

UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

PRÉDICTION ET PLANIFICATION DE DÉCÉLÉRATION ADAPTATIVE POUR
UNE STRATÉGIE DE FREINAGE RÉGÉNÉRATIF OPTIMISÉE DES VÉHICULES
INTELLIGENTS

THÈSE PRÉSENTÉE
COMME EXIGENCE PARTIELLE DU
DOCTORAT EN GÉNIE MÉCANIQUE

PAR
MARWA ZIADIA

JUILLET 2025

Université du Québec à Trois-Rivières

Service de la bibliothèque

Avertissement

L'auteur de ce mémoire, de cette thèse ou de cet essai a autorisé l'Université du Québec à Trois-Rivières à diffuser, à des fins non lucratives, une copie de son mémoire, de sa thèse ou de son essai.

Cette diffusion n'entraîne pas une renonciation de la part de l'auteur à ses droits de propriété intellectuelle, incluant le droit d'auteur, sur ce mémoire, cette thèse ou cet essai. Notamment, la reproduction ou la publication de la totalité ou d'une partie importante de ce mémoire, de cette thèse et de son essai requiert son autorisation.

UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

Doctorat en génie mécanique (Ph.D)

Direction de recherche :

Sousso Kelouwani	Directeur de recherche
------------------	------------------------

Kodjo Agbossou	Codirecteur de recherche
----------------	--------------------------

Jury d'évaluation

Mamadou Lamine Doumbia	Président du jury
------------------------	-------------------

Kodjo Agbossou	Codirecteur de recherche
----------------	--------------------------

Sousso Kelouwani	Directeur de recherche
------------------	------------------------

Tahar Tafticht	Évaluateur externe, UQAT
----------------	--------------------------

Karim Belmokhtar	Évaluateur externe, CGEP/CNIMI
------------------	--------------------------------

Thèse soutenue le 4 juin 2025

Remerciements

Réaliser ce doctorat a constitué une aventure intellectuellement stimulante et humainement enrichissante, marquant une étape décisive dans mon parcours. Ce travail n'aurait pu voir le jour sans le soutien inestimable et les conseils avisés de nombreuses personnes, dont la bienveillance, la disponibilité et l'expertise ont été des piliers essentiels tout au long de cette recherche.

Je tiens tout particulièrement à exprimer ma profonde gratitude à mon directeur de recherche, Monsieur Souso Kelouwani, professeur au département de génie mécanique de l'UQTR, pour son encadrement rigoureux, ses orientations éclairées et son soutien constant, qui ont grandement contribué à la qualité et à la réussite de ce projet. Mes remerciements vont également à mon co-directeur de thèse, le Professeur Kodjo Agbossou, du département de génie électrique et génie informatique, dont les suggestions pertinentes et l'encouragement permanent ont enrichi mes travaux. Je souhaite aussi remercier chaleureusement le Dr. Ali Amamou pour son soutien et son aide précieuse durant toute cette période.

Je remercie l'ensemble des membres du jury pour avoir accepté d'évaluer mon travail avec attention et bienveillance. Je suis également profondément reconnaissant envers tous mes collègues et amis de l'Institut de recherche sur l'hydrogène (IRH) pour leur soutien constant et leur camaraderie qui ont rendu ce parcours encore plus enrichissant.

Un remerciement tout particulier s'adresse à ma mère, dont le dévouement et les sacrifices ont constitué la pierre angulaire de mon éducation et de mon parcours. Sa force et sa patience m'ont toujours inspiré la persévérance nécessaire pour surmonter les obstacles. Je souhaite exprimer toute ma gratitude à mon époux, Mohamed, dont le soutien inébranlable et la présence bienveillante ont été une source inestimable de motivation et de

réconfort. Son amour et sa confiance ont été essentiels à l'aboutissement de ce doctorat.

Je n'oublie pas non plus mes deux précieux garçons, Aman et Nassim, qui représentent ma plus grande source d'inspiration. Aman, ta curiosité et ton énergie m'ont rappelé l'importance de poursuivre mes rêves, malgré les sacrifices et les moments d'éloignement ; Nassim, ta venue au monde a apporté une lumière nouvelle à cette aventure, renforçant ma détermination à réussir. Je dédie cette réussite à vous, en espérant que vous grandirez en poursuivant vos propres rêves avec passion, courage et détermination.

Enfin, je tiens à remercier mes frères ainsi que mes beaux-parents, dont le soutien et l'encouragement ont été précieux tout au long de ce parcours.

Merci à toutes et à tous.

Résumé

L'électrification des transports représente une solution incontournable pour réduire l'empreinte carbone, atténuer le changement climatique et préserver l'environnement. Parmi les technologies émergentes, les véhicules électriques à batterie (BEV) suscitent un intérêt croissant dans les milieux académiques et industriels grâce à leur fonctionnement sans émissions directes de gaz à effet de serre. Toutefois, leur déploiement rencontre des défis majeurs, notamment en termes d'autonomie limitée et d'optimisation de l'efficacité énergétique en conditions de conduite réelles. Dans ce contexte, le développement de véhicules électriques intelligents (IEV) apparaît comme une solution prometteuse, car ils intègrent des capacités de prévision en temps réel des conditions de conduite et de l'environnement, permettant une gestion optimisée de l'énergie et une adaptation dynamique des stratégies de conduite pour améliorer l'efficacité énergétique et le confort des utilisateurs.

La littérature scientifique s'est largement penchée sur l'optimisation du freinage régénératif afin de maximiser la récupération d'énergie jusqu'à la limite de capacité du moteur dans les environnements urbains. Cependant, la plupart des recherches s'appuient sur des cycles de conduite standard qui ne reflètent pas la variabilité des styles de conduite et leur effet sur le potentiel de régénération d'énergie. De plus, leur effet sur le potentiel de régénération et n'intègrent pas aussi l'effet des conditions climatiques variées ni la présence de véhicules en amont, limitant ainsi l'adaptabilité des stratégies de freinage et leur acceptation par les conducteurs. Pour pallier ces lacunes, cette thèse propose un nouveau paradigme basé sur l'estimation préventive des performances naturelles de régénération individuelle, c'est-à-dire la potentialité du système à récupérer l'énergie jusqu'à la limite maximale du moteur propre à chaque conducteur. En intégrant cette estimation dans la stratégie de freinage, le profil de décélération est optimisé de manière

dynamique en fonction des caractéristiques spécifiques du style de conduite.

Motivée par cette problématique, la recherche a tout d'abord analysé la variabilité du potentiel de régénération en fonction des habitudes de freinage et des préférences de vitesse, démontrant que ce potentiel n'est pas fixe, mais dépend fortement du comportement individuel. Sur cette base, une stratégie de freinage adaptative a été développée pour optimiser la récupération d'énergie sur route sèche, en s'appuyant sur une prédiction à long terme (30 secondes) de la puissance régénérée, et en ajustant dynamiquement l'horizon de planification (choisi parmi quatre niveaux : long, moyen, court et optimal) via un modèle d'optimisation basé sur la programmation dynamique. Par la suite, afin d'adapter cette approche aux conditions climatiques variées, un modèle de reconnaissance du style de conduite a été intégré pour ajuster les contraintes de décélération en fonction des variations de l'adhérence et de la visibilité, permettant ainsi d'activer des stratégies spécifiques pour les routes glacées ou en conditions hivernales. Enfin, pour garantir une application efficace dans des environnements impliquant plusieurs véhicules, la stratégie a été étendue afin de trouver un compromis entre la maximisation de la récupération d'énergie jusqu'à la limite individuelle et le maintien des distances de sécurité entre véhicules.

