\tau)\mathcal{R}u(\tau))d\tau \quad (3.45)$$

où $Q = W^T W \succ 0$ et $\mathcal{R} \succ 0$ sont les matrices de pondération.

Étant donné que $\rho \in [0, 1]$, nous pouvons effectuer la décomposition suivante :

$$\rho \mathcal{Q} = \left(\sum_{j=1}^2 g_j(\rho) \mathcal{W}_j \right)^T \left(\sum_{j=1}^2 g_j(\rho) \mathcal{W}_j \right) \quad (3.46)$$

avec :

$$g_1(\rho) = \sqrt{\rho}, \quad g_2(\rho) = 1 - g_1(\rho), \quad \mathcal{W}_1 = \mathcal{W}, \quad \mathcal{W}_2 = 0.$$

Remarque : Inspiré par le principe bien connu d'un régulateur linéaire quadratique (LQR), nous pouvons voir dans l'équation (3.45) que lorsque l'autorité de contrôle est entièrement confiée au système de maintien de voie (LKS), c'est-à-dire lorsque $\rho = 1$, l'action de contrôle T_a est conçue pour obtenir les meilleures performances de maintien de voie en pénalisant principalement le terme lié aux performances de suivi de voie, c'est-à-dire $z^\top(\tau) \rho \mathcal{Q} z(\tau)$. En revanche, lorsque l'autorité de contrôle est entièrement attribuée au conducteur humain, c'est-à-dire lorsque $\rho = 0$, une action de contrôle minimale T_a est conçue pour minimiser $\mathcal{J}(\rho)$ en pénalisant le terme lié à l'effort de contrôle, c'est-à-dire $u^\top(\tau) \mathcal{R} u(\tau)$. Ainsi, l'intégration du paramètre variant dans le temps ρ dans la fonction de coût $\mathcal{J}(\rho)$ permet d'équilibrer de manière adaptative l'autorité de contrôle entre le conducteur humain et le système de maintien de voie en fonction de la situation de conduite et des besoins spécifiques d'assistance du conducteur, sans pondération directe de l'entrée de contrôle comme dans la plupart des travaux connexes existants sur le partage de contrôle entre conducteur et système automatisé [Marcano et al., 2020]. Cela peut contribuer à améliorer la sécurité et le confort de conduite tout en évitant les conflits entre l'humain et la machine.

Pour la conception de la commande, nous considérons le contrôleur PDC (Parallel Distributed Compensation) à retour d'état dépendant des paramètres α et ρ donné par :

$$u = \sum_{i=1}^2 \sum_{j=1}^2 h_i(\alpha) g_j(\rho) \mathcal{K}_{ij} x \quad (3.47)$$

où les gains de contrôle \mathcal{K}_{ij} , $i, j \in 1, 2$, doivent être déterminés. En utilisant la loi de commande (3.47) et le modèle flou T-S (3.41), le système en boucle fermée peut être exprimé comme suit :

$$\sum_{\alpha \rho} : \left\{ \dot{x} = \sum_{i=1}^2 \sum_{j=1}^2 h_i(\alpha) g_j(\rho) ((A_i + B \mathcal{K}_{ij}) x + E_i d) \right. \quad (3.48)$$

Le résultat suivant fournit une solution de contrôle, dans laquelle notre analyse est effectuée en utilisant la fonction de Lyapunov suivante :

$$\mathcal{V}(x) = x^T \mathcal{P} x, \quad \mathcal{P} > 0 \quad (3.49)$$

Théorème 3.1. S'il existe un scalaire positif γ , ainsi qu'une matrice définie positive X , et des matrices \mathcal{N}_{ij} pour $i, j \in 1, 2$ qui résolvent le problème d'optimisation LMI suivant :

$$\begin{bmatrix} He(A_i X + B \mathcal{N}_{ij}) & E_i & X C^T \mathcal{W}_j^T & \mathcal{N}_{ij}^T \\ * & -\gamma I & 0 & 0 \\ * & * & -I & 0 \\ * & * & * & -\mathcal{R}^{-1} \end{bmatrix} \prec 0, \quad i, j \in \{1, 2\} \quad (3.50)$$

alors, le régulateur LPV (3.47) stabilise le système du véhicule (3.48) et garantit une borne supérieure pour la fonction de coût (3.45) sous condition initiale nulle, comme suit :

$$\mathcal{J}(\rho) < \gamma \|d\|^2. \quad (3.51)$$

De plus, les gains de rétroaction peuvent être calculés comme suit :

$$\mathcal{K}_{ij} = \mathcal{N}_{ij} X^{-1}, \quad i, j \in \{1, 2\} \quad (3.52)$$

3.7.3 Analyse de la stabilité

Dans cette sous-section, l'analyse de la stabilité de l'ensemble du système est présentée.

Preuve. En multipliant (3.50) avec $\sum_{i=1}^2 \sum_{j=1}^2 h_i(\alpha)g_j(\rho) \geq 0$, on obtient :

$$\sum_{i=1}^2 \sum_{j=1}^2 h_i(\alpha)g_j(\rho) \begin{bmatrix} He(A_i X + B N_{ij}) & E_i & X C^T W_j^T & \mathcal{N}_{ij}^T \\ * & -\gamma I & 0 & 0 \\ * & * & -I & 0 \\ * & * & * & -\mathcal{R}^{-1} \end{bmatrix} \prec 0 \quad (3.53)$$

Pour des raisons de concision, pour toutes les matrices de dimensions appropriées χ_i et μ_{ij} , $i, j \in 1, 2$, nous notons :

$$\chi(\alpha) = \sum_{i=1}^2 h_i(\alpha)\chi_i, \quad \mu(\alpha, \rho) = \sum_{i=1}^2 \sum_{j=1}^2 h_i(\alpha)g_j(\rho)\mu_{ij}, \quad He(X) = X + X^T$$

En appliquant le lemme du complément de Schur successif (SCL) [Boyd et al., 1994], nous obtenons l'inégalité équivalente à (3.53) où $\Gamma(\alpha, \rho) = He(A(\alpha)X + B\mathcal{N}(\alpha, \rho))$, $\nabla = X C^T \rho Q C X$:

$$\begin{bmatrix} \Gamma(\alpha, \rho) + \mathcal{N}(\alpha, \rho)^T \mathcal{R} \mathcal{N}(\alpha, \rho) + \nabla & E(\alpha) \\ * & -\gamma I \end{bmatrix} \prec 0 \quad (3.54)$$

où $\mathcal{P} = X^{-1}$ et $\mathcal{N}(\alpha, \rho) = \mathcal{K}(\alpha, \rho)X$, en pré et post-multipliant (3.54) avec $\begin{bmatrix} \mathcal{P} & 0 \\ 0 & I \end{bmatrix}$,

$$\begin{bmatrix} \partial(\alpha, \rho) + \mathcal{K}(\alpha, \rho)^T \mathcal{R} \mathcal{K}(\alpha, \rho) + C^T \rho Q C & \mathcal{P} E(\alpha) \\ * & -\gamma I \end{bmatrix} \prec 0 \quad (3.55)$$

où $\partial(\alpha, \rho) = He(\mathcal{P}(A(\alpha) + B\mathcal{K}(\alpha, \rho)))$. En pré et post-multipliant (3.55) avec $[x, d]^T$ et sa transposée, on obtient :

$$\dot{\mathcal{V}}(x) + z^T \rho Q z + u^T \mathcal{R} u < \gamma d^T d \quad (3.56)$$

où $\dot{\mathcal{V}}(x)$ représente la dérivation temporelle de la fonction candidate de Lyapunov (3.49) pour la trajectoire du système (3.48). À partir de (3.56), nous distinguons deux cas.

- $\dot{\mathcal{V}}(x) < 0$, $\forall x \neq 0$, pour un système avec une perturbation libre ($d = 0$), ce qui implique que le système en boucle fermée (3.48) est globalement exponentiellement stable.
- $\dot{\mathcal{V}}(x) < \gamma \|d\|^2$, dans le cas d'un système perturbé ($d \neq 0$). Alors, en intégrant les deux côtés de l'équation (3.56) de 0 à ∞ , on obtient :

$$\mathcal{V}(\infty) - \mathcal{V}(0) + \mathcal{J}(\rho) < \gamma \int_0^{\infty} d^T(t) d(t). \quad (3.57)$$

Puisque $\mathcal{V}(\infty) > 0$, sous condition initiale nulle, c'est-à-dire $\mathcal{V}(0) = 0$, il est clair que l'inégalité (3.57) implique l'inégalité (3.51). Notez également à partir de (3.51) que la fonction de coût adaptative $\mathcal{J}(\rho)$ peut être minimisée en minimisant γ .

Les conditions de conception de la commande selon le Théorème 3.1 sont formulées en termes de LMI (Inégalités Matricielles Linéaires), qui peuvent être efficacement résolues à l'aide de la boîte à outils YALMIP et du solveur SeDuMi [Löfberg, 2004].

3.8 Validation expérimentale

La section suivante présente des résultats illustratifs démontrant les performances du contrôleur partagé proposé en termes de maintien de voie et de minimisation des conflits, à l'aide d'expériences

interactives réalisées sur le simulateur de conduite dynamique SHERPA. Toutes les évaluations de performance sont effectuées sur une piste d’essai autoroutière à deux voies avec circulation à sens unique. Cette section est structurée en quatre sous-sections afin de fournir une vue d’ensemble plus complète du chapitre.

La première sous-section est consacrée à l’évaluation de la robustesse du contrôleur conçu pour le maintien de voie (LKS) en mode de conduite autonome, face aux variations de la vitesse du véhicule et aux perturbations externes.

La deuxième sous-section se consacre à la comparaison entre le contrôleur partagé proposé dans [Nguyen et al., 2017] (sans adaptation de la fonction de coût) et celui proposé dans ce chapitre.

La troisième sous-section présente un exemple concret démontrant comment le contrôleur proposé assure la sécurité du conducteur dans une situation risquée. Une situation de danger est simulée, et le contrôleur est évalué en fonction de sa capacité à réagir de manière appropriée pour éviter l’accident et préserver la sécurité du conducteur.

Enfin, dans la dernière partie, les résultats des expériences de test utilisateurs sont exposés. Une évaluation à la fois objective et subjective a été réalisée pour comparer le contrôleur partagé proposé dans [Nguyen et al., 2017] (sans adaptation de la fonction de coût) et celui proposé dans ce chapitre, en utilisant un scénario d’évitement d’obstacles. Les performances des deux contrôleurs sont comparées en termes d’efficacité, de réactivité et de sécurité. Cette évaluation permet de mettre en évidence les avantages et les améliorations apportées par le contrôleur proposé dans ce chapitre. Le tableau 3.2 récapitule les valeurs numériques des paramètres du modèle du véhicule.

TABLE 3.2 – Les valeurs numériques des paramètres du modèle du véhicule.

| Par. | Valeur | Unit | Par. | Valeur | Unit | Par. | Valeur | Unit |
|-------|--------|------|-------|----------|----------------|----------|----------|----------------|
| l_f | 1.3 | m | J_s | 0.05 | $kg \cdot m^2$ | I_z | 2800 | $kg \cdot m^2$ |
| l_r | 1.6 | m | C_f | 57000 | N/rad | ρ | [0 , 1] | – |
| l_w | 0.4 | m | C_r | 59000 | N/rad | m | 2024 | kg |
| l_s | 5 | m | R_s | 16 | – | η_t | 0.13 | m |
| B_s | 5.73 | – | v_x | [8 , 30] | m/s | α | [-1 , 1] | – |

3.8.1 Performance du contrôleur LKS en mode de conduite autonome

Sur le simulateur SHERPA, un test de robustesse du système de maintien de voie (LKS) est effectué en mode de conduite autonome pour des vitesses de véhicule variables. Les résultats du test sont présentés en détail dans la Figure 3.14. Il est clair que le LKS assure de bonnes performances, avec des erreurs maximales de déviation latérale et de cap de ($|y_L|_{max} = 0.6m$, $|\psi_L|_{max} = 0.37deg$), où la largeur de la voie est de $3.5m$.

Pour évaluer la robustesse du contrôleur face aux perturbations externes, un test de conduite automatique est réalisé en maintenant une vitesse constante de $v_x = 22m/s$, tandis que le véhicule est soumis à une force latérale de vent intense d’une magnitude de $1000N$. Les résultats de ce test sont illustrés en détail dans la Figure 3.15. Ils indiquent que le contrôleur réagit de manière adéquate à la perturbation, la rejetant efficacement. En conséquence, les erreurs maximales de déviation latérale et de cap sont mesurées à ($|y_L|_{max} = 0.98m$, $|\psi_L|_{max} = 0.41deg$).

3.8.2 Performance du contrôle partagé adaptatif

Dans cette sous-section, nous allons comparer le contrôleur partagé en utilisant deux approches : avec et sans la fonction de coût adaptative. Pour le test d’évitement d’obstacles, nous

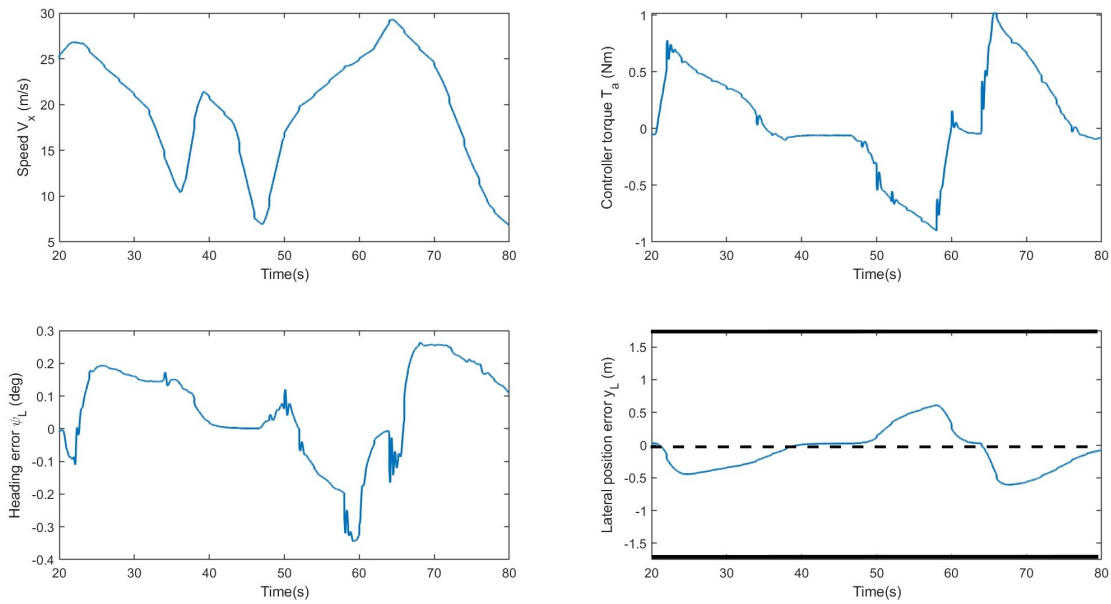


FIGURE 3.14 – Performances du système de maintien de voie (LKS) pour un scénario de vitesse variable.

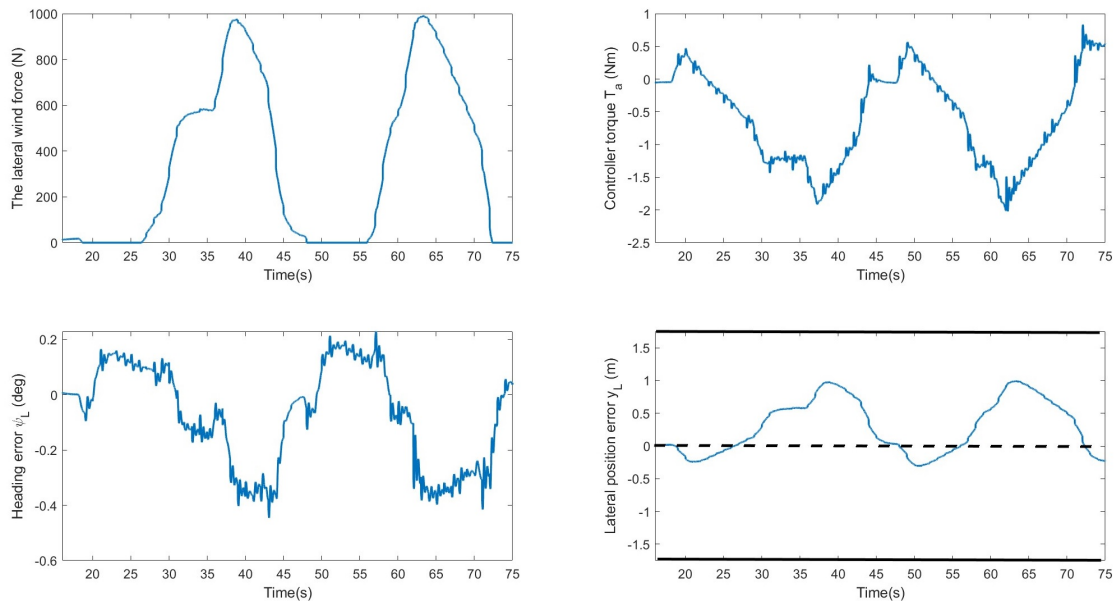


FIGURE 3.15 – Performance du système de maintien de voie (LKS) obtenue sur le simulateur SHERPA dans un scénario de perturbation due au vent latéral.

avons disposé trois obstacles et demandé au conducteur de les éviter en changeant de voie et en se rapprochant du centre de la voie adjacente (la voie de gauche), c'est-à-dire $y_{L_{ref}} \geq 3.5$, m.

Les résultats du test sont présentés dans la Figure 3.16. On peut observer que le conducteur a eu du mal à passer l'obstacle en utilisant le contrôleur sans adaptation, de sorte que la position latérale est inférieure à $y_{L_{ref}}$. Le couple de braquage du conducteur et celui du contrôleur sont élevés comparé au test réalisé avec le contrôleur intégrant la fonction de coût adaptative, où le conducteur a pu éviter l'obstacle facilement avec un couple de direction beaucoup plus faible.

Comme illustré dans la Figure 3.16, nous pouvons constater que l'adaptation du niveau

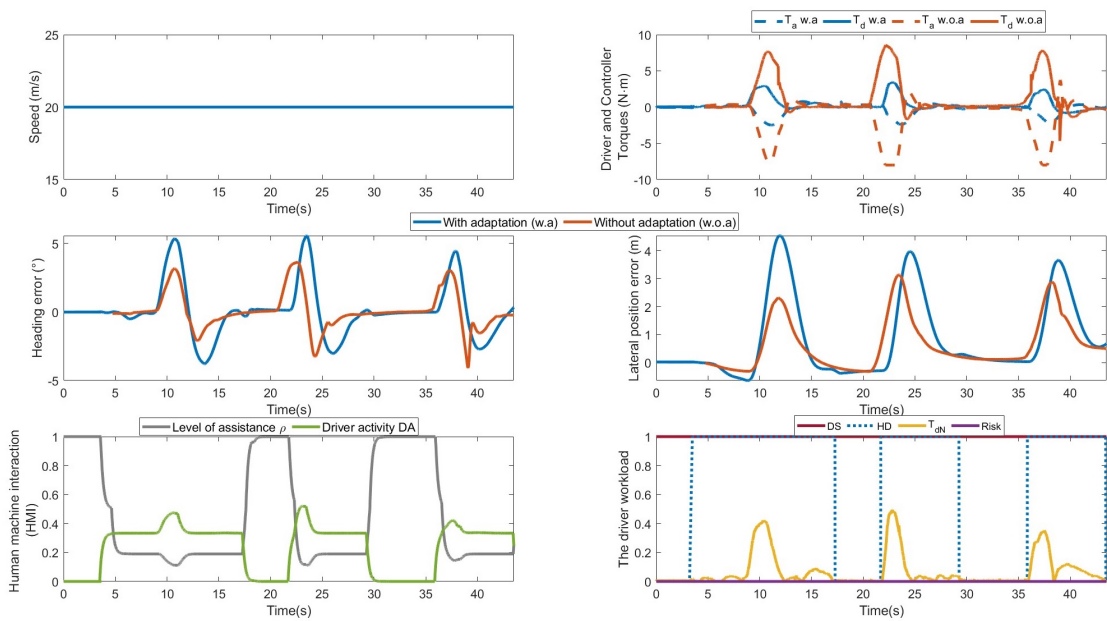


FIGURE 3.16 – Les performances du contrôleur partagé avec et sans la fonction de coût adaptative lors d’un test d’évitement d’obstacles sur le simulateur SHERPA.

d’assistance varie en fonction des exigences et de l’activité du conducteur. Selon ces résultats, le contrôleur conçu avec une fonction de coût adaptative proposée est plus efficace. Cela peut s’expliquer par le fait que l’objectif du contrôleur sans adaptation est fixe, c’est-à-dire qu’il a comme seul objectif le maintien de voie et rejette toute action du conducteur qu’il juge comme une perturbation, tandis que le contrôleur avec la fonction de coût adaptative est dynamique, il modifie l’objectif en fonction de la situation et des besoins du conducteur.

3.8.3 Prise en compte du risque dans le contrôle partagé adaptatif

Cette sous-section présente un scénario de dépassement à vitesse constante dans lequel le conducteur est en contrôle partagé et est chargé de dépasser deux véhicules. L’objectif est d’évaluer la capacité du contrôleur partagé à gérer des situations de dépassement sécurisées et risquées (voir la Figure 3.17) .




FIGURE 3.17 – Scénario de changement de voie risqué et non risqué.

Lors du premier dépassement (à $t = 29s$), il est constaté que le conducteur effectue facilement la manœuvre de dépassement et a le sentiment de contrôler la situation. Le degré d’assistance du contrôleur diminue progressivement, car l’activité du conducteur se situe dans la zone de charge normale. Cela signifie que le conducteur est capable de prendre en charge la conduite de manière autonome et que l’autorité de conduite est principalement donnée au conducteur lui-même.

Cependant, lors du deuxième dépassement (à $t = 61s$), une situation risquée se présente avec une voiture proche sur la voie de gauche, comme illustré dans la Figure 3.18. Dans cette situation, le conducteur est guidé par le contrôleur pour rester sur la voie actuelle ($y_l < 1m$) afin d'éviter un risque de collision. De plus, l'activité du conducteur augmente jusqu'à atteindre la zone de "Surcharge". Cela indique que le conducteur a besoin d'une assistance accrue pour éviter un accident potentiel avec le véhicule adjacent. Par conséquent, le niveau d'assistance du contrôleur est augmenté à sa valeur maximale ($\rho = 1$), donnant ainsi l'autorité de conduite principalement au système.

Une fois que le véhicule adjacent s'éloigne et que la situation redevienne sûre, le conducteur effectue le troisième dépassement (à $t = 72s$). Cette fois-ci, le dépassement se déroule sans risque, et le conducteur réussit à dépasser le deuxième véhicule facilement. Le niveau d'assistance du contrôleur est diminué, permettant au conducteur de reprendre le contrôle du véhicule. L'activité du conducteur revient à la zone de charge normale, indiquant qu'il est capable de gérer la conduite de manière autonome.

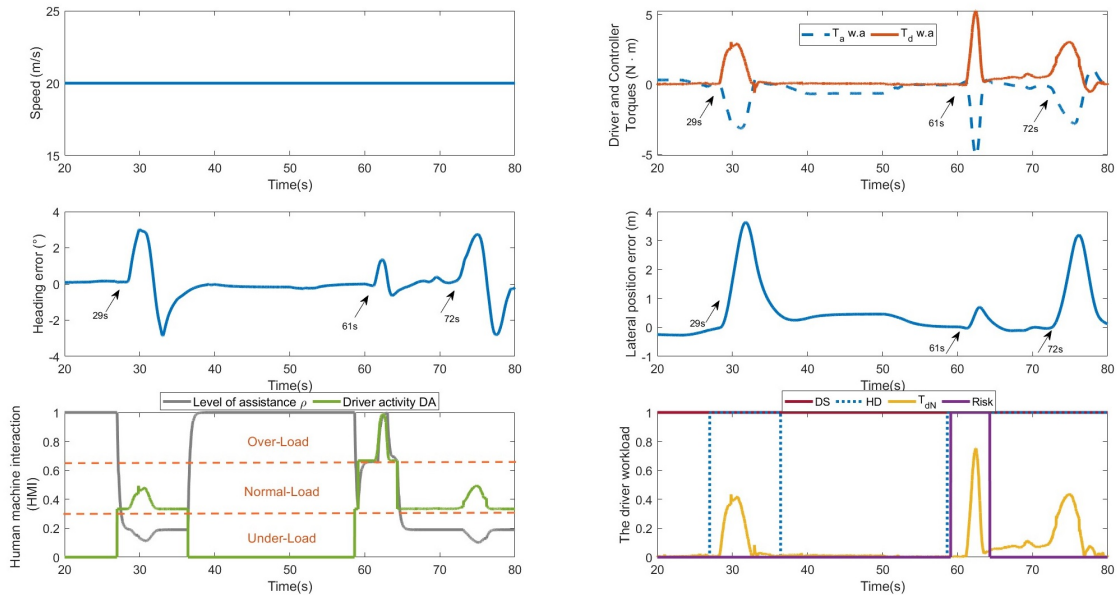


FIGURE 3.18 – Performances du contrôle partagé pour un scénario de changement de voie risqué et non risqué.

3.8.4 Expériences de test utilisateurs

Dans cette sous-section, une étude préliminaire a été menée pour évaluer l'approche proposée de contrôle partagé optimal adaptatif pour le système de maintien de voie coopératif, en termes de gestion des conflits et de l'autorité de contrôle. L'objectif de cette étude était également de recueillir des informations sur l'acceptabilité du conducteur à partir d'expériences de tests utilisateurs.

L'étude a été réalisée sur le simulateur SHERPA. Six participants ont pris part aux expériences préliminaires, dont 4 hommes et 2 femmes. L'âge moyen des participants était de 34 ± 9 ans, avec un kilométrage annuel moyen de 8500 km.

Dans cette expérience, un scénario d'évitement d'obstacles a été étudié. Le scénario se déroule sur une route droite à deux voies d'une longueur de 4 km. Les conducteurs ont reçu pour instructions de rester dans leur voie et de faire attention aux obstacles immobiles présents sur la route. L'objectif était d'évaluer la capacité des participants à changer de voie pour éviter les collisions.

Dans cette expérience, les participants ont conduit en utilisant trois stratégies différentes :

(i) Contrôle manuel "*Manuel*" : Les participants ont conduit en mode manuel, où ils étaient responsables de toutes les décisions de conduite et du changement de voie pour éviter les obstacles.

(ii) Système de maintien de voie classique [Nguyen et al., 2017] sans adaptation de la fonction de coût "*LKS_{WOA}*".

(iii) Système de maintien de voie adaptatif proposé intégrant l'approche dynamique de la fonction de coût "*LKS_{WA}*".

Après chaque phase de test, des questionnaires ont été fournis aux participants pour recueillir une évaluation subjective de leur expérience de conduite avec chaque stratégie.

L'analyse des données recueillies dans cette étude est divisée en deux parties, permettant d'examiner les performances objectives et l'acceptabilité subjective des différentes stratégies de conduite. Cela permettra d'évaluer l'efficacité de l'approche de contrôle partagé adaptatif proposée et de recueillir des retours intéressants sur l'expérience vécue par les conducteurs lors de l'évitement des obstacles.

3.8.4.1 Evaluation objective

Dans cette évaluation objective, plusieurs métriques ont été utilisées pour analyser l'interaction du conducteur avec le système de maintien de voie (LKS) et la qualité du contrôle partagé. Les quatre métriques suivantes ont été examinées dans cette étude, comme précédemment utilisées dans [Oudainia et al., 2022a, Oudainia et al., 2023] :

— L'effort de direction du conducteur (*StD*) représente la quantité d'effort physique exercée par le conducteur pour maintenir le véhicule dans la voie pendant la période expérimentale (T_{Ex}). Un calcul intégral est effectué pour obtenir cette métrique en fonction du couple de direction du conducteur au fil du temps :

$$StD = \int_{T_{Ex}} T_d^2(\tau) d\tau \quad (3.58)$$

— L'effort de direction du système (*StC*) mesure l'effort physique exercé par le système de maintien de voie pour maintenir le véhicule dans la voie pendant la période expérimentale (T_{Ex}). De manière similaire à l'effort de direction du conducteur, cette métrique est calculée en fonction du couple de direction du système au fil du temps :

$$StC = \int_{T_{Ex}} T_a^2(\tau) d\tau \quad (3.59)$$

— Le conflit conducteur-LKS représente la différence entre les efforts de direction du conducteur et du système de maintien de voie pendant la période expérimentale (T_{Ex}). Cette métrique permet de quantifier le degré de coopération ou de divergence entre le conducteur et le système :

$$Conflict = \int_{T_{Ex}} |T_a(\tau) - T_d(\tau)| d\tau \quad (3.60)$$

— La charge de travail de direction (*SW*) est une mesure de la charge de travail physique générée lorsque le conducteur interagit avec le système pour accomplir la manœuvre de conduite requise. Cette métrique est calculée en prenant en compte le produit du couple de direction du conducteur, du couple de direction du système et de la vitesse de rotation du volant au fil du temps [Sentouh et al., 2018] :

$$SW = \int_{T_{EX}} |T_a(\tau) \cdot T_d(\tau) \cdot \dot{\delta}_d(\tau)| d\tau \quad (3.61)$$

La Figure 3.19 présente les résultats de ces métriques pour les différentes stratégies évaluées. On peut observer que dans la stratégie " LKS_{WOA} ", l'effort requis pour diriger le véhicule et éviter les obstacles est très élevé lorsque le système ne coopère pas, par rapport à la stratégie "Manuel". En revanche, dans la stratégie " LKS_{WA} ", l'effort fourni par le conducteur est du même ordre que dans la condition "Manuel".

Il est clair à partir de la Figure 3.19 que la condition " LKS_{WA} " réduit considérablement l'effort du conducteur et le conflit entre le conducteur et le système de maintien de voie par rapport à la condition " LKS_{WOA} ". Ces résultats quantitatifs démontrent de manière convaincante que l'approche de contrôle partagé proposée est très efficace pour réduire l'effort du conducteur et le conflit entre le conducteur et le système de maintien de voie.




FIGURE 3.19 – Résultats de l'évaluation objective du contrôleur partagé avec une fonction de coût dynamique et constante pour un scénario d'évitement d'obstacles.

3.8.4.2 Evaluation subjective

Les questionnaires ont permis de recueillir des données subjectives détaillées sur cinq aspects différents de l'expérience de conduite. Les participants ont évalué leur ressenti en termes de confort de conduite, de sentiment de contrôle et de sécurité, de facilité d'évitement des obstacles, ainsi que leur évaluation globale des performances de conduite pour chaque phase de test.

Pour chaque aspect évalué, les participants ont attribué des notes sur une échelle de 0 à 100, où 0 correspondait à la pire évaluation possible et 100 à la meilleure. Les résultats présentés dans la Figure 3.20 ont révélé des différences significatives entre les stratégies de conduite.

En ce qui concerne le confort de conduite, la stratégie " LKS_{WOA} " a obtenu les scores les plus bas, indiquant que les participants se sont sentis moins à l'aise lorsqu'ils utilisaient cette stratégie. De même, pour le sentiment de contrôle et de sécurité, ainsi que pour la facilité d'évitement des obstacles, la stratégie " LKS_{WOA} " a également reçu les scores les plus bas, suggérant que les participants se sont sentis moins en confiance et moins en contrôle lorsqu'ils utilisaient cette stratégie.

En revanche, la stratégie " LKS_{WA} " a montré des résultats comparables ou légèrement inférieurs à la stratégie "Manuel" pour ces différents aspects. Cela suggère que cette stratégie a permis aux participants de maintenir un niveau de confort, de contrôle et de sécurité lié à l'évitement d'obstacles similaire à celui ressenti lorsqu'ils conduisaient manuellement.




FIGURE 3.20 – Résultats de l'évaluation subjective du contrôleur partagé avec une fonction de coût dynamique et constante pour un scénario d'évitement d'obstacles.

En résumé, les résultats subjectifs des questionnaires confirment que la stratégie " LKS_{WA} " offre une meilleure expérience de conduite en termes de confort, de contrôle, de sécurité et de facilité d'évitement des obstacles par rapport à la stratégie " LKS_{WOA} ".

Enfin, les résultats de l'évaluation subjective de la performance de conduite globale lors du scénario d'évitement des obstacles avec les différentes conditions sont présentés dans la Figure 3.21. Cette évaluation permet de mesurer la perception globale des participants quant à leur performance de conduite dans chaque condition.

Il est clairement visible que la stratégie " LKS_{WOA} " a obtenu les scores les plus bas en termes de performance de conduite perçue. Cela indique que les participants ont considéré cette stratégie comme la moins performante par rapport aux autres conditions. En revanche, les stratégies " LKS_{WA} " et "Manuel" ont obtenu des scores similaires ou légèrement supérieurs, ce qui suggère que les participants ont considéré ces deux stratégies comme offrant une meilleure performance de conduite.

Ces résultats confirment que la stratégie " LKS_{WOA} " a été perçue comme étant moins efficace en termes de performance de conduite globale lors du scénario d'évitement des obstacles, tandis que les stratégies " LKS_{WA} " et "Manuel" ont été mieux évaluées.

3.9 Conclusion

Ce chapitre a traité la conception d'un contrôle partagé LPV optimal basé sur une fonction de coût adaptative pour les systèmes de maintien de voie coopératifs (LKS) afin de gérer l'autorité entre le conducteur et le système. Le niveau d'assistance est ajusté, en temps réel, en fonction des conditions de conduite, de la disponibilité et de l'activité du conducteur. Pour permettre à la fonction de coût d'être multi-objectif et dynamique, le niveau d'assistance, fourni par un superviseur de conduite, est intégré dans cette fonction et considéré comme un paramètre variant dans la conception du contrôleur.

La stabilité du système en boucle fermée, en tenant compte des contraintes réelles telles que la variation de la vitesse du véhicule et de la fonction de coût dynamique, est garantie en

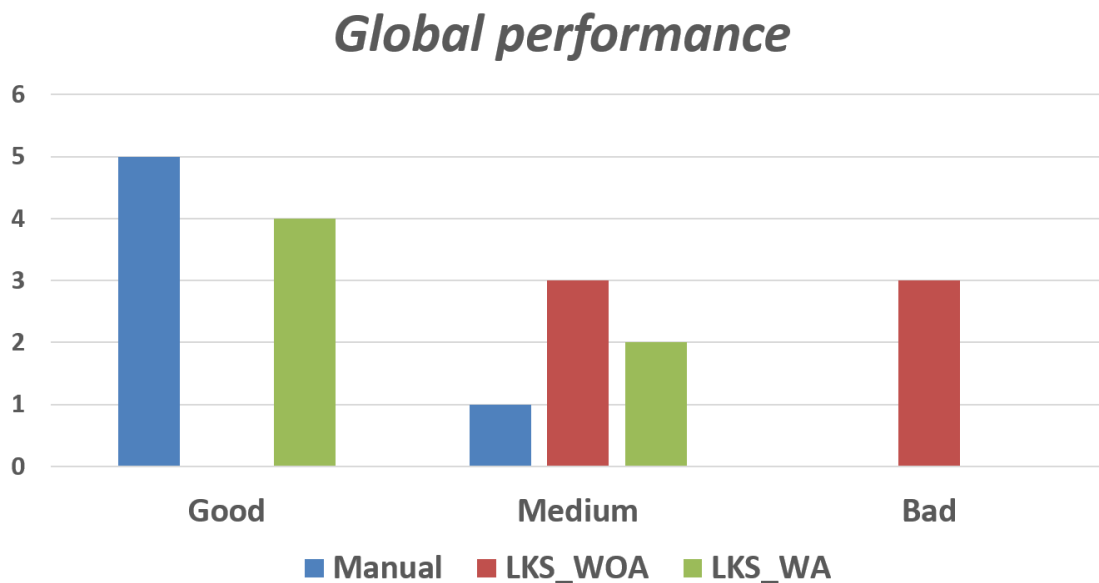


FIGURE 3.21 – Résultats globaux des performances du contrôleur partagé conçu à l’aide d’une fonction de coût constante et dynamique pour un scénario d’évitement d’obstacles.

utilisant le cadre d’optimisation LMI basé sur des arguments de stabilité de Lyapunov.

Des expériences de test utilisateurs ont également été réalisées à l’aide du simulateur de véhicule dynamique SHERPA afin de démontrer l’efficacité du contrôle partagé proposé.

Les résultats ont montré que le contrôle partagé proposé était très efficace pour gérer l’allocation de l’autorité entre le conducteur et le système de maintien de voie en minimisant les conflits et l’effort du conducteur.

Cependant, il est nécessaire de veiller à ce que ce nouveau type de mobilité prenne en compte à la fois les attentes des conducteurs et les changements prévisibles dans le comportement des usagers de la route [Sentouh et al., 2009]. Dans le chapitre suivant, un modèle dynamique du conducteur sera intégré dans la conception du contrôle afin de personnaliser les fonctionnalités du système.

Chapitre 4

Contrôle partagé basé sur l'identification en ligne des paramètres d'un modèle de conducteur

Sommaire

| | | |
|------------|--|------------|
| 4.1 | Introduction | 130 |
| 4.2 | Les stratégies de contrôle partagé basées sur un modèle conducteur | 130 |
| 4.3 | Contribution | 132 |
| 4.4 | Dynamique Conducteur-Véhicule-Route | 133 |
| 4.4.1 | Dynamique Véhicule-Route | 133 |
| 4.4.2 | Etat de l'art sur les modèles conducteur | 133 |
| 4.4.3 | Modèle intégré LPV CVR | 139 |
| 4.5 | Identification en ligne des paramètres du conducteur | 140 |
| 4.5.1 | Processus d'identification en ligne des paramètres du conducteur à l'aide de l'approche MRIL | 140 |
| 4.5.2 | Validation du modèle conducteur proposé par simulation numérique et interactive sur le simulateur SHERPA | 142 |
| 4.5.3 | Validation du modèle CVR sur SHERPA | 144 |
| 4.6 | La conception du contrôleur partagé adaptatif basé sur la dynamique du conducteur | 145 |
| 4.6.1 | Représentation LPV-TS du Modèle augmenté Conducteur-Vehicule-Route | 146 |
| 4.6.2 | Conception du contrôleur partagé basée sur l'approche PDC | 150 |
| 4.6.3 | Analyse de la stabilité | 151 |
| 4.7 | Validation expérimentale | 152 |
| 4.7.1 | Performance du contrôle partagé adaptatif | 152 |
| 4.7.2 | Evaluation objective | 154 |
| 4.8 | Conclusion | 155 |

4.1 Introduction

Le chapitre précédent a mis en exergue l'intérêt du contrôle partagé LPV optimal, qui s'appuie sur une fonction de coût adaptative multi-objectif, et en prenant en compte l'activité du conducteur et son état physiologique pour gérer efficacement l'autorité entre le conducteur et le système de maintien de voie coopératif (LKS). Toujours dans une perspective d'un contrôle partagé adaptatif, le but de ce chapitre est de personnaliser la conduite, et de ce fait l'adapter au style de conduite du conducteur afin d'améliorer l'acceptabilité du système. La piste explorée dans ce chapitre est l'exploitation des flux d'informations échangés entre le conducteur et le système automatisé à travers l'interface haptique (le ressenti au volant) où le conducteur ressent les actions du système. L'idée est d'intégrer, dans le processus de conception du contrôle, un modèle dynamique de conducteur capable de capturer en temps réel les variations liées à l'interaction entre le conducteur, le véhicule et l'environnement, ce qui permet une adaptation continue du contrôleur. Afin d'identifier en ligne les paramètres de ce modèle conducteur, une nouvelle approche d'identification basée sur le critère de stabilité de Lyapunov est proposée. En utilisant les paramètres variants du modèle conducteur identifiés en ligne, nous concevons un contrôleur partagé LPV qui s'ajuste de manière dynamique pour minimiser les conflits entre le conducteur et le système de maintien de voie. La stabilité asymptotique en boucle fermée du système LPV global Conducteur-Véhicule-Route (CVR) en considérant la variation de la vitesse du véhicule ainsi que les paramètres variants du modèle conducteur est démontrée à l'aide d'arguments de stabilité de Lyapunov. La conception du contrôle partagé est formulée sous forme d'un problème d'optimisation LMI (Linear Matrix Inequality). Enfin, pour évaluer les performances de l'approche de contrôle partagé proposée, une phase de validation expérimentale en simulation interactive est réalisée en utilisant le simulateur de conduite automobile dynamique SHERPA dans des situations de conduite réalistes. Les résultats principaux de ce chapitre font l'objet de la publication [Oudainia et al., 2022a].

4.2 Les stratégies de contrôle partagé basées sur un modèle conducteur

Différentes architectures de contrôle partagé ont été proposées dans diverses études, notamment [Saleh et al., 2013], [Soualmi et al., 2014], [Oufroukh and Mammam, 2014], [Wang et al., 2016], [Nguyen et al., 2017], [Schnelle et al., 2017], en se basant sur des modèles conducteurs.

Dans l'article de [Lefevre et al., 2014], un modèle de conducteur basé sur l'apprentissage, combinant un Modèle de Markov Caché et une Régression par Mélange de Gaussiennes, est introduit. Ce modèle anticipe le comportement du conducteur en ce qui concerne les sorties de voie plus tôt que les systèmes LKAS existants, afin d'adapter l'action du contrôleur pour reproduire au mieux les actions attendues du conducteur. Dans l'étude menée par [Flad et al., 2017], les systèmes de contrôle partagé sont décrits comme un problème de jeu différentiel visant à résoudre les conflits (voir Figure 4.1). Dans cette approche, un modèle décrivant le mouvement de direction du conducteur est utilisé pour prendre en compte de manière explicite les objectifs et les actions de direction du conducteur lors du calcul du couple optimal que le système d'assistance devrait appliquer.

Dans l'étude de [Medero et al., 2022], un système de contrôle latéral partagé LPV est proposé (voir Figure 4.2). Ce système s'adapte en fonction des capacités du conducteur, où les performances de ce dernier sont estimées à l'aide d'un observateur proportionnel-intégral (PI) LPV et d'un modèle idéalisé décrivant le comportement souhaité du conducteur. Par la suite, ces estimations sont utilisées pour ajuster les paramètres du contrôleur latéral LPV du véhicule.

Dans l'étude de [Wang et al., 2016], un contrôleur partagé robuste H_∞ basé sur un séquençement de gain a été proposé pour tenir compte des caractéristiques variables du conducteur telles que le temps de réaction et le temps d'anticipation.




FIGURE 4.1 – Le jeu différentiel comme modèle du problème de contrôle partagé de la direction [Flad et al., 2017].

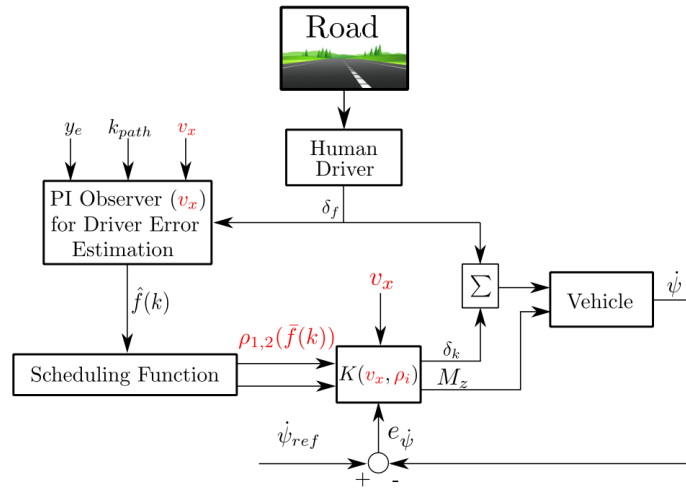


FIGURE 4.2 – Contrôle latéral LPV pour les systèmes avancés d'assistance à la conduite basé sur les performances du conducteur [Medero et al., 2022].

Dans l'article de [Saleh et al., 2013], un système avancé d'assistance à la conduite (ADAS) pour le maintien de voie est développé en utilisant la théorie de la commande $H_2 - Preview$ où un modèle de conducteur cybernétique est utilisé pour prendre en compte les variations du comportement du conducteur (Voir Figure 4.3). De même, dans [Pano et al., 2019], un contrôle partagé basé sur un modèle de conducteur cybernétique est utilisé.

Une approche de contrôle partagé utilisant des modèles T-S a été proposée dans l'étude de [Nguyen et al., 2017], en étendant les travaux de [Nguyen et al., 2015]. Cette approche vise à réaliser à la fois le maintien de voie et la minimisation des conflits. Un modèle de conducteur simplifié à deux niveaux est utilisé pour intégrer la gestion des conflits dans le critère quadratique du contrôleur. Dans l'étude de [Chen et al., 2020], la méthode de contrôle du maintien de voie adopte un modèle de conducteur basé sur des angles visuels proches et éloignés avec un contrôleur robuste PDC (Parallel Distributed Compensation) H_∞ .

Cependant, il est important de noter que ces approches nécessitent l'identification des paramètres du conducteur et doivent également prendre en compte les erreurs de modèle, ce qui peut affecter les performances du système. De plus, il est essentiel que ces approches prennent en compte à la fois les attentes des conducteurs et les changements prévisibles dans leurs comportements en temps réel [Sentouh et al., 2009]. Dans ce contexte, un modèle dynamique du

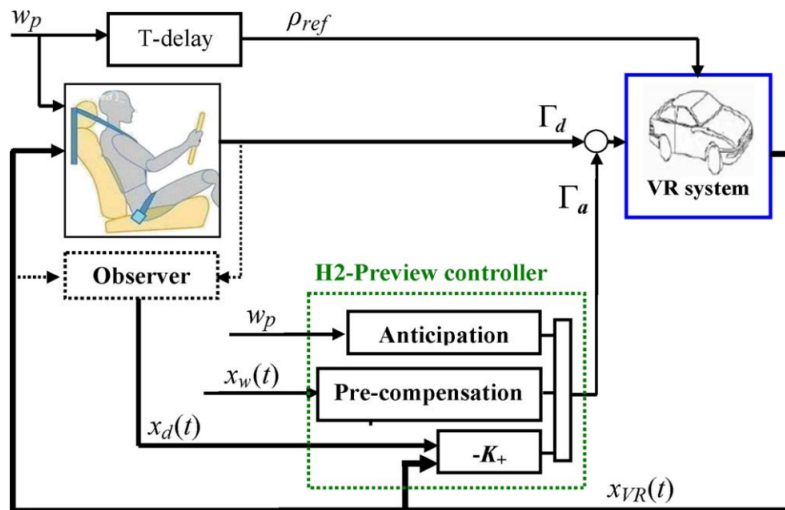


FIGURE 4.3 – Contrôle partagé basé sur la théorie de contrôle $H_2 - Preview$ [Saleh et al., 2013].

conducteur sera intégré dans la conception du contrôle afin de personnaliser les fonctionnalités du système.

4.3 Contribution

Dans ce chapitre, nous proposons une nouvelle architecture de contrôle partagé, illustrée dans la Figure 4.4, qui vise à fournir une assistance adaptée aux capacités du conducteur en prenant en considération ses caractéristiques visuelles et neuromotrices. Cette nouvelle approche est basée sur l'estimation de la dynamique des paramètres liés aux systèmes visuel et neuromusculaire du conducteur. Ces paramètres sont identifiés en temps réel grâce à une nouvelle approche d'estimation basée sur le critère de stabilité de Lyapunov.

Les principales contributions de cette étude sont les suivantes :

- Proposition d'un nouveau modèle de conducteur cybernétique qui intègre à la fois les aspects visuels et neuro-musculaires. Ce modèle permet de mieux représenter les capacités et les réactions du conducteur dans différentes situations de conduite.
- Développement d'une nouvelle approche d'estimation en ligne des paramètres du modèle de conducteur. Cette approche repose sur la stabilité de Lyapunov, ce qui permet d'obtenir des estimations précises et réactives des paramètres en fonction des données disponibles en temps réel.
- Conception d'un contrôleur PDC (Parallel Distributed Compensation) pour la conduite partagée, prenant en compte des variations en temps réel de la vitesse longitudinale du véhicule et des propriétés des paramètres du modèle conducteur. Ces variations sont traitées en utilisant l'approche polytopique pour les systèmes LPV-TS, à travers la définition d'un polytope à sommets finis et y sont intégrées dans le domaine des contraintes du système de contrôle.
- Analyse de la stabilité en boucle fermée du système global CVR, représenté sous forme TS en considérant le modèle conducteur adaptatif LPV et le couplage entre la dynamique latérale et longitudinale du véhicule. La conception de la commande, garantissant la stabilité au sens de Lyapunov, est formulée sous la forme d'un problème d'optimisation convexe sous contraintes LMI.
- Validation expérimentale et en temps réel de l'architecture de contrôle partagé proposée à l'aide du simulateur de conduite SHERPA-LAMIH, en considérant différents scénarios

de conduite.

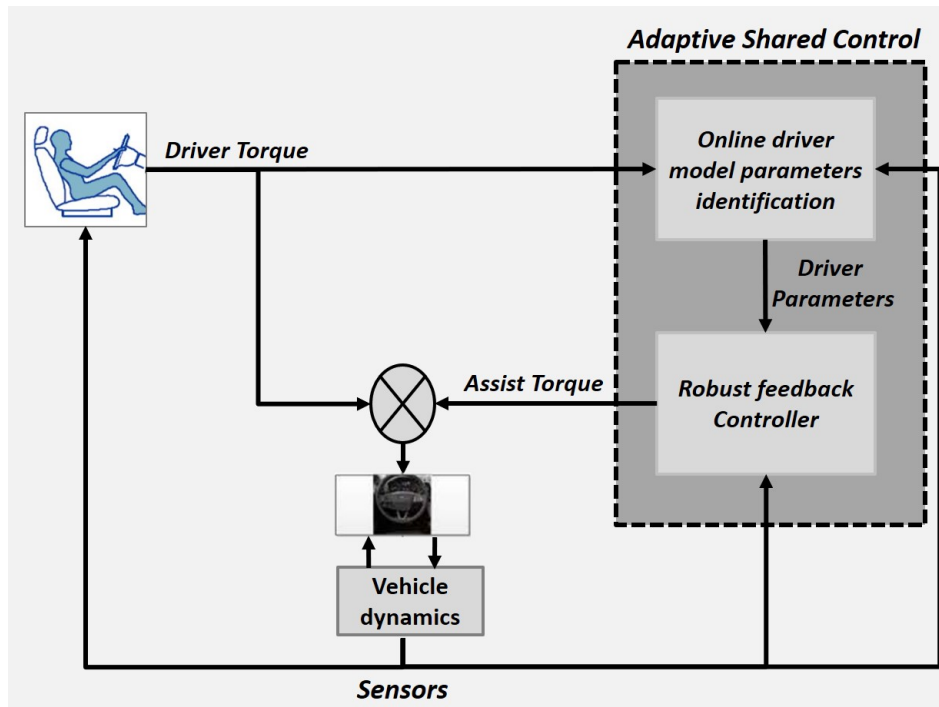


FIGURE 4.4 – Architecture du contrôle partagé basé sur l'identification en ligne des paramètres d'un modèle de conducteur.

Ces contributions permettent de mettre en place une architecture avancée de contrôle partagé, qui considère les caractéristiques spécifiques du conducteur, en particulier celles liées à ses stratégies visuelles et neuromusculaires. L'algorithme de contrôle proposé permet d'assurer un contrôle partagé continu et personnalisé lors de la conduite partagée, et un transfert progressif du contrôle de manière sûre et intuitive, afin de minimiser les conflits entre les actions du conducteur et celles du système de conduite automatisée.

4.4 Dynamique Conducteur-Véhicule-Route

Dans cette section, nous débutons en rappelant la dynamique véhicule-route telle qu'exposée dans le chapitre précédent. Ensuite, nous présentons un état de l'art sur les modèles de conducteur dans la littérature. Par la suite, nous présentons le modèle de la dynamique visuelle-neuromusculaire du conducteur qui a été proposé. Enfin, nous terminons en exposant la dynamique intégrée du véhicule en boucle fermée avec le conducteur.

4.4.1 Dynamique Véhicule-Route

Il convient de rappeler que la dynamique du système Véhicule-Route utilisée dans ce manuscrit est dérivée du modèle bicyclette, tel qu'expliqué dans le chapitre précédent et représentée par le modèle (3.10).

4.4.2 Etat de l'art sur les modèles conducteur

Le principe d'un modèle conducteur cybernétique repose sur un "cycle perception-action" qui représente les processus perceptifs et sensorimoteurs [Mulder et al., 2004]. Le développement de tels modèles trouve son origine dans les modèles d'opérateurs humains en aéronautique [McRuer

et al., 1977]. De nombreux modèles de conducteur ont été présentés dans la littérature. Donges [Donges, 1978] a proposé un modèle à deux niveaux qui combine à la fois le contrôle anticipatoire en boucle ouverte et le contrôle compensatoire en boucle fermée. L'anticipation est rendue possible par l'observation de la route à distance, tandis que les informations plus immédiates contribuent à la compensation des erreurs de positionnement latéral sur la voie (Voir Figure 4.5).




FIGURE 4.5 – Modèle conducteur à deux niveaux combinant des structures de contrôle anticipatoire en boucle ouverte et de contrôle compensatoire en boucle fermée [Donges, 1978].

Hess & Modjtahedzadeh [Hess and Modjtahedzadeh, 1990] ont proposé un modèle de conducteur qui n'utilise que l'erreur de déplacement latéral en tant qu'entrée et produit un angle du volant en tant que sortie. Ce modèle intègre les attributs physiques humains et le système neuromusculaire.

Des questions ont ensuite émergé concernant les vraies entrées du modèle de direction du conducteur, c'est-à-dire les informations auxquelles le conducteur se réfère effectivement pendant la direction. Land & Lee [Land and Lee, 1994] ont observé que les conducteurs passaient un temps significatif à regarder le point tangent, c'est-à-dire le point où la direction de la ligne de bordure intérieure semble s'inverser du point de vue du conducteur. Les auteurs ont proposé que l'angle entre la direction de la trajectoire du véhicule et la direction du point tangent soit utilisé par les conducteurs pour anticiper les variations de la courbure de la route. En d'autres termes, regarder le point tangent pourrait fournir un signal d'entrée au système sensorimoteur en charge du contrôle de direction.

Dans [Salvucci and Gray, 2004], un modèle de direction est développé en se basant sur la définition du point proche et du point éloigné. Le point proche vise à maintenir la ligne médiane de la voie, tandis que le point éloigné vise à anticiper la route à venir. Ce modèle est basé sur les caractéristiques perceptuelles des points proches et éloignés en utilisant des caractéristiques visuelles. Le point proche est fixé au centre de la route à une certaine distance devant le véhicule. Le point éloigné est situé à une distance du véhicule et dépend de la nature de la route. Ensuite, un contrôleur PI (proportionnel-intégral) alimente l'angle de direction pour gérer la négociation des virages, la correction de la direction après une dérive latérale, le changement de voie et les différences individuelles. Malheureusement, sa structure interne ne fournit que peu d'informations sur la manière dont le conducteur manipule le volant. En réalité, les conducteurs doivent interagir avec le volant à l'aide des muscles de leurs bras pour atteindre un angle souhaité. Ceci n'est pas explicitement inclus dans la plupart des modèles précédents.

Il a été souligné dans [Abbink and Mulder, 2010] que l'analyse neuromusculaire devrait être considérée comme un guide dans la conception du contrôle partagé. Des expériences ont montré

que les mesures de l'impédance neuromusculaire contribueraient à une meilleure compréhension de la réponse humaine aux forces, et par conséquent, à la conception du contrôle partagé haptique. Un autre modèle de conducteur est également évoqué, développé par [Sentouh et al., 2009], qui prend en compte l'interaction entre le conducteur et le véhicule. Ce modèle intègre la perception visuelle et kinesthésique en combinant des processus anticipatoires et compensatoires (Voir Figure 4.6). Les paramètres et gains du modèle sont déterminés à l'aide de la méthode d'erreur de prédiction (PEM). Ce modèle est conçu pour générer le couple de direction appliqué au véhicule par le conducteur, en prenant en compte de manière plus détaillée les interactions entre le conducteur et le véhicule.




FIGURE 4.6 – La structure du modèle conducteur [Sentouh et al., 2009].

Le modèle de conducteur proposé dans [Saleh et al., 2011] prend directement le couple auto-alignant comme entrée (voir Figure 4.7). Il repose sur l'hypothèse que le conducteur transforme la sortie du contrôleur visuel exprimée en angle du volant calculé à l'aide de l'anticipation et la compensation visuelles. Ensuite, l'angle de direction souhaité est transmis au système neuromusculaire inspiré du travail de [Hoult and Cole, 2008], qui génère le couple de direction.




FIGURE 4.7 – Modèle cybernétique du conducteur [Saleh et al., 2011].

Un modèle de contrôle latéral du conducteur est proposé dans [Bi et al., 2015], où la dynamique neuromotrice du conducteur est intégrée dans le modèle de contrôle latéral où ce dernier est basé sur un réseau de files d'attente (Queuing Network "QN") (Voir Figure 4.8). Le modèle de conducteur basé sur le QN commence par calculer un angle de direction souhaité en utilisant

les entrées de l'ensemble du modèle comprenant des informations sur la route et les états du véhicule. Ensuite, l'angle de direction souhaité est utilisé comme entrée de référence du système neuromusculaire soumis à une rétroaction de couple inspiré du travail de [Pick and Cole, 2008]. Après cela, le système neuromusculaire génère l'angle de direction réel appliqué au modèle de véhicule. Cependant, Ce modèle ne tient pas compte de l'utilisation des entrées visuelles proches et lointaines, comme décrit précédemment.

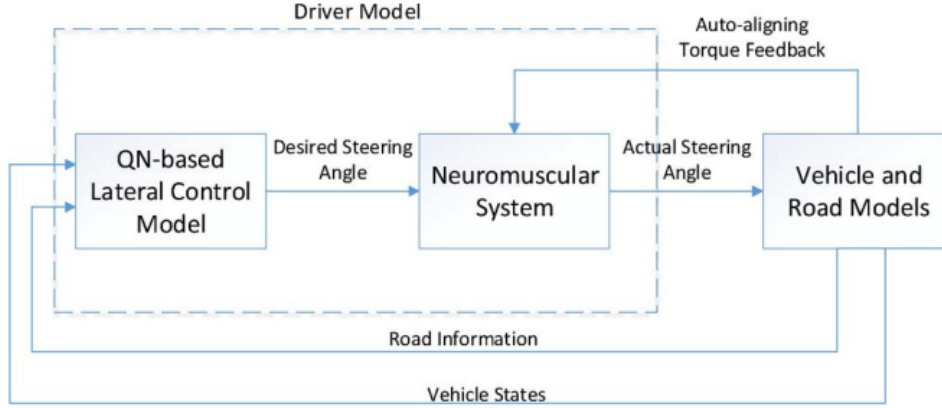


FIGURE 4.8 – Modèle de conducteur basé sur un réseau de files d’attente (Queuing Network “QN”) [Bi et al., 2015].

Dans ce chapitre, le modèle du conducteur proposé vise à prendre en compte à la fois l’aspect visuel et l’aspect neuromusculaire pour capturer au mieux le comportement du conducteur lors de la conduite. L’aspect visuel est basé sur le concept d’un point de vision proche et d’un point de vision éloigné, comme décrit dans [Sentouh et al., 2009]. En plus de l’aspect visuel, le modèle du conducteur intègre également l’aspect neuromusculaire, tel qu’utilisé dans [Bi et al., 2015]. Cela permet de prendre en compte les réponses neuromusculaires du conducteur, qui peuvent influencer sa capacité à réagir aux changements de la situation de conduite.

L’architecture du modèle conducteur proposé, qui combine ces deux aspects, est représentée dans la Figure 4.9. Cette approche permet de mieux comprendre et reproduire le comportement du conducteur, en prenant en compte à la fois ses processus visuels et ses réponses neuromusculaires lors de la tâche de maintien de voie.

4.4.2.1 Le système visuel

La littérature a montré que le conducteur se base sur deux points visuels pour guider son véhicule sur la route [McRuer et al., 1977] [Donges, 1978] : un point proche qui lui confère un comportement compensatoire et un point éloigné lui permettant d’anticiper l’évolution de la courbure. Ces points peuvent être caractérisés par les deux angles θ_{far} et θ_{near} utilisés dans [Sentouh et al., 2009] et peuvent être représentés par les relations suivantes :

$$\theta_{\text{near}} = \frac{y_L}{l_p} + \psi_L, \quad \theta_{\text{far}} = D_{\text{far}} \frac{r}{v_x} \quad (4.1)$$

L’angle θ_{far} représente l’angle entre le cap du véhicule et la tangente à la courbe. Quant à θ_{near} , il représente l’angle entre la direction du véhicule et la ligne droite reliant le centre de gravité du véhicule à un point situé au centre de la voie devant le véhicule, à une distance l_p , comme illustré dans la Figure 4.10.

Comme mentionné dans [Sentouh et al., 2009], le modèle visuel est composé de trois blocs de transfert, G_a , G_c et G_d , qui représentent respectivement le comportement anticipatif, le comportement compensatoire et le délai de traitement de l’information visuelle (Figure 4.9).

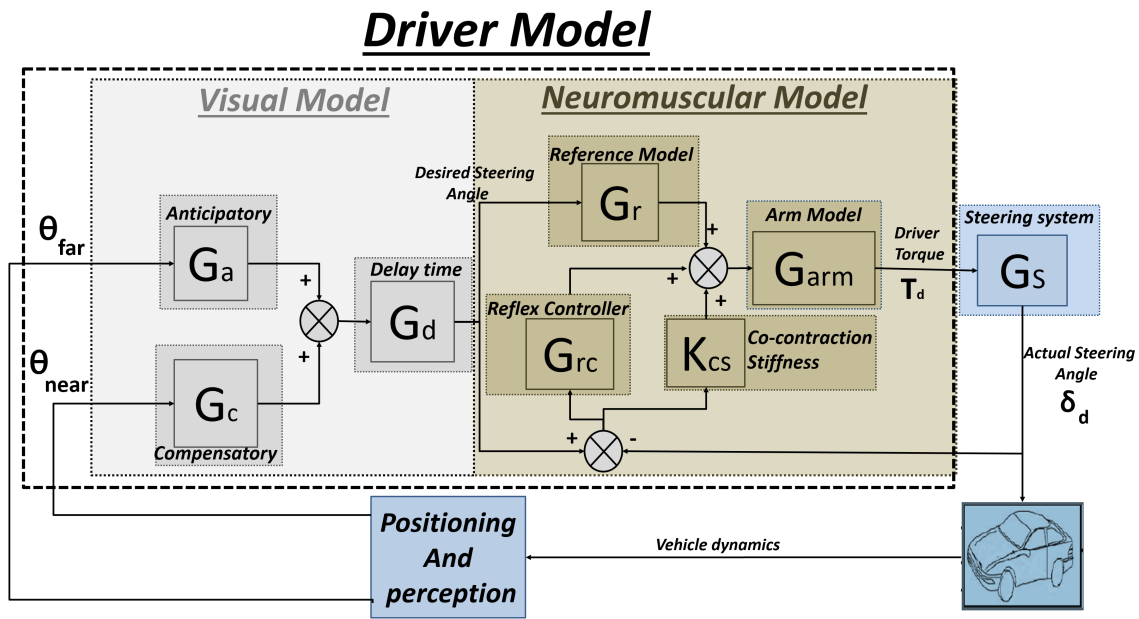


FIGURE 4.9 – Architecture du modèle de conducteur proposé.




FIGURE 4.10 – Angles visuels pour les comportements anticipatifs et compensatoires [Sentouh et al., 2009].

En ce qui concerne le contrôle anticipatif, le conducteur prédit la trajectoire future du véhicule et fournit une commande de direction anticipée via le volant avant d'entrer dans la courbe. Cela permet au conducteur d'anticiper les mouvements du véhicule et d'ajuster sa trajectoire en conséquence. Cette partie représente l'action de contrôle feedforward du conducteur.

Quant au contrôle compensatoire, le conducteur ajuste le couple appliqué au volant en utilisant des informations visuelles provenant de la région proche de l'avant du véhicule, c'est-à-dire l'angle visuel proche θ_{near} . L'objectif est de maintenir une déviation latérale sûre par rapport au centre de la voie. Cette partie représente le contrôle de rétroaction du conducteur.

Enfin, le bloc de transfert G_d représente le temps de traitement cognitif. Il modélise, sous forme d'un retard pur, le temps nécessaire pour que le conducteur traite les informations visuelles perçues et prenne des décisions. Ces transferts sont modélisés respectivement de la manière suivante [Sentouh et al., 2009] :

$$G_a = k_a, \quad G_c = k_c \frac{T_L s + 1}{T_I s + 1}, \quad G_d = e^{-\tau_d s} \quad (4.2)$$

où k_a est le gain d'anticipation, T_L et T_I sont les constantes de temps de retard et d'avance respectivement, et le gain k_c représente l'action proportionnelle du conducteur par rapport à l'erreur de l'angle visuel proche, et τ_d le temps de traitement cognitif.

En résumé, le modèle visuel propose une représentation du comportement du conducteur en termes de contrôle anticipatif et compensatoire, en utilisant les blocs de transfert G_a , G_c et G_d décrits précédemment. Cette modélisation permet de prendre en compte les réactions visuelles du conducteur et de les intégrer dans l'architecture globale de commande partagée.

4.4.2.2 Le système neuromusculaire

Le modèle neuromusculaire utilisé dans cette étude, basé sur [Bi et al., 2015], se compose de quatre blocs de transfert qui décrivent différents aspects du système neuromusculaire du conducteur.

Le premier bloc, G_r , représente le modèle de référence et est caractérisé par le paramètre k_r . Ce modèle de référence permet de fournir une action feedforward du couple de direction proportionnel à l'angle de braquage souhaité par le conducteur.

Le deuxième bloc, K_{cs} , est associé à la raideur de co-contraction, qui représente l'augmentation de la raideur intrinsèque du muscle due à son activation. Ce paramètre permet de capturer l'influence de la co-contraction musculaire sur le contrôle du volant.

Le troisième bloc, G_{rc} , correspond au régulateur des réflexes d'étirement et est caractérisé par les paramètres B_r et K (voir (4.3)). Il modélise la dynamique du réflexe d'étirement musculaire, qui contribue à la stabilisation de la position du volant en réaction aux perturbations.

Enfin, le quatrième bloc, G_{arm} , représente le modèle du bras et est défini par la constante de temps T_n . Ce bloc décrit la dynamique de l'activation musculaire du bras et permet de modéliser les réponses temporelles du système neuromusculaire. Ces transferts sont modélisés comme dans [Bi et al., 2015] et [Sentouh et al., 2009] :

$$G_r = k_r, \quad K_{cs}, \quad G_{rc} = \omega_c \frac{B_r s + K}{s + \omega_c}, \quad G_{arm} = \frac{1}{T_n s + 1} \quad (4.3)$$

où k_r est le gain du transfert du modèle référence, K_{cs} est la raideur de co-contraction, K et B_r représentent respectivement la raideur et l'amortissement du réflexe, ω_c est la fréquence de coupure du filtre du premier ordre et T_n est la constante de temps du système du bras.