Les résultats de simulations et d'expérimentations montrent que l'approche proposée permet d'améliorer significativement la récupération d'énergie, avec des gains variant de 16% à 39,6% selon le profil du conducteur, tout en réduisant les rétroactions inutiles des systèmes d'assistance à la conduite (ADAS). De plus, l'ajustement dynamique des horizons de planification contribue à réduire le coût computationnel, facilitant ainsi l'implémentation en temps réel. En somme, cette thèse propose un cadre novateur pour l'optimisation du freinage régénératif, capable de s'adapter aux variations des styles de

conduite, aux conditions climatiques et aux scénarios multivéhicules, et ouvre la voie à des systèmes de mobilité électrique plus intelligents, durables et acceptables.

Table des matières

Remerciements	iii
Résumé	vii
Table des matières	viii
Liste des tableaux	xi
Liste des figures	xii
Liste des symboles	xiv
Chapitre 1 - Introduction	1
1.1 Contexte général de recherche	1
1.1.1 Enjeux environnementaux et émissions du secteur des transports ..	1
1.1.2 Transition énergétique et électrification des transports	3
1.1.3 Innovations technologiques et systèmes de mobilité intelligente ...	4
1.1.4 Optimisation du freinage et stratégies de régénération d'énergie ...	8
1.1.5 Objectifs et stratégie de freinage optimisée	9
1.2 Problématique de la thèse	11
1.2.1 Stratégies de freinage adaptatif et régénération d'énergie	11
1.2.2 Influence du style de conduite et de la vitesse	11
1.2.3 Horizon de planification et coût computationnel	12
1.2.4 Adaptation aux conditions climatiques variables	13
1.2.5 Adaptation aux scénarios multi-véhicules	14
1.3 Contributions du projet	14

1.3.1	Synthèse des approches existantes et identification des lacunes	14
1.3.2	Axes de contribution	17
1.4	Objectifs	17
1.5	Méthodologie	19
1.5.1	Modélisation prédictive de la performance de régénération	23
1.5.2	Intégration des conditions climatiques et reconnaissance du style de conduite	24
1.5.3	Déploiement dans des scénarios multi-véhicules	25
1.6	Structure de la thèse	25
Chapitre 2 - État de l'art		28
2.1	Les facteurs influençant l'écoconduite dans les intersections	30
2.1.1	Vitesse de conduite	32
2.1.2	Accélération	34
2.1.3	Décélération et freinage régénératif	36
2.1.4	Variables météorologiques	41
2.1.5	Éléments d'infrastructure	47
2.1.6	Acceptation des conducteurs	50
2.2	Optimisation Prédictive du Freinage Régénératif dans des Scénarios Représentatifs	56
2.2.1	Méthodes et Mise en Œuvre de l'Optimisation Prédictive du Freinage Régénératif	58
2.2.2	Scénarios à véhicules uniques	67
2.2.3	Scénarios à véhicules doubles	78

Chapitre 3 - Développement d'une stratégie adaptative basée sur l'analyse des performances de régénération naturelle	83
3.1 Introduction	83
3.2 Méthodologie	83
3.3 Résultats	86
3.4 Conclusion	88
Chapitre 4 - Adaptation du freinage régénératif aux variations climatiques	105
4.1 Introduction	105
4.2 Méthodologie	105
4.3 Résultats	108
4.4 Conclusion	109
Chapitre 5 - Optimisation du freinage dans des scénarios multi-véhicules	138
5.1 Introduction	138
5.2 Méthodologie	138
5.3 Résultats	140
5.4 Conclusion	141
Chapitre 6 - Synthèse, Conclusions et Perspectives Futures	162
6.1 Synthèse des Contributions	162
6.2 Principaux Résultats	163
6.3 Discussions	165
6.4 Perspectives Futures	166
6.5 Conclusions	167

Liste des tableaux

Liste des figures

Figure 1.1 : Principaux contributeurs aux émissions de gaz à effet de serre aux États-Unis en 2022 [1].	1
Figure 1.2 : Prévion de l'évolution des émissions de CO ₂ [2].	2
Figure 1.3 : Composants de base des BEVs [3].	4
Figure 1.4 : Approches d'optimisation essentielles pour l'extension de l'autonomie des BEVs.	4
Figure 1.5 : Technologies des véhicules intelligents [4].	5
Figure 1.6 : Avancées pour une mobilité efficace [5].	6
Figure 1.7 : Degré d'autonomie du véhicule [6].	7
Figure 1.8 : Architecture d'un système de freinage adaptatif.	15
Figure 2.1 : Les principaux facteurs affectant l'éco-conduite dans les intesections [7].	31
Figure 2.2 : Marge de vitesse optimale pour les EVs et ICEVs [8].	34
Figure 2.3 : Analyse des performances du freinage régénératif [8].	37
Figure 2.4 : Les températures ambiantes idéales pour une efficacité énergétique maximale [8].	42
Figure 2.5 : Classification des stratégies de freinage régénératif en fonction du type de scénario étudié.	57
Figure 2.6 : Schéma d'entraînement d'un réseau de neurones pour la prédiction de la vitesse de conduite [9].	59
Figure 2.7 : Architecture d'une cellule LSTM et mise à jour des états [10].	61
Figure 2.8 : Architecture d'une cellule LSTM et mise à jour des états [10].	63

Figure 2.9 : Classification des stratégies de freinage prédictives en fonction des paramètres temporels et informationnels.	65
Figure 2.10 : Optimisation du freinage régénératif en fonction de la topographie et des positions d'arrêt.	69
Figure 2.11 : Optimisation du freinage régénératif basé sur l'écoconduite et la gestion des distances inter-véhicules	79

Liste des symboles

ADAS	Advanced Driver Assistance Systems
ANFIS	Adaptive Neuro-Fuzzy Inference System
BEV	Battery Electric Vehicle (Véhicule Électrique à Batterie)
CED	Connected Eco-Driving
DP	Dynamic Programming (Programmation Dynamique)
IEV	Intelligent Electric Vehicle
ICE	Internal Combustion Engine
IRH	Institut de Recherche sur l'Hydrogène
LSTM	Long Short-Term Memory
NARX	Nonlinear Autoregressive with Exogenous Inputs
RL	Reinforcement Learning (Apprentissage par Renforcement)
SPAD	Speed-Acceleration Probability Distribution
V2V	Vehicle-to-Vehicle
V2I	Vehicle-to-Infrastructure
WARBS	Weather-Adaptive Regenerative Braking Strategy

Chapitre 1 - Introduction

1.1 Contexte général de recherche

1.1.1 Enjeux environnementaux et émissions du secteur des transports

Le secteur des transports demeure l'un des principaux contributeurs aux émissions de gaz à effet de serre (GES) aux États-Unis. Selon l'Environmental Protection Agency, en 2022, il était responsable d'environ 28 % des émissions totales, se plaçant légèrement derrière le secteur industriel (23 %) et la production d'électricité (25 %), comme le montre la figure 1.1.

La part importante des émissions provenant du secteur des transports s'explique principalement par la forte dépendance aux combustibles fossiles et la croissance continue du parc de véhicules motorisés. Cette tendance souligne l'importance de développer des stratégies de décarbonation dans ce secteur pour atteindre les objectifs de réduction des émissions de GES aux États-Unis [1].




Figure 1.1 : Principaux contributeurs aux émissions de gaz à effet de serre aux États-Unis en 2022 [1].

Cette empreinte carbone ne cesse d'augmenter en raison de la croissance rapide du parc automobile mondial, du développement du transport de marchandises et de l'intensification du trafic en milieu urbain. Les projections de l'Energy Information Administration présentée dans la figure 1.2 indiquent que, si les tendances actuelles se maintiennent, les émissions de dioxyde de carbone liées au transport atteindront 42,5 milliards de tonnes métriques d'ici à 2050, soit une augmentation de 21 % par rapport à 2021 [2].