En résumé, ces quatre blocs de transfert du modèle neuromusculaire contribuent à capturer les différents aspects de la dynamique visuo-neuromusculaire du conducteur et sont essentiels pour reproduire ses réponses en termes de contrôle du volant pour la tâche de maintien de voie.

4.4.2.3 Un modèle conducteur simplifié

En utilisant le modèle illustré dans la Figure 4.9, il est évident que nous disposons de 11 paramètres ($[k_a, k_c, T_L, T_I, \tau_d, k_r, K_{cs}, K, B_r, \omega_c, T_n]$) qui reflètent le comportement dynamique du conducteur pour la tâche de maintien de voie. Cependant, concevoir un contrôle partagé en utilisant un aussi grand nombre de paramètres entraînerait une charge de calcul numérique considérable. C'est pourquoi, au lieu d'identifier et d'utiliser chaque paramètre du modèle, nous opterons pour une simplification de la représentation du modèle comme illustré dans la Figure 4.11. En utilisant cette architecture simplifiée, nous pourrions identifier les comportements

du conducteur plutôt que les paramètres, c'est-à-dire les dynamiques compensatoires, anticipatoires et de rigidité musculaire du conducteur (l'impédance du conducteur).




FIGURE 4.11 – Architecture simplifiée du modèle de conducteur proposé.

Selon cette architecture simplifiée, le modèle de conducteur utilisé est donné dans le domaine de Laplace par l'équation suivante :

$$T_d(s) = G_{arm}(s)U_d(s) \quad (4.4)$$

Les transferts $K_1(s)$, $K_2(s)$, $K_3(s)$ et $U_d(s)$ sont définis comme suit :

$$\begin{cases} K_1(s) = G_c G_d (G_r + G_{rc} + K_{cs}) \\ K_2(s) = G_a G_d (G_r + G_{rc} + K_{cs}) \\ K_3(s) = -(G_{rc} + K_{cs}) \\ U_d(s) = K_1(s)\theta_{near}(s) + K_2(s)\theta_{far}(s) + K_3(s)\delta_d(s) \end{cases} \quad (4.5)$$

Ainsi, le modèle du conducteur peut être exprimé sous la forme d'une représentation d'état, comme suit :

$$\dot{T}_d(t) = a_d T_d(t) + b_d u_d(t) \quad (4.6)$$

où $T_d(t)$ représente le couple exercé par le conducteur, $a_d = -\frac{1}{T_n}$ et $b_d = \frac{1}{T_n}$ sont les matrices du système, et $u_d(t)$ est l'entrée du système de conducteur, donnée par :

$$u_d(t) = k_1(t)\theta_{near}(t) + k_2(t)\theta_{far}(t) + k_3(t)\delta_d(t) \quad (4.7)$$

Les nouveaux paramètres du conducteur utilisés pour concevoir le contrôleur partagé sont $k_1(t)$, $k_2(t)$ et $k_3(t)$, qui représentent respectivement les dynamiques compensatoires, anticipatoires et de l'impédance (rigidité musculaire) du conducteur. La valeur de T_n est une constante choisie comme dans [Sentouh et al., 2009].

Dans (4.5), $K_1(s)$, $K_2(s)$ et $K_3(s)$ sont des fonctions de transfert (dans le domaine fréquentiel), et dans (4.7), leur représentation dans le domaine temporel où ces dernières représentent des dynamiques temporelles inconnues. Le Modèle conducteur (4.6) ainsi obtenu est linéaire variant dans le temps (LTV). Par conséquent, une estimation en ligne des paramètres représentant les dynamiques inconnues du modèle conducteur, est réalisée en utilisant une nouvelle approche basée sur le critère de stabilité de Lyapunov qui sera présentée dans la Section 4.5.

4.4.3 Modèle intégré LPV CVR

Le modèle intégré CVR peut être formulé à partir des dynamiques (3.10) et (4.6) de la manière suivante :

$$\dot{x} = A(t)x + Bu + Ed \quad (4.8)$$

où $x = [\beta \ r \ \psi_L \ y_L \ \delta_d \ \dot{\delta}_d \ T_d]^T$ est le vecteur d'état, $u = T_a$ est l'entrée de contrôle, $d = [f_w, \rho_c]$ est le vecteur de perturbations, avec :

$$A(t) = \begin{bmatrix} a_{11} & a_{12} & 0 & 0 & a_{15} & 0 & 0 \\ a_{21} & a_{22} & 0 & 0 & a_{25} & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ v_x & l_s & v_x & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ a_{61} & a_{62} & 0 & 0 & a_{65} & a_{66} & a_{67} \\ 0 & a_{72} & a_{73} & a_{74} & a_{75} & 0 & a_{77} \end{bmatrix},$$

$$B = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & b_6 & 0 \end{bmatrix}^T,$$

$$E = \begin{bmatrix} e_1 & e_2 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & -v_x & 0 & 0 & 0 & 0 \end{bmatrix}^T.$$

avec :

$$\begin{aligned} a_{11} &= -\frac{2(C_f+C_r)}{mv_x}, & a_{12} &= \frac{2(C_rl_r-C_fl_f)}{mv_x^2} - 1, & a_{15} &= \frac{2C_f}{mv_xR_s}, \\ a_{21} &= \frac{2(C_rl_r-C_fl_f)}{I_z}, & a_{22} &= -\frac{2(C_rl_r^2+C_fl_f^2)}{v_xI_z}, & a_{25} &= \frac{2C_fl_f}{I_zR_s}, \\ a_{61} &= \frac{2C_f\eta_t}{J_sR_s}, & a_{62} &= \frac{2C_fl_f\eta_t}{v_xJ_sR_s}, & a_{65} &= -\frac{2C_f\eta_t}{J_sR_s^2}, & a_{66} &= -\frac{B_s}{J_s}, \\ a_{67} &= \frac{1}{J_s}, & a_{72} &= \frac{k'_2(t)D_{far}}{T_n}, & k'_2(t) &= \frac{k_2(t)}{v_x}, & a_{73} &= \frac{k_1(t)}{T_n}, & a_{74} &= \frac{k_1(t)}{T_n l_p}, \\ a_{75} &= \frac{k_3(t)}{T_n}, & a_{77} &= -\frac{1}{T_n}, & b_6 &= \frac{1}{J_s}, & e_1 &= \frac{1}{mv_x}, & e_2 &= \frac{l_w}{I_z} \end{aligned}$$

Nous pouvons constater d'après (4.8) que le modèle augmenté qui sera utilisé pour la synthèse du contrôle partagé est un système linéaire LPV.

4.5 Identification en ligne des paramètres du conducteur

Dans le contexte de notre étude, nous proposons une nouvelle approche d'identification en ligne des paramètres, inspirée du concept de la commande adaptative à modèle de référence, basée sur le critère de stabilité de Lyapunov. Elle sera utilisée pour estimer les grandeurs des paramètres inconnus du modèle conducteur $k_1(t)$, $k_2(t)$ et $k_3(t)$ à partir des mesures en temps réel des variables d'entrées/sortie du système.

L'approche que nous avons nommé MRIL (Model Reference Identification-based Lyapunov approach) nous permet de formuler un critère d'optimisation visant à minimiser l'écart entre les valeurs prédites par le modèle et les mesures réelles. En ajustant itérativement les valeurs des paramètres, le modèle s'adapte progressivement aux caractéristiques spécifiques du conducteur en temps réel.

Dans cette section, nous allons détailler cette approche d'identification en ligne des paramètres. Nous présenterons les étapes spécifiques de l'algorithme utilisé et partagerons les résultats obtenus. Ces éléments permettront de mieux appréhender le processus d'estimation des paramètres et de mettre en évidence l'efficacité de l'approche MRIL proposée dans la modélisation du comportement du conducteur.

4.5.1 Processus d'identification en ligne des paramètres du conducteur à l'aide de l'approche MRIL

Notre objectif est de concevoir un estimateur pour l'identification en ligne des paramètres qui garantit la stabilité asymptotique du système en boucle fermée, composé des équations (4.6) et (4.7), tel qu'illustré dans la Figure 4.12.




FIGURE 4.12 – Diagramme représentant l'approche d'identification en ligne des paramètres du conducteur (approche MRIL).

Le schéma d'identification se compose de trois blocs. Le premier bloc est le modèle conducteur proposé, représenté par l'équation (4.6), qui comprend des paramètres ajustables. Ce modèle est utilisé pour estimer le couple de braquage $T_d(t)$ en fonction des entrées du système.

Le deuxième bloc représente le modèle de référence, qui est une boîte noire dont la structure est décrite par l'équation suivante :

$$\dot{X}_m(t) = a_d X_m(t) + b_d (b_1 \theta_{near}(t) + b_2 \theta_{far}(t) + b_3 \delta_d(t)) \quad (4.9)$$

Ce modèle de référence définit la trajectoire souhaitée du couple de braquage $X_m(t)$, que le modèle conducteur doit suivre où $a_d = -\frac{1}{T_n}$, qui est négatif, et $b_d = \frac{1}{T_n}$ (comme utilisé dans (4.6)).

Le troisième bloc est le mécanisme d'adaptation, qui contient l'algorithme d'adaptation utilisé pour l'identification en ligne des paramètres. Cet algorithme ajuste itérativement les valeurs des paramètres afin que le modèle conducteur s'adapte aux caractéristiques du conducteur en temps réel.

Les algorithmes d'adaptation utilisés pour l'identification des paramètres du modèle conducteur sont donnés par les expressions suivantes :

$$\begin{cases} \dot{k}_1(t) = -\lambda \theta_{near}(t) E(t) \\ \dot{k}_2(t) = -\lambda \theta_{far}(t) E(t) \\ \dot{k}_3(t) = -\lambda \delta_d(t) E(t) \end{cases} \quad (4.10)$$

où λ est un paramètre d'adaptation positif et $E(t)$ est l'erreur de suivi, donnée par $E(t) = T_d(t) - X_m(t)$, qui satisfait l'équation suivante :

$$\dot{E}(t) = a_d E(t) + b_d ((k_1(t) - b_1) \theta_{near}(t) + (k_2(t) - b_2) \theta_{far}(t) + (k_3(t) - b_3) \delta_d(t)) \quad (4.11)$$

Ces équations permettent d'ajuster itérativement les valeurs des paramètres $k_1(t)$, $k_2(t)$ et $k_3(t)$ en fonction de l'erreur de suivi $E(t)$ et des signaux $\theta_{near}(t)$, $\theta_{far}(t)$ et $\delta_d(t)$. L'objectif est de minimiser l'erreur de suivi en ajustant les paramètres en ligne.

Nous allons détailler par la suite la méthodologie utilisée pour déterminer les lois (4.10).

Théorème 4.1. Considérons le système décrit par l'équation (4.6), et un modèle de référence décrit par l'équation (4.9) dont l'entrée et la variable d'état sont bornées. Si nous appliquons l'entrée du système décrite par (4.7) au système (4.6) dont les paramètres sont ajustés et identifiés par les lois d'adaptations (4.10), alors la sortie du système en boucle fermée est bornée pour tout signal d'entrée borné, et l'erreur de suivi converge asymptotiquement vers zéro.

L'analyse de stabilité du système en boucle fermée est basée sur l'approche de Lyapunov. Soit la fonction quadratique de Lyapunov donnée par l'expression suivante :

$$V = \frac{1}{2}(E^2(t) + \frac{b_d}{\lambda}((k_1(t) - b_1)^2 + (k_2(t) - b_2)^2 + (k_3(t) - b_3)^2)) \quad (4.12)$$

La dérivation de la fonction de Lyapunov (4.12) donne :

$$\dot{V} = E(t)\dot{E}(t) + \frac{b_d}{\lambda}(\dot{k}_1(t)(k_1(t) - b_1) + \dot{k}_2(t)(k_2(t) - b_2) + \dot{k}_3(t)(k_3(t) - b_3)) \quad (4.13)$$

En remplaçant (4.11) dans (4.13) et après simplification, nous obtenons :

$$\begin{aligned} \dot{V} = a_d E^2(t) + \frac{b_d}{\lambda}((k_1(t) - b_1)(\dot{k}_1(t) + \lambda\theta_{near}(t)E(t)) + (k_2(t) - b_2)(\dot{k}_2(t) + \lambda\theta_{far}(t)E(t)) + \\ (k_3(t) - b_3)(\dot{k}_3(t) + \lambda\delta_d(t)E(t))) \end{aligned} \quad (4.14)$$

En utilisant le mécanisme d'adaptation et d'identification (4.10), nous obtenons :

$$\dot{V} = a_d E^2(t) \quad (4.15)$$

qui est semi-définie négative (a_d est négatif). Cela implique que $V(t) \leq V(0)$ et donc que $E(t)$, $k_1(t)$, $k_2(t)$ et $k_3(t)$ sont bornés ; ainsi $T_d(t) = E(t) + X_m(t)$ est également borné. Lorsque nous calculons la deuxième dérivée de la fonction de Lyapunov, nous obtenons :

$$\ddot{V} = 2a_d E(t)\dot{E}(t) \quad (4.16)$$

En remplaçant (4.11) dans (4.16) et après simplification, nous obtenons :

$$\ddot{V} = 2a_d E(t)(a_d E(t) + b_d((k_1(t) - b_1)\theta_{near}(t) + (k_2(t) - b_2)\theta_{far}(t) + (k_3(t) - b_3)\delta_d(t))) \quad (4.17)$$

Comme les entrées $(\theta_{near}(t), \theta_{far}(t), \delta_d(t))$, et $E(t)$ sont bornées, alors \ddot{V} est borné. Ainsi, \dot{V} est uniformément continue, puis l'erreur $E(t)$ converge vers 0.

4.5.2 Validation du modèle conducteur proposé par simulation numérique et interactive sur le simulateur SHERPA

Cette sous-section se compose de deux parties. La première consiste en la comparaison entre l'approche d'identification proposée (MRIL) et l'approche des moindres carrés récurrents (RLS). La seconde partie concerne la validation et l'analyse du modèle de comportement du conducteur sur différents parcours.

4.5.2.1 Comparaison entre l'approche d'identification proposée (MRIL) et l'approche RLS

Dans cette partie, nous allons effectuer une comparaison entre la méthode d'identification proposée (MRIL) et la méthode (RLS). Cette comparaison repose sur un modèle de référence préalablement établi, dans lequel les paramètres varient de manière connue. Ces paramètres de référence serviront de base pour la comparaison.

Le schéma d'identification est illustré dans la Figure 4.13. Les résultats de l'identification obtenus par les deux méthodes sont présentés dans la Figure 4.14. En examinant ces résultats, il est possible de constater que l'approche proposée (MRIL) offre des performances satisfaisantes en comparaison avec la méthode RLS, notamment en ce qui concerne le suivi de la sortie de référence, à savoir le suivi du couple de commande de référence.

Pour expliquer cet avantage, nous analysons les résultats de l'identification paramétrique. Il est évident que les paramètres identifiés par l'approche proposée (MRIL) correspondent aux paramètres réels du modèle de référence, contrairement à ce que nous observons avec l'approche RLS. Par conséquent, en utilisant l'approche MRIL, nous sommes en mesure d'identifier les paramètres réels du modèle du conducteur avec une erreur de suivi minimale.

Cette comparaison entre les deux approches d'identification nous conduit donc à la conclusion que l'approche MRIL offre des avantages significatifs en termes de précision et d'exactitude dans l'identification des paramètres du modèle.

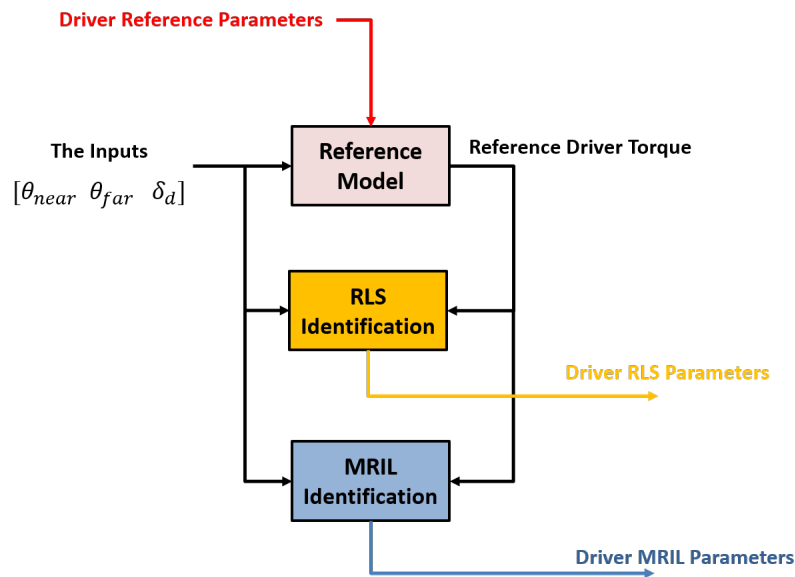


FIGURE 4.13 – Architecture pour la comparaison des deux approches d'identification (RLS et MRIL).




FIGURE 4.14 – Les résultats de l'identification paramétrique par les deux approches (RLS et MRIL).

4.5.2.2 Validation et analyse du modèle conducteur sur différents parcours

Afin d'analyser le comportement du conducteur dans différentes situations, une identification paramétrique a été réalisée en mode de conduite manuelle pour le maintien de voie sur deux parcours différents pour un même conducteur. Le premier parcours est la piste de Satory avec des virages de forte courbure et une vitesse constante de $v_x = 14m/s$, le deuxième est un parcours de type autoroute, avec une faible courbure et une vitesse constante de $v_x = 22m/s$. Les trajectoires et courbures des deux parcours sont présentées dans la Figure 4.15.

Les résultats de l'identification en ligne des paramètres du conducteur pour les deux par-

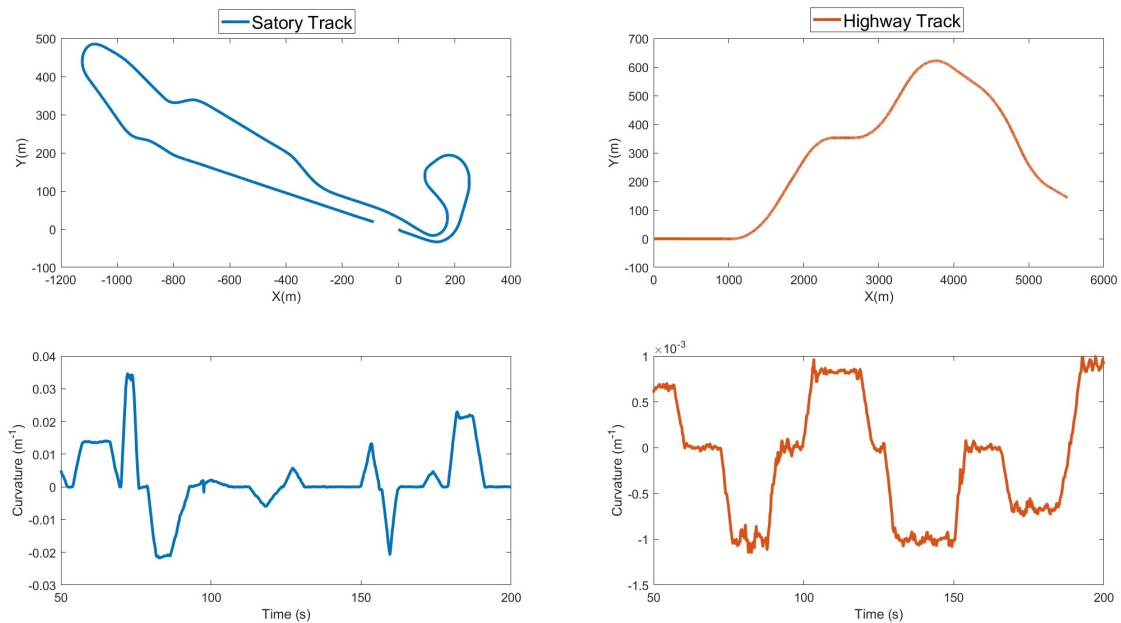


FIGURE 4.15 – La trajectoire et la courbure pour la piste d'autoroute et la piste de Satory.

cours (autoroute et Satory) sont affichés dans la Figure 4.16. Comme on peut le voir, la sortie du modèle, c'est-à-dire le couple de braquage, correspond parfaitement à celui mesuré sur le simulateur pour les deux parcours. Cependant, la variation des paramètres du conducteur n'est pas la même pour les deux tests. La dynamique des paramètres est beaucoup plus faible lors du test sur le parcours type autoroute où les stratégies visuelles et neuromusculaires sont différentes par rapport à une conduite sur une route sinueuse qui nécessite plus d'attention de la part du conducteur. Nous pouvons donc dire que le comportement du conducteur dépend de la situation de conduite qu'il rencontre.

Il est également possible de remarquer que le comportement dynamique du conducteur peut être modélisé avec un modèle linéaire sur le deuxième parcours (autoroute), c'est-à-dire que ses paramètres convergent vers une valeur constante. En revanche, durant le premier parcours réalisé sur la piste sinueuse de Satory, il est clair que le comportement du conducteur est représenté par un modèle non linéaire. De plus, on peut remarquer que le paramètre qui représente les dynamiques compensatoires sur le deuxième parcours est faible par rapport aux deux autres paramètres. Cela peut s'expliquer par le fait que sur le tracé où la courbure de la route est faible (en ligne droite), le conducteur ne se concentre pas autant sur le maintien de voie car cette situation ne demande pas une charge de travail importante en terme de contrôle compensatoire. Il accorde donc de l'importance uniquement aux deux autres paramètres (anticipation et rigidité). En comparaison, par rapport au premier parcours, nous pouvons observer que le conducteur accorde de l'importance à la compensation en raison de la présence de plusieurs virages avec des courbures beaucoup plus prononcées, ce qui lui demande une charge de travail importante liée à l'action compensatoire. L'analyse des résultats nous montre clairement que l'identification en ligne des paramètres permet de capturer le comportement du conducteur en termes de stratégies visuelles (anticipation et compensation) et neuromotrices (impédance) utilisées.

4.5.3 Validation du modèle CVR sur SHERPA

Afin d'utiliser le modèle augmenté (Conducteur-Véhicule-Route), développé dans la Section 4.4.3, pour la synthèse du contrôleur partagé pour l'assistance au maintien de voie, il est essentiel de vérifier la validité de ce modèle. Pour ce faire, une étape cruciale consiste à valider

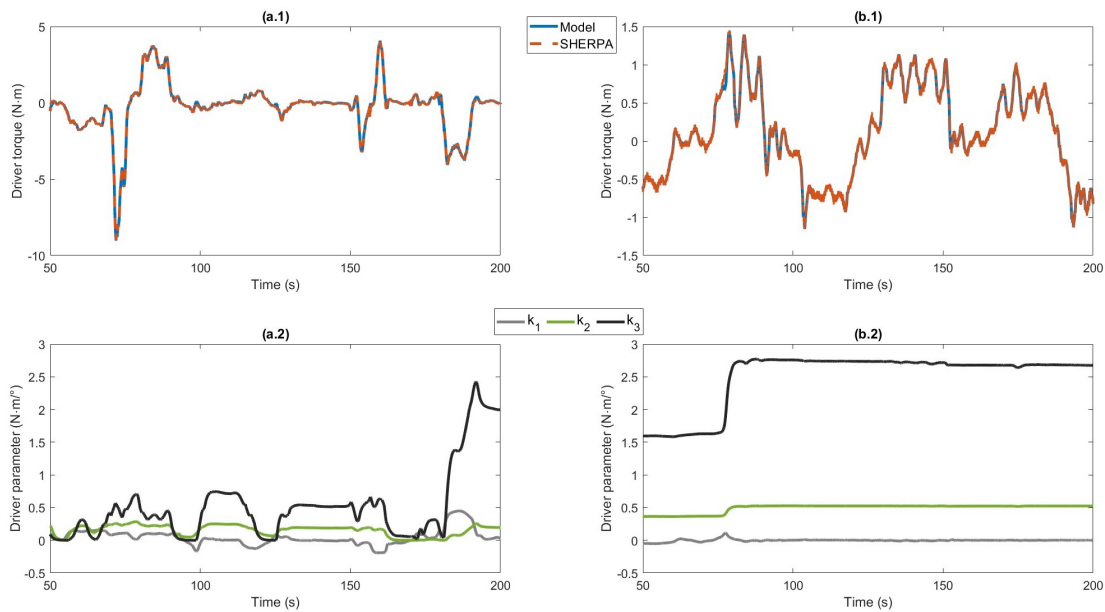


FIGURE 4.16 – Les résultats de l'approche d'identification en ligne des paramètres du conducteur sur la piste de Satory (a.1 et a.2) et sur la piste d'autoroute (b.1 et b.2) pour le test de maintien de voie sur le simulateur SHERPA.

le modèle en comparant ses prédictions avec les mesures réelles obtenues à l'aide du simulateur SHERPA-LAMIH.

Le modèle augmenté CVR en question, défini par l'équation (4.8), est validé à l'aide d'essais en simulation interactive effectués sur la piste de Satory (comme illustré dans la Figure 4.15). La reproduction fidèle du parcours dans le simulateur implique la mise en œuvre de phases d'accélération et de décélération soigneusement planifiées. Les résultats issus de ces essais de validation sont présentés graphiquement dans la Figure 4.17. Cette représentation visuelle permet une comparaison entre les prédictions du modèle augmenté CVR et les mesures réelles, facilitant ainsi l'évaluation de la performance du modèle. Parallèlement, les erreurs de validation sont exposées dans la Figure 4.18, confirmant ainsi la précision du modèle obtenue dans différentes situations.

L'analyse des résultats, obtenus sur le simulateur dynamique et interactif SHERPA-LAMIH, met en avant une observation cruciale : le modèle d'interaction Conducteur-Véhicule-Route que nous avons élaboré est capable de reproduire de manière satisfaisante la dynamique à la fois du véhicule et du conducteur en interaction avec la route.

4.6 La conception du contrôleur partagé adaptatif basé sur la dynamique du conducteur

Dans cette section, nous commençons par introduire la représentation floue T-S du modèle intégré du véhicule en boucle fermée avec le conducteur. Ensuite, nous présentons dans la deuxième sous-section une solution basée sur les LMI pour le problème de contrôle partagé entre le conducteur et l'automatisation. Enfin, dans la dernière sous-section, nous abordons l'analyse de la stabilité de l'ensemble du système.




FIGURE 4.17 – Analyse comparative entre les sorties du modèle augmenté Conducteur-Véhicule-Route proposé et les données recueillies sur SHERPA-LAMIH.

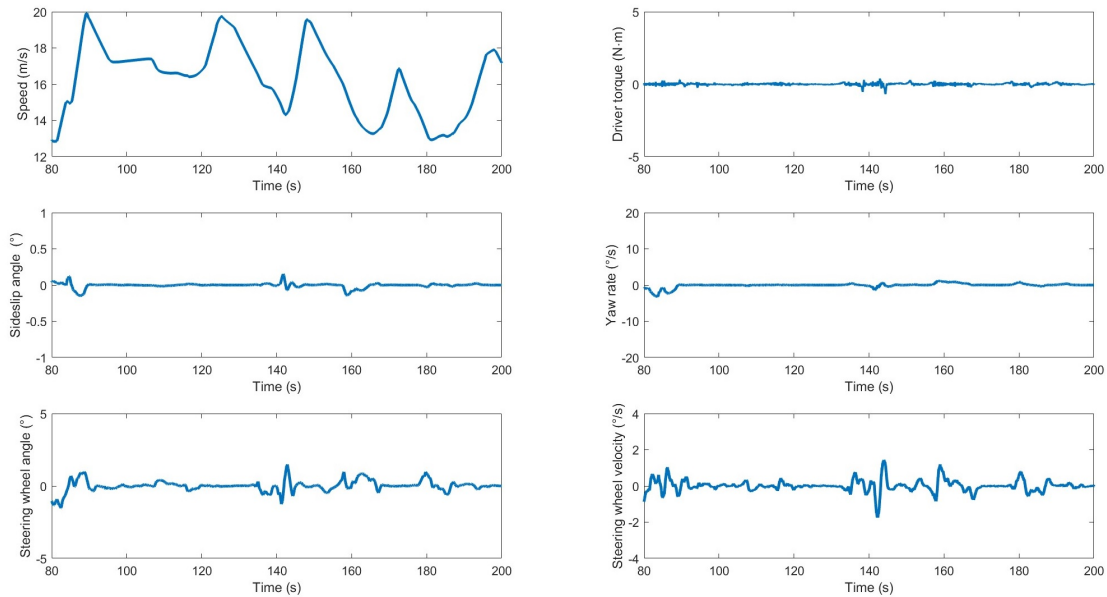


FIGURE 4.18 – Écart entre les prédictions du modèle augmenté Conducteur-Véhicule-Route proposé et les données enregistrées sur SHERPA-LAMIH.

4.6.1 Représentation LPV-TS du Modèle augmenté Conducteur-Véhicule-Route

Veillez noter que les termes $A(t)$ et E dans l'équation (4.8) dépendent des termes mesurés, identifiés et bornés suivants :

$$\left\{ v_x, \frac{1}{v_x}, \frac{1}{v_x^2}, k_1, k_2', k_3 \right\}$$

$$\begin{aligned} v_{\min} &\leq v_x \leq v_{\max} \\ k_{1\min} &\leq k_1 \leq k_{1\max} \\ k'_{2\min} &\leq k'_2 \leq k'_{2\max} \\ k_{3\min} &\leq k_3 \leq k_{3\max} \end{aligned}$$

En utilisant l'approche des secteurs non linéaires [Wang and Tanaka, 2004], un modèle flou T-S exact de l'équation (4.8) peut être obtenu avec $2^6 = 64$ sous-systèmes linéaires. Cependant, afin de réduire significativement la complexité et le conservatisme de la méthode de contrôle proposée, nous effectuons le changement de paramètres suivant, comme utilisé dans le chapitre précédent :

$$\begin{aligned} \frac{1}{v_x} &= \frac{1}{v_0} + \frac{1}{v_1}\alpha, \\ v_x &\approx v_0 \left(1 - \frac{v_0}{v_1}\alpha\right), \\ \frac{1}{v_x^2} &\approx \frac{1}{v_0^2} \left(1 + 2\frac{v_0}{v_1}\alpha\right) \end{aligned} \quad (4.18)$$

où : $\alpha_{\min} \leq \alpha \leq \alpha_{\max}$, $v_0 = \frac{2v_{\min}v_{\max}}{v_{\min}+v_{\max}}$, $v_1 = \frac{2v_{\min}v_{\max}}{v_{\min}-v_{\max}}$.