Figure 1.2 : Préviction de l'évolution des émissions de CO₂ [2].

En plus du dioxyde de carbone, les moteurs thermiques rejettent une quantité importante de suie et de particules fines, qui jouent un rôle majeur dans le forçage radiatif, un mécanisme clé du dérèglement climatique. Ces particules en suspension, principalement issues de la combustion incomplète des carburants fossiles, modifient l'équilibre énergétique de l'atmosphère en absorbant et en diffusant le rayonnement solaire, contribuant ainsi au réchauffement climatique. Leur interaction avec les nuages peut également perturber les cycles hydrologiques, influençant la fréquence et l'intensité des précipitations [11]. Les données du California Air Resources Board indiquent que le secteur des transports est responsable de 38 % des émissions totales de particules fines et de 45 % des émissions de suie aux États-Unis [12]. Ces polluants ont des effets délétères sur la qualité de l'air et la santé humaine, aggravant les maladies respiratoires et

cardiovasculaires, notamment en milieu urbain où leur concentration est particulièrement élevée.

1.1.2 Transition énergétique et électrification des transports

Face à ces enjeux, l'électrification des transports apparaît comme une solution essentielle pour réduire les émissions de gaz à effet de serre et améliorer l'efficacité énergétique des véhicules. Les scientifiques, ingénieurs et décideurs politiques concentrent leurs efforts sur le développement et l'optimisation des technologies de propulsion électrique afin de limiter l'impact du transport sur le climat. Parmi les stratégies adoptées, l'introduction des véhicules électrique, incluant les véhicules électriques à batterie, les hybrides rechargeables et les véhicules à hydrogène, est une priorité [13].

Pour soutenir la croissance des véhicules électriques, en novembre 2024, le California Air Resources Board a compté environ 105 000 bornes de recharge publiques ou privées pour véhicules électriques, ainsi que 500 000 chargeurs résidentiels. En plus, l'État a approuvé un plan d'investissement de 1,9 milliard de dollars visant à déployer 40 000 bornes de recharge supplémentaires à travers la Californie [14]. Les véhicules électriques à batterie représentent une alternative prometteuse pour éliminer totalement les émissions d'échappement. Toutefois, ils sont confrontés à deux défis majeurs : un temps de recharge prolongé et une anxiété liée à l'autonomie lors des longs trajets, en raison du fait que la batterie constitue leur unique source d'énergie [15]. La configuration de base d'un véhicule électrique à batterie est illustrée à la figure 1.3. Ses principaux composants incluent un pack de batteries, un redresseur, un contrôleur, une machine électrique et une transmission.

Bien que les stratégies d'extension d'autonomie reposent sur l'optimisation des

performances des composants et du contrôle, comme illustrée dans la figure 1.4, et que les batteries lithium-ion aient bénéficié d'avancées technologiques avec une densité énergétique accrue et des temps de charge réduits, leurs performances restent un obstacle à une adoption généralisée [16]. Cela contraint les chercheurs à explorer des solutions plus avancées pour optimiser le contrôle.




Figure 1.3 : Composants de base des BEVs [3].




Figure 1.4 : Approches d'optimisation essentielles pour l'extension de l'autonomie des BEVs.

1.1.3 Innovations technologiques et systèmes de mobilité intelligente

L'optimisation du contrôle pour l'extension de l'autonomie et de l'efficacité énergétique des véhicules électriques à batterie repose non seulement sur les progrès

en électrification, mais également sur l'intégration des véhicules connectés et des technologies de conduite automatisée [17, 18]. Ces innovations transforment le transport en un système intelligent capable d'optimiser la gestion du trafic, de réduire la congestion et d'améliorer la fluidité des déplacements tout en minimisant les pertes énergétiques [19]. Grâce aux communications entre véhicules et infrastructures, les véhicules peuvent échanger des informations en temps réel sur le trafic, les conditions routières et les changements de signalisation [20, 21]. Cette interconnectivité permet l'adoption de stratégies de conduite optimisées, réduisant ainsi la consommation d'énergie et améliorant l'efficacité énergétique de 15 à 20 % dans les environnements urbains [22]. Les véhicules automatisés, équipés de capteurs avancés, tels que les caméras, les lidars et les radars, ainsi que de systèmes d'intelligence artificielle, analysent leur environnement et ajustent leur trajectoire et leur vitesse de manière autonome, minimisant les freinages inutiles et les accélérations brusques, comme illustrés dans la figure 1.5.



Figure 1.5 : Technologies des véhicules intelligents [4].

La figure 1.6 illustre que l'intégration de la connectivité, de l'automatisation et de l'intelligence artificielle permet d'exploiter les synergies entre ces technologies pour trouver une approche de contrôle optimal des BEVs. Elle contribue également à la

réduction de l'empreinte carbone du secteur des transports [4].




Figure 1.6 : Avancées pour une mobilité efficace [5].

L'automatisation des véhicules électriques a évolué progressivement, intégrant différents niveaux de conduite assistée jusqu'à une autonomie complète. Selon la Society of Automotive Engineers, cinq niveaux d'automatisation sont présentés dans la figure 1.7. Le premier niveau correspond à l'absence totale d'automatisation, où le conducteur est entièrement responsable du véhicule. Le second niveau intègre une assistance à la conduite, telle que le régulateur de vitesse adaptatif ou l'aide au maintien dans la voie, mais sans prise en charge simultanée de la direction et du freinage. Le troisième niveau introduit une automatisation partielle, où le véhicule peut gérer simultanément la direction et l'accélération dans certaines conditions spécifiques, bien que le conducteur doive rester vigilant. Le quatrième niveau permet au véhicule de prendre en charge l'ensemble des tâches de conduite dans des environnements spécifiques, mais le conducteur doit rester prêt à intervenir en cas de besoin. À partir du cinquième niveau, l'automatisation devient avancée et permet au véhicule de gérer toutes les opérations de conduite sans intervention

humaine, même dans des conditions complexes. Enfin, l'autonomie totale du véhicule représente une révolution, éliminant le besoin d'un conducteur humain et ouvrant la voie aux taxis autonomes et aux flottes de véhicules à la demande [6].




Figure 1.7 : Degré d'autonomie du véhicule [6].

Bien que les pays du G7 aient levé certaines barrières réglementaires freinant le développement des véhicules autonomes, leur adoption massive reste un défi. Des études montrent que la perception du public varie selon les groupes sociodémographiques [23]. Les chercheurs ont également démontré que les voyageurs sont plus enclins à utiliser des véhicules autonomes (VA) sur des trajets monotones, comme les autoroutes, plutôt qu'en milieu urbain. En revanche, la plupart des consommateurs se montrent favorables à l'acquisition de véhicules électriques autonomes (AEVs) équipés d'un système avancé d'assistance à la conduite (ADAS) de niveau 2 ou 3. Cela, malgré le fait que ces véhicules ne soient pas totalement autonomes et que l'infrastructure de recharge demeure insuffisante [24, 25]. Ces niveaux d'automatisation présentent un potentiel d'amélioration de l'efficacité énergétique comparable à celui des systèmes de niveau 6, grâce à l'utilisation des mêmes capteurs de perception. Ainsi, l'amélioration des technologies d'assistance à la conduite de niveau 2 et 3, combinée à une meilleure prise en compte du facteur humain, représente une avancée clé vers un transport plus sécurisé, plus intelligent et plus durable.

1.1.4 Optimisation du freinage et stratégies de régénération d'énergie

Le style de conduite influence directement la consommation d'énergie lors d'un trajet. Les variations d'accélération, de freinage et de vitesse peuvent engendrer des écarts significatifs en matière d'efficacité énergétique. L'optimisation de ces paramètres est désignée sous le terme d'optimisation du contrôle. De plus, la définition d'un profil de vitesse optimal est connue sous le nom d'écoconduite. L'ADAS englobe principalement les fonctions d'optimisation du contrôle fournies par un véhicule intelligent, soit de manière autonome, soit en assistant le conducteur dans l'exécution d'un trajet. Ces systèmes incluent notamment la planification de stratégies d'écoconduite, visant à améliorer l'efficacité énergétique et le confort de conduite [26]. Le programme Connected Eco-Driving (CED), initié par le Bureau conjoint des programmes des systèmes de transport intelligents, a exploré plusieurs stratégies visant à optimiser le profil de vitesse des véhicules connectés et autonomes (CAV). Parmi ces stratégies, l'éco-approche aux intersections et l'optimisation du passage des feux de circulation ont été identifiées comme des solutions efficaces pour réduire la consommation de carburant et les émissions polluantes dans les milieux urbains [27]. Ces approches reposent sur l'échange en temps réel d'informations entre les infrastructures routières et les véhicules afin d'ajuster la vitesse et minimiser les arrêts inutiles, contribuant ainsi à une mobilité plus durable.

Le freinage régénératif joue un rôle essentiel dans les stratégies d'écoapproche des véhicules électriques, offrant une opportunité significative de récupération d'énergie grâce aux fréquentes phases de décélération dans ces scénarios [28, 29]. Différents modèles de conduite écologique ont été développés pour gérer les interactions avec les panneaux de signalisation et optimiser le freinage. Toutefois, la littérature indique que leur principal objectif est d'ajuster la vitesse afin d'éviter l'arrêt complet aux intersections. Bien

que ces approches proposent un profil de vitesse optimisé avec un freinage progressif, elles ne permettent pas d'exploiter pleinement le potentiel du freinage régénératif. En effet, en limitant la décélération progressive sans atteindre un arrêt total, elles réduisent l'efficacité maximale de récupération d'énergie. Ainsi, une stratégie de freinage optimal aux intersections avec panneaux d'arrêt constitue une meilleure approche pour maximiser la récupération d'énergie, tout en garantissant une conduite plus fluide et efficiente.

Les chercheurs ont relevé ce défi en anticipant la position d'arrêt et les caractéristiques de l'infrastructure grâce à un niveau d'automatisation avancé des BEVs. Ils ont ainsi planifié un profil de décélération préventive optimisé afin de maximiser la récupération d'énergie. Toutefois, leur approche n'a pas permis d'exploiter complètement la régénération jusqu'à la capacité maximale du moteur. Pour surmonter cette limitation, seulement quelques études ont consacré d'importants efforts à la caractérisation des performances du moteur et à l'anticipation de sa limite de régénération. Ces informations ont ensuite été intégrées dans les modèles d'optimisation du profil de décélération afin d'améliorer l'efficacité énergétique globale du système [30].

1.1.5 Objectifs et stratégie de freinage optimisée

L'objectif de ce projet est de développer une stratégie de freinage optimisée visant à maximiser la régénération d'énergie aux intersections nécessitant un arrêt complet, tout en améliorant l'efficacité et la fiabilité de son déploiement par les systèmes ADAS. Au-delà de ces objectifs, l'approche proposée doit également garantir le confort et renforcer la confiance des conducteurs, tout en exploitant pleinement la régénération d'énergie jusqu'à atteindre la capacité maximale du moteur. Les indicateurs identifiés mettent en évidence plusieurs facteurs clés susceptibles d'influencer cette capacité de régénération et la fiabilité des ADAS, comme suit :

- Le style de conduite joue un rôle déterminant, chaque conducteur possédant des préférences spécifiques en matière de vitesse maximale, directement liées à la capacité de régénération du moteur.
- Les conditions météorologiques variables, telles qu'une visibilité réduite ou des variations d'adhérence causées par la pluie, la neige ou le verglas, peuvent également modifier le comportement de conduite, réduisant ainsi le potentiel de régénération en raison de l'ajustement nécessaire des vitesses et des manœuvres pour assurer la sécurité.
- les scénarios impliquant plusieurs véhicules sur la route restreignent les possibilités d'optimiser la régénération, car les contraintes liées à la distance de sécurité et aux interactions avec le trafic limitent les opportunités d'appliquer une décélération optimale.

L'intégration de ces facteurs dans les stratégies d'optimisation est essentielle pour maximiser la récupération d'énergie, tout en renforçant l'efficacité et la fiabilité de leur déploiement par les systèmes ADAS, de manière à garantir une conduite adaptée à l'environnement et aux besoins des conducteurs. Par conséquent, l'utilisation d'une stratégie de freinage conçue pour un seul style de conduite ou adaptée uniquement à des conditions climatiques spécifiques, comme le temps estival, ne peut être considérée comme fiable ni satisfaire l'ensemble des conducteurs. En particulier, son déploiement dans un système ADAS universel risque de générer un excès de rétroactions, pouvant entraîner une surcharge cognitive, notamment lorsque ces signaux sont trop fréquents ou jugés non pertinents. Cette situation pourrait détériorer la confiance du conducteur envers le système, l'incitant à ignorer les alertes, voire à désactiver complètement l'ADAS, compromettant ainsi ses bénéfices potentiels.

Les stratégies de freinage adaptatives offrent de nombreux avantages, favorisant

l'adoption de pratiques de conduite écologique, l'amélioration du confort et l'extension de l'autonomie des BEVs.

1.2 Problématique de la thèse

1.2.1 Stratégies de freinage adaptatif et régénération d'énergie

Au vu des travaux étudiés, il est possible de déduire que l'utilisation de stratégies de freinage adaptatif visant à optimiser la régénération, tout en prenant en compte les contraintes liées au style de conduite, aux conditions climatiques et au mouvement du véhicule en amont en temps réel, mérite une attention renforcée. Cet objectif spécifique cherche à améliorer l'acceptation du conducteur, la maximisation de régénération jusqu'à la limite de capacité du moteur, ainsi que la performance et l'acceptabilité des systèmes avancés d'aide à la conduite (ADAS).

1.2.2 Influence du style de conduite et de la vitesse

Comme mentionné précédemment, le comportement de conduite dans une intersection à véhicule unique reflète des préférences de vitesse maximale qui varient d'un conducteur à l'autre. En outre, une stratégie de freinage optimale, respectant ces préférences individuelles, devrait intégrer la variabilité des contraintes de régénération propres à chaque style de conduite dans son modèle d'optimisation. Il est important de noter que la limite de régénération du moteur est étroitement liée à la vitesse du véhicule. À basse vitesse, la capacité de récupération d'énergie est réduite en raison de contraintes dynamiques (énergie cinétique faible) et d'une faible capacité du moteur. En revanche, à des vitesses plus élevées, la capacité de régénération du moteur s'accroît significativement, et de même l'énergie cinétique augmente proportionnellement au carré de la vitesse, ce qui améliore la quantité d'énergie récupérable [31]. Néanmoins, cette variation du

potentiel de régénération influence directement la performance de régénération naturelle du conducteur, mesurée par la capacité du système à récupérer l'énergie jusqu'à la limite maximale de régénération du moteur. Les conducteurs adoptant un style de conduite à basse vitesse atteignent plus facilement un niveau maximal de régénération naturelle, car leur mode de conduite sollicite moins la capacité maximale du système. En revanche, ce n'est pas le cas pour les conducteurs qui circulent à des vitesses plus élevées, où le potentiel de régénération, bien que plus important, devient également plus difficile à exploiter pleinement naturellement.