On peut remarquer que le nouveau paramètre α peut être utilisé pour représenter la variation de v_x entre ses bornes inférieure et supérieure, c'est-à-dire $\alpha_{\min} = -1$ et $\alpha_{\max} = 1$. De plus, v_x , $\frac{1}{v_x}$ et $\frac{1}{v_x^2}$ dans l'équation (5.13) dépendent linéairement du nouveau paramètre α . En substituant ces expressions dans l'équation (4.8), nous obtenons un modèle (C-V-R) dont les matrices d'espace d'état dépendent de $\{\alpha, ; k_1, ; k'_2, ; k_3\}$. En utilisant l'approche des secteurs non linéaires [Wang and Tanaka, 2004], on obtient la représentation LPV floue T-S à 16 règles suivante du modèle (4.8) :

$$\sum : \dot{x} = \left(\sum_{i=1}^{16} h_i(A_i x + E_i d) \right) + Bu \quad (4.19)$$

où A_i et E_i sont calculés selon :

$$\begin{aligned} i = 1 : & \{A(\alpha_{\min}, k_{1\min}, k'_{2\min}, k_{3\min}), E(\alpha_{\min})\} & i = 9 : & \{A(\alpha_{\max}, k_{1\min}, k'_{2\min}, k_{3\min}), E(\alpha_{\max})\} \\ i = 2 : & \{A(\alpha_{\min}, k_{1\max}, k'_{2\min}, k_{3\min}), E(\alpha_{\min})\} & i = 10 : & \{A(\alpha_{\max}, k_{1\max}, k'_{2\min}, k_{3\min}), E(\alpha_{\max})\} \\ i = 3 : & \{A(\alpha_{\min}, k_{1\min}, k'_{2\max}, k_{3\min}), E(\alpha_{\min})\} & i = 11 : & \{A(\alpha_{\max}, k_{1\min}, k'_{2\max}, k_{3\min}), E(\alpha_{\max})\} \\ i = 4 : & \{A(\alpha_{\min}, k_{1\min}, k'_{2\min}, k_{3\max}), E(\alpha_{\min})\} & i = 12 : & \{A(\alpha_{\max}, k_{1\min}, k'_{2\min}, k_{3\max}), E(\alpha_{\max})\} \\ i = 5 : & \{A(\alpha_{\min}, k_{1\max}, k'_{2\max}, k_{3\min}), E(\alpha_{\min})\} & i = 13 : & \{A(\alpha_{\max}, k_{1\max}, k'_{2\max}, k_{3\min}), E(\alpha_{\max})\} \\ i = 6 : & \{A(\alpha_{\min}, k_{1\max}, k'_{2\min}, k_{3\max}), E(\alpha_{\min})\} & i = 14 : & \{A(\alpha_{\max}, k_{1\max}, k'_{2\min}, k_{3\max}), E(\alpha_{\max})\} \\ i = 7 : & \{A(\alpha_{\min}, k_{1\min}, k'_{2\max}, k_{3\max}), E(\alpha_{\min})\} & i = 15 : & \{A(\alpha_{\max}, k_{1\min}, k'_{2\max}, k_{3\max}), E(\alpha_{\max})\} \\ i = 8 : & \{A(\alpha_{\min}, k_{1\max}, k'_{2\max}, k_{3\max}), E(\alpha_{\min})\} & i = 16 : & \{A(\alpha_{\max}, k_{1\max}, k'_{2\max}, k_{3\max}), E(\alpha_{\max})\} \end{aligned}$$

Les 8 fonctions d'appartenance utilisées dans la représentation floue T-S de (4.19) sont définies de la manière suivante :

$$\begin{aligned} m_1^1 &= \frac{\alpha_{\max} - \alpha}{\alpha_{\max} - \alpha_{\min}}, & m_1^2 &= 1 - m_1^1 \\ m_2^1 &= \frac{k_{1\max} - k_1}{k_{1\max} - k_{1\min}}, & m_2^2 &= 1 - m_2^1 \\ m_3^1 &= \frac{k'_{2\max} - k'_2}{k'_{2\max} - k'_{2\min}}, & m_3^2 &= 1 - m_3^1 \\ m_4^1 &= \frac{k_{3\max} - k_3}{k_{3\max} - k_{3\min}}, & m_4^2 &= 1 - m_4^1 \end{aligned}$$

Les non-linéarités dans les conséquences des règles floues sont exprimées de la manière suivante :

$$\begin{aligned}
 h_1 &= m_1^1 \cdot m_2^1 \cdot m_3^1 \cdot m_4^1, & h_9 &= m_1^2 \cdot m_2^1 \cdot m_3^1 \cdot m_4^1 \\
 h_2 &= m_1^1 \cdot m_2^2 \cdot m_3^1 \cdot m_4^1, & h_{10} &= m_1^2 \cdot m_2^2 \cdot m_3^1 \cdot m_4^1 \\
 h_3 &= m_1^1 \cdot m_2^1 \cdot m_3^2 \cdot m_4^1, & h_{11} &= m_1^2 \cdot m_2^1 \cdot m_3^2 \cdot m_4^1 \\
 h_4 &= m_1^1 \cdot m_2^1 \cdot m_3^1 \cdot m_4^2, & h_{12} &= m_1^2 \cdot m_2^1 \cdot m_3^1 \cdot m_4^2 \\
 h_5 &= m_1^1 \cdot m_2^2 \cdot m_3^2 \cdot m_4^1, & h_{13} &= m_1^2 \cdot m_2^2 \cdot m_3^2 \cdot m_4^1 \\
 h_6 &= m_1^1 \cdot m_2^2 \cdot m_3^1 \cdot m_4^2, & h_{14} &= m_1^2 \cdot m_2^2 \cdot m_3^1 \cdot m_4^2 \\
 h_7 &= m_1^1 \cdot m_2^1 \cdot m_3^2 \cdot m_4^2, & h_{15} &= m_1^2 \cdot m_2^1 \cdot m_3^2 \cdot m_4^2 \\
 h_8 &= m_1^1 \cdot m_2^2 \cdot m_3^2 \cdot m_4^2, & h_{16} &= m_1^2 \cdot m_2^2 \cdot m_3^2 \cdot m_4^2
 \end{aligned}$$

4.6.1.1 Validation du modèle augmenté LPV-TS sur SHERPA

Afin de valider le modèle augmenté LPV-TS du système Conducteur-Véhicule-Route sur SHERPA, il est essentiel de procéder au calcul préliminaire des limites des paramètres du modèle conducteur.

Ce calcul des limites des paramètres du conducteur repose sur la mise en œuvre d'un scénario de changement de voie réalisé sur le simulateur SHERPA par six participants distincts, et ce pour quatre scénarios différents. Les trois premiers scénarios mettent en jeu une vitesse constante ($v_x = 70km/h$, $v_x = 90km/h$ et $v_x = 110km/h$), tandis que le quatrième scénario implique une vitesse variable. Chacun des participants a effectué cinq dépassements pour chaque scénario. Le tableau ci-dessous présente les résultats de l'identification en mettant en évidence les valeurs maximales et minimales de chaque paramètre pour chaque scénario.

| Scénario | k_1 | k_2 | k_3 |
|----------|---------------|-----------|----------|
| S1 | [-0.05, 0.19] | [0, 0.4] | [0 2] |
| S2 | [-0.11, 0.07] | [0, 0.53] | [0 2.87] |
| S3 | [-0.19, 0.11] | [0, 0.72] | [0 4.07] |
| S4 | [-0.4, 0.27] | [0, 0.71] | [0 4.82] |

TABLE 4.1 – Les limites minimales et maximales de chaque paramètre pour chaque scénario.

En se basant sur ces résultats, les limites des paramètres du modèle sont établies en tenant compte des valeurs minimales et maximales de ces scénarios (avec une marge d'environ 25% par rapport à ces valeurs). Dans ce contexte, les intervalles obtenus sont les suivants :

$$\begin{aligned}
 k_1 &\in [-0.5, 0.34], \\
 k_2 &\in [0, 0.9], \\
 k_3 &\in [0, 6.02].
 \end{aligned}$$

Suite au calcul des limites paramétriques, le processus de validation du modèle LPV-TS (4.19) sur le simulateur SHERPA-LAMIH est basé sur un scénario de changement de voie sur autoroute. Pour ce faire, les entrées du modèle LPV-TS sont constituées de la vitesse longitudinale du véhicule ainsi que des paramètres variants du modèle conducteur, comme illustré dans la Figure 4.19. Ces quatre paramètres sont fondamentaux pour simuler le comportement du véhicule et du conducteur dans le simulateur.

Les résultats issus de cette étape de validation sont visuellement présentés dans la Figure 4.20. Cette représentation graphique illustre la comparaison entre les prédictions du modèle augmenté LPV-TS et les données réelles enregistrées dans le simulateur. Les courbes superposées montrent une évaluation de la fidélité du modèle CVR proposé par la comparaison entre les réponses du modèle augmenté LPV-TS et les comportements observés du véhicule et du conducteur sur le simulateur SHERPA.




FIGURE 4.19 – Les résultats de l'identification en ligne des paramètres du modèle du conducteur ainsi que la variation de la vitesse du véhicule sur le simulateur SHERPA-LAMIH.




FIGURE 4.20 – Comparaison entre les sorties du modèle augmenté LPV-TS du véhicule et les données obtenues à partir du simulateur SHERPA-LAMIH.

Les erreurs de prédiction du modèle sont illustrées dans la Figure 4.21. En analysant ces résultats, on peut constater que le modèle augmenté LPV-TS représente fidèlement le comportement dynamique du véhicule ainsi que celui du conducteur, observés sur le simulateur SHERPA-LAMIH. Ceci démontre la pertinence du modèle augmenté LPV-TS pour saisir les comportements du véhicule et du conducteur dans différentes situations de conduite.

Ce modèle augmenté LPV-TS sera utilisé pour développer un contrôleur LPV-TS partagé adaptatif. L'objectif de ce contrôleur est d'assurer le maintien de voie du véhicule tout en minimisant, dans le cas d'une conduite partagée, les éventuels conflits entre les actions du conducteur

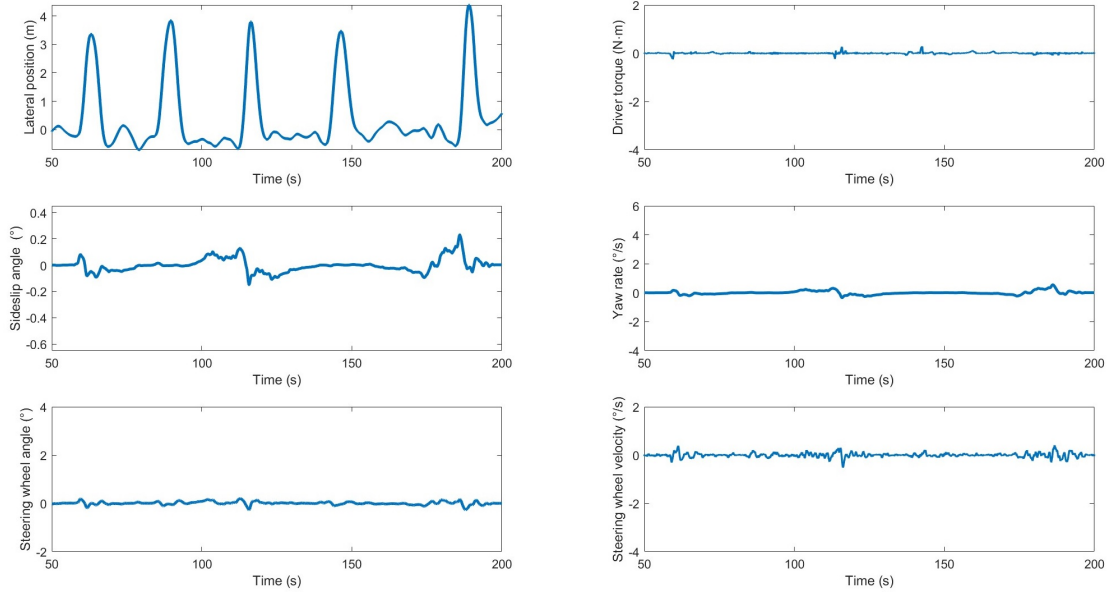


FIGURE 4.21 – Écart entre les prédictions du modèle augmenté LPV-TS proposé et les données enregistrées sur SHERPA-LAMIH.

et celles du système de maintien de voie (LKS).

4.6.2 Conception du contrôleur partagé basée sur l'approche PDC

Tout d'abord, nous définissons la sortie de performance du système (4.19) comme étant :

$$z = Cx = \left[\beta \quad r \quad \psi_L \quad y_L \quad \dot{\delta}_d \quad T_d \right]^T \quad (4.20)$$

Il est important de noter que les variables β , r , ψ_L et y_L dans le vecteur performance z représentent la qualité de suivi de voie pour assurer l'aspect sécurité, tandis que $\dot{\delta}_d$ et T_d sont inclus dans z pour rendre compte du confort de conduite et de la réduction de l'effort du conducteur. Pour mettre en place un tel schéma de contrôle partagé, nous recherchons le contrôleur u , permettant de minimiser la fonction de coût donnée par le critère quadratique de performance suivant :

$$\mathfrak{J} = \int_0^{\infty} \left(z^T(\tau)Qz(\tau) + u^T(\tau)Ru(\tau) \right) d\tau \quad (4.21)$$

Pour la conception du contrôle partagé, nous considérons la loi de commande LPV-TS suivante de type PDC (Parallel Distributed Compensation) partageant les mêmes règles des prémisses du modèle LPV-TS (4.19) :

$$u = \sum_{i=1}^r h_i F_i x \quad (4.22)$$

où les gains de contrôle F_i , avec $i \in 1, 2, \dots, 16$, doivent être déterminés. Les fonctions non-linéaires h_i sont les mêmes que celles du modèle (4.19).

En utilisant la loi de commande (4.22) et le modèle flou T-S (4.19), le système en boucle fermée peut être exprimé comme suit :

$$\dot{x} = \sum_{i=1}^r h_i ((A_i + BF_i)x + E_i d) \quad (4.23)$$

Le résultat suivant fournit une solution de contrôle u , où l'analyse de stabilité est effectuée en utilisant la fonction de Lyapunov suivante :

$$V(x) = x^T P x, \quad P > 0 \quad (4.24)$$

Théorème 4.2. S'il existe une matrice définie positive X , des matrices M_i , avec $i \in 1, 2, \dots, 16$, et un scalaire positif γ , satisfaisant le problème d'optimisation LMI suivant :

$$\Gamma_i \prec 0, \quad i \in \{1, 2, \dots, 16\} \quad (4.25)$$

où

$$\Gamma_i = \begin{bmatrix} He(A_i X + B M_i) & E_i & X C^T & M_i^T \\ * & -\gamma I & 0 & 0 \\ * & * & -Q^{-1} & 0 \\ * & * & * & -R^{-1} \end{bmatrix} \quad (4.26)$$

alors, le contrôleur LPV-TS (4.22) stabilise le système (4.23) et garantit une borne supérieure pour la fonction de coût (4.21) sous condition initiale nulle, comme suit :

$$\mathfrak{J} < \gamma \|d\|^2. \quad (4.27)$$

Ainsi, les gains de rétroaction dans (4.22) peuvent être calculés de la manière suivante :

$$F_i = M_i X^{-1}, \quad i \in \{1, 2, \dots, 16\} \quad (4.28)$$

4.6.3 Analyse de la stabilité

Dans cette sous-section, l'analyse de la stabilité de l'ensemble du système par l'approche de Lyapunov est présentée.

En multipliant (4.25) par $h_i \geq 0$, pour $\forall i \in 1, 2, \dots, 16$, on obtient :

$$\sum_{i=1}^r h_i \Gamma_i \prec 0 \quad (4.29)$$

Pour plus de concision, pour toute matrice de dimensions appropriées χ_i , avec $i \in 1, 2, \dots, 16$, nous notons

$$\chi(\alpha k) = \sum_{i=1}^r h_i \chi_i$$

En utilisant successivement le lemme du complément de Schur, il en résulte que l'inégalité (4.29) est équivalente :

$$\begin{bmatrix} \sum(\alpha k) + M(\alpha k)^T R M(\alpha k) + \nabla & E(\alpha k) \\ * & -\gamma I \end{bmatrix} \prec 0 \quad (4.30)$$

où : $\sum(\alpha k) = He(A(\alpha k)X + B M(\alpha k))$, $\nabla = X C^T Q C X$.

En pré- et post-multipliant (4.30) par $\begin{bmatrix} P & 0 \\ 0 & I \end{bmatrix}$ où $P = X^{-1}$, suivi du changement de variable $M(\alpha k) = F(\alpha k)X$, on obtient :

$$\begin{bmatrix} \partial(\alpha k) + F(\alpha k)^T R F(\alpha k) + C^T Q C & P E(\alpha) \\ * & -\gamma I \end{bmatrix} \prec 0 \quad (4.31)$$

où $\partial(\alpha k) = He(P(A(\alpha k) + B F(\alpha k)))$.

En pré- et post-multipliant (4.31) par $[x, d]^T$ et sa transposée, on obtient

$$\dot{V}(x) + z^T Qz + u^T Ru < \gamma d^T d \quad (4.32)$$

où $\dot{V}(x)$ est la dérivée temporelle de la fonction de Lyapunov candidate (4.24) le long de la trajectoire de (4.23). À partir de (4.32), on distingue les deux cas suivants.

- Pour le système sans perturbation (c'est-à-dire $d = 0$), $\dot{V}(x) < 0$, pour $\forall x \neq 0$, ce qui signifie que le système (4.23) avec le contrôleur (4.22) est globalement exponentiellement stable.
- Pour le système perturbé (c'est-à-dire $d \neq 0$), il découle de (4.32) que $\dot{V}(x) < \gamma \|d\|^2$. Alors, en intégrant les deux côtés de l'équation (4.32) de 0 à ∞ , on obtient :

$$V(\infty) - V(0) + \mathfrak{S} < \gamma \int_0^{\infty} d^T(t)d(t). \quad (4.33)$$

Puisque $V(\infty) > 0$, sous condition initiale nulle, c'est-à-dire $V(0) = 0$, il est clair que l'inégalité (4.33) implique l'inégalité (4.27). Notez également à partir de (4.27) que la fonction de coût adaptative \mathfrak{S} peut être minimisée en minimisant γ .

4.7 Validation expérimentale

Cette section présente des résultats expérimentaux qui mettent en évidence les performances du contrôleur partagé proposé, en se concentrant sur la réduction des conflits et le maintien de la trajectoire. Ces résultats sont issus d'expériences interactives menées sur le simulateur de conduite dynamique SHERPA. Toutes les évaluations de performance sont réalisées sur une piste d'essai autoroutière à deux voies avec circulation à sens unique. Les valeurs des paramètres mathématiques du modèle du véhicule (SHERPA) et celles du contrôleur sont répertoriées dans le Tableau 4.2.

Cette section est organisée en deux sous-sections pour fournir une vue d'ensemble complète du chapitre.

La première sous-section se concentre sur la comparaison entre le contrôleur partagé décrit dans l'article [Nguyen et al., 2017], qui repose sur un modèle de conducteur avec des paramètres constants, et celui présenté dans ce chapitre. Cette comparaison est réalisée dans le cadre d'un scénario d'évitement d'obstacles.

La deuxième sous-section consiste en une évaluation objective qui vise à comparer les performances du contrôleur partagé issu de l'article [Nguyen et al., 2017] dans un scénario d'évitement d'obstacles, avec celles du contrôleur proposé dans ce chapitre. Cette évaluation permet de mettre en lumière les avantages et les améliorations apportés par le contrôleur présenté dans ce chapitre.

4.7.1 Performance du contrôle partagé adaptatif

Dans cette sous-section, nous allons procéder à une comparaison entre notre contrôleur partagé et celui proposé dans [Nguyen et al., 2017]. Ce dernier utilise un contrôle partagé basé sur un modèle de conducteur avec des paramètres constants pour un scénario de maintien de voie (ces paramètres sont obtenus hors ligne). Cette comparaison est effectuée dans le cadre d'un test d'évitement d'obstacles sur une autoroute. Trois obstacles ont été placés, et trois conducteurs différents ont été sollicités à effectuer des changements de voie afin de les éviter en utilisant le mode de contrôle partagé.

Les résultats du test sont exposés dans les Figures 4.22 et 4.23, où la Figure 4.23 représente le comportement du système pour le premier conducteur. Il est clair que les trois conducteurs ont rencontré des difficultés à dépasser les obstacles en utilisant le contrôleur basé sur les paramètres constants du conducteur, où les couples appliqués par le conducteur et le contrôleur étaient plus

| Par. | Valeur | Unit | Par. | Valeur | Unit |
|-----------|--------|----------------|-----------|--------------|----------------------|
| l_f | 1.3 | m | C_r | 59000 | N/rad |
| l_r | 1.6 | m | R_s | 16 | — |
| l_w | 0.4 | m | B_s | 5.73 | — |
| l_s | 5 | m | T_n | 0.11 | s |
| η_t | 0.13 | m | v_x | [5, 30] | m/s |
| D_{far} | 10 | m | k_1 | [-0.5, 0.34] | $(N \cdot m/^\circ)$ |
| m | 2024 | kg | k'_2 | [0, 1,204] | $(N \cdot m/^\circ)$ |
| I_z | 2800 | $kg \cdot m^2$ | k_3 | [0, 6.02] | $(N \cdot m/^\circ)$ |
| J_s | 0.05 | $kg \cdot m^2$ | λ | 30 | — |
| C_f | 57000 | N/rad | | | |

TABLE 4.2 – Les valeurs numériques des paramètres pour le modèle mathématique du véhicule SHERPA-LAMIH et du conducteur.

importants. En revanche, le contrôleur partagé que nous avons proposé, utilisant le modèle de conducteur avec des paramètres estimés en ligne, a permis aux trois conducteurs de dépasser facilement les obstacles avec un couple conducteur beaucoup moins important. Cela s'explique par le fait qu'en utilisant un modèle avec des paramètres constants pour l'évitement d'obstacles, le modèle peut devenir non représentatif. Ce résultat confirme les conclusions obtenues lors de la phase d'identification, illustrées dans les Figures (4.16, 4.19), où l'on peut observer que le comportement du conducteur évolue en fonction de la situation. Ces résultats démontrent encore une fois l'efficacité de notre méthode pour adapter le contrôle partagé à divers scénarios et le personnaliser à chaque conducteur, en tenant compte de son impédance (rigidité musculaire) estimée en temps réel.

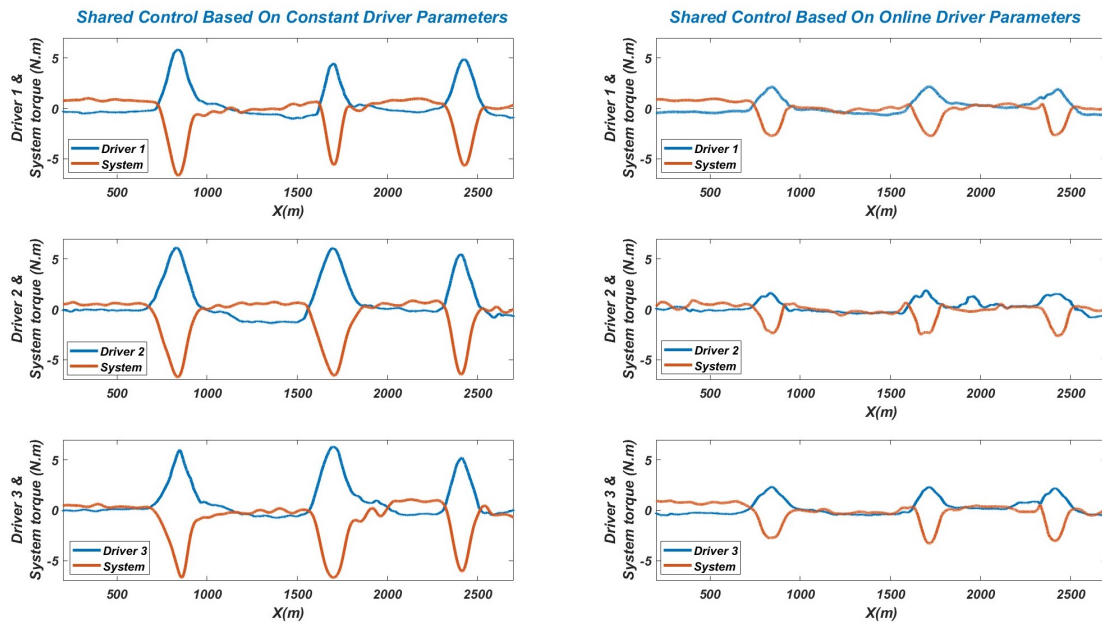


FIGURE 4.22 – Les performances du contrôleur partagé basé sur les paramètres constants et dynamiques du conducteur lors d'un test d'évitement d'obstacles sur le simulateur SHERPA-LAMIH.




FIGURE 4.23 – Les performances du contrôleur partagé basé sur les paramètres constants et dynamiques du conducteur lors d'un test d'évitement d'obstacles sur le simulateur SHERPA-LAMIH pour le premier conducteur.

4.7.2 Evaluation objective

Pour renforcer davantage les résultats déjà obtenus, une évaluation objective basée sur des métriques, visant à analyser l'interaction entre le conducteur et le système LKS ainsi que la qualité du contrôle a été menée. L'interaction a été évaluée à travers le couple exercé sur le volant et la vitesse angulaire du volant pendant la phase de test, en utilisant les deux contrôleurs : celui basé sur les paramètres constants du conducteur (Shared_CDP) et le contrôleur proposé basé sur les paramètres adaptés en ligne du conducteur (Shared_ODP). Les quatre métriques StD , StC , $Conflict$ et SW (voir la Section 3.8.4.1) ont été considérées dans cette étude, de la même manière que dans le chapitre précédent.

Les résultats de l'analyse objective sont représentés dans la Figure 4.24. Comme illustré, l'indicateur d'effort exercé par le conducteur et par le système, en utilisant un contrôleur qui ne prend pas en compte l'adaptation au niveau du comportement du conducteur lorsqu'il interagit avec le LKS (Shared_CDP), est notablement élevé en comparaison avec celui de l'approche proposée (Shared_ODP). Cette observation met en évidence que le contrôleur que nous avons proposé permet de minimiser l'effort imposé au conducteur lors du fonctionnement en mode de contrôle partagé, tout en réduisant l'effort requis du système pour éviter la saturation de la commande et protéger ainsi le moteur de la direction du véhicule de la surchauffe.

De plus, lorsque nous examinons l'indicateur de conflit, il est clair que l'approche du contrôle partagé adaptatif proposée (Shared_ODP) réduit dynamiquement les conflits entre le système et le conducteur par rapport à l'approche non adaptative (Shared_CDP). En analysant le dernier indicateur, qui reflète la charge de travail de conduite, il devient évident que le contrôleur adaptatif proposé diminue la charge physique de braquage par rapport au contrôleur non adaptatif (Shared_CDP).

En résumé, le contrôleur que nous avons développé permet de minimiser l'effort requis du conducteur, l'effort demandé au système, les conflits entre le conducteur et le système, ainsi que la charge physique de braquage au volant lors de l'utilisation du mode de contrôle partagé. Les résultats obtenus ont clairement démontré l'efficacité de notre méthode de contrôle partagé

dans la réduction de l'effort du conducteur et du conflit entre le système de maintien de voie et le conducteur. Ceci favorise considérablement l'amélioration de la sécurité du véhicule et de l'acceptabilité de ce type de systèmes par les conducteurs.

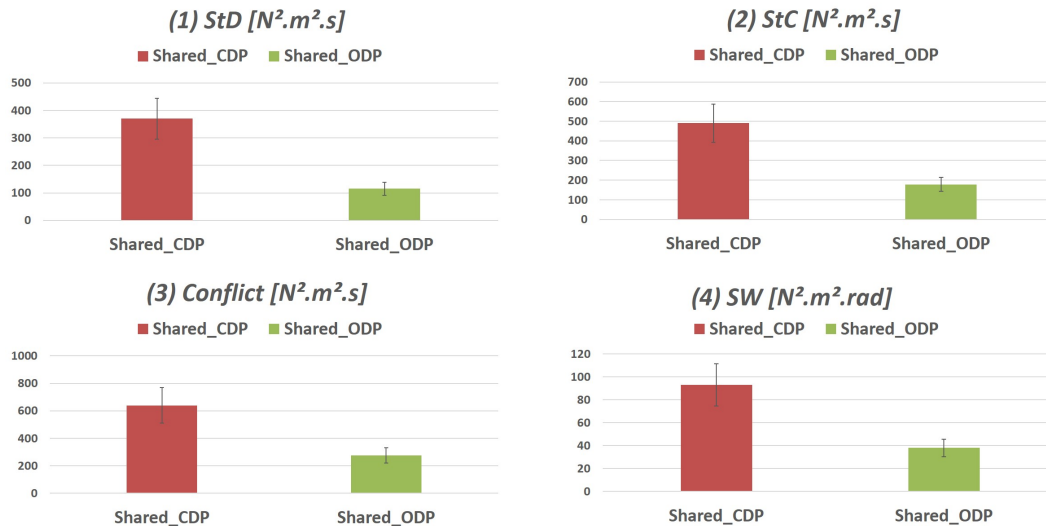


FIGURE 4.24 – Résultats de l'évaluation objective du contrôleur partagé basé sur les paramètres du conducteur constants et dynamiques, lors d'un test d'évitement d'obstacles sur le simulateur SHERPA.

4.8 Conclusion

Ce chapitre a introduit une nouvelle stratégie de contrôle partagé adaptatif, fondée sur l'identification en ligne des paramètres du conducteur, dans le but de minimiser les conflits entre le système de maintien de voie et le conducteur humain. Pour ce faire, un modèle de conducteur intégrant les aspects visuels et neuromusculaires a été développé. Ce modèle a été simplifié pour faciliter la conception du contrôle partagé.

Par la suite, une approche basée sur le principe de stabilité au sens de Lyapunov a été proposée pour l'identification en ligne des paramètres du conducteur. Cette approche vise à rendre le modèle du conducteur adaptatif en fonction de la situation de conduite et personnalisé pour chaque conducteur. La stabilité en boucle fermée du système Conducteur-Véhicule-Route, doté du modèle de conducteur adaptatif et en tenant compte des variations de la vitesse longitudinale du véhicule, a été garantie à l'aide des arguments de stabilité de Lyapunov. La conception du contrôleur PDC a été formulée sous la forme d'un problème d'optimisation convexe sous contraintes LMI.

Les approches que nous avons proposées, à savoir l'approche d'identification en ligne et l'approche du contrôleur partagé, ont été évaluées expérimentalement en utilisant le simulateur de conduite dynamique et interactif pleine échelle SHERPA. Ces évaluations ont été menées dans des situations de conduite réalistes, en se concentrant sur des scénarios d'évitement d'obstacles. Les résultats obtenus à travers ces expériences ont clairement mis en évidence l'efficacité de la méthode de contrôle partagé que nous avons développée. Cette méthode a démontré sa capacité à réduire notablement l'effort requis du conducteur tout en minimisant les conflits entre le système de maintien de voie et le conducteur.

Néanmoins, cette méthode ne tient pas compte de la possible inattention ou hypovigilance des conducteurs, qui a été abordée dans le chapitre précédent. Le chapitre suivant propose une approche de contrôle partagé combinant les résultats issus des chapitres 3 et 4. L'objectif

est de capitaliser sur les avantages des deux approches présentées précédemment. Cette nouvelle approche intègre une fonction de coût à multi-objectif permettant de prendre en compte, dans la conception de la commande, les décisions d'un superviseur de conduite au niveau tactique, ainsi qu'un modèle de conducteur adaptatif afin de personnaliser le système de conduite automatisée.

Chapitre 5

Contrôle partagé adaptatif LPV basé sur l'impédance du conducteur et une fonction de coût multi-objectif

Sommaire

| | | |
|------------|--|------------|
| 5.1 | Introduction | 159 |
| 5.2 | Contribution | 159 |
| 5.3 | Activité du conducteur & niveau d'assistance variable | 160 |
| 5.4 | Dynamique Conducteur-Véhicule-Route | 160 |
| 5.4.1 | Modèle d'interaction dynamique du conducteur | 161 |
| 5.4.2 | Modèle Intégré CVR | 162 |
| 5.5 | Approche d'identification en ligne de l'impédance du conducteur | 162 |
| 5.5.1 | Le processus d'identification en ligne de l'impédance du conducteur avec l'approche MRIL | 162 |
| 5.5.2 | Validation du modèle CVR | 166 |
| 5.6 | Conception du contrôleur partagé haptique LPV basé sur l'impédance du conducteur | 166 |
| 5.6.1 | Représentation TS du Modèle Conducteur-Véhicule-Route | 168 |
| 5.6.2 | Conception du contrôleur PDC pour le contrôle partagé haptique LPV | 169 |
| 5.6.3 | Analyse de la stabilité | 173 |
| 5.7 | Validation expérimentale | 174 |
| 5.7.1 | Les performances du contrôle partagé LPV multi-objectif | 174 |
| 5.7.2 | Expériences de test utilisateur | 176 |
| 5.8 | Conclusion | 179 |

5.1 Introduction

Dans le chapitre 3, nous avons présenté une méthode de conception du contrôle partagé LPV-TS optimal pour les systèmes de maintien de voie coopératifs (LKS), qui repose sur l'utilisation d'une fonction de coût multi-objectif LPV. Cette approche a permis de considérer, dans le contrôleur, une variable de décision fournie par un superviseur de conduite calculée au niveau tactique en prenant en compte la disponibilité et l'activité du conducteur.

Dans le chapitre 4, nous nous sommes focalisés sur le problème de la prise en compte des caractéristiques de conduite du conducteur par l'introduction d'un modèle conducteur LPV pour le développement d'une approche de contrôle partagé LPV adaptatif. Ce modèle capture en temps réel les variations du comportement du conducteur dans le processus de conception du contrôle, visant ainsi à obtenir une solution plus personnalisée.

Le présent chapitre est dédié au développement d'une nouvelle approche de contrôle partagé coopératif et auto-adaptatif dont l'architecture globale est représentée sur la Figure 5.1. Cette approche se fonde sur le principe d'un contrôle centré sur l'humain, en tirant parti des avantages et des résultats des deux stratégies précédemment exposées dans les chapitres 3 et 4, à savoir l'utilisation d'une fonction de coût adaptative et multi-objectif, combinée à l'intégration d'un modèle dynamique de comportement du conducteur pour prendre en compte son impédance lors de l'interaction avec le volant.

5.2 Contribution

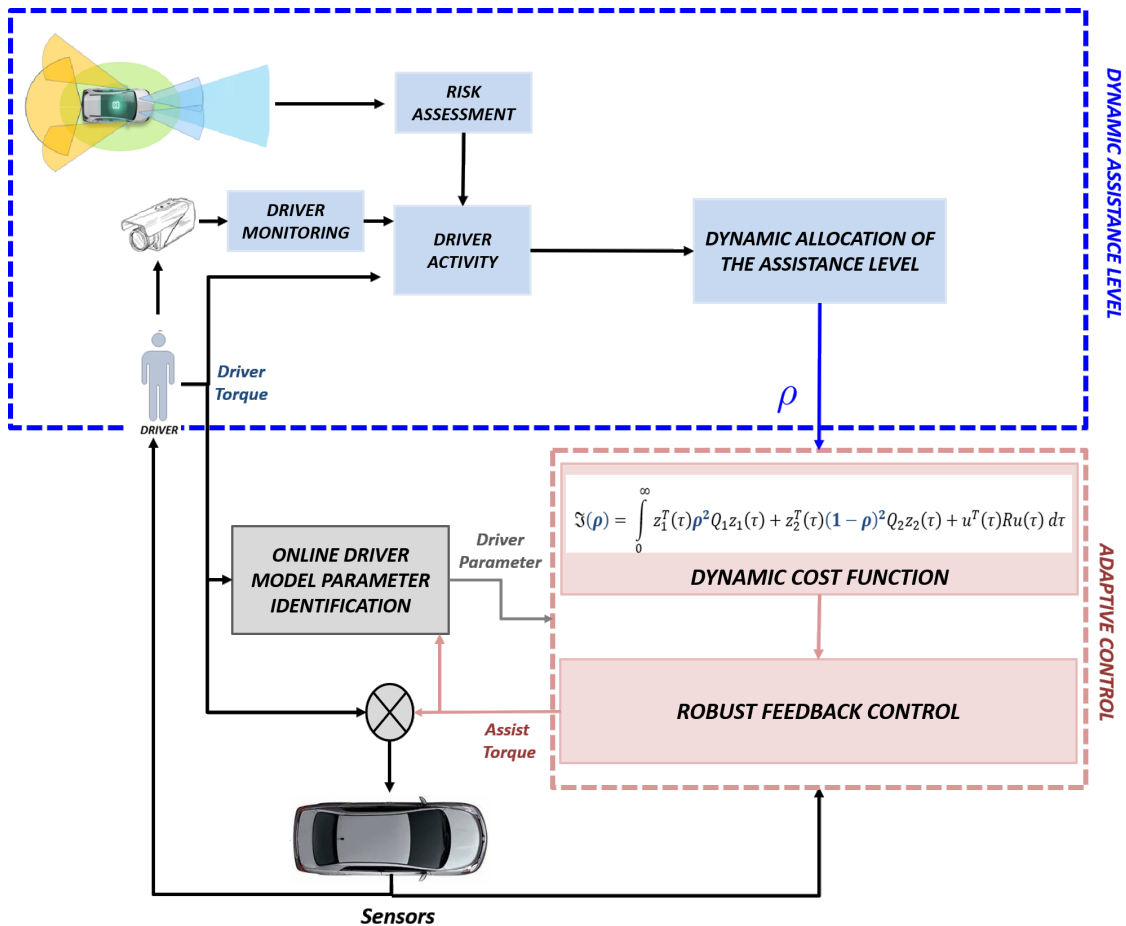


FIGURE 5.1 – La stratégie de contrôle partagé adaptatif multi-objectif et coopératif.