1.2.3 Horizon de planification et coût computationnel

Lorsque ces variations de performance de régénération naturelle ne sont ni prédites par un long horizon ni intégrées dans le modèle d'optimisation, cela peut entraîner une gestion inefficace du fonctionnement du véhicule, générant des rétroactions inutiles et perturbantes pour le conducteur. De plus, les rares travaux existants sur la planification de la décélération visant à maximiser la régénération jusqu'à la limite du moteur reposent principalement sur des horizons de planification à long terme. Cette approche nécessite une optimisation globale à travers l'ensemble des états prévus sur cet horizon, ce qui augmente considérablement le coût computationnel. Cependant, l'intégration de la prédiction de la performance de régénération naturelle permettrait d'adapter dynamiquement l'horizon de planification de la décélération. Une telle adaptation offrirait une optimisation plus ciblée, réduisant ainsi la charge computationnelle tout en maintenant l'efficacité énergétique du système. Ainsi, une stratégie de freinage régénératif adaptative aux performances de la régénération naturelle est essentielle pour l'efficacité énergétique en temps réel et l'amélioration de l'acceptation des systèmes ADAS.

1.2.4 Adaptation aux conditions climatiques variables

Un autre aspect souvent négligé par de nombreux chercheurs dans le domaine de l'optimisation prédictive du freinage est l'adaptation des stratégies de freinage aux conditions climatiques variables. Il est essentiel de développer une assistance à la conduite qui soit à la fois efficace et confortable pour l'utilisateur, quelles que soient les conditions météorologiques rencontrées, d'autant plus que les contraintes de maximisation de la régénération sont fortement affectées par les variations climatiques. Les stratégies de freinage régénératif existantes se concentrent principalement sur l'optimisation de l'efficacité énergétique dans des conditions météorologiques spécifiques. Certaines se focalisent sur des conditions estivales, tandis que d'autres développent des stratégies adaptées aux routes glacées en hiver. Toutefois, cette limitation réduit l'efficacité de ces stratégies dans des environnements climatiques variés, où les systèmes d'assistance à la conduite peuvent générer des alertes inutiles ou ne pas atteindre des performances énergétiques optimales. Par ailleurs, le comportement du conducteur est considérablement influencé par les changements climatiques, notamment en raison de la diminution de l'adhérence et de la réduction de la visibilité lors des journées enneigées. Ainsi, la reconnaissance du style de conduite dans des conditions météorologiques variables pourrait constituer une piste innovante pour adapter le modèle de freinage prédictif aux conditions climatiques fluctuantes. À la connaissance des auteurs, l'intégration d'un modèle de reconnaissance du style de conduite dans la conception d'une stratégie de freinage adaptative aux conditions climatiques variables n'a pas encore été envisagée à ce jour. De plus, la stratégie conserve son mode adaptatif aux préférences naturelles de régénération lorsque le conducteur circule sur des routes sèches.

1.2.5 Adaptation aux scénarios multi-véhicules

Cette problématique conduit à un troisième défi qui est l'adaptation des stratégies de freinage aux scénarios impliquant plusieurs véhicules. Dans de telles situations, la capacité de régénération, même lorsqu'elle atteint la limite maximale du moteur, peut être compromise afin de maintenir une distance de sécurité avec le véhicule précédent. Une stratégie de freinage optimale dans un scénario à deux véhicules, tout en respectant les préférences individuelles de vitesse maximale, doit non seulement intégrer dans son modèle la contrainte de limite de régénération propre à chaque style de conduite, mais aussi récupérer le maximum d'énergie cinétique tout en assurant le respect des distances de sécurité. Ce défi, pourtant crucial, n'a pas encore été exploré dans la littérature existante. Il ouvre ainsi de nouvelles perspectives pour le développement de stratégies de freinage régénératif adaptatives, capables de concilier sécurité, efficacité énergétique et confort de conduite dans des environnements multi-véhicules complexes. La figure 1.8 illustre l'architecture des trois problématiques abordées dans cette thèse, visant à développer un modèle adaptatif de planification de décélération pour la conception d'un système ADAS prenant en compte l'humain et les conditions climatiques.

1.3 Contributions du projet

1.3.1 Synthèse des approches existantes et identification des lacunes

L'examen de la littérature révèle une diversité d'approches et de stratégies de freinage visant à améliorer l'efficacité de la régénération d'énergie dans les véhicules électriques à batterie (BEVs). Plusieurs méthodes ont été développées pour planifier efficacement les trajectoires de décélération afin de maximiser la récupération d'énergie en anticipant les

occasions d'arrêt et en tenant compte de l'infrastructure du trajet.




Figure 1.8 : Architecture d'un système de freinage adaptatif.

Toutefois, peu d'approches exploitent pleinement la régénération jusqu'à la limite maximale de la capacité du moteur. Plusieurs facteurs viennent en effet limiter la récupération maximale d'énergie lors des phases de décélération :

- **La vitesse initiale de décélération** : à basse vitesse, la capacité de régénération est faible en raison du couple limité généré par le moteur en mode générateur, réduisant ainsi l'énergie récupérable.
- **Les limites de capacité du moteur électrique et du convertisseur** : les courants maximaux admissibles par les composants électroniques imposent une contrainte

sur la puissance régénérative pouvant être extraite lors des phases de freinage.

- **Les contraintes de sécurité et la distance inter-véhicules** : la nécessité de maintenir une distance sécuritaire avec le véhicule précédent limite parfois la décélération maximale autorisée, et donc le potentiel de récupération d'énergie.
- **Les conditions d'adhérence de la route** : en conditions de faible adhérence (pluie, neige, verglas), le système de gestion de stabilité restreint l'intensité de la régénération pour éviter les pertes de contrôle, réduisant la récupération d'énergie.
- **La performance de la batterie selon la température** : la capacité de la batterie et sa résistance interne varient fortement avec la température ambiante. À basse température, la résistance interne de la batterie augmente, ce qui limite le courant de charge accepté lors de la régénération et réduit l'efficacité de récupération d'énergie. À haute température, bien que la résistance interne diminue, des limitations sont imposées par le système de gestion thermique de la batterie pour éviter les surchauffes, ce qui peut également restreindre la puissance régénérative disponible.
- **L'état de charge de la batterie (SOC)** : lorsque le SOC est élevé, la batterie ne peut pas accepter de forts courants de charge, ce qui limite la puissance régénérative disponible.

Par ailleurs, la plupart des travaux se concentrent sur des cycles de conduite standards et n'intègrent ni la variabilité en temps réel de la limite de régénération liée au style de conduite ni les contraintes imposées par la présence d'un véhicule en amont ou par les conditions climatiques. La méthodologie développée dans cette thèse vise précisément à intégrer ces facteurs dynamiques dans l'optimisation de la stratégie de freinage régénératif, afin de s'approcher des limites réelles tout en assurant la sécurité et le confort de conduite.

1.3.2 Axes de contribution

Ce projet poursuit deux directions principales pour combler ces lacunes :

a) Stratégie adaptative aux performances naturelles de régénération

Cette contribution vise à développer une stratégie de freinage régénératif qui adapte dynamiquement son horizon de planification en fonction de la performance naturelle de régénération du conducteur. En exploitant des algorithmes d'estimation de paramètres, la stratégie ajuste en temps réel la limite de régénération du moteur, maximisant la récupération d'énergie jusqu'à la capacité maximale sans générer de rétroactions inutiles qui nuisent au confort et à l'acceptabilité des ADAS.

b) Stratégie adaptative aux conditions climatiques

La seconde contribution consiste à étendre la stratégie de freinage adaptative pour qu'elle soit robuste face aux variations climatiques. Un modèle de reconnaissance du style de conduite détecte les conditions routières (routes sèches vs glissantes) et ajuste automatiquement les contraintes de vitesse et d'accélération ainsi que l'horizon de planification, garantissant une récupération d'énergie optimale et une conduite sécurisée, quelle que soit la météo.