La conception du contrôleur partagé adaptatif multi-objectif et coopératif repose sur une fonction de coût dynamique qui s'ajuste en fonction du niveau d'assistance fourni par le superviseur de conduite. Ce niveau d'assistance est déterminé en se basant sur l'activité et la disponibilité du conducteur, ainsi que sur les risques environnants. Cette nouvelle conception pondère les deux critères de performance, permettant ainsi de choisir entre accompagner le conducteur dans sa conduite et la réalisation de ses manœuvres, et l'aide au maintien de voie du véhicule et à la prévention des collisions.

Les principales contributions de ce travail peuvent être résumées comme suit :

- Proposition d'un nouveau modèle simplifié d'interaction du conducteur avec le volant, en se concentrant sur la prise en compte de l'impédance (rigidité musculaire) physique associée à cette interaction.
- Développement d'une approche d'estimation en ligne de l'impédance du conducteur : l'approche d'estimation MRIL proposé dans le chapitre 4 est utilisée pour estimer l'impédance du conducteur qui sera intégrée dans le modèle de synthèse Conducteur-Véhicule-Route (CVR) LPV.
- L'approche de contrôle partagé adaptatif : Cette approche introduit une assistance adaptative basée sur la disponibilité et l'activité du conducteur, ainsi que sur les conditions de conduite. Cela est réalisé en utilisant une fonction de coût multi-objectif et dynamique, qui se distingue des méthodes existantes par sa capacité à s'adapter en temps réel.
- Prise en compte des non-linéarités : Les variations en temps réel de la vitesse du véhicule, de l'impédance du conducteur et de la fonction de coût multi-objectif dynamique sont prises en compte à travers d'une approche LPV. Une forme floue Takagi-Sugeno (T-S) est utilisée pour la conception du système LKS centré sur l'humain basé sur l'approche PDC (Parallel Distributed Compensation).
- Analyse de la stabilité : L'analyse de la stabilité en boucle fermée du contrôle partagé adaptatif (LPV) est réalisée à l'aide d'arguments de stabilité de Lyapunov.
- Validation par test utilisateurs : Des expériences ont été menées avec le simulateur de conduite dynamique SHERPA pour évaluer l'acceptabilité du conducteur envers le système de contrôle partagé adaptatif. Ces expériences ont démontré l'efficacité de l'approche pour améliorer la sécurité et le confort de conduite.

5.3 Activité du conducteur & niveau d'assistance variable

Dans cette section, nous résumons la dynamique de l'activité du conducteur et le niveau d'assistance dynamique tels qu'ils ont été exposés dans le Chapitre 3.

Dans ce chapitre, l'activité du conducteur utilisée est comme déjà exposée dans la Section 3.4.1, où nous avons présenté un modèle de l'activité du conducteur (DA) qui se compose de trois composantes (voir l'équation (3.5)) : une composante de "Sous-charge" représentant l'aspect mental du conducteur (voir l'équation (3.1)), une composante de "Charge normale" représentant à la fois l'aspect mental et physique du conducteur (voir l'équation (3.2)), et une composante de "Surcharge" qui englobe non seulement l'état mental et physique du conducteur, mais également l'évaluation des risques associés à la situation de conduite (voir l'équation (3.4)).

De même, le calcul de la dynamique du niveau d'assistance ρ , qui prend en compte l'activité du conducteur DA, est utilisé comme le montre l'équation (3.6) présentée dans la Section 3.4.2.

5.4 Dynamique Conducteur-Véhicule-Route

Dans cette section, nous présentons le modèle simplifié de l'interaction du conducteur avec le volant. Ensuite, nous exposons la dynamique intégrée du véhicule en boucle fermée avec le conducteur.

5.4.1 Modèle d'interaction dynamique du conducteur

Dans le cadre de l'intégration des interactions entre le conducteur et le système au niveau du volant, une approche consiste à augmenter le modèle utilisé pour la synthèse de la commande avec un modèle conducteur. Pour évaluer le système d'assistance, un critère couramment utilisé est la courbe de Lissajous, qui décrit la relation entre le couple exercé par le conducteur et l'angle de braquage du volant (c'est-à-dire la rigidité du conducteur). En conduite normale, le conducteur fournit un couple pour tourner le volant, auquel s'ajoute un couple d'assistance fourni par un moteur électrique, ce qui réduit le couple exercé par le conducteur. Pour modéliser cette interaction, un modèle conducteur simplifié est proposé (voir Figure 5.2), qui prend en compte la rigidité du conducteur ("La rigidité θ_s est liée aux caractéristiques d'impédance des muscles du bras du conducteur") [Pick and Cole, 2007, Boehm et al., 2016], le couple d'assistance et le système neuromusculaire.

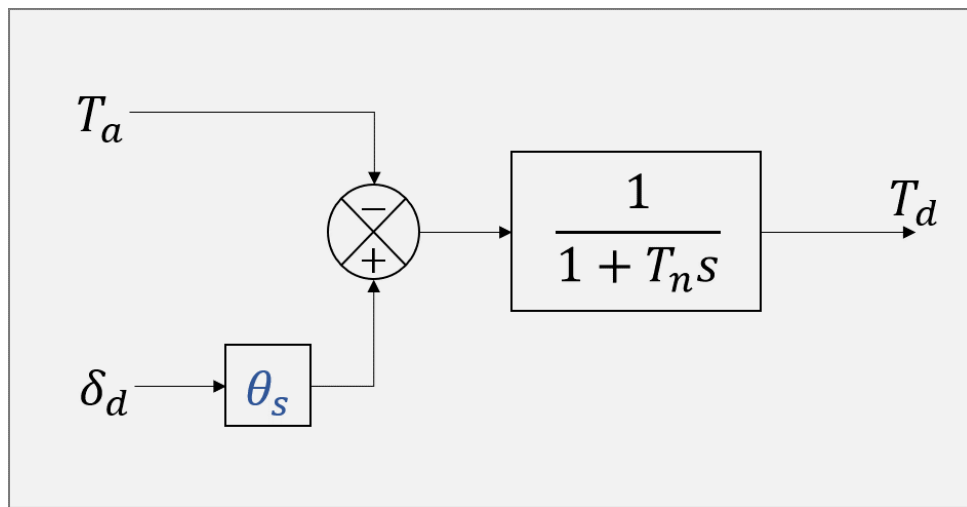


FIGURE 5.2 – Modèle d'interaction dynamique du conducteur.

Le modèle conducteur que nous proposons prend en compte des paramètres clés pour modéliser l'interaction entre le conducteur et le système au niveau du volant. Notamment, le coefficient de rigidité du conducteur est représenté par θ_s , tandis que le couple d'assistance fourni par le moteur électrique est noté T_a . Le couple exercé par le conducteur est représenté par T_d . De plus, la constante T_n est également utilisée dans le modèle, et sa valeur est déterminée en fonction de la méthodologie décrite dans [Sentouh et al., 2009]. En combinant tous ces éléments, le modèle conducteur proposé est capable de saisir les interactions physiques au volant entre le conducteur et le système, ce qui permet d'évaluer l'efficacité des systèmes d'assistance à la conduite.

À partir de la Figure 5.2, le modèle conducteur peut être écrit comme suit :

$$\dot{T}_d = a_d T_d + b_d u_d \quad (5.1)$$

avec : $a_d = -\frac{1}{T_n}$, $b_d = \frac{1}{T_n}$, et u_d étant l'entrée du modèle.

$$u_d = \theta_s \delta_d - u \quad (5.2)$$

où θ_s représente le coefficient de rigidité du conducteur, représentant l'impédance de ce dernier. δ_d est l'angle de braquage du conducteur au volant, et $u = T_a$ est le couple d'assistance.

L'équation (5.2) implique que le paramètre θ_s est inconnu, ce qui nécessite une identification en ligne de ce paramètre en utilisant l'approche d'identification présentée dans le chapitre 4 pour estimer sa valeur. Cette approche sera expliquée dans la section suivante.

5.4.2 Modèle Intégré CVR

Il convient de rappeler que la dynamique véhicule-route utilisée dans ce manuscrit est dérivée du modèle bicyclette, tel qu'expliqué dans le chapitre 3 (voir la Section 3.5.1). À partir des dynamiques (3.10), (5.1) et (5.2), le modèle Conducteur-Véhicule-Route peut être formulé comme suit :

$$\dot{x} = Ax + Bu + Ed \quad (5.3)$$

où $x = [\beta \quad r \quad \psi_L \quad y_L \quad \delta_d \quad \dot{\delta}_d \quad T_d]^T$ est le vecteur d'état, $u = T_a$ est l'entrée de commande, $d = [f_w, \rho_c]^T$ est le vecteur de perturbations, et

$$A = \begin{bmatrix} -\frac{2(C_f+C_r)}{mv_x} & \frac{2(C_rl_r-C_fl_f)}{mv_x^2} - 1 & 0 & 0 & \frac{2C_f}{mv_x R_s} & 0 & 0 \\ \frac{2(C_rl_r-C_fl_f)}{I_z} & -\frac{2(C_rl_r^2+C_fl_f^2)}{v_x I_z} & 0 & 0 & \frac{2C_f l_f}{I_z R_s} & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ v_x & l_s & v_x & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ \frac{2C_f \eta_t}{J_s R_s} & \frac{2C_f l_f \eta_t}{v_x J_s R_s} & 0 & 0 & -\frac{2C_f \eta_t}{J_s R_s^2} & -\frac{B_s}{J_s} & \frac{1}{J_s} \\ 0 & 0 & 0 & 0 & \frac{\theta_s}{T_n} & 0 & -\frac{1}{T_n} \end{bmatrix},$$

$$B = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & \frac{1}{J_s} & -\frac{1}{T_n} \end{bmatrix}^T,$$

$$E = \begin{bmatrix} \frac{1}{mv_x} & \frac{l_w}{I_z} & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & -v_x & 0 & 0 & 0 & 0 \end{bmatrix}^T.$$

5.5 Approche d'identification en ligne de l'impédance du conducteur

Comme déjà mentionné dans le Chapitre 4, l'approche MRIL (Model Reference Identification-based Lyapunov approach) est utilisée pour estimer la valeur du paramètre inconnu du conducteur θ_s (son impédance) à partir des mesures en temps réel des variables du système.

5.5.1 Le processus d'identification en ligne de l'impédance du conducteur avec l'approche MRIL

L'objectif est de concevoir un estimateur pour l'identification en ligne de l'impédance du conducteur qui garantit la stabilité asymptotique du système en boucle fermée (5.1), comme illustré dans la Figure 5.3.

Le schéma d'identification se compose de trois blocs. Le premier bloc est le modèle du conducteur proposé avec le paramètre ajustable θ_s ((5.1),(5.2)). Le deuxième bloc est le mécanisme d'adaptation contenant l'algorithme d'adaptation utilisé pour l'identification de l'impédance du conducteur. Le troisième bloc représente le modèle de référence, ce dernier étant décrit par l'équation suivante :

$$\dot{T}_{dm} = a_d T_{dm} + b_d u_{dm} \quad (5.4)$$

où T_{dm} représente la trajectoire souhaitée (le couple conducteur mesuré) que T_d dans (5.1) doit suivre, et $u_{dm} = \theta_{sm} \delta_d - u$ est l'entrée du modèle de référence où θ_{sm} est l'impédance du conducteur. $a_d = -\frac{1}{T_n}$ (qui est négatif), et $b_d = \frac{1}{T_n}$, comme utilisé dans (5.1).

L'algorithme d'adaptation utilisé pour l'identification en ligne de l'impédance du conducteur est donné par la loi suivante :

$$\dot{\theta}_s = -\lambda \delta_d E T_d \quad (5.5)$$

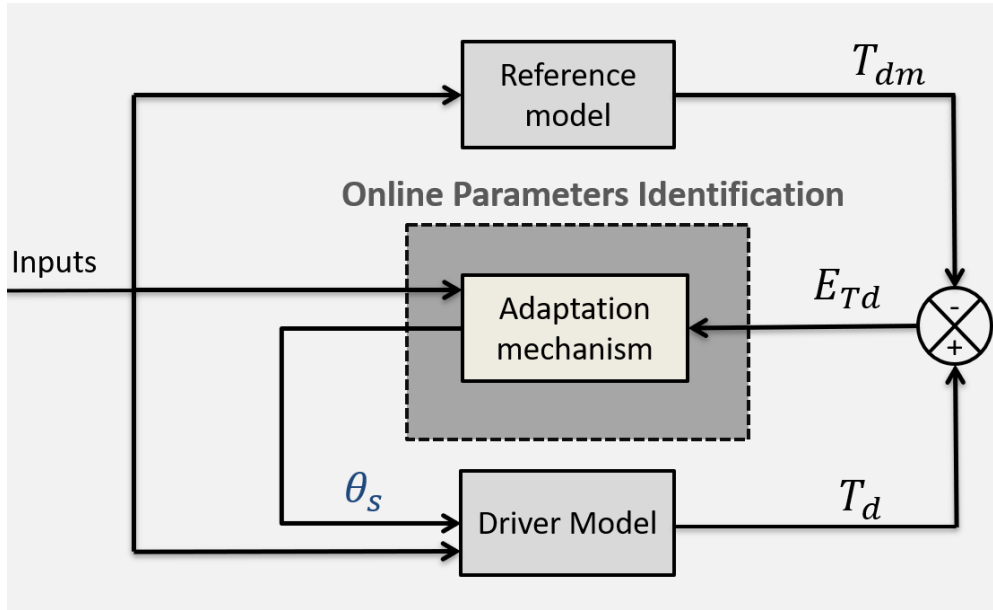


FIGURE 5.3 – Schéma de l'approche d'identification en ligne de l'impédance du conducteur.

avec λ représente un paramètre d'adaptation positif. E_{Td} l'erreur de suivi définie comme $E_{Td} = T_d - T_{dm}$, et elle satisfait l'équation suivante :

$$\dot{E}_{Td} = a_d E_{Td} + b_d (\theta_s - \theta_{sm}) \delta_d \quad (5.6)$$

Nous allons détailler par la suite la méthodologie utilisée pour déterminer la loi d'adaptation (5.5).

Théorème 5.1. Considérons le système décrit par l'équation (5.1), et un modèle de référence décrit par l'équation (5.4) dont l'entrée et la variable d'état sont bornées. Si nous appliquons l'entrée du système décrite par (5.2) au système dont le paramètre est ajusté et identifié par l'algorithme (5.5), alors la sortie du système en boucle fermée est bornée pour tout signal d'entrée borné, et l'erreur de suivi converge asymptotiquement vers zéro.

L'analyse de stabilité du système en boucle fermée est basée sur la fonction de Lyapunov suivante :

$$V_{Td} = \frac{1}{2} (E_{Td}^2 + \frac{b_d}{\lambda} (\theta_s - \theta_{sm})^2) \quad (5.7)$$

La dérivation de la fonction de Lyapunov (5.7) donne :

$$\dot{V}_{Td} = E_{Td} \dot{E}_{Td} + \frac{b_d}{\lambda} (\dot{\theta}_s (\theta_s - \theta_{sm})) \quad (5.8)$$

Remplaçons (5.6) dans (5.8) et après simplification, nous obtenons :

$$\dot{V}_{Td} = a_d E_{Td}^2 + \frac{b_d}{\lambda} ((\theta_s - \theta_{sm}) (\dot{\theta}_s + \lambda \delta_d E_{Td})) \quad (5.9)$$

En utilisant le mécanisme d'adaptation et d'identification (5.5), on obtient :

$$\dot{V}_{Td} = a_d E_{Td}^2 \quad (5.10)$$

Comme $V_{Td}(t)$ est une fonction de Lyapunov définie positive, la dérivée de $V_{Td}(t)$ par rapport au temps est négative semi-définie car a_d est négatif. Cela implique que $V_{Td}(t) \leq V_{Td}(0)$ et donc que E_{Td} et θ_s sont bornés. Ainsi, $T_d = E_{Td}(t) + T_{dm}$ est également borné et lorsque nous calculons la deuxième dérivée de la fonction de Lyapunov, nous obtenons :

$$\ddot{V}_{Td} = 2a_d E_{Td} \dot{E}_{Td} \quad (5.11)$$

remplaçant (5.6) dans (5.11) et après simplification, on obtient :

$$\ddot{V}_{Td} = 2a_d E_{Td} (a_d E_{Td} + b_d (\theta_s - \theta_{sm}) \delta_d) \quad (5.12)$$

Comme l'entrée, δ_d , et E_{Td} sont bornés, alors \ddot{V}_{Td} est borné, donc \dot{V}_{Td} est uniformément continue, puis l'erreur E_{Td} converge vers 0.

5.5.1.1 Validation du modèle d'interaction dynamique du conducteur

Afin de valider et analyser le comportement du conducteur dans diverses situations, une identification paramétrique a été effectuée selon trois modes de conduite distincts : en mode partagé avec le système LKS, en mode d'assistance DAE (Direction Assistée Electrique), ainsi qu'en mode manuel pour le scénario d'évitement de trois obstacles, le tout avec le même conducteur, et à une vitesse constante de $v_x = 25m/s$.

Les résultats de l'identification en ligne des paramètres du conducteur pour chacun de ces trois scénarios sont illustrés respectivement dans les Figures 5.4, 5.5, et 5.6 (avec assistance LKS et DAE, et sans assistance). Il est notable que la sortie du modèle, représentée par le couple de braquage, correspond parfaitement à celle produite par le simulateur dans les trois scénarios. Toutefois, la variation paramétrique du conducteur diffère selon les trois tests. Ainsi, il est possible de conclure que le comportement en terme d'interaction au volant du conducteur n'est pas fixe, mais évolue en fonction de la situation rencontrée, corroborant ainsi les résultats du chapitre précédent.




FIGURE 5.4 – Les résultats de l'identification en ligne de paramètre du conducteur en utilisant le système LKS pour l'évitement d'obstacles sur le simulateur SHERPA.

Il est également intéressant de noter que dans le cas de conflit, comme observé dans le premier scénario entre le système LKS et le conducteur, la rigidité du conducteur (θ_s) atteint une valeur élevée, jusqu'à $\theta_{smax} = 4.73$. En revanche, la valeur maximale la plus basse parmi

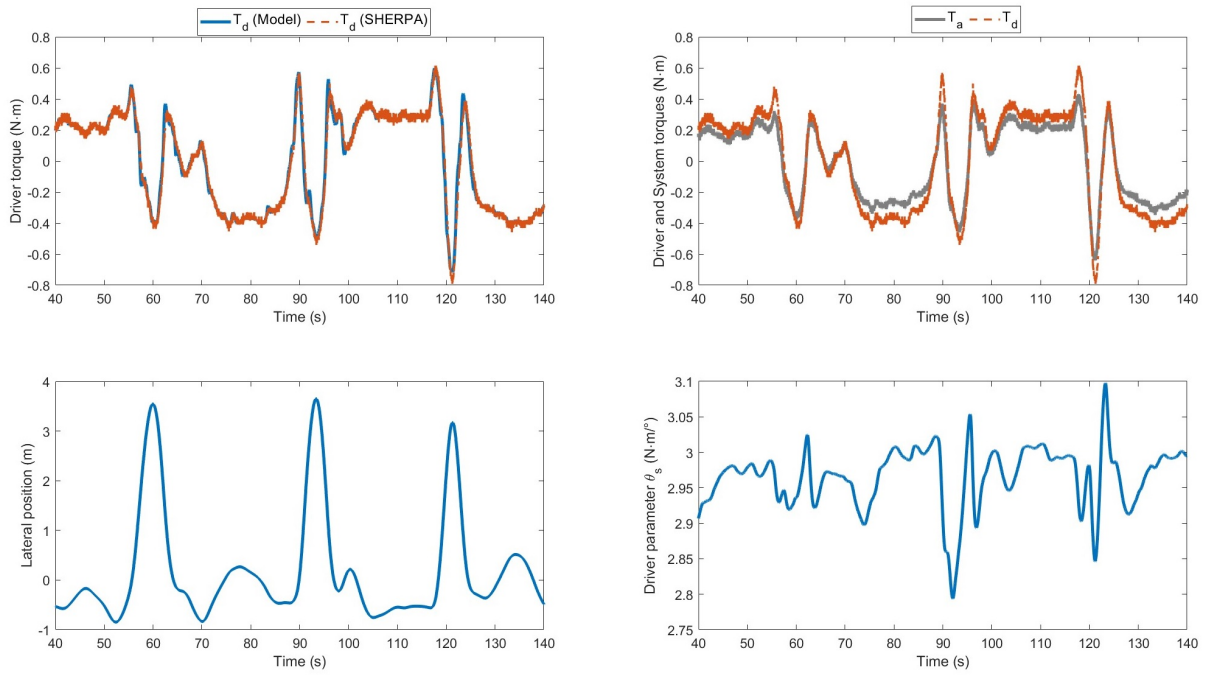


FIGURE 5.5 – Les résultats de l'identification en ligne de paramètre du conducteur en utilisant le système d'assistance DAE pour l'évitement d'obstacles sur le simulateur SHERPA.




FIGURE 5.6 – Les résultats de l'identification en ligne des paramètres du conducteur en mode manuel et sans assistance pour l'évitement d'obstacles sur le simulateur SHERPA.

les trois tests est enregistrée dans le deuxième scénario (avec le DAE comme assistance), où la valeur de rigidité atteint $\theta_{smax} = 3.1$.

Ces résultats ont des implications significatives pour le développement des systèmes d'assistance à la conduite plus adaptatifs et personnalisés, capables de répondre aux besoins et aux

préférences variables des conducteurs dans des situations diverses

5.5.2 Validation du modèle CVR

Afin d'utiliser le modèle augmenté (CVR) sélectionné pour la synthèse du contrôleur partagé, nous avons validé le modèle en comparant ses prédictions avec les mesures réelles obtenues à l'aide du simulateur SHERPA-LAMIH.

Le modèle augmenté CVR en question, défini par l'équation (5.3), est soumis à des essais de validation lors de simulations de trajets effectués sur la piste de Satory. La reproduction fidèle du parcours dans le simulateur implique la mise en œuvre de phases d'accélération et de décélération soigneusement planifiées (voir la Figure 5.7). Les résultats issus de ces essais de validation sont présentés graphiquement dans la Figure 5.8 où la variation paramétrique du conducteur est présentée dans la Figure 5.7. Cette représentation visuelle permet une comparaison entre les prédictions du modèle augmenté (CVR) et les mesures réelles, facilitant ainsi l'évaluation de la performance du modèle. Parallèlement, les erreurs de validation sont exposées dans la Figure 5.9, confirmant ainsi la précision du modèle obtenue dans différentes situations.

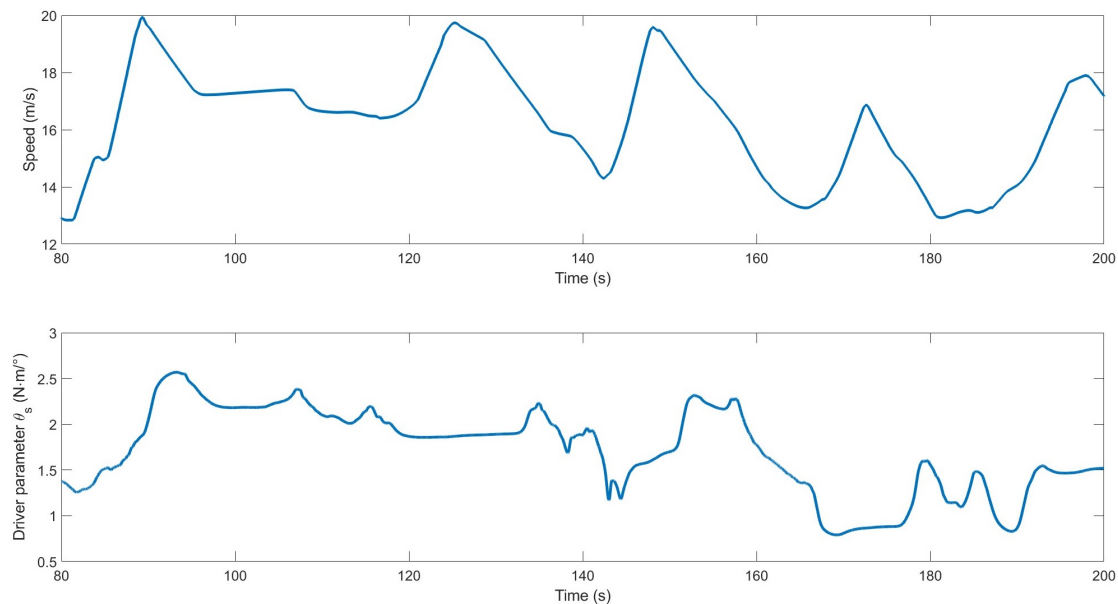


FIGURE 5.7 – Les résultats de l'identification en ligne des paramètres du modèle du conducteur, ainsi que les variations de la vitesse du véhicule, dans le scénario de maintien de voie sur la piste de Satory.

L'analyse des résultats met en avant une observation cruciale : le modèle augmenté Conducteur-Véhicule-Route que nous avons élaboré est capable de reproduire de manière satisfaisante la dynamique à la fois du véhicule et du conducteur, telle qu'il a été observé sur le simulateur SHERPA-LAMIH.

5.6 Conception du contrôleur partagé haptique LPV basé sur l'impédance du conducteur

Dans cette section, nous commençons par introduire la représentation LPV-TS du modèle intégré du véhicule en boucle fermée avec le conducteur. Ensuite, nous présentons dans la deuxième sous-section une solution pour le problème du contrôle partagé haptique entre le conducteur et l'automatisation, basée sur l'estimation en ligne de l'impédance du conducteur.




FIGURE 5.8 – Comparaison entre les sorties du modèle Conducteur-Véhicule-Route et les données obtenues à partir du simulateur SHERPA-LAMIH, dans le scénario de maintien de voie sur la piste de Satory.




FIGURE 5.9 – Écart entre les prédictions du modèle Conducteur-Véhicule-Route proposé et les données enregistrées sur SHERPA-LAMIH, dans le scénario de maintien de voie sur piste de Satory.

Enfin, dans la dernière sous-section, nous abordons l'analyse de la stabilité de l'ensemble du système.

5.6.1 Représentation TS du Modèle Conducteur-Véhicule-Route

Dans cette sous-section, nous allons développer la représentation TS du système CVR (5.3) afin de l'utiliser par la suite pour la synthèse du contrôleur partagé LPV pour le maintien de voie. En effet, les matrices A et E dans (5.3) dépendent des termes mesurés, identifiés et bornés suivants :

$$\left\{ v_x, \frac{1}{v_x}, \frac{1}{v_x^2}, \theta_s \right\}$$

$$v_{\min} \leq v_x \leq v_{\max}$$

$$\theta_{s_{\min}} \leq \theta_s \leq \theta_{s_{\max}}$$

Dans le but de réduire la complexité et le caractère conservatif de la méthode de contrôle proposée dans [Wang and Tanaka, 2004], un changement de paramètre est effectué. Un modèle T-S flou exact du système (5.3) peut être obtenu avec 16 sous-systèmes linéaires. Cependant, cela entraîne une charge numérique importante pour une implémentation en temps réel et des résultats de contrôle conservatifs. Pour réduire le conservatisme et la complexité des calculs, comme cela a été illustré dans les deux chapitres précédents, nous utilisons le développement de Taylor d'ordre 1 pour effectuer le changement de variables suivant :

$$\begin{aligned} \frac{1}{v_x} &= \frac{1}{v_0} + \frac{1}{v_1} \alpha, \\ v_x &\approx v_0 (1 - \frac{v_0}{v_1} \alpha), \\ \frac{1}{v_x^2} &\approx \frac{1}{v_0^2} (1 + 2 \frac{v_0}{v_1} \alpha) \end{aligned} \quad (5.13)$$

$$\text{où : } \alpha_{\min} \leq \alpha \leq \alpha_{\max}, \quad v_0 = \frac{2v_{\min}v_{\max}}{v_{\min}+v_{\max}}, \quad v_1 = \frac{2v_{\min}v_{\max}}{v_{\min}-v_{\max}}.$$

Le nouveau paramètre α peut être utilisé pour représenter la variation de v_x entre ses bornes inférieure et supérieure, c'est-à-dire $\alpha_{\min} = -1$ et $\alpha_{\max} = 1$. En effet, les variables v_x , $\frac{1}{v_x}$ et $\frac{1}{v_x^2}$ dans (5.13) dépendent linéairement du nouveau paramètre α . En substituant ces expressions dans (5.3), nous obtenons un modèle CVR dont les matrices d'espace d'état dépendent de $\{\alpha, \theta_s\}$. En utilisant l'approche des secteurs non-linéaires [Wang and Tanaka, 2004], on obtient la représentation LPV-TS à 4 règles du système (5.3) comme suit :

$$\dot{x} = \sum_{i=1}^4 h_i (A_i x + E_i d) + B u \quad (5.14)$$

Les quatre fonctions d'appartenance utilisées dans la représentation T-S floue de (5.14) sont définies par les expressions suivantes :

$$\begin{aligned} m_1 &= \frac{\alpha_{\max} - \alpha}{\alpha_{\max} - \alpha_{\min}}, & m_2 &= 1 - m_1 \\ m_3 &= \frac{\theta_{s_{\max}} - \theta_s}{\theta_{s_{\max}} - \theta_{s_{\min}}}, & m_4 &= 1 - m_3 \end{aligned}$$

Les non-linéarités dans les conséquences des règles floues sont représentées par :

$$\begin{aligned} h_1 &= m_1 \cdot m_3, & h_2 &= m_1 \cdot m_4 \\ h_3 &= m_2 \cdot m_3, & h_4 &= m_2 \cdot m_4 \end{aligned}$$

où les matrices A_i et E_i sont calculées comme suit :

$$\begin{aligned} i = 1 : & \quad \{A(\alpha_{\max}, \theta_{s_{\min}}), E(\alpha_{\max})\} \\ i = 2 : & \quad \{A(\alpha_{\max}, \theta_{s_{\max}}), E(\alpha_{\max})\} \\ i = 3 : & \quad \{A(\alpha_{\min}, \theta_{s_{\min}}), E(\alpha_{\min})\} \\ i = 4 : & \quad \{A(\alpha_{\min}, \theta_{s_{\max}}), E(\alpha_{\min})\} \end{aligned}$$

5.6.1.1 Validation du modèle augmenté TS

Afin de valider le modèle augmenté TS du système CVR sur SHERPA, il est essentiel de procéder au calcul préliminaire des limites de paramètre du modèle conducteur θ_s .

Ce calcul des limites de paramètre du conducteur repose sur la mise en œuvre d'un scénario de changement de voie réalisé sur le simulateur SHERPA par six participants distincts, et ce pour quatre scénarios différents comme utilisé dans le chapitre précédent. Les trois premiers scénarios mettent en jeu une vitesse constante ($v_x = 70km/h$, $v_x = 90km/h$ et $v_x = 110km/h$), tandis que le quatrième scénario autorise une vitesse variable. Chacun des participants a effectué cinq dépassements dans chaque scénario. Le tableau ci-dessous présente les résultats de l'identification en mettant en évidence les valeurs maximales et minimales du paramètre θ_s du conducteur pour chaque scénario.

| Scénario | θ_s |
|----------|------------|
| S1 | [0, 2.79] |
| S2 | [0, 4.21] |
| S3 | [0, 5.92] |
| S4 | [0, 6.67] |

TABLE 5.1 – Les limites minimales et maximales de la rigidité du conducteur θ_s pour chaque scénario.

En se basant sur ces résultats, les limites de paramètre du modèle sont établies en tenant compte des valeurs minimales et maximales de ces scénarios (avec une marge d'incertitude d'environ 25% par rapport à ces valeurs). D'après les résultats obtenus, l'intervalle obtenu pour la rigidité du conducteur est le suivant :

$$\theta_s \in [0, 8.34].$$

Comme pour le calcul des limites paramétriques, le processus de validation du modèle TS (5.14) sur le simulateur SHERPA-LAMIH est basé sur un scénario de changement de voie sur autoroute. Pour ce faire, les entrées du modèle TS sont constituées de la vitesse longitudinale du véhicule ainsi que l'impédance variable du conducteur identifiée de manière récursive θ_s , comme illustré dans la Figure 5.10. Ces deux paramètres sont fondamentaux pour simuler le comportement du véhicule et du conducteur dans le simulateur.