1.4 Objectifs

Cette thèse vise à combler les lacunes identifiées en explorant les axes décrits précédemment. Dans ce contexte, l'objectif principal est de développer une stratégie adaptative tenant compte à la fois des styles de conduite et des conditions climatiques variés, afin d'améliorer l'efficacité du freinage, le confort du conducteur et l'acceptabilité des systèmes avancés d'aide à la conduite (ADAS). Pour atteindre cet objectif, les axes

suivants ont été définis :

- **Développer une stratégie de freinage régénératif adaptative aux performances naturelles de régénération** : Les études précédentes reposent sur des cycles de conduite classiques, sans intégrer la variabilité des limites de régénération ni les performances naturelles individuelles, lesquelles sont influencées par le style de conduite. Dans ce travail, une prédiction à long terme de la performance de régénération naturelle est réalisée afin de déterminer l'horizon de planification de décélération le plus approprié. L'objectif est de maximiser la récupération d'énergie en tenant compte des limites spécifiques à chaque conducteur, tout en trouvant un compromis entre l'optimisation du freinage régénératif et la performance naturelle de régénération, et en respectant les préférences de vitesse maximale lors des trajets entre deux arrêts. Puisque la stratégie se doit d'assurer le confort du conducteur et l'acceptabilité des ADAS, elle doit être robuste et fiable, même dans des conditions climatiques variées et en présence de scénarios de suivi de véhicule.

- **Développer une stratégie de freinage régénératif adaptative aux conditions climatiques variées et au style de conduite** : L'analyse de l'impact du style de conduite sur les limites de régénération et la performance naturelle montre que ces deux aspects sont fortement affectés par les variations climatiques, telles que les routes sèches, les routes glissantes ou encore les situations de faible visibilité. Le style de conduite évolue également en fonction de ces conditions, ce qui conduit à adapter la stratégie de freinage en s'appuyant sur un modèle de reconnaissance du style de conduite. Ce modèle permet d'ajuster les contraintes dans le modèle d'optimisation et de sélectionner l'horizon de planification de décélération le

plus approprié pour chaque condition climatique, garantissant ainsi l'efficacité énergétique, le confort de conduite, ainsi que l'acceptabilité et le déploiement des ADAS en toutes circonstances.

- **Développer une stratégie de freinage régénératif adaptative au style de conduite dans des scénarios de suivi de véhicule** : Dans les scénarios de suivi, la limite de régénération individuelle, sur laquelle repose le modèle d'optimisation, peut être compromise par le besoin de respecter les distances de sécurité lors de la décélération. Cette thèse vise donc à développer une stratégie capable de trouver un équilibre entre la maximisation de la régénération jusqu'à la limite individuelle et le respect strict des distances de sécurité, afin de garantir une récupération d'énergie optimale, adaptée aux préférences de chaque conducteur, tout en assurant une conduite sécurisée.

1.5 Méthodologie

Après avoir exposé la motivation et mené une étude approfondie de la littérature (présentée dans le chapitre « État de l'art ») afin d'identifier les lacunes existantes, la première étape de cette méthodologie consiste à établir une base de données solide. Celle-ci rassemblera des informations issues de cycles de conduite couvrant trois styles différents et des conditions climatiques variées. Ces données permettront de soutenir l'hypothèse selon laquelle le développement d'une stratégie de freinage adaptative, intégrant à la fois le style de conduite et les variations climatiques, peut améliorer significativement la récupération d'énergie et renforcer l'acceptabilité des systèmes avancés d'aide à la conduite (ADAS).

Dans le cadre de cette étude, les hypothèses suivantes sont retenues pour le modèle

dynamique longitudinal du véhicule électrique à batterie (BEVs) utilisé:

- **Style de conduite caractérisé par la cinématique du véhicule** : le style de conduite est estimé uniquement à partir des données cinématiques mesurées (vitesse, accélération, décélération, etc.), sans recours à des données biométriques ou physiologiques du conducteur. Il est également supposé que le conducteur se trouve dans un état normal, sans stress excessif, ni comportement d'urgence.
- **Force hydraulique négligée** : $P_{Hyd} = 0$, ce qui simplifie le modèle de récupération d'énergie en posant :

$$P_{Brk} = P_w = P_{Rgn}$$

où P_{Brk} est la puissance totale de freinage appliquée aux roues [W], P_w la puissance mécanique aux roues [W] définie comme $P_w = F_w v$, et P_{Rgn} la puissance récupérée par le freinage régénératif [W].

- **Vitesse du vent considérée nulle** : $v_{vent} = 0$.
- **État de charge (SOC) constant** : aucune variation du niveau de charge n'est introduite dans les simulations pour ne pas altérer la limite de récupération.
- **Pertes de transmission modélisées explicitement**: selon

$$\eta = \eta_{gen} \times \eta_a \times \eta_d$$

où η_{gen} est le rendement de génération de l'énergie régénérative, η_a le rendement de l'arbre de transmission, et η_d le rendement de l'onduleur, en utilisant des valeurs réelles mesurées sur le Kia Soul afin de refléter fidèlement le rendement global du système.

- **Modèle de dynamique longitudinale** : basé sur la relation $P_w = F_w v$, avec :

$$F_w - F_{\text{res}} = m \frac{dv}{dt}$$

où F_w est la force longitudinale appliquée aux roues [N], F_{res} la force de résistance totale incluant la résistance aérodynamique, la résistance au roulement et les pentes [N], m la masse du véhicule [kg], et v la vitesse du véhicule [m/s].

Ces hypothèses et choix méthodologiques permettent de simplifier le cadre de modélisation tout en maintenant une représentation réaliste et robuste du comportement énergétique d'un BEV, adaptée à l'analyse et à l'optimisation des stratégies de freinage régénératif développées dans cette thèse.

Par ailleurs, le choix d'utiliser seulement trois conducteurs pour générer les profils de conduite s'explique par des contraintes pratiques de faisabilité expérimentale. Le nombre de bénévoles disponibles pour participer aux sessions de collecte de données était limité, et leur disponibilité restreinte par leurs obligations personnelles et professionnelles. De plus, la qualité des données collectées auprès d'autres conducteurs s'est révélée insuffisante (bruit, interruptions de trajectoire, dysfonctionnements capteurs), rendant leur exploitation impossible pour cette étude. Bien que ce choix restreigne la généralisation des résultats à l'ensemble des profils de conduite possibles, il permet néanmoins d'établir des tendances robustes sur des comportements typiques et variés, en assurant la cohérence et la fiabilité des données pour évaluer la stratégie proposée. Il est toutefois reconnu que cette limitation pourrait induire une variabilité des gains énergétiques si des profils extrêmes, non inclus, étaient pris en compte, ce qui pourrait réduire légèrement les gains estimés.

Dans cette étude, les données utilisées pour le développement et la validation de la

stratégie de freinage régénératif adaptative proviennent de deux sources complémentaires : un environnement expérimental contrôlé et un environnement virtuel de simulation.

Données expérimentales: Les données ont été collectées à partir d'un *véhicule Kia Soul 2017 instrumenté*, équipé de capteurs de haute précision, incluant:

- GPS RTK (Septentrio AsteRx-i3 D Pro+) pour une précision centimétrique de la position ;
- Caméra Mobileye pour la détection long horizon (jusqu'à 200 m) des obstacles, de la topographie et des arrêts fixes ;
- Radar et Lidar pour la détection des distances inter-véhicules et de la topographie ;
- Interface CAN-Bus / OBDlinkMx pour l'acquisition des paramètres internes tels que la vitesse, le couple, la puissance électrique et l'état de charge (SOC).

Ces collectes ont été réalisées dans un **environnement contrôlé**, avec des conditions météorologiques variées (routes sèches, routes glissantes) et des parcours présentant une topographie variable avec des arrêts fixes. Cette configuration expérimentale permet de garantir une cohérence et une fiabilité des données, tout en assurant la représentativité des situations de conduite urbaine et suburbaines courantes.

Un environnement virtuel de simulation développé sous *Matlab/Simulink* a été utilisé en complément pour générer des données synthétiques. Ce simulateur intègre: **Données synthétiques** :

- Un **modèle physique complet** du Kia Soul 2017 ;
- Des **capteurs virtuels** (Radar, Lidar, GPS) ;
- Des **scénarios simulés réalistes** incluant la position des arrêts, la topographie de la

route et différents styles de conduite.

L'environnement de simulation permet de tester et valider les algorithmes de freinage régénératif sur un ensemble élargi de conditions climatiques et de scénarios multivéhicules difficilement reproductibles expérimentalement, tout en conservant un environnement contrôlé où les variables peuvent être isolées et ajustées systématiquement.

Cette approche combinée assure la robustesse des résultats obtenus et renforce la validité des conclusions sur la performance de la stratégie proposée.

1.5.1 Modélisation prédictive de la performance de régénération

Afin de démontrer que la prédiction de la variabilité des performances de régénération naturelle permet d'ajuster l'horizon de planification de décélération (long, moyen, court et optimal) et d'assurer une optimisation adaptative du freinage, un modèle de prédiction de la puissance régénérée est développé pour chaque style de conduite sur un horizon long (30 secondes). Pour cela, nous utilisons des techniques basées sur les réseaux LSTM et le modèle NARX. La puissance régénérée prédite est ensuite comparée aux limites de régénération individuelles du moteur, ce qui permet :

- D'évaluer la performance de régénération naturelle,
- D'estimer le taux de maximisation de la régénération,
- De déterminer l'horizon de planification de décélération le plus appropriée.

Ces informations sont intégrées dans un modèle d'optimisation reposant sur une programmation dynamique, qui tient compte des contraintes propres à chaque conducteur. Cette approche vise à garantir une récupération d'énergie optimale, adaptée aux comportements individuels, tout en réduisant le temps de calcul.

1.5.2 Intégration des conditions climatiques et reconnaissance du style de conduite

La troisième étape vise à quantifier l'impact des conditions climatiques sur le style de conduite et à exploiter cette information pour montrer la nécessité d'un modèle de reconnaissance du style de conduite dans une stratégie de freinage adaptative. Une revue de la littérature a permis d'identifier et d'évaluer les modèles de classification les plus performants dans ce domaine. À l'aide d'un ensemble de données représentant divers styles de conduite dans des conditions météorologiques variées (environnements estivaux, enneigés, faible visibilité), ces modèles sont évalués en fonction de leur précision. Les résultats obtenus permettent de définir des contraintes spécifiques de vitesse et d'accélération pour chaque classe de style de conduite. Ces contraintes sont intégrées dans le modèle d'optimisation pour adapter dynamiquement l'horizon de planification de décélération :

- Lorsqu'une route verglacée (typiquement en conditions enneigées) est détectée, une stratégie de freinage innovante est déployée pour compenser la faible adhérence. Dans ce cas, l'horizon de planification est ajusté en fonction de la pente anticipée : un horizon court est privilégié en descente pour limiter les risques de perte de contrôle, tandis qu'un horizon optimal est retenu sur terrain plat lorsque le taux de maximisation reste faible.
- Pour une route sèche, la stratégie reste alignée sur les performances de régénération naturelle développées précédemment.

Afin d'améliorer la précision de cette reconnaissance en conditions variées, le modèle LSTM est remplacé dans cette étape par un modèle de classification ANFIS, spécialement calibré à partir de données collectées dans des conditions climatiques diversifiées. Cette approche permet ainsi d'optimiser la récupération d'énergie tout en garantissant une expérience de conduite confortable et en évitant des rétroactions inutiles dans l'ADAS.

1.5.3 Déploiement dans des scénarios multi-véhicules

La quatrième étape consiste à déployer la stratégie adaptative dans des scénarios impliquant la présence d'un véhicule en tête. Dans ces conditions, le modèle d'optimisation doit intégrer simultanément :

- La contrainte de limite de régénération individuelle,
- La contrainte de distance de sécurité, essentielle pour maintenir un espacement adéquat avec le véhicule précédent.

L'objectif est de trouver un compromis optimal entre la maximisation de la régénération (jusqu'à la limite individuelle) et le respect strict des distances de sécurité. Cette démarche garantit non seulement une récupération d'énergie optimale, mais également une conduite sécurisée et confortable.

En combinant ces quatre étapes; constitution d'une base de données solide, modélisation prédictive, adaptation au style de conduite, adaptation aux conditions climatiques via la reconnaissance du style de conduite, et déploiement dans des scénarios multi-véhicules, cette méthodologie offre une approche complète et robuste pour développer une stratégie de freinage adaptative. Celle-ci permet d'optimiser la récupération d'énergie tout en répondant aux exigences de sécurité et de confort exigées par les ADAS.

1.6 Structure de la thèse

Cette section détaille la structure générale de la thèse, en mettant en évidence la logique sous-jacente à l'analyse et en décrivant la progression des chapitres.

Chapitre 1 : Contexte et fondations de l'étude.

Le premier chapitre offre une vue d'ensemble du projet de recherche en mettant en

présentant la problématique, les objectifs et la méthodologie de recherche. Il pose ainsi les fondations indispensables pour appréhender le contexte de l'étude et la nécessité d'une stratégie de freinage adaptative.

Chapitre 2 : État de l'art et limites des approches existantes.

Le deuxième chapitre présente une revue de la littérature sur les facteurs influençant l'efficacité de l'écoconduite et aborde les stratégies d'optimisation prédictive du freinage régénératif. Ce chapitre compare les approches appliquées dans des scénarios à véhicule unique et dans ceux impliquant deux véhicules. Il expose également les limites des stratégies existantes, justifiant le choix de la nouvelle approche développée dans cette thèse.

Chapitre 3 : Développement d'une stratégie de freinage adaptative basée sur l'analyse des performances de régénération.

Dans ce chapitre, nous présentons une stratégie de freinage adaptative basée sur l'analyse des performances naturelles de régénération. Les résultats publiés dans l'article « An Adaptive Regenerative Braking Strategy Design Based on Naturalistic Regeneration Performance for Intelligent Vehicles » sont détaillés, avec une évaluation approfondie de l'adaptabilité des retours des systèmes ADAS aux différents styles de conduite.

Chapitre 4 : Adaptation du freinage régénératif aux variations climatiques.

Ce chapitre présente les résultats relatifs à l'adaptation de la stratégie de freinage aux conditions climatiques diverses. Basée sur l'article « Weather-Adaptive Regenerative Braking Strategy Based on Driving Style Recognition for Intelligent Electric Vehicles », l'approche repose sur la reconnaissance du style de conduite pour ajuster les contraintes d'optimisation (vitesse, accélération, horizon de planification) en fonction des conditions environnementales (routes sèches, routes glissantes, faible visibilité).

Chapitre 5 : Optimisation du freinage dans des scénarios multi-véhicules.