Les résultats issus de cette étape de validation sont représentés graphiquement dans la Figure 5.11. Cette représentation graphique illustre la comparaison entre les prédictions du modèle augmenté TS et les données réelles enregistrées dans le simulateur. Les courbes superposées illustrent bien la fidélité du modèle augmenté TS par rapport au comportement observé sur le simulateur SHERPA en simulation interactive avec conducteur.

Afin d'évaluer la performance du modèle augmenté TS avec plus de précision, les erreurs de validation sont détaillées dans la Figure 5.12.

En analysant ces résultats, on peut constater que le modèle augmenté TS est assez représentatif pour reproduire le comportement dynamique du véhicule en interaction avec son conducteur, observé sur le simulateur SHERPA.

Ce modèle LPV-TS sera utilisé dans la section suivante pour la conception du nouveau contrôleur partagé multi-objectif qui tient en compte également de l'aspect interaction physique au volant entre le conducteur et le système de conduite automatisée.

5.6.2 Conception du contrôleur PDC pour le contrôle partagé haptique LPV

Afin que le contrôleur soit adaptatif et multi-objectif, l'idée est d'ajuster en temps réel l'objectif de la fonction de coût pour choisir entre accompagner le conducteur pour la réalisation




FIGURE 5.10 – Les résultats de l'identification en ligne de la rigidité (impédance) du conducteur, ainsi que les variations de la vitesse du véhicule, dans le scénario de changement de voie sur le simulateur SHERPA-LAMIH.




FIGURE 5.11 – Analyse comparative entre les sorties du modèle augmenté de type TS et les données recueillies à partir du simulateur SHERPA-LAMIH, dans le contexte du scénario de changement de voie.

de sa manœuvre, ou bien l'aider à maintenir le véhicule dans la voie et à éviter les collisions, nous définissons deux vecteurs de performance (z_1, z_2) de (5.3) comme suit :

$$z_1 = Cx = \left[a_y \quad r \quad \psi_L \quad y_L \quad \dot{\delta}_d \right]^T$$




FIGURE 5.12 – Différences entre les prédictions du modèle augmenté de type TS proposé et les données enregistrées sur le simulateur SHERPA-LAMIH dans le contexte du scénario de changement de voie.

avec

$$C = \begin{bmatrix} 0 & v_x & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix}$$

et

$$z_2 = C_2 x + D_2 u = [T_d - \zeta T_a]$$

$$C_2 = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}, \quad D_2 = -\zeta$$

Il convient de noter que dans le modèle de véhicule (5.3), les variables a_y , r , ψ_L et y_L représentent la performance de suivi de voie, tandis que la vitesse de braquage δ_d est incluse dans z_1 pour représenter le confort de braquage, et le vecteur de performance z_2 est utilisée pour minimiser l'effort du conducteur et éliminer le conflit entre le système et le conducteur. Afin de garantir que le schéma de contrôle partagé proposé assure les objectifs désirés en termes de performances, nous proposons de minimiser l'indice de performance LPV suivant :

$$\mathfrak{S}(\rho) = \int_0^{\infty} z_1^T(\tau) \rho^2 Q_1 z_1(\tau) + z_2^T(\tau) (1 - \rho)^2 Q_2 z_2(\tau) + u^T(\tau) R u(\tau) \quad d\tau \quad (5.15)$$

Dans cette expression, $Q_1 = W^T W \succ 0$, $Q_2 = W'^T W' \succ 0$ et $R \succ 0$ représentent les matrices de pondération. En utilisant le fait que $\rho \in [0, 1]$, on peut décomposer

$$\rho^2 Q_1 = \left(\sum_{j=1}^2 \eta_j(\rho) W_j \right)^T \left(\sum_{j=1}^2 \eta_j(\rho) W_j \right) \quad (5.16)$$

$$(1 - \rho)^2 Q_2 = \left(\sum_{j=1}^2 \eta_j(\rho) W_j' \right)^T \left(\sum_{j=1}^2 \eta_j(\rho) W_j' \right), \quad (5.17)$$

avec : $\eta_1(\rho) = \rho$, $\eta_2(\rho) = 1 - \eta_1(\rho)$, $W_1 = W$, $W_2 = 0$, $W_1' = 0$, $W_2' = W'$.

Cette décomposition est utilisée pour adapter les pondérations Q_1 et Q_2 en fonction du paramètre ρ représentant le niveau d'assistance, afin de résoudre les conflits entre le conducteur et le système. De plus, cela permet une adaptation en temps réel de la performance du système en boucle fermée.

Remarque : Inspiré par le principe bien connu d'un régulateur linéaire quadratique (LQR), nous pouvons voir dans l'équation (5.15) que lorsque l'autorité de contrôle est entièrement confiée au système de maintien dans la voie (LKS), c'est-à-dire lorsque $\rho = 1$, l'action de contrôle T_a est conçue pour obtenir les meilleures performances de maintien de voie en pénalisant principalement le terme lié au performance de suivi de voie, c'est-à-dire $z_1^T(\tau) \rho^2 Q_1 z_1(\tau)$. En revanche, lorsque l'autorité de contrôle est entièrement attribuée au conducteur humain, c'est-à-dire lorsque $\rho = 0$, une action de contrôle T_a est conçue pour minimiser $\mathfrak{S}(\rho)$ en pénalisant le terme lié au conflits entre le système et le conducteur, c'est-à-dire $z_2^T(\tau) (1 - \rho)^2 Q_2 z_2(\tau)$.

Pour la conception du contrôle partagé, la loi de commande suivante est utilisée :

$$u = T_a = \sum_{i=1}^4 \sum_{j=1}^2 h_i \eta_j K_{ij} x \quad (5.18)$$

En utilisant l'équation de commande d'entrée (5.18) et le modèle flou T-S (5.14), le système en boucle fermée peut être exprimé de la manière suivante :

$$\dot{x} = \sum_{i=1}^4 \sum_{j=1}^2 h_i \eta_j ((A_i + BK_{ij}) x + E_i d) \quad (5.19)$$

où les gains de commande K_{ij} , $i \in 1, 4, j \in 1, 2$, sont à déterminer. En utilisant le résultat suivant, une solution de contrôle est fournie sur la base de la fonction de Lyapunov candidate suivante :

$$V(x) = x^T P x, \quad P > 0 \quad (5.20)$$

Théorème 5.2. S'il existe des matrices définies positives \mathcal{X} , un scalaire positif γ , ainsi que des matrices \mathcal{M}_{ij} , avec $(i \in 1, 4, j \in 1, 2)$ satisfaisant l'optimisation suivante :

$$\begin{bmatrix} H_e \left((A_i \mathcal{X} + B \mathcal{M}_{ij})^T \right) & \mathcal{X} C^T W_j^T & (C_2 \mathcal{X} + D_2 \mathcal{M}_{ij})^T (W_j')^T & \mathcal{M}_{ij}^T & E_i \\ W_j C \mathcal{X} & -I_{z_1} & 0 & 0 & 0 \\ (W_j') (C_2 \mathcal{X} + D_2 \mathcal{M}_{ij}) & 0 & -I_{z_2} & 0 & 0 \\ \mathcal{M}_{ij} & 0 & 0 & -R^{-1} & 0 \\ E_i^T & 0 & 0 & 0 & -\gamma I \end{bmatrix} < 0 \quad (5.21)$$

Alors, le contrôleur LPV (5.18) stabilise le système du véhicule (5.19) et garantit une borne supérieure pour la fonction de coût (5.15) sous condition initiale nulle, comme suit :

$$\mathfrak{S}(\rho) < \gamma \|d\|^2. \quad (5.22)$$

De plus, les gains de rétroaction dans (5.18) peuvent être calculés de la manière suivante :

$$K_{ij} = \mathcal{M}_{ij} \mathcal{X}^{-1}, \quad (i \in 1, 4, j \in 1, 2) \quad (5.23)$$

5.6.3 Analyse de la stabilité

Dans cette sous-section, nous abordons l'analyse de stabilité de l'ensemble du système. Pour des raisons de concision, notons :

$$A(\theta) = \sum_{i=1}^4 h_i A_i, \quad E(\theta) = \sum_{i=1}^4 h_i E_i, \quad K(\theta, \rho) = \sum_{i=1}^4 \sum_{j=1}^2 h_i \eta_j K_{ij}, \quad H_e(X) = X^T + X,$$

$$W(\rho) = \sum_{j=1}^2 \eta_j(\rho) W_j, \quad W'(\rho) = \sum_{j=1}^2 \eta_j(\rho) W'_j,$$

En multipliant (5.21) avec $\sum_{i=1}^4 \sum_{j=1}^2 h_i(\theta) \eta_j(\rho) \geq 0$ et en appliquant trois fois le lemme du complément de Schur successif (SCL) [Boyd et al., 1994], sachant que les dimensions de W'_j sont égales à un, nous obtenons l'inégalité équivalente suivante :

$$\left[\begin{array}{ccc} H_e \left((A(\theta) \mathcal{X} + B\mathcal{M}(\theta, \rho))^T \right) + \mathcal{X} C^T W^T(\rho) W(\rho) C \mathcal{X} + & & \\ (C_2 \mathcal{X} + D_2 \mathcal{M}(\theta, \rho))^T \left(W'^T(\rho) W'(\rho) \right) (C_2 \mathcal{X} + D_2 \mathcal{M}(\theta, \rho)) + & E(\theta) & \\ \mathcal{M}(\theta, \rho)^T R \mathcal{M}(\theta, \rho) & & -\gamma I \end{array} \right] < 0 \quad (5.24)$$

Avec $P = \mathcal{X}^{-1}$ et $\mathcal{M}(\theta, \rho) = K(\theta, \rho) \mathcal{X}$, en pré et post-multipliant (5.24) avec $\begin{bmatrix} P & 0 \\ 0 & I \end{bmatrix}$, on obtient :

$$\left[\begin{array}{ccc} H_e \left((A(\theta) + BK(\theta, \rho))^T P \right) + C^T W^T(\rho) W(\rho) C + & & \\ (C_2 + D_2 K(\theta, \rho))^T \left(W'^T(\rho) W'(\rho) \right) (C_2 + D_2 K(\theta, \rho)) + & PE(\theta) & \\ K(\theta, \rho)^T R K(\theta, \rho) & & -\gamma I \end{array} \right] < 0 \quad (5.25)$$

En pré et post-multipliant (5.25) avec $[x, d]^T$ et sa transposée, on obtient :

$$\dot{V}(x) + z_1^T \rho^2 Q_1 z_1 + z_2^T (1 - \rho)^2 Q_2 z_2 + u^T R u < \gamma d^T d \quad (5.26)$$

où $\dot{V}(x)$ représente la dérivée temporelle de la fonction candidate de Lyapunov (5.20) pour la trajectoire de (5.19). À partir de (5.26), nous distinguons deux cas.

- $\dot{V}(x) < 0, \forall x \neq 0$, pour un système avec une perturbation nulle ($d = 0$), ce qui implique que le système en boucle fermée (5.19) est globalement exponentiellement stable.
- $\dot{V}(x) < \gamma \|d\|^2$, dans le cas d'un système perturbé ($d \neq 0$). Alors, en intégrant les deux côtés de l'équation (5.26) de 0 à ∞ , on obtient :

$$V(\infty) - V(0) + \mathfrak{S}(\rho) < \gamma \int_0^{\infty} d^T(t) d(t). \quad (5.27)$$

Puisque $V(\infty) > 0$, sous condition initiale nulle, c'est-à-dire $V(0) = 0$, il est clair que l'inégalité (5.27) implique l'inégalité (5.22). Notez également à partir de (5.22) que la fonction de coût adaptative $\mathfrak{S}(\rho)$ peut être minimisée en minimisant γ .

5.7 Validation expérimentale

La section suivante présente des résultats illustratifs démontrant les performances du contrôleur partagé proposé en termes de réduction des conflits et de maintien de voie, à l'aide d'expériences interactives réalisées sur le simulateur de conduite dynamique SHERPA. Toutes les évaluations de performance sont effectuées sur une piste d'essai autoroutière. Les valeurs des paramètres mathématiques du modèle du véhicule (SHERPA) et celles du contrôleur sont répertoriées dans le tableau 5.2.

Cette section est structurée en deux sous-sections afin de fournir une vue d'ensemble plus complète du chapitre. La première sous-section présente un exemple concret démontrant comment le contrôleur proposé assure la sécurité du conducteur dans une situation risquée. Une situation de danger est simulée, et le contrôleur est évalué en fonction de sa capacité à réagir de manière appropriée pour éviter l'accident et préserver la sécurité du conducteur. La deuxième sous-section met en lumière les résultats des expériences de test effectuées avec des utilisateurs. Une évaluation à la fois objective et subjective a été menée pour comparer le contrôleur partagé tel qu'il est décrit dans la référence [Nguyen et al., 2017] (sans ajustement de la fonction de coût et avec les paramètres du modèle conducteur maintenus constants) avec le contrôleur présenté dans ce chapitre ainsi que dans les deux autres chapitres. Cela a été réalisé en utilisant un scénario de manœuvre d'évitement d'obstacles. Les performances des quatre contrôleurs sont comparées en termes d'efficacité, de réactivité et de sécurité. L'objectif de cette évaluation est de mettre en évidence les avantages et les améliorations apportés par le contrôleur proposé dans ce chapitre.

TABLE 5.2 – Les valeurs numériques des paramètres du modèle du véhicule et du conducteur.

| Par. | Valeur | Unit | Par. | Valeur | Unit | Par. | Valeur | Unit |
|---------|--------|------|-----------|----------|----------------|------------|------------|----------------------|
| l_f | 1.3 | m | J_s | 0.05 | $kg \cdot m^2$ | I_z | 2800 | $kg \cdot m^2$ |
| l_r | 1.6 | m | C_f | 57000 | N/rad | ρ | [0 , 1] | – |
| l_w | 0.4 | m | C_r | 59000 | N/rad | m | 2024 | kg |
| l_s | 5 | m | R_s | 16 | – | g_t | 0.13 | m |
| B_s | 5.73 | – | v_x | [8 , 30] | m/s | α | [-1 , 1] | – |
| ζ | 0.1 | – | λ | 30 | – | θ_s | [0 , 8.34] | $(N \cdot m/^\circ)$ |
| T_n | 0.11 | s | | | | | | |

5.7.1 Les performances du contrôle partagé LPV multi-objectif

Cette sous-section présente un scénario de dépassement à vitesse constante, dans lequel le conducteur est en contrôle partagé et est chargé de dépasser trois véhicules. L'objectif de ce scénario est d'évaluer la capacité du contrôleur partagé à gérer des situations de dépassement à la fois sécurisées (les deux premiers dépassements) et risquées (le dernier dépassement), comme présenté dans la Figure 5.13.




FIGURE 5.13 – Les trois situations de changement de voie (risquées et non risquées).

Tout d'abord, comme illustré dans la Figure 5.14 (a), nous pouvons remarquer que le modèle conducteur utilisé s'ajuste parfaitement à la mesure.

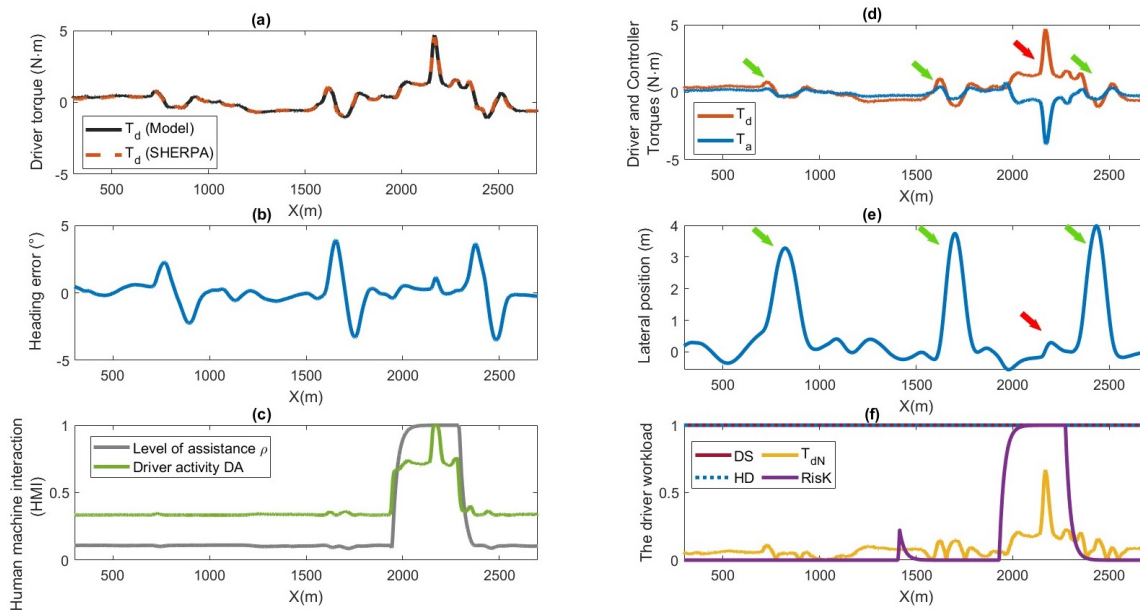


FIGURE 5.14 – Les performances du contrôle partagé multi-objectif proposé dans des scénarios de changement de voie avec différentes situations de risque réalisés sur le simulateur SHERPA.

Lors des deux premiers dépassements (à $X = 800m$ et $X = 1700m$), on remarque que le conducteur s'insère efficacement dans la boucle de contrôle et effectue facilement la manœuvre de dépassement avec un sentiment d'un total contrôle de la situation. Le niveau d'assistance du contrôleur diminue graduellement, car l'activité du conducteur reste dans la plage normale. Cela indique que le conducteur est capable de prendre en charge la conduite de manière autonome et que l'autorité de conduite est principalement déléguée au conducteur lui-même. De plus, le contrôleur partagé LPV multi-objectif proposé dans ce chapitre assiste le conducteur dans la réalisation sans conflit de ces deux manœuvres de dépassement. Ceci est illustré dans la Figure 5.14 (d) où on peut remarquer que le couple conducteur et celui de l'assistance sont en accord. En effet, dans ce cas là et au regard des éléments suite à l'analyse de la situation de conduite, l'objectif du contrôleur décidé par le superviseur de conduite au niveau tactique est d'aider le conducteur dans la manœuvre de dépassement.

Cependant, lors du troisième dépassement (à $X = 2100m$), une situation à risque se présente avec un véhicule proche sur la voie de gauche, comme le montre la Figure 5.14 (d et e). Dans cette situation, le contrôleur guide le conducteur pour rester sur la voie actuelle ($y_L < 1m$) afin d'éviter un risque de collision. De plus, l'activité du conducteur augmente jusqu'à atteindre la zone de "Surcharge". Cela indique que le conducteur a besoin d'un niveau élevé d'assistance pour éviter une collision potentielle avec le véhicule présent dans la voie adjacente. Par conséquent, le niveau d'assistance du contrôleur est augmenté à sa valeur maximale ($\rho = 1$), donnant ainsi au système la principale autorité de conduite. Dans ce cas là et au regard des éléments suite à l'analyse de la situation de conduite, l'objectif du contrôleur décidé par le superviseur de conduite au niveau tactique est de maintenir le véhicule sur la voie pour éviter une potentielle collision.

Une fois que le véhicule présent sur la voie adjacente s'éloigne et que la situation redevienne sûre, le conducteur effectue le dépassement (à $X = 2400m$). Cette fois-ci, le dépassement se déroule sans risque, et le conducteur parvient à dépasser le véhicule sans conflit. Le niveau d'assistance du contrôleur est réduit, permettant au conducteur de reprendre le contrôle du

véhicule. L'activité du conducteur revient à la plage normale, indiquant sa capacité à gérer la conduite de manière autonome et sans conflit avec l'assistance.

En résumé, ce scénario de dépassement illustre l'évaluation des risques et le contrôle partagé adaptatif à objectifs multiples. Le contrôleur ajuste son niveau d'assistance en fonction de la situation de conduite, offrant un soutien accru lorsque la situation devient risquée et permettant au conducteur de reprendre le contrôle lorsqu'elle est sécurisée. Cette approche garantit la sécurité du conducteur et des autres usagers de la route tout en optimisant l'efficacité du dépassement.

5.7.2 Expériences de test utilisateur

Dans cette sous-section, une étude préliminaire a été conduite pour évaluer l'approche de contrôle partagé adaptatif à objectifs multiples proposée pour le système de maintien de voie coopératif. L'objectif de cette étude était de comprendre comment cette approche gère les conflits et l'autorité de contrôle, tout en recueillant des données sur l'acceptabilité par les conducteurs à partir d'expériences de tests utilisateurs.

L'étude a été réalisée au moyen du simulateur SHERPA. Six participants ont pris part à ces expériences préliminaires, dont 4 hommes et 2 femmes. L'âge moyen des participants est de 34 ± 9 ans, avec une moyenne de 8500 km parcourus par an.

Le scénario d'évitement d'obstacles a été choisi pour cette expérience. Ce scénario se déroule sur une route droite à deux voies avec circulation à sens unique, d'une longueur de 4 km avec une vitesse constante. Les participants ont reçu l'instruction de rester dans leur voie et de faire attention aux obstacles immobiles présents sur la route. L'objectif de cette expérience était d'évaluer la capacité des participants à changer de voie en mode "contrôle partagé" afin d'éviter des collisions.

Les participants ont réalisé les tests en utilisant quatre stratégies de contrôle partagé :

(i) Système de maintien de voie classique [Nguyen et al., 2017] noté "*LKS_WOA_CDP*". Dans cette stratégie, les participants ont utilisé le système traditionnel de maintien de voie sans adaptation de la fonction de coût (objectif de partage fixe) et avec un modèle de conducteur possédant des paramètres constants. Ce système fournit une assistance pour le maintien de voie mais ne tient pas compte des obstacles sur la route.

(ii) Système de maintien de voie adaptatif développé au chapitre 4 noté "*LKS_ODP*". Dans cette stratégie, les participants ont utilisé le système de maintien de voie adaptatif proposé dans le chapitre 4, basé sur l'identification en ligne des paramètres d'un modèle conducteur mais qui intègre un objectif de partage fixe.

(iii) Système de maintien de voie adaptatif développé au chapitre 3 noté "*LKS_WA*". Les participants ont utilisé le système de maintien de voie adaptatif proposé dans le chapitre 3, qui intègre une approche LPV considérant une fonction de coût adaptative (objectif de partage variable) mais sans l'intégration d'un modèle conducteur.

(iv) Système d'assistance adaptatif à objectifs multiples proposé dans le présent chapitre noté "*LKS_WA_ODP*". Les participants ont utilisé le système de maintien de voie adaptatif à objectifs multiples développé dans le présent chapitre, qui intègre une approche LPV considérant une fonction de coût adaptative multi-objectif et en introduisant également l'identification en ligne de la propriété de rigidité musculaire (impédance) du conducteur.

Après chaque phase de test, les participants ont rempli des questionnaires pour fournir une évaluation subjective de leur expérience de conduite avec chaque stratégie.

L'analyse des données collectées dans cette étude est divisée en deux parties, permettant d'évaluer à la fois les performances objectives et l'acceptabilité subjective des différentes stratégies de conduite. Cette évaluation permettra de mesurer l'efficacité de l'approche de contrôle partagé adaptatif à objectifs multiples proposée, tout en recueillant des retours utilisateurs essentiels sur l'expérience vécue par les conducteurs lors de l'évitement des obstacles.

5.7.2.1 Evaluation objective

Dans cette évaluation objective, diverses mesures ont été employées pour analyser l'interaction du conducteur avec le système de maintien de voie (LKS) et l'efficacité du contrôle partagé. Les quatre métriques *StD*, *StC*, *Conflict* et *SW* (voir la section 3.8.4.1) ont été considérées dans cette étude, de la même manière que dans les deux chapitres précédents.

La Figure 5.15 illustre les résultats obtenus pour ces métriques en ce qui concerne les différentes stratégies évaluées. On peut constater qu'avec la stratégie "*LKS_WOA_CDP*", l'effort requis pour diriger le véhicule et éviter les obstacles est nettement plus élevé lorsque le système n'est pas coopératif, en comparaison avec les trois autres stratégies. En revanche, en utilisant la stratégie "*LKS_WA_ODP*", l'effort fourni par le conducteur est considérablement réduit, principalement grâce à l'approche multi-objectifs du contrôleur, où le conducteur reçoit une assistance adaptée pour ses manœuvres.

FIGURE 5.15 – Les résultats de l'évaluation objective du contrôle partagé en utilisant quatre stratégies différentes dans le contexte d'un scénario d'évitement d'obstacles.

Il est évident d'après la Figure 5.15 que les stratégies "*LKS_WA_ODP*", "*LKS_ODP*", et "*LKS_WA*" diminuent substantiellement l'effort du conducteur ainsi que les conflits entre le conducteur et le système de maintien de voie par rapport à la stratégie "*LKS_WOA_CDP*". Ces résultats quantitatifs démontrent de manière concluante que les trois approches de contrôle partagé présentées dans ce manuscrit sont très efficaces pour réduire l'effort du conducteur et atténuer les conflits entre le conducteur et le système de maintien de voie. En particulier, l'approche présentée dans ce chapitre "*LKS_WA_ODP*" semble être particulièrement performante, en assistant le conducteur dans la réalisation de ses manœuvres tout en minimisant de façon significative les conflits aux volant.

5.7.2.2 Evaluation subjective

Les questionnaires ont permis de recueillir des données subjectives détaillées concernant cinq aspects distincts de l'expérience de conduite. Les participants ont évalué leur sentiment de confort en conduite, leur perception de contrôle et de sécurité, la facilité avec laquelle ils ont pu éviter les obstacles, ainsi que leur évaluation globale des performances de conduite pour chaque phase de test.

Pour chaque aspect évalué, les participants ont attribué des scores sur une échelle allant de 0 à 100, où 0 représentait la pire évaluation possible et 100 la meilleure. Les résultats présentés dans la Figure 5.16 ont mis en évidence des différences significatives entre les stratégies de conduite testées.

En ce qui concerne le confort de conduite, la stratégie "*LKS_WOA_CDP*" a obtenu les scores les plus bas, indiquant que les participants se sont sentis moins à l'aise lorsqu'ils utilisaient cette stratégie. De même, en ce qui concerne le sentiment de contrôle et de sécurité, ainsi que la facilité d'évitement des obstacles, la stratégie "*LKS_WOA_CDP*" a également reçu les scores les plus bas. Ces résultats suggèrent que les participants ont éprouvé moins de confiance et de sentiment de contrôle lorsqu'ils utilisaient cette stratégie.

En revanche, les trois stratégies "*LKS_ODP*", "*LKS_WA*" et "*LKS_WA_ODP*" ont montré des résultats plus satisfaisants, avec la stratégie "*LKS_WA_ODP*" proposée dans ce chapitre obtenant les scores les plus élevés. Cela indique que cette stratégie a permis aux participants de maintenir un niveau élevé de confort, de contrôle et de sécurité, ainsi qu'une facilité accrue pour éviter les obstacles.

En résumé, les résultats subjectifs issus des questionnaires confirment que les stratégies "*LKS_ODP*", "*LKS_WA*" et "*LKS_WA_ODP*" offrent une expérience de conduite plus favo-

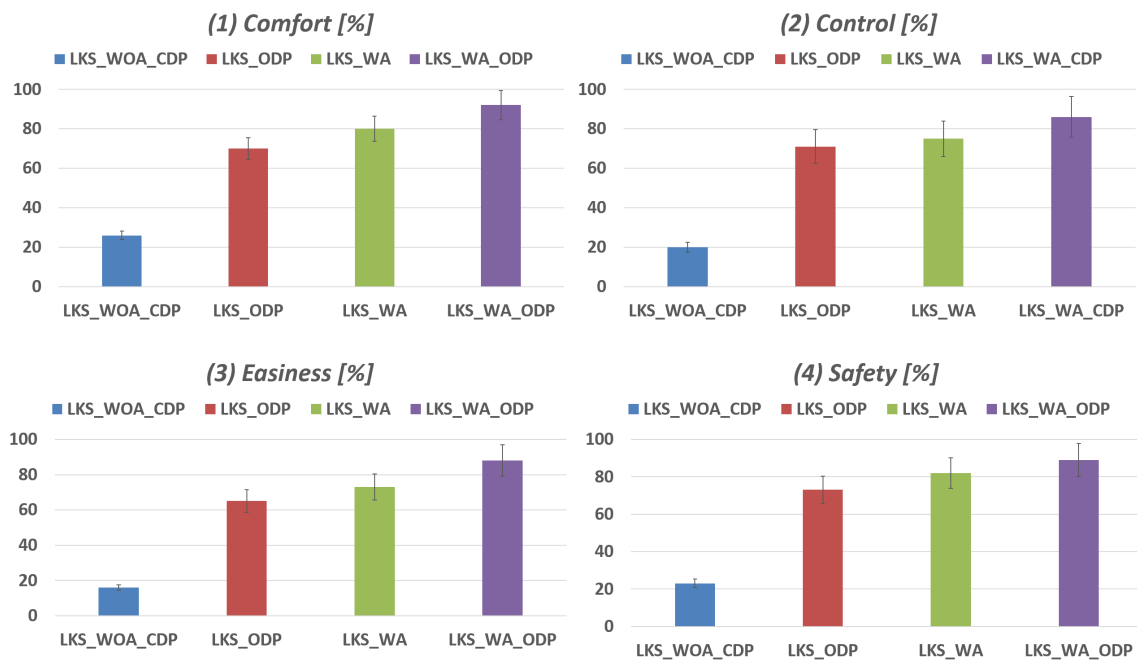


FIGURE 5.16 – Les résultats de l'évaluation subjective du contrôle partagé en utilisant quatre stratégies différentes dans le contexte d'un scénario d'évitement d'obstacles.

nable en termes de confort, de contrôle, de sécurité et de facilité pour éviter les obstacles, par rapport à la stratégie "LKS.WOA.CDP".

Enfin, les résultats de l'évaluation subjective de la performance globale de conduite dans le scénario d'évitement d'obstacles pour les différentes stratégies sont présentés dans la Figure 5.17. Cette évaluation vise à capturer la perception globale des participants concernant leur propre performance de conduite dans chaque situation.

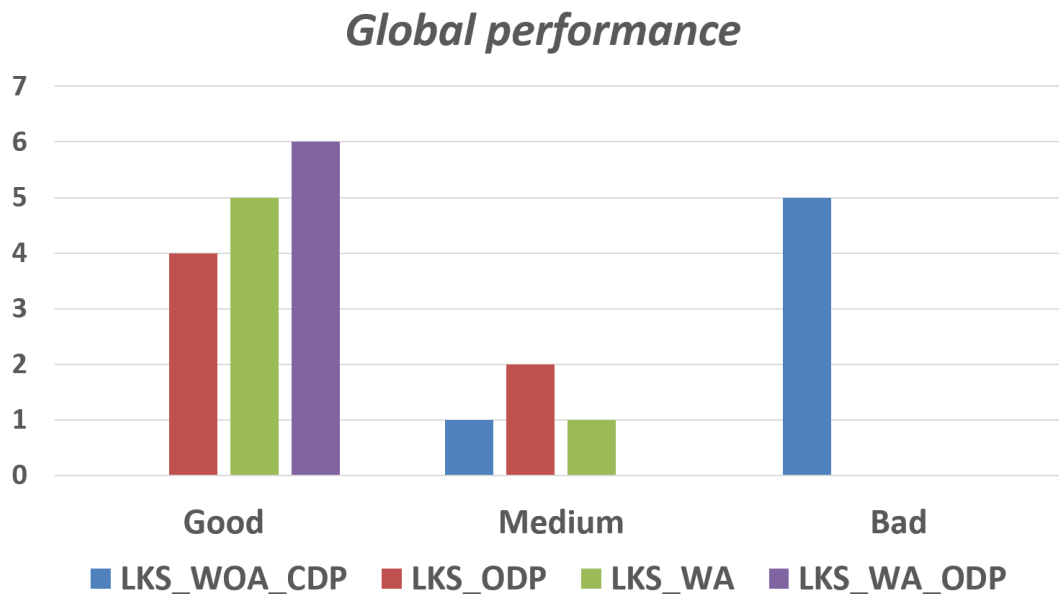


FIGURE 5.17 – Les résultats globaux des performances du contrôle partagé en utilisant quatre stratégies différentes dans le contexte d'un scénario d'évitement d'obstacles.

Il apparaît clairement que la stratégie "*LKS_WOA_CDP*" a obtenu les scores les plus bas en termes de performance de conduite perçue. Cela indique que les participants ont considéré cette stratégie comme la moins performante par rapport aux autres conditions. En revanche, les stratégies "*LKS_ODP*", "*LKS_WA*" et "*LKS_WA_ODP*" ont obtenu des scores élevés et acceptables, et en particulier la stratégie "*LKS_WA_ODP*" a obtenu un score global avec 100% des points dans la case "Good". Cela signifie que les participants ont perçu cette stratégie comme celle qui offre la meilleure performance de conduite en termes de sécurité, de confort et de qualité d'utilisation par rapport aux différents systèmes testés.

5.8 Conclusion

En conclusion, ce chapitre a été dédié à la conception d'une nouvelle génération de systèmes d'assistance à la conduite, en mettant en avant une approche axée sur l'humain. En capitalisant sur les bénéfices et les résultats issus des stratégies exposées dans les chapitres précédents, ce système d'assistance novateur opère en temps réel en tenant compte de l'activité du conducteur, de sa disponibilité, de ses capacités neuromotrices ainsi que du risque lié à la situation de conduite, afin de moduler le niveau d'assistance. Cette adaptation est rendue possible grâce à l'intégration de l'impédance du conducteur au travers d'un modèle simplifié de conducteur représentant ainsi la variation de sa rigidité lors de l'interaction avec le système de conduite automatisée. Cette caractéristique du conducteur est identifiée en ligne grâce à l'approche d'identification proposée dans cette thèse, permettant ainsi une reconfiguration du contrôleur en fonction de l'état du conducteur et du contexte de conduite.

La conception du contrôleur partagé adaptatif multi-objectif LPV repose sur une fonction de coût dynamique, son ajustement dépendant du degré d'assistance dicté par le superviseur de conduite. Pour insuffler à cette fonction de coût une dynamique multi-objectif, le niveau d'assistance y est incorporé, pondérant ainsi les deux vecteurs de performances. Cette conception offre la souplesse pour adapter la nature de l'assistance requise au regard de la situation de conduite, qui facilite ainsi l'insertion du conducteur dans la boucle de contrôle.

Les fluctuations en temps réel de la vitesse du véhicule, de la rigidité du conducteur et de la fonction de coût multi-objectif dynamique sont toutes prises en considération. L'approche floue de type Takagi-Sugeno (T-S) est adoptée pour concevoir ce système d'assistance centré sur l'humain. La stabilité en boucle fermée du système est garantie en utilisant le cadre d'optimisation LMI basé sur des arguments de stabilité de Lyapunov.

Les expérimentations menées au moyen du simulateur de conduite dynamique SHERPA ont fourni des preuves concluantes quant à l'efficacité du contrôle partagé avancé. Les résultats obtenus ont clairement démontré la performance du contrôle partagé dans la gestion de l'autorité entre le conducteur et le système de maintien de voie. En outre, cette approche a eu pour effet d'accroître la confiance et l'acceptabilité du conducteur envers le système. Cette amélioration provient du fait que le système s'ajuste désormais au plus près aux préférences et au style de conduite spécifique de chaque conducteur.

Conclusion générale et Perspectives

Conclusion générale

La thèse aborde la problématique de l'interaction entre les conducteurs humains et les systèmes automatisés, en se concentrant sur :

1. La personnalisation des systèmes d'assistance : Comment personnaliser les systèmes d'assistance à la conduite pour répondre aux préférences individuelles des conducteurs en matière de conduite, de confort et de sécurité, tout en assurant une prise de décision sur les manœuvres et une planification de trajectoires efficaces ?
2. La gestion des conflits conducteur-système : Comment résoudre les éventuels conflits qui peuvent survenir entre le conducteur et le système automatisé, en particulier dans le contexte du contrôle partagé, où les deux entités doivent collaborer de manière transparente ?
3. L'adaptation aux comportements humains : Comment concevoir des systèmes qui s'adaptent aux comportements et aux réactions dynamiques des conducteurs humains, en prenant en compte les variations dans leur façon de conduire et leur niveau d'attention ?
4. L'amélioration de la sécurité routière : Comment contribuer à améliorer la sécurité routière en réduisant les erreurs humaines, qui sont souvent la principale cause d'accidents de la route ?
5. L'amélioration de la confiance et l'acceptabilité des conducteurs : Comment accroître la confiance et l'acceptabilité de ces systèmes automatisés par les conducteurs, en les rendant plus personnalisés et en répondant davantage à leurs besoins et à leur style de conduite ?

Le premier chapitre, consacré à l'état de l'art, a souligné l'importance cruciale de concevoir les systèmes d'aide à la conduite avancés (ADAS) et l'automatisation de la conduite en mettant l'accent sur l'humain. Cette approche est fondamentale pour améliorer la sécurité routière et l'efficacité de la conduite, en réduisant notamment les erreurs humaines, responsables de la majorité des accidents de la route. Nous avons également identifié les défis majeurs auxquels cette collaboration entre l'humain et la machine est confrontée, notamment en termes de confiance mutuelle, de compréhension des intentions et des actions, de gestion de la charge cognitive et d'adaptation aux préférences individuelles des conducteurs.

Pour relever ces défis, cette thèse a élaboré une architecture auto-adaptative de coopération entre l'humain et le véhicule, comprenant des niveaux stratégiques, tactiques et opérationnels clairement définis. Chacun de ces niveaux joue un rôle spécifique dans la prise de décision, la planification des manœuvres et la mise en œuvre du contrôle, contribuant ainsi à accroître la sécurité et l'efficacité de la conduite.

Les chapitres suivants de notre thèse ont développé des solutions concrètes pour mettre en œuvre cette architecture, donnant ainsi un cadre théorique pour considérer des informations décisionnelles du niveau tactique dans la conception de contrôleurs au niveau opérationnel.

Le deuxième chapitre a mis en avant l'application novatrice de notre architecture pour personnaliser les systèmes d'assistance au changement de voie (LCAS) dans les véhicules intelligents.

Nous avons examiné en détail la manière de prendre en compte le comportement unique et les caractéristiques individuelles de chaque conducteur lors de la prise de décision sur les manœuvres et de la planification de trajectoires en mode de conduite manuelle, mettant ainsi l'accent sur le niveau tactique. Cette exploration en profondeur ouvre la voie à des avancées significatives dans le domaine de la personnalisation des systèmes d'assistance à la conduite, améliorant ainsi l'expérience de conduite tout en renforçant la sécurité et le confort pour chaque conducteur.

Le niveau opérationnel a été exploré dans le troisième chapitre, où nous avons présenté une méthode de conception du contrôle partagé LPV optimal pour les systèmes de maintien de voie coopératifs (LKS), basée sur l'utilisation d'une fonction de coût adaptable. Bien que cette approche soit efficace pour gérer la répartition de l'autorité entre le conducteur et le système LKS, elle n'a pas explicitement pris en compte les attentes des conducteurs ni les éventuels changements dans leur comportement.

Pour remédier à cette limitation, le quatrième chapitre a introduit une solution en intégrant un modèle dynamique du conducteur. Ce modèle capture en temps réel les variations du comportement du conducteur dans le processus de conception du contrôle, visant ainsi à obtenir une solution plus personnalisée. Néanmoins, il est important de noter que cette méthode ne prend pas en compte la possible inattention ou hypovigilance du conducteur, un aspect déjà abordé dans le chapitre 3.

Le cinquième chapitre se concentre sur la conception d'une nouvelle génération de systèmes d'assistance à la conduite, mettant en avant une approche axée sur l'humain. En capitalisant sur les avantages et les résultats des stratégies exposées dans les chapitres précédents, ce système d'assistance novateur fonctionne en temps réel en prenant en compte l'activité du conducteur, sa disponibilité et les dangers environnants pour ajuster continuellement le niveau d'assistance. Cette adaptation est rendue possible grâce à l'intégration des paramètres dynamiques du modèle conducteur, identifiés en ligne grâce à l'approche MRIL proposée, permettant ainsi un ajustement continu du contrôleur en fonction du conducteur et du contexte de conduite.

Les expériences menées avec le simulateur de conduite dynamique SHERPA ont montré l'intérêt et l'efficacité de l'approche de contrôle partagé avancé proposée.

Les résultats obtenus ont clairement démontré la performance remarquable du contrôle partagé dans la gestion de la répartition d'autorité entre le conducteur et le système de maintien de voie. Cette approche a permis de minimiser tout conflit potentiel et à réduire l'effort requis de la part du conducteur, ce qui confirme son efficacité.

De plus, cette approche a contribué à accroître la confiance et l'acceptabilité du conducteur envers le système, car le système s'ajuste désormais plus étroitement aux préférences et au style de conduite spécifiques de chaque conducteur.

En résumé, cette thèse a mis en évidence la nécessité impérieuse de développer des approches centrées sur l'humain et personnalisées pour assurer une coopération efficace entre le conducteur et les systèmes d'automatisation. Ces avancées ouvrent la voie à une conduite plus sécurisée, plus fluide et plus agréable, tout en garantissant une mobilité plus sûre et plus efficace pour tous les usagers de la route. Cette recherche marque une étape importante dans le développement de véhicules automatisés adaptés aux besoins individuels des conducteurs, tout en garantissant une conduite sécurisée et responsable.

Perspectives

Envisager l'avenir de notre recherche ouvre la porte à des horizons passionnants et à des développements novateurs. Les résultats obtenus jusqu'à présent ont été prometteurs, mais ils marquent seulement le début d'une exploration bien plus vaste. Parmi les directions prospectives les plus cruciales on peut noter :

1. Validation en conditions réelles : Les expérimentations réalisées en simulateur ont généré des résultats encourageants. Toutefois, une étape cruciale à franchir est la validation de ces approches sur le terrain, en conditions réelles, en utilisant des véhicules d'essais. Cela permettra de mettre à l'épreuve la robustesse et l'efficacité de notre architecture de coopération entre le conducteur et le véhicule dans des situations de conduite réelles.
2. Adaptabilité multi-scénario : Le chapitre 2 a démontré avec succès la personnalisation des systèmes d'aide au changement de voie en adaptant la prise de décision et la trajectoire générée en temps réel, selon les préférences du conducteur. Cette réussite ouvre une perspective intrigante : adapter cette architecture pour qu'elle fonctionne simultanément avec différents types de systèmes en fonction des situations et des scénarios rencontrés. Par exemple, lors d'une manœuvre d'insertion sur la route, notre système pourrait prendre en compte trois types de décisions possibles (céder le passage au véhicule qui s'insère, passer devant lui, ou changer de voie). Cette flexibilité multicritères pourrait considérablement améliorer l'efficacité et la sécurité de la conduite dans des situations complexes.
3. Intégration d'un niveau de diagnostic : Une autre perspective importante serait d'intégrer un niveau de diagnostic à l'architecture de coopération évolutive entre le conducteur et le véhicule que nous proposons. Cela renforcerait la robustesse du système en permettant la détection et la gestion efficace des éventuelles défaillances ou erreurs. Une architecture tolérante aux fautes contribuerait à garantir une interaction fiable et sécurisée entre le conducteur et le système automatisé, renforçant ainsi la confiance des conducteurs envers cette technologie émergente.
4. Interaction multimodale : Explorer des modes d'interaction plus riches et variés entre le conducteur et le véhicule représente une autre perspective prometteuse. Cela pourrait inclure des interfaces utilisateur avancées, telles que des commandes vocales plus sophistiquées ou des gestes, pour offrir aux conducteurs des moyens plus intuitifs de communiquer avec leur véhicule.

En résumé, ces perspectives tracent un chemin vers un avenir où la conduite automatisée et la coopération conducteur-véhicule deviennent plus sûres, plus efficaces et plus en phase avec les besoins des utilisateurs. La validation en conditions réelles, l'adaptabilité multi-scénario, l'intégration du diagnostic, et l'exploration d'interactions multimodales sont autant de facettes de cette évolution. En poursuivant ces pistes de recherche, nous contribuons à façonner une nouvelle ère de la mobilité, où la sécurité, la personnalisation et l'efficacité se conjuguent pour offrir une expérience de conduite optimale.

Bibliographie

- [Abbink et al., 2018] Abbink, D. A., Carlson, T., Mulder, M., De Winter, J. C., Aminravan, F., Gibo, T. L., and Boer, E. R. (2018). A topology of shared control systems—finding common ground in diversity. *IEEE Transactions on Human-Machine Systems*, 48(5) :509–525.
- [Abbink and Mulder, 2010] Abbink, D. A. and Mulder, M. (2010). *Neuromuscular analysis as a guideline in designing shared control*. INTECH Open Access Publisher.
- [Abbink et al., 2012] Abbink, D. A., Mulder, M., and Boer, E. R. (2012). Haptic shared control : smoothly shifting control authority? *Cognition, Technology & Work*, 14 :19–28.
- [Al Mahi et al., 2017] Al Mahi, S., Atkins, M., and Crick, C. (2017). Learning to assess the cognitive capacity of human partners. In *Proceedings of the Companion of the 2017 ACM/IEEE International Conference on Human-Robot Interaction*, pages 63–64.
- [Anund and Nilsson, 2020] Anund, A. and Nilsson, L. (2020). Adas&me project final report. deliverable 10.4. *Swedish Nat. Road Transp. Res. Inst.(VTI), Linköping, Sweden D*, 10.
- [Argall et al., 2009] Argall, B. D., Chernova, S., Veloso, M., and Browning, B. (2009). A survey of robot learning from demonstration. *Robotics and autonomous systems*, 57(5) :469–483.
- [Bailey and Scerbo, 2007] Bailey, N. R. and Scerbo, M. W. (2007). Automation-induced complacency for monitoring highly reliable systems : the role of task complexity, system experience, and operator trust. *Theoretical Issues in Ergonomics Science*, 8(4) :321–348.
- [Banks et al., 2018] Banks, V. A., Eriksson, A., O’Donoghue, J., and Stanton, N. A. (2018). Is partially automated driving a bad idea? observations from an on-road study. *Applied ergonomics*, 68 :138–145.
- [Barry, 2019] Barry, K. (2019). Tesla’s updated navigate on autopilot requires significant driver intervention. *Consumer Reports*. URL : <https://www.consumerreports.org/autonomous-driving/tesla-navigate-on-autopilot-automatic-lane-change-requires-significant-driver-intervention/>.
- [Basu et al., 2017] Basu, C., Yang, Q., Hungerman, D., Singhal, M., and Dragan, A. D. (2017). Do you want your autonomous car to drive like you? In *Proceedings of the 2017 ACM/IEEE International Conference on Human-Robot Interaction*, pages 417–425.
- [Bauer et al., 2008] Bauer, A., Wollherr, D., and Buss, M. (2008). Human–robot collaboration : a survey. *International Journal of Humanoid Robotics*, 5(01) :47–66.
- [Benloucif et al., 2019a] Benloucif, A., Nguyen, A.-T., Sentouh, C., and Popieul, J.-C. (2019a). Cooperative trajectory planning for haptic shared control between driver and automation in highway driving. *IEEE Transactions on Industrial Electronics*, 66(12) :9846–9857.
- [Benloucif et al., 2019b] Benloucif, M., Sentouh, C., Floris, J., Simon, P., and Popieul, J.-C. (2019b). Online adaptation of the level of haptic authority in a lane-keeping system considering the driver’s state. *Transportation Research Part F : Traffic Psychology and Behaviour*, 61 :107–119. Special TRF issue : Driving simulation.
- [Benloucif et al., 2017] Benloucif, M. A., Nguyen, A.-T., Sentouh, C., and Popieul, J.-C. (2017). A new scheme for haptic shared lateral control in highway driving using trajectory planning. *IFAC-PapersOnLine*, 50(1) :13834–13840.

- [Benloucif et al., 2016] Benloucif, M. A., Popieul, J. C., and Sentouh, C. (2016). Multi-level co-operation between the driver and an automated driving system during lane change maneuver. In *2016 IEEE Intelligent Vehicles Symposium (IV)*, pages 1224–1229.
- [Bi et al., 2015] Bi, L., Wang, M., Wang, C., and Liu, Y. (2015). Development of a driver lateral control model by integrating neuromuscular dynamics into the queuing network-based driver model. *IEEE Transactions on Intelligent Transportation Systems*, 16(5) :2479–2486.
- [Biondi et al., 2017] Biondi, F., Goethe, R., Cooper, J., and Strayer, D. (2017). Partial-autonomous frenzy : Driving a level-2 vehicle on the open road. In Harris, D., editor, *Engineering Psychology and Cognitive Ergonomics : Cognition and Design*, pages 329–338. Springer International Publishing.
- [Biondi et al., 2015] Biondi, F., Turrill, D. M., Coleman, J. R., Cooper, J. M., and Strayer, D. L. (2015). Cognitive distraction impairs drivers’ anticipatory glances : An on-road study. In *Driving Assesment Conference*, volume 8. University of Iowa.
- [Biondi et al., 2018] Biondi, F. N., Getty, D., McCarty, M. M., Goethe, R. M., Cooper, J. M., and Strayer, D. L. (2018). The challenge of advanced driver assistance systems assessment : A scale for the assessment of the human–machine interface of advanced driver assistance technology. *Transportation research record*, 2672(37) :113–122.
- [Boehm et al., 2016] Boehm, P., Ghasemi, A. H., O’Modhrain, S., Jayakumar, P., and Gillespie, R. B. (2016). Architectures for shared control of vehicle steering. *IFAC-PapersOnLine*, 49(19) :639–644.
- [Bojarski et al., 2016] Bojarski, M., Del Testa, D., Dworakowski, D., Firner, B., Flepp, B., Goyal, P., Jackel, L. D., Monfort, M., Muller, U., Zhang, J., et al. (2016). End to end learning for self-driving cars. *arXiv preprint arXiv :1604.07316*.
- [Bonnin et al., 2014] Bonnin, S., Weisswange, T. H., Kummert, F., and Schmuедderich, J. (2014). General behavior prediction by a combination of scenario-specific models. *IEEE Transactions on Intelligent Transportation Systems*, 15(4) :1478–1488.
- [Bottou et al., 1991] Bottou, L. et al. (1991). Stochastic gradient learning in neural networks. *Proceedings of Neuro-Nimes*, 91(8) :12.
- [Boverie and Giralt, 2008] Boverie, S. and Giralt, A. (2008). Driver vigilance diagnostic based on eyelid movement observation. *IFAC Proceedings Volumes*, 41(2) :12831–12836. 17th IFAC World Congress.
- [Boyd et al., 1994] Boyd, S., El Ghaoui, L., Feron, E., and Balakrishnan, V. (1994). *Linear matrix inequalities in system and control theory*. Society for Industrial and Applied Mathematics.
- [Broggi et al., 2010] Broggi, A., Medici, P., Cardarelli, E., Cerri, P., Giacomazzo, A., and Finessardi, N. (2010). Development of the control system for the vislab intercontinental autonomous challenge. In *13th International IEEE Conference on Intelligent Transportation Systems*, pages 635–640.
- [Buehler et al., 2009] Buehler, M., Iagnemma, K., and Singh, S. (2009). *The DARPA urban challenge : autonomous vehicles in city traffic*, volume 56. springer.
- [Butakov and Ioannou, 2014] Butakov, V. A. and Ioannou, P. (2014). Personalized driver/vehicle lane change models for adas. *IEEE Transactions on Vehicular Technology*, 64(10) :4422–4431.
- [Castellano et al., 2020] Castellano, A., Fossanetti, M., Landini, E., Tango, F., and Montanari, R. (2020). Automation as driver companion : Findings of automate project. In *Intelligent Human Systems Integration 2020 : Proceedings of the 3rd International Conference on Intelligent Human Systems Integration (IHSI 2020) : Integrating People and Intelligent Systems, February 19-21, 2020, Modena, Italy*, pages 1048–1054. Springer.

- [Chen et al., 2019] Chen, J., Yuan, B., and Tomizuka, M. (2019). Deep imitation learning for autonomous driving in generic urban scenarios with enhanced safety. In *2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 2884–2890.
- [Chen et al., 2020] Chen, W., Zhao, L., Wang, H., and Huang, Y. (2020). Parallel distributed compensation/h control of lane-keeping system based on the takagi-sugeno fuzzy model. *Chinese Journal of Mechanical Engineering*, 33(1) :1–13.
- [Costilla-Reyes et al., 2017] Costilla-Reyes, O., Scully, P., and Ozanyan, K. B. (2017). Deep neural networks for learning spatio-temporal features from tomography sensors. *IEEE Transactions on Industrial Electronics*, 65(1) :645–653.
- [De Winter et al., 2014] De Winter, J. C., Happee, R., Martens, M. H., and Stanton, N. A. (2014). Effects of adaptive cruise control and highly automated driving on workload and situation awareness : A review of the empirical evidence. *Transportation research part F : traffic psychology and behaviour*, 27 :196–217.
- [Do et al., 2017] Do, Q. H., Tehrani, H., Mita, S., Egawa, M., Muto, K., and Yoneda, K. (2017). Human drivers based active-passive model for automated lane change. *IEEE Intelligent Transportation Systems Magazine*, 9(1) :42–56.
- [Dogan et al., 2011] Dogan, r., Edelbrunner, J., and Iossifidis, I. (2011). Autonomous driving : A comparison of machine learning techniques by means of the prediction of lane change behavior. In *2011 IEEE International Conference on Robotics and Biomimetics*, pages 1837–1843.
- [Donges, 1978] Donges, E. (1978). A two-level model of driver steering behavior. *Human factors*, 20(6) :691–707.
- [Donges, 1999] Donges, E. (1999). A conceptual framework for active safety in road traffic. *Vehicle System Dynamics*, 32(2-3) :113–128.
- [Endsley, 1995] Endsley, M. R. (1995). Toward a theory of situation awareness in dynamic systems. *Human factors*, 37(1) :32–64.
- [Endsley, 2017] Endsley, M. R. (2017). Autonomous driving systems : A preliminary naturalistic study of the tesla model s. *Journal of Cognitive Engineering and Decision Making*, 11(3) :225–238.
- [Englund et al., 2016] Englund, C., Chen, L., Ploeg, J., Semsar-Kazerooni, E., Voronov, A., Bengtsson, H. H., and Didoff, J. (2016). The grand cooperative driving challenge 2016 : boosting the introduction of cooperative automated vehicles. *IEEE Wireless Communications*, 23(4) :146–152.
- [Eriksson and Stanton, 2017] Eriksson, A. and Stanton, N. A. (2017). Takeover time in highly automated vehicles : noncritical transitions to and from manual control. *Human factors*, 59(4) :689–705.
- [Etemad, 2017] Etemad, A. (2017). Adaptive : Automated driving applications and technologies for intelligent vehicles. *Automated Driving : Safer and More Efficient Future Driving*, pages 535–540.
- [Fastenmeier and Gstalter, 2007] Fastenmeier, W. and Gstalter, H. (2007). Driving task analysis as a tool in traffic safety research and practice. *Safety Science*, 45(9) :952–979.
- [Fitch et al., 2009] Fitch, G., Lee, S., Klauer, S., Hankey, J., Sudweeks, J., and Dingus, T. (2009). Analysis of lane-change crashes and near-crashes. *US Department of Transportation, National Highway Traffic Safety Administration*.
- [Flad et al., 2017] Flad, M., Fröhlich, L., and Hohmann, S. (2017). Cooperative shared control driver assistance systems based on motion primitives and differential games. *IEEE Transactions on Human-Machine Systems*, 47(5) :711–722.
- [Flad et al., 2014] Flad, M., Otten, J., Schwab, S., and Hohmann, S. (2014). Steering driver assistance system : A systematic cooperative shared control design approach. In *2014 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pages 3585–3592.

- [Flemisch et al., 2003] Flemisch, F. O., Adams, C. A., Conway, S. R., Goodrich, K. H., Palmer, M. T., and Schutte, P. C. (2003). The h-metaphor as a guideline for vehicle automation and interaction. Technical report.
- [Gahinet et al., 1994] Gahinet, P., Nemirovskii, A., Laub, A., and Chilali, M. (1994). The lmi control toolbox. In *Proceedings of 1994 33rd IEEE Conference on Decision and Control*, volume 3, pages 2038–2041 vol.3.
- [Galvani, 2019] Galvani, M. (2019). History and future of driver assistance. *IEEE Instrumentation & Measurement Magazine*, 22(1) :11–16.
- [Gauriau et al., 2015] Gauriau, R., Cuingnet, R., Lesage, D., and Bloch, I. (2015). Multi-organ localization with cascaded global-to-local regression and shape prior. *Medical image analysis*, 23(1) :70–83.
- [Geiger et al., 2012] Geiger, A., Lauer, M., Moosmann, F., Ranft, B., Rapp, H., Stiller, C., and Ziegler, J. (2012). Team annieway’s entry to the 2011 grand cooperative driving challenge. *IEEE Transactions on Intelligent Transportation Systems*, 13(3) :1008–1017.
- [Glaser et al., 2010] Glaser, S., Vanholme, B., Mammar, S., Gruyer, D., and Nouveliere, L. (2010). Maneuver-based trajectory planning for highly autonomous vehicles on real road with traffic and driver interaction. *IEEE Transactions on intelligent transportation systems*, 11(3) :589–606.
- [Gold et al., 2016] Gold, C., Körber, M., Lechner, D., and Bengler, K. (2016). Taking over control from highly automated vehicles in complex traffic situations : The role of traffic density. *Human factors*, 58(4) :642–652.
- [Gordon and Lidberg, 2015] Gordon, T. and Lidberg, M. (2015). Automated driving and autonomous functions on road vehicles. *Vehicle System Dynamics*, 53(7) :958–994.
- [Graf et al., 2013] Graf, R., Deusch, H., Fritzsche, M., and Dietmayer, K. (2013). A learning concept for behavior prediction in traffic situations. In *2013 IEEE Intelligent Vehicles Symposium (IV)*, pages 672–677.
- [Griffin et al., 2005] Griffin, W. B., Provancher, W. R., and Cutkosky, M. R. (2005). Feedback strategies for telemanipulation with shared control of object handling forces. *Presence*, 14(6) :720–731.
- [Groeger, 2000] Groeger, J. A. (2000). *Understanding driving : Applying cognitive psychology to a complex everyday task*. Psychology Press.
- [Haigney et al., 2000] Haigney, D., Taylor, R., and Westerman, S. (2000). Concurrent mobile (cellular) phone use and driving performance : task demand characteristics and compensatory processes. *Transportation Research Part F : Traffic Psychology and Behaviour*, 3(3) :113–121.
- [Hamdan et al., 2021] Hamdan, A., Talj, R., and Cherfaoui, V. (2021). A fuzzy logic shared steering control approach for semi-autonomous vehicle. In *2021 20th International Conference on Advanced Robotics (ICAR)*, pages 83–90.
- [Han et al., 2021] Han, J., Zhao, J., Zhu, B., and Song, D. (2021). Adaptive steering torque coupling framework considering conflict resolution for human-machine shared driving. *IEEE Transactions on Intelligent Transportation Systems*.
- [Hang et al., 2017] Hang, P., Chen, X., and Luo, F. (2017). Path-tracking controller design for a 4wis and 4wid electric vehicle with steer-by-wire system. Technical report, SAE Technical Paper.
- [Hang et al., 2020] Hang, P., Lv, C., Huang, C., Cai, J., Hu, Z., and Xing, Y. (2020). An integrated framework of decision making and motion planning for autonomous vehicles considering social behaviors. *IEEE transactions on vehicular technology*, 69(12) :14458–14469.
- [Hang et al., 2021] Hang, P., Lv, C., Huang, C., Xing, Y., and Hu, Z. (2021). Cooperative decision making of connected automated vehicles at multi-lane merging zone : A coalitional game approach. *IEEE Transactions on Intelligent Transportation Systems*, 23(4) :3829–3841.

- [Hasenjäger and Wersing, 2017] Hasenjäger, M. and Wersing, H. (2017). Personalization in advanced driver assistance systems and autonomous vehicles : A review. In *2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*, pages 1–7.
- [Hemminghaus and Kopp, 2017] Hemminghaus, J. and Kopp, S. (2017). Towards adaptive social behavior generation for assistive robots using reinforcement learning. In *Proceedings of the 2017 ACM/IEEE International Conference on Human-Robot Interaction*, pages 332–340.
- [Hess and Modjtahedzadeh, 1990] Hess, R. and Modjtahedzadeh, A. (1990). A control theoretic model of driver steering behavior. *IEEE Control Systems Magazine*, 10(5) :3–8.
- [Hinds et al., 2004] Hinds, P. J., Roberts, T. L., and Jones, H. (2004). Whose job is it anyway? a study of human-robot interaction in a collaborative task. *Human-Computer Interaction*, 19(1-2) :151–181.
- [Hoc et al., 2012] Hoc, J., Chevrel, P., Deroo, M., Mars, F., Petiot, J., Bellet, T., Paris, J., Netto, M., Saint-Pierre, G., Goyat, L., et al. (2012). Partage-contrôle partagé entre conducteur et assistance à la conduite automobile pour une trajectoire sécurisée (rapport de synthèse). *Iffstar, Publications scientifiques*.
- [Hoc, 2001] Hoc, J.-M. (2001). Towards a cognitive approach to human-machine cooperation in dynamic situations. *International journal of human-computer studies*, 54(4) :509–540.
- [Hoc et al., 2006] Hoc, J.-M., Mars, F., Milleville-Pennel, I., Jolly, É., Netto, M., and Blosseville, J.-M. (2006). Human-machine cooperation in car driving for lateral safety : delegation and mutual control. *Le travail humain*, 69(2) :153–182.
- [Hoc et al., 2009] Hoc, J.-M., Young, M. S., and Blosseville, J.-M. (2009). Cooperation between drivers and automation : implications for safety. *Theoretical Issues in Ergonomics Science*, 10(2) :135–160.
- [Hoeger et al., 2008] Hoeger, R., Amditis, A., Kunert, M., Hoess, A., Flemisch, F., Krueger, H.-P., Bartels, A., Beutner, A., and Pagle, K. (2008). Highly automated vehicles for intelligent transport : Haveit approach. In *ITS World Congress, NY, USA*.
- [Hoeger et al., 2011] Hoeger, R., Zeng, H., Hoess, A., Kranz, T., Boverie, S., Strauss, M., Jakobsson, E., Beutner, A., Bartels, A., To, T., et al. (2011). The future of driving-haveit (final report, deliverable d61. 1). *Regensburg, Germany : Continental Automotive GmbH*.
- [Hosking et al., 2009] Hosking, S. G., Young, K. L., and Regan, M. A. (2009). The effects of text messaging on young drivers. *Human factors*, 51(4) :582–592.
- [Hou et al., 2013] Hou, Y., Edara, P., and Sun, C. (2013). Modeling mandatory lane changing using bayes classifier and decision trees. *IEEE Transactions on Intelligent Transportation Systems*, 15(2) :647–655.
- [Houenou et al., 2013] Houenou, A., Bonnifait, P., Cherfaoui, V., and Yao, W. (2013). Vehicle trajectory prediction based on motion model and maneuver recognition. In *2013 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pages 4363–4369.
- [Hoult and Cole, 2008] Hoult, W. and Cole, D. J. (2008). A neuromuscular model featuring co-activation for use in driver simulation. *Vehicle System Dynamics*, 46(S1) :175–189.
- [Huang et al., 2006] Huang, G.-B., Zhu, Q.-Y., and Siew, C.-K. (2006). Extreme learning machine : theory and applications. *Neurocomputing*, 70(1-3) :489–501.
- [Huang et al., 2019] Huang, M., Gao, W., Wang, Y., and Jiang, Z.-P. (2019). Data-driven shared steering control of semi-autonomous vehicles. *IEEE Transactions on Human-Machine Systems*, 49(4) :350–361.
- [Inagaki and Sheridan, 2019] Inagaki, T. and Sheridan, T. B. (2019). A critique of the sae conditional driving automation definition, and analyses of options for improvement. *Cognition, technology & work*, 21 :569–578.

- [Johansen et al., 2000] Johansen, T. A., Shorten, R., and Murray-Smith, R. (2000). On the interpretation and identification of dynamic takagi-sugeno fuzzy models. *IEEE Transactions on Fuzzy systems*, 8(3) :297–313.
- [Jordan et al., 2007] Jordan, N., Franck, M., and Jean-Michel, H. (2007). Lateral control support for car drivers : a human-machine cooperation approach. In *Proceedings of the 14th European Conference on Cognitive Ergonomics : Invent ! Explore !*, pages 249–252.
- [Kahneman, 1973] Kahneman, D. (1973). *Attention and effort*, volume 1063. Citeseer.
- [Kashevnik et al., 2021] Kashevnik, A., Shchedrin, R., Kaiser, C., and Stocker, A. (2021). Driver distraction detection methods : A literature review and framework. *IEEE Access*, 9 :60063–60076.
- [Kasper et al., 2012] Kasper, D., Weidl, G., Dang, T., Breuel, G., Tamke, A., Wedel, A., and Rosenstiel, W. (2012). Object-oriented bayesian networks for detection of lane change maneuvers. *IEEE Intelligent Transportation Systems Magazine*, 4(3) :19–31.
- [Katzourakis et al., 2011] Katzourakis, D., Alirezaei, M., de Winter, J. C. F., Corno, M., Happee, R., Ghaffari, A., and Kazemi, R. (2011). Shared control for road departure prevention. In *2011 IEEE International Conference on Systems, Man, and Cybernetics*, pages 1037–1043.
- [Koga et al., 2016] Koga, A., Okuda, H., Tazaki, Y., Suzuki, T., Haraguchi, K., and Kang, Z. (2016). Realization of different driving characteristics for autonomous vehicle by using model predictive control. In *2016 IEEE Intelligent Vehicles Symposium (IV)*, pages 722–728.
- [Koga et al., 2015] Koga, A., Okuda, H., Tazaki, Y., Suzuki, T., Levedahl, B., Haraguchi, K., and Kang, Z. (2015). Autonomous lane tracking reflecting skilled/un-skilled driving characteristics. In *IECON 2015 - 41st Annual Conference of the IEEE Industrial Electronics Society*, pages 003175–003180.
- [Kraetsch et al., 2021] Kraetsch, C., Eriksson, G., Strand, N., Anon, F., Leuteritz, J.-P., and Schrauth, B. (2021). *Bridging Gaps for the Adoption of Automated Vehicles—BRAVE Aspects for Trust Vehicles—Development of Innovative HMIs to Increase Acceptance*, pages 25–43. Springer International Publishing, Cham.
- [Kuderer et al., 2015] Kuderer, M., Gulati, S., and Burgard, W. (2015). Learning driving styles for autonomous vehicles from demonstration. In *2015 IEEE International Conference on Robotics and Automation (ICRA)*, pages 2641–2646.
- [Kumar et al., 2013] Kumar, P., Perrollaz, M., Lefèvre, S., and Laugier, C. (2013). Learning-based approach for online lane change intention prediction. In *2013 IEEE Intelligent Vehicles Symposium (IV)*, pages 797–802.
- [Kuutti et al., 2020] Kuutti, S., Bowden, R., Jin, Y., Barber, P., and Fallah, S. (2020). A survey of deep learning applications to autonomous vehicle control. *IEEE Transactions on Intelligent Transportation Systems*, 22(2) :712–733.
- [Land and Lee, 1994] Land, M. F. and Lee, D. N. (1994). Where we look when we steer. *Nature*, 369(6483) :742–744.
- [Lawitzky et al., 2013] Lawitzky, A., Althoff, D., Passenberg, C. F., Tanzmeister, G., Wollherr, D., and Buss, M. (2013). Interactive scene prediction for automotive applications. In *2013 IEEE Intelligent Vehicles Symposium (IV)*, pages 1028–1033.
- [Lecun et al., 1998] Lecun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11) :2278–2324.
- [Lee and Moray, 1992] Lee, J. and Moray, N. (1992). Trust, control strategies and allocation of function in human-machine systems. *Ergonomics*, 35(10) :1243–1270.
- [Lee et al., 2020] Lee, J. D., Regan, M. A., and Horrey, W. J. (2020). Workload, distraction, and automation. *Handbook of Human Factors for Automated, Connected, and Intelligent Vehicles*, pages 107–125.

- [Lee and See, 2004] Lee, J. D. and See, K. A. (2004). Trust in automation : Designing for appropriate reliance. *Human factors*, 46(1) :50–80.
- [Lee et al., 2018] Lee, J.-W., Lee, S.-K., and Oh, H.-s. (2018). Autopilot project : Development of intersection safety information system and service technology for autonomous driving. *The Journal of Korean Institute of Communications and Information Sciences*, 43(01) :83–90.
- [Lefevre et al., 2014] Lefevre, S., Gao, Y., Vasquez, D., Tseng, H. E., Bajcsy, R., and Borrelli, F. (2014). Lane keeping assistance with learning-based driver model and model predictive control. In *12th International Symposium on Advanced Vehicle Control*.
- [Li et al., 2016] Li, L., Liu, Y., Wang, J., Deng, W., and Oh, H. (2016). Human dynamics based driver model for autonomous car. *IET Intelligent Transport Systems*, 10(8) :545–554.
- [Li et al., 2018] Li, L., Ota, K., and Dong, M. (2018). Humanlike driving : Empirical decision-making system for autonomous vehicles. *IEEE Transactions on Vehicular Technology*, 67(8) :6814–6823.
- [Li et al., 2017a] Li, R., Li, S., Gao, H., Li, K., Cheng, B., and Li, D. (2017a). Effects of human adaptation and trust on shared control for driver-automation cooperative driving. Technical report, SAE Technical Paper.
- [Li et al., 2017b] Li, R., Li, Y., Li, S. E., Burdet, E., and Cheng, B. (2017b). Driver-automation indirect shared control of highly automated vehicles with intention-aware authority transition. In *2017 IEEE Intelligent Vehicles Symposium (IV)*, pages 26–32.
- [Li et al., 2017c] Li, R., Li, Y., Li, S. E., Burdet, E., and Cheng, B. (2017c). Indirect shared control of highly automated vehicles for cooperative driving between driver and automation. *arXiv preprint arXiv :1704.00866*.
- [Lin et al., 2018] Lin, Q., Li, S. E., Du, X., Zhang, X., Peng, H., Luo, Y., and Li, K. (2018). Minimize the fuel consumption of connected vehicles between two red-signalized intersections in urban traffic. *IEEE Transactions on Vehicular Technology*, 67(10) :9060–9072.
- [Liu et al., 2014] Liu, Q., Lathrop, B., and Butakov, V. (2014). Vehicle lateral position prediction : A small step towards a comprehensive risk assessment system. In *17th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, pages 667–672.
- [Liu et al., 2016] Liu, T., Yang, Y., Huang, G.-B., Yeo, Y. K., and Lin, Z. (2016). Driver distraction detection using semi-supervised machine learning. *IEEE Transactions on Intelligent Transportation Systems*, 17(4) :1108–1120.
- [Liu et al., 2019] Liu, Y., Wang, X., Li, L., Cheng, S., and Chen, Z. (2019). A novel lane change decision-making model of autonomous vehicle based on support vector machine. *IEEE Access*, 7 :26543–26550.
- [Löfberg, 2004] Löfberg, J. (2004). YALMIP : A toolbox for modeling and optimization in Matlab. In *IEEE Int. Symp. Comput. Aided Control Syst. Des.*, pages 284–289, Tapei.
- [Louw et al., 2015] Louw, T. L., Merat, N., and Jamson, A. H. (2015). Engaging with highly automated driving : to be or not to be in the loop? In *8th International Driving Symposium on Human Factors in Driver Assessment, Training and Vehicle Design*. Leeds.
- [Lu et al., 2019] Lu, C., Gong, J., Lv, C., Chen, X., Cao, D., and Chen, Y. (2019). A personalized behavior learning system for human-like longitudinal speed control of autonomous vehicles. *Sensors*, 19(17) :3672.
- [Lu et al., 2005] Lu, M., Wevers, K., and Van Der Heijden, R. (2005). Technical feasibility of advanced driver assistance systems (adas) for road traffic safety. *Transportation Planning and Technology*, 28(3) :167–187.
- [Lu et al., 2016] Lu, Z., Happee, R., Cabrall, C. D., Kyriakidis, M., and de Winter, J. C. (2016). Human factors of transitions in automated driving : A general framework and literature survey. *Transportation research part F : traffic psychology and behaviour*, 43 :183–198.

- [Lydia and Francis, 2019] Lydia, A. and Francis, S. (2019). Adagrad-an optimizer for stochastic gradient descent. *int. Journal of Computing and Information Sciences*, 6.
- [Ma et al., 2021] Ma, J., Cheng, Z., Zhang, X., Tomizuka, M., and Lee, T. H. (2021). Optimal decentralized control for uncertain systems by symmetric gauss–seidel semi-proximal alm. *IEEE Transactions on Automatic Control*, 66(11) :5554–5560.
- [Mamdani and Assilian, 1975] Mamdani, E. H. and Assilian, S. (1975). An experiment in linguistic synthesis with a fuzzy logic controller. *International journal of man-machine studies*, 7(1) :1–13.
- [Marcano et al., 2020] Marcano, M., Díaz, S., Pérez, J., and Irigoyen, E. (2020). A review of shared control for automated vehicles : Theory and applications. *IEEE Transactions on Human-Machine Systems*, 50(6) :475–491.
- [Mars et al., 2014] Mars, F., Deroo, M., and Hoc, J.-M. (2014). Analysis of human-machine cooperation when driving with different degrees of haptic shared control. *IEEE transactions on haptics*, 7(3) :324–333.
- [McRuer et al., 1977] McRuer, D. T., Allen, R. W., Weir, D. H., and Klein, R. H. (1977). New results in driver steering control models. *Human factors*, 19(4) :381–397.
- [McWilliams and Ward, 2021] McWilliams, T. and Ward, N. (2021). Underload on the road : Measuring vigilance decrements during partially automated driving. *Frontiers in Psychology*, 12.
- [Medero et al., 2022] Medero, A., Sename, O., and Puig, V. (2022). Lpv lateral control for adas based on driver performance monitoring. *IFAC-PapersOnLine*, 55(6) :685–690.
- [Michon, 1985] Michon, J. A. (1985). A critical view of driver behavior models : what do we know, what should we do? *Human behavior and traffic safety*, pages 485–524.
- [Miller et al., 2016] Miller, D., Johns, M., Mok, B., Gowda, N., Sirkin, D., Lee, K., and Ju, W. (2016). Behavioral measurement of trust in automation : the trust fall. In *Proceedings of the human factors and ergonomics society annual meeting*, volume 60, pages 1849–1853. SAGE Publications Sage CA : Los Angeles, CA.
- [Mitsunaga et al., 2006] Mitsunaga, N., Smith, C., Kanda, T., Ishiguro, H., and Hagita, N. (2006). Robot behavior adaptation for human-robot interaction based on policy gradient reinforcement learning. *Journal of the Robotics Society of Japan*, 24(7) :820–829.
- [Mouhagir et al., 2019] Mouhagir, H., Talj, R., Cherfaoui, V., Aioun, F., and Guillemard, F. (2019). Evidential-based approach for trajectory planning with tentacles, for autonomous vehicles. *IEEE Transactions on Intelligent Transportation Systems*, 21(8) :3485–3496.
- [Mulder et al., 2004] Mulder, M., Paassen, M. R. v., and Boer, E. R. (2004). Exploring the roles of information in the manual control of vehicular locomotion : From kinematics and dynamics to cybernetics. *Presence : Teleoperators & Virtual Environments*, 13(5) :535–548.
- [Muslim and Itoh, 2019] Muslim, H. and Itoh, M. (2019). A theoretical framework for designing human-centered automotive automation systems. *Cognition, Technology & Work*, 21 :685–697.
- [Naujoks and Neukum, 2014] Naujoks, F. and Neukum, A. (2014). Specificity and timing of advisory warnings based on cooperative perception. *Mensch & Computer 2014-Workshopband*.
- [Nguyen et al., 2017] Nguyen, A.-T., Sentouh, C., and Popieul, J.-C. (2017). Driver-automation cooperative approach for shared steering control under multiple system constraints : Design and experiments. *IEEE Transactions on Industrial Electronics*, 64(5) :3819–3830.
- [Nguyen et al., 2015] Nguyen, A.-T., Sentouh, C., Popieul, J.-C., and Soualmi, B. (2015). Shared lateral control with online adaptation of the automation degree for driver steering assist system : A weighting design approach. In *IEEE 54th Annual Conference on Decision and Control (CDC)*, pages 857–862, Osaka, Japan.

- [Nilsson et al., 2016] Nilsson, J., Silvlin, J., Brannstrom, M., Coelingh, E., and Fredriksson, J. (2016). If, when, and how to perform lane change maneuvers on highways. *IEEE Intelligent Transportation Systems Magazine*, 8(4) :68–78.
- [Nishimura et al., 2015] Nishimura, R., Wada, T., and Sugiyama, S. (2015). Haptic shared control in steering operation based on cooperative status between a driver and a driver assistance system. *arXiv preprint arXiv :1504.05770*.
- [Noto et al., 2011] Noto, N., Okuda, H., Tazaki, Y., Inagaki, S., and Suzuki, T. (2011). Obstacle avoidance assisting system based on personalized potential field. In *SICE Annual Conference 2011*, pages 476–481.
- [Noto et al., 2012] Noto, N., Okuda, H., Tazaki, Y., and Suzuki, T. (2012). Steering assisting system for obstacle avoidance based on personalized potential field. In *2012 15th International IEEE Conference on Intelligent Transportation Systems*, pages 1702–1707.
- [NTSB, 2016] NTSB (2016). Collision between a car operating with automated vehicle control systems and a tractor-semitrailer truck near williston. *National Transportation Safety Board : Highway Accident Report NTSB/HAR-17/02*. Washington, DC.
- [NTSB, 2018] NTSB (2018). Most wanted list of transportation safety improvements : Reduce fatigue-related accidents. *National Transportation Safety Board : Washington, DC, USA, 2018*.
- [Ohtake et al., 2003] Ohtake, H., Tanaka, K., and Wang, H. O. (2003). Fuzzy modeling via sector nonlinearity concept. *Integrated Computer-Aided Engineering*, 10(4) :333–341.
- [Okamoto and Tsiotras, 2019] Okamoto, K. and Tsiotras, P. (2019). Data-driven human driver lateral control models for developing haptic-shared control advanced driver assist systems. *Robotics and Autonomous Systems*, 114 :155–171.
- [O’Malley et al., 2006] O’Malley, M. K., Gupta, A., Gen, M., and Li, Y. (2006). Shared control in haptic systems for performance enhancement and training. *Journal of Dynamic Systems, Measurement, and Control*, 128(1) :75–85.
- [OMS, 2018] OMS (2018). Global status report on road safety 2018. World Health Organisation.
- [Ortiz et al., 2012] Ortiz, M. G., Kummert, F., and Schmüdderich, J. (2012). Prediction of driver behavior on a limited sensory setting. In *2012 15th International IEEE Conference on Intelligent Transportation Systems*, pages 638–643.
- [Oudainia et al., 2022a] Oudainia, M. R., Sentouh, C., Nguyen, A.-T., and Popieul, J.-C. (2022a). Online driver model parameter identification using the lyapunov approach based shared control. *Frontiers in Control Engineering*, 3.
- [Oudainia et al., 2022b] Oudainia, M. R., Sentouh, C., Nguyen, A.-T., and Popieul, J.-C. (2022b). Personalized decision making and lateral path planning for intelligent vehicles in lane change scenarios. In *2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC)*, pages 4302–4307.
- [Oudainia et al., 2023] Oudainia, M. R., Sentouh, C., Nguyen, A.-T., and Popieul, J.-C. (2023). Adaptive cost function-based shared driving control for cooperative lane-keeping systems with user-test experiments. *IEEE Transactions on Intelligent Vehicles*, pages 1–11.
- [Oufroukh and Mammar, 2014] Oufroukh, N. A. and Mammar, S. (2014). Integrated driver co-pilote approach for vehicle lateral control. In *2014 IEEE Intelligent Vehicles Symposium Proceedings*, pages 1163–1168.
- [Pano et al., 2022] Pano, B., Chevrel, P., Claveau, F., Sentouh, C., and Mars, F. (2022). Obstacle avoidance in highly automated cars : can progressive haptic shared control make it safer and smoother ? *IEEE Transactions on Human-Machine Systems*, 52(4) :547–556.
- [Pano et al., 2020] Pano, B., Claveau, F., Chevrel, P., Sentouh, C., and Mars, F. (2020). Systematic h_2/h_∞ haptic shared control synthesis for cars, parameterized by sharing level. In *2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pages 4416–4423.

- [Pano et al., 2019] Pano, B., Zhao, Y., Chevrel, P., Claveau, F., and Mars, F. (2019). Shared control based on an ecological feedforward and a driver model based feedback. *IFAC-PapersOnLine*, 52(5) :385–392.
- [Parasuraman et al., 2000] Parasuraman, R., Sheridan, T. B., and Wickens, C. D. (2000). A model for types and levels of human interaction with automation. *IEEE Transactions on systems, man, and cybernetics-Part A : Systems and Humans*, 30(3) :286–297.
- [Pashler, 1994] Pashler, H. (1994). Overlapping mental operations in serial performance with preview. *The Quarterly Journal of Experimental Psychology Section A*, 47(1) :161–191.
- [Payre et al., 2016] Payre, W., Cestac, J., and Delhomme, P. (2016). Fully automated driving : Impact of trust and practice on manual control recovery. *Human factors*, 58(2) :229–241.
- [Peters et al., 2013] Peters, M., Ketter, W., Saar-Tsechansky, M., and Collins, J. (2013). A reinforcement learning approach to autonomous decision-making in smart electricity markets. *Machine learning*, 92 :5–39.
- [Pick and Cole, 2007] Pick, A. and Cole, D. J. (2007). Dynamic properties of a driver’s arms holding a steering wheel. *Proceedings of the Institution of Mechanical Engineers, Part D : Journal of Automobile Engineering*, 221(12) :1475–1486.
- [Pick and Cole, 2008] Pick, A. J. and Cole, D. J. (2008). A mathematical model of driver steering control including neuromuscular dynamics. *Journal of Dynamic Systems, Measurement, and Control*, 130.
- [Pilkington-Cheney et al., 2021] Pilkington-Cheney, F., Afghari, A. P., Filtness, A., Papadimitriou, E., Lourenço, A., and Brijs, T. (2021). The i-dreams intervention strategies to reduce driver fatigue and sleepiness for different transport modes. In *2021 7th IEEE International Conference on Models and Technologies for Intelligent Transportation Systems (MT-ITS)*, pages 1–6.
- [Plöchl and Edelman, 2007] Plöchl, M. and Edelman, J. (2007). Driver models in automobile dynamics application. *Vehicle system dynamics*, 45(7-8) :699–741.
- [Pomerleau, 1997] Pomerleau, D. (1997). *Neural Network Vision for Robot Driving*, pages 53–72. Springer US, Boston, MA.
- [Pomerleau, 1988] Pomerleau, D. A. (1988). *Alvinn : An autonomous land vehicle in a neural network*. In Touretzky, D., editor, *Advances in Neural Information Processing Systems*, volume 1. Morgan-Kaufmann.
- [Rajamani, 2011] Rajamani, R. (2011). *Vehicle dynamics and control*. Springer Science & Business Media.
- [Rakshitha and Naveen, 2022] Rakshitha, K. P. and Naveen, N. (2022). Op-rmsprop (optimized-root mean square propagation) classification for prediction of polycystic ovary syndrome (pcos) using hybrid machine learning technique. *International Journal of Advanced Computer Science and Applications*, 13(6).
- [Ranney et al., 2005] Ranney, T. A., Harbluk, J. L., and Noy, Y. I. (2005). Effects of voice technology on test track driving performance : Implications for driver distraction. *Human factors*, 47(2) :439–454.
- [Rasmussen, 1983] Rasmussen, J. (1983). Skills, rules, and knowledge ; signals, signs, and symbols, and other distinctions in human performance models. *IEEE transactions on systems, man, and cybernetics*, (3) :257–266.
- [Rath et al., 2019] Rath, J. J., Senouth, C., and Popieul, J. C. (2019). Personalised lane keeping assist strategy : adaptation to driving style. *IET Control Theory & Applications*, 13(1) :106–115.
- [Reichenbach et al., 2010] Reichenbach, J., Onnasch, L., and Manzey, D. (2010). Misuse of automation : The impact of system experience on complacency and automation bias in interaction
-

- with automated aids. *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, 54(4) :374–378.
- [Rossi et al., 2012] Rossi, R., Gastaldi, M., Biondi, F., and Mulatti, C. (2012). Evaluating the impact of processing spoken words on driving : experiments with driving simulator. *Transportation research record*, 2321(1) :66–72.
- [SAE, 2021] SAE (2021). *Taxonomy and definitions for terms related to driving automation systems for on-road motor vehicles*. SAE International.
- [Sala and Arino, 2009] Sala, A. and Arino, C. (2009). Polynomial fuzzy models for nonlinear control : A taylor series approach. *IEEE Transactions on Fuzzy Systems*, 17(6) :1284–1295.
- [Sala et al., 2005] Sala, A., Guerra, T. M., and Babuška, R. (2005). Perspectives of fuzzy systems and control. *Fuzzy sets and systems*, 156(3) :432–444.
- [Saleh, 2012] Saleh, L. (2012). *Contrôle latéral partagé d’un véhicule automobile*. PhD thesis, Ecole Centrale de Nantes (ECN).
- [Saleh et al., 2013] Saleh, L., Chevrel, P., Claveau, F., Lafay, J.-F., and Mars, F. (2013). Shared steering control between a driver and an automation : Stability in the presence of driver behavior uncertainty. *IEEE Transactions on Intelligent Transportation Systems*, 14(2) :974–983.
- [Saleh et al., 2011] Saleh, L., Chevrel, P., Mars, F., Lafay, J.-F., and Claveau, F. (2011). Human-like cybernetic driver model for lane keeping. *IFAC Proceedings Volumes*, 44(1) :4368–4373.
- [Salvucci, 2006] Salvucci, D. D. (2006). Modeling driver behavior in a cognitive architecture. *Human factors*, 48(2) :362–380.
- [Salvucci and Gray, 2004] Salvucci, D. D. and Gray, R. (2004). A two-point visual control model of steering. *Perception*, 33(10) :1233–1248.
- [Sama et al., 2020] Sama, K., Morales, Y., Liu, H., Akai, N., Carballo, A., Takeuchi, E., and Takeda, K. (2020). Extracting human-like driving behaviors from expert driver data using deep learning. *IEEE transactions on vehicular technology*, 69(9) :9315–9329.
- [Sarter and Woods, 1995] Sarter, N. B. and Woods, D. D. (1995). How in the world did we ever get into that mode? mode error and awareness in supervisory control. *Human factors*, 37(1) :5–19.
- [Saunders et al., 2015] Saunders, J., Syrdal, D. S., Koay, K. L., Burke, N., and Dautenhahn, K. (2015). “teach me–show me”—end-user personalization of a smart home and companion robot. *IEEE Transactions on Human-Machine Systems*, 46(1) :27–40.
- [Schlechtriemen et al., 2014] Schlechtriemen, J., Wedel, A., Hillenbrand, J., Breuel, G., and Kuhnert, K.-D. (2014). A lane change detection approach using feature ranking with maximized predictive power. In *2014 IEEE Intelligent Vehicles Symposium Proceedings*, pages 108–114.
- [Schleicher et al., 2011] Schleicher, S., Gelau, C., et al. (2011). The influence of cruise control and adaptive cruise control on driving behaviour—a driving simulator study. *Accident Analysis & Prevention*, 43(3) :1134–1139.
- [Schnelle et al., 2017] Schnelle, S., Wang, J., Su, H., and Jagacinski, R. (2017). A driver steering model with personalized desired path generation. *IEEE Transactions on Systems, Man, and Cybernetics : Systems*, 47(1) :111–120.
- [Schubert, 2011] Schubert, R. (2011). Evaluating the utility of driving : Toward automated decision making under uncertainty. *IEEE Transactions on Intelligent Transportation Systems*, 13(1) :354–364.
- [Sentouh et al., 2009] Sentouh, C., Chevrel, P., Mars, F., and Claveau, F. (2009). A sensorimotor driver model for steering control. In *2009 IEEE International Conference on Systems, Man and Cybernetics*, pages 2462–2467.

- [Sentouh et al., 2018] Sentouh, C., Nguyen, A.-T., Benloucif, M. A., and Popieul, J.-C. (2018). Driver-automation cooperation oriented approach for shared control of lane keeping assist systems. *IEEE Transactions on Control Systems Technology*, 27(5) :1962–1978.
- [Sentouh et al., 2014] Sentouh, C., Popieul, J.-C., Debernard, S., and Boverie, S. (2014). Human-machine interaction in automated vehicle : The abv project. *IFAC Proceedings Volumes*, 47(3) :6344–6349.
- [Sentouh et al., 2013] Sentouh, C., Soualmi, B., Popieul, J.-C., and Debernard, S. (2013). Co-operative steering assist control system. In *2013 IEEE International Conference on Systems, Man, and Cybernetics*, pages 941–946.
- [Sheridan and Verplank, 1978] Sheridan, T. B. and Verplank, W. L. (1978). Human and computer control of undersea teleoperators. Technical report, Massachusetts Inst of Tech Cambridge Man-Machine Systems Lab.
- [Shu et al., 2017] Shu, T., Gao, X., Ryoo, M. S., and Zhu, S.-C. (2017). Learning social affordance grammar from videos : Transferring human interactions to human-robot interactions. In *2017 IEEE International Conference on Robotics and Automation (ICRA)*, pages 1669–1676.
- [Soualmi et al., 2014] Soualmi, B., Sentouh, C., Popieul, J., and Debernard, S. (2014). Automation-driver cooperative driving in presence of undetected obstacles. *Control Engineering Practice*, 24 :106–119.
- [Stanton et al., 1997] Stanton, N. A., Young, M., and McCaulder, B. (1997). Drive-by-wire : The case of driver workload and reclaiming control with adaptive cruise control. *Safety science*, 27(2-3) :149–159.
- [Stanton and Young, 2005] Stanton, N. A. and Young, M. S. (2005). Driver behaviour with adaptive cruise control. *Ergonomics*, 48(10) :1294–1313.
- [Strayer and Drews, 2007] Strayer, D. L. and Drews, F. A. (2007). Cell-phone-induced driver distraction. *Current Directions in Psychological Science*, 16(3) :128–131.
- [Strayer and Fisher, 2016] Strayer, D. L. and Fisher, D. L. (2016). Spider : A framework for understanding driver distraction. *Human factors*, 58(1) :5–12.
- [Strayer et al., 2011] Strayer, D. L., Watson, J. M., and Drews, F. A. (2011). Cognitive distraction while multitasking in the automobile. In *Psychology of learning and motivation*, volume 54, pages 29–58. Elsevier.
- [Sweke et al., 2020] Sweke, R., Wilde, F., Meyer, J., Schuld, M., Fährmann, P. K., Meynard-Piganeau, B., and Eisert, J. (2020). Stochastic gradient descent for hybrid quantum-classical optimization. *Quantum*, 4 :314.
- [Takagi and Sugeno, 1985] Takagi, T. and Sugeno, M. (1985). Fuzzy identification of systems and its applications to modeling and control. *IEEE transactions on systems, man, and cybernetics*, (1) :116–132.
- [Takahashi et al., 1989] Takahashi, A., Hongo, T., Ninomiya, Y., and Sugimoto, G. (1989). Local path planning and motion control for agv in positioning. In *Proceedings. IEEE/RSJ International Workshop on Intelligent Robots and Systems ' (IROS '89) 'The Autonomous Mobile Robots and Its Applications*, pages 392–397.
- [Tanaka et al., 1998] Tanaka, K., Ikeda, T., and Wang, H. O. (1998). Fuzzy regulators and fuzzy observers : relaxed stability conditions and lmi-based designs. *IEEE Transactions on fuzzy systems*, 6(2) :250–265.
- [Tanaka and Sugeno, 1992] Tanaka, K. and Sugeno, M. (1992). Stability analysis and design of fuzzy control systems. *Fuzzy sets and systems*, 45(2) :135–156.
- [Tanaka and Wang, 2004] Tanaka, K. and Wang, H. O. (2004). *Fuzzy control systems design and analysis : a linear matrix inequality approach*. John Wiley & Sons.

- [Tattegrain et al., 2021] Tattegrain, H., Coeugnet, S., Petrov, M., Mars, F., Wang, X., Hidalgo-Munoz, A., Jallais, C., Fort, A., Schnebelen, D., and Beurrier, G. (2021). Approach used to merge the different driver monitoring diagnostics in the AutoConduct project. In *7th International Conference on Driver Distraction and Inattention (DDI2021)*, pages 93–95, Lyon, France.
- [Taylor et al., 2013] Taylor, T., Pradhan, A., Divekar, G., Romoser, M., Muttart, J., Gomez, R., Pollatsek, A., and Fisher, D. L. (2013). The view from the road : The contribution of on-road glance-monitoring technologies to understanding driver behavior. *Accident Analysis & Prevention*, 58 :175–186.
- [Tian et al., 2022] Tian, H., Wei, C., Jiang, C., Li, Z., and Hu, J. (2022). Personalized lane change planning and control by imitation learning from drivers. *IEEE Transactions on Industrial Electronics*, 70(4) :3995–4006.
- [Tombu and Jolicœur, 2003] Tombu, M. and Jolicœur, P. (2003). A central capacity sharing model of dual-task performance. *Journal of Experimental Psychology : Human perception and performance*, 29(1) :3.
- [Treat et al., 1979] Treat, J. R., Tumbas, N. S., McDonald, S. T., Shinar, D., Hume, R. D., Mayer, R., Stansifer, R., and Castellan, N. J. (1979). Tri-level study of the causes of traffic accidents : final report. executive summary. Technical report, Indiana University, Bloomington, Institute for Research in Public Safety.
- [Treiber et al., 2000] Treiber, M., Hennecke, A., and Helbing, D. (2000). Congested traffic states in empirical observations and microscopic simulations. *Physical review E*, 62(2) :1805.
- [Vallon et al., 2017] Vallon, C., Ercan, Z., Carvalho, A., and Borrelli, F. (2017). A machine learning approach for personalized autonomous lane change initiation and control. In *2017 IEEE Intelligent Vehicles Symposium (IV)*, pages 1590–1595.
- [Vanderhaegen, 2012] Vanderhaegen, F. (2012). Cooperation and learning to increase the autonomy of adas. *Cognition, Technology & Work*, 14 :61–69.
- [Walch et al., 2015] Walch, M., Lange, K., Baumann, M., and Weber, M. (2015). Autonomous driving : investigating the feasibility of car-driver handover assistance. In *Proceedings of the 7th international conference on automotive user interfaces and interactive vehicular applications*, pages 11–18.
- [Wang and Tanaka, 2004] Wang, H. O. and Tanaka, K. (2004). *Fuzzy control systems design and analysis : A linear matrix inequality approach*. John Wiley & Sons.
- [Wang et al., 1996] Wang, H. O., Tanaka, K., and Griffin, M. F. (1996). An approach to fuzzy control of nonlinear systems : Stability and design issues. *IEEE transactions on fuzzy systems*, 4(1) :14–23.
- [Wang et al., 2016] Wang, J., Zhang, G., Wang, R., Schnelle, S. C., and Wang, J. (2016). A gain-scheduling driver assistance trajectory-following algorithm considering different driver steering characteristics. *IEEE Transactions on Intelligent Transportation Systems*, 18(5) :1097–1108.
- [Waytz et al., 2014] Waytz, A., Heafner, J., and Epley, N. (2014). The mind in the machine : Anthropomorphism increases trust in an autonomous vehicle. *Journal of experimental social psychology*, 52 :113–117.
- [Wei et al., 2010] Wei, J., Dolan, J. M., and Litkouhi, B. (2010). A prediction- and cost function-based algorithm for robust autonomous freeway driving. In *2010 IEEE Intelligent Vehicles Symposium*, pages 512–517.
- [Wickens, 2008] Wickens, C. D. (2008). Multiple resources and mental workload. *Human factors*, 50(3) :449–455.
- [Xiong et al., 2017] Xiong, L., Chng, C. B., Chui, C. K., Yu, P., and Li, Y. (2017). Shared control of a medical robot with haptic guidance. *International journal of computer assisted radiology and surgery*, 12 :137–147.

- [Xu et al., 2021] Xu, D., Zhang, S., Zhang, H., and Mandic, D. P. (2021). Convergence of the rmsprop deep learning method with penalty for nonconvex optimization. *Neural Networks*, 139 :17–23.
- [Xu et al., 2018] Xu, X., Zuo, L., Li, X., Qian, L., Ren, J., and Sun, Z. (2018). A reinforcement learning approach to autonomous decision making of intelligent vehicles on highways. *IEEE Transactions on Systems, Man, and Cybernetics : Systems*, 50(10) :3884–3897.
- [Yang et al., 2021] Yang, S., Zheng, H., Wang, J., and El Kamel, A. (2021). A personalized human-like lane-changing trajectory planning method for automated driving system. *IEEE Transactions on Vehicular Technology*, 70(7) :6399–6414.
- [Yang et al., 2019] Yang, W., Zheng, L., Li, Y., Ren, Y., and Xiong, Z. (2019). Automated highway driving decision considering driver characteristics. *IEEE transactions on intelligent transportation systems*, 21(6) :2350–2359.
- [Yerkes and Dodson, 1908] Yerkes, R. M. and Dodson, J. D. (1908). The relation of strength of stimulus to rapidity of habit-formation. *Journal of Comparative Neurology and Psychology*, 18(5) :459–482.
- [Young et al., 2011] Young, M. S., Birrell, S. A., and Stanton, N. A. (2011). Safe driving in a green world : A review of driver performance benchmarks and technologies to support ‘smart’ driving. *Applied ergonomics*, 42(4) :533–539.
- [Yu and Sethi, 1995] Yu, G. and Sethi, I. (1995). Road-following with continuous learning. In *Proceedings of the Intelligent Vehicles ’95. Symposium*, pages 412–417.
- [Yu et al., 2018] Yu, H., Tseng, H. E., and Langari, R. (2018). A human-like game theory-based controller for automatic lane changing. *Transportation Research Part C : Emerging Technologies*, 88 :140–158.
- [Zadeh, 1965] Zadeh, L. A. (1965). Fuzzy sets. *Information and control*, 8(3) :338–353.
- [Zhang et al., 2017] Zhang, J., Liao, Y., Wang, S., and Han, J. (2017). Study on driving decision-making mechanism of autonomous vehicle based on an optimized support vector machine regression. *Applied Sciences*, 8(1) :13.
- [Zhao and Rong, 2012] Zhao, X. and Rong, J. (2012). The relationship between driver fatigue and monotonous road environment. In *Computational intelligence for traffic and mobility*, pages 19–36. Springer.
- [Zhou et al., 2017] Zhou, B., Wang, Y., Yu, G., and Wu, X. (2017). A lane-change trajectory model from drivers’ vision view. *Transportation Research Part C : Emerging Technologies*, 85 :609–627.
- [Zhu et al., 2020] Zhu, B., Han, J., Zhao, J., and Wang, H. (2020). Combined hierarchical learning framework for personalized automatic lane-changing. *IEEE Transactions on Intelligent Transportation Systems*, 22(10) :6275–6285.
- [Ziebinski et al., 2016] Ziebinski, A., Cupek, R., Erdogan, H., and Waechter, S. (2016). A survey of adas technologies for the future perspective of sensor fusion. In *Computational Collective Intelligence : 8th International Conference, ICCCI 2016, Halkidiki, Greece, September 28-30, 2016. Proceedings, Part II 8*, pages 135–146. Springer.
- [Zinkevich et al., 2010] Zinkevich, M., Weimer, M., Li, L., and Smola, A. (2010). Parallelized stochastic gradient descent. *Advances in neural information processing systems*, 23.