Ce dernier chapitre expose l'implémentation de la stratégie de freinage adaptative en présence d'un véhicule en tête. Les résultats, présentés dans l'article « Personalized Energy-Efficient Deceleration for Intelligent Electric Vehicles: Integrating Driver Preferences and Preceding Vehicle Dynamics », démontrent comment l'intégration de la contrainte de distance de sécurité avec la limite de régénération individuelle permet d'optimiser la récupération d'énergie tout en garantissant une conduite sécurisée et confortable.

Chapitre 6 : Synthèse, Conclusions et Perspectives Futures.

Ce dernier chapitre propose une synthèse critique des travaux réalisés, présente les conclusions générales de la thèse et identifie des axes de recherche pour l'avenir. Il réunit les résultats tirés des contributions présentées dans les chapitres précédents, analyse les points forts et les limites de l'approche développée, et ouvre des perspectives d'amélioration pour l'optimisation des systèmes de freinage régénératif dans le cadre de la mobilité électrique intelligente.

Chapitre 2 - État de l'art

L'écoconduite constitue une stratégie incontournable pour optimiser l'autonomie des véhicules électriques et réduire leur consommation énergétique, en particulier dans les environnements urbains ou sur des axes à forte densité de trafic. Cette approche repose principalement sur l'optimisation des profils de vitesse, ce qui permet de minimiser les pertes d'énergie liées aux forces mécaniques et aérodynamiques [32]. L'efficacité énergétique d'un véhicule électrique dépend étroitement de sa plage de fonctionnement, laquelle est déterminée par les pertes spécifiques aux composants de la chaîne cinématique ainsi que par des paramètres de conduite, tels que la vitesse et l'accélération. Ainsi, le comportement du conducteur joue un rôle central, car une conduite optimisée et adaptée aux conditions routières peut considérablement améliorer les performances énergétiques du véhicule.

L'intégration de stratégies d'écoconduite dans les véhicules intelligents ouvre de nouvelles perspectives grâce à leurs capacités avancées de communication et de perception en temps réel. Ces technologies permettent d'optimiser de manière précise les trajectoires et les vitesses en s'appuyant sur les données collectées par divers capteurs, qu'il s'agisse des conditions routières ou du trafic [33]. Par exemple, des algorithmes de planification de vitesse optimale, basés sur des prévisions détaillées des conditions microscopiques (arrêts, géométrie des routes, feux de signalisation) et macroscopiques (trafic global, itinéraire), permettent de réduire les freinages inutiles et d'offrir un contrôle prédictif précis du groupe motopropulseur. La mise en œuvre de l'écoconduite est accessible à tous les types de véhicules, indépendamment de leur âge ou de leur taille, et ses bénéfices sont immédiatement observables à l'échelle d'une flotte. Selon la littérature, cette approche peut améliorer l'efficacité énergétique jusqu'à 45% [34].

Au-delà de l'amélioration de l'efficacité énergétique, la conduite écologique présente des avantages environnementaux considérables. Elle contribue à la réduction du bruit et de la pollution atmosphérique, en particulier pour les véhicules hybrides, ainsi qu'à la diminution des coûts d'entretien. Une étude menée par Ho et al. [35] a montré qu'un moteur fonctionnant à 5400 tr/min génère un niveau sonore équivalent à celui de 32 voitures tournant à 2000 tr/min. Par ailleurs, adopter une conduite progressive permet de diminuer les coûts d'entretien en réduisant les réparations associées aux comportements agressifs et en minimisant les risques d'accident.

Face à ces nombreux avantages, plusieurs études approfondies ont permis d'identifier trois stratégies principales d'écoconduite : l'écoroutage, le platooning et l'écoapproche. L'écoroutage repose sur une planification optimisée des itinéraires en fonction des conditions de trafic, permettant de réduire les variations de vitesse inutiles, particulièrement dans les embouteillages [36–38]. Le platooning, quant à lui, consiste à regrouper les véhicules en convois rapprochés, ce qui permet de réduire la traînée aérodynamique et d'engendrer des économies substantielles, notamment pour les véhicules lourds [39, 40]. L'écoapproche, destinée principalement aux environnements urbains, anticipe les conditions d'arrêt aux intersections (panneaux de stop, feux de signalisation, etc.) grâce à la technologie véhicule-infrastructure. Cette méthode ajuste la vitesse des véhicules, réduisant ainsi les accélérations et freinages inutiles [41, 42].

La recherche sur l'écoapproche à proximité des intersections progresse rapidement et s'appuie sur divers cadres conceptuels. Étant donné que cette thèse se concentre sur l'amélioration de l'efficacité énergétique des véhicules électriques aux intersections, ce chapitre présente une analyse des facteurs influençant l'écoconduite dans ce contexte spécifique. Il explore également les implications de l'anticipation de certains de ces

facteurs pour optimiser de manière prédictive le freinage régénératif à travers des scénarios représentatifs.

2.1 Les facteurs influençant l'écoconduite dans les intersections

Avant d'aborder les modèles et scénarios d'éco-conduite aux intersections, il est essentiel de comprendre les principaux facteurs qui influencent cette pratique. Contrairement aux véhicules équipés de moteurs à combustion interne (ICE), les véhicules électriques (VE) possèdent des caractéristiques énergétiques spécifiques qui rendent leur éco-conduite unique. Leur consommation d'énergie peut être décomposée en trois sous-composantes principales, chacune étant étroitement liée au comportement de conduite :

- **Énergie utilisée pour la propulsion** : Cette composante dépend directement de la gestion de l'accélération, de la vitesse de croisière et des transitions entre ces phases. Une conduite fluide et optimisée permet de minimiser les pertes énergétiques dues aux résistances mécaniques et aérodynamiques [43].
- **Récupération d'énergie cinétique** : Le freinage régénératif, qui permet de récupérer une partie de l'énergie cinétique du véhicule, est particulièrement efficace lors de décélérations progressives, contrairement aux freinages brusques [44].
- **Énergie consommée par les systèmes auxiliaires** : Bien que moins directement influencée par la conduite, cette composante dépend également de l'utilisation rationnelle des équipements de confort et de sécurité, tels que la climatisation ou le chauffage, lesquels répondent aux préférences du conducteur [45].

Ces trois sous-composantes illustrent l'impact direct du comportement de conduite sur l'efficacité énergétique des véhicules électriques. Par exemple, Nan et al. [46] ont

démontré que l'accélération, la vitesse de croisière et le freinage figurent parmi les principaux déterminants de la consommation énergétique. D'autres facteurs, tels que l'état de la route, la position des feux de circulation, la présence de panneaux de stop ou encore les conditions climatiques, influencent également les décisions du conducteur. Par ailleurs, les caractéristiques techniques du groupe motopropulseur contribuent à la perception et à l'ajustement du comportement de conduite en milieu urbain. La Figure 2.1 regroupe ces facteurs en quatre catégories : ceux liés au véhicule, au scénario, aux conditions météorologiques, et enfin ceux dépendant du comportement du conducteur.




Figure 2.1 : Les principaux facteurs affectant l'éco-conduite dans les intesections [7] .

Ces considérations montrent qu'une grande variété de facteurs, tels que le style de conduite, la carte caractéristique de consommation énergétique d'un véhicule électrique, sa traînée aérodynamique, la pente de la route avec ses courbes à venir, les limitations de vitesse, la visibilité sur la route, la dynamique du flux de trafic, la température et les conditions météorologiques, a un impact significatif sur la consommation énergétique d'un

VE. Par conséquent, l'objectif d'une conduite économique (éco-conduite) est d'adapter la stratégie de conduite afin qu'elle soit sensible à ces paramètres énergétiques, optimisant ainsi l'efficacité globale du véhicule.

2.1.1 Vitesse de conduite

La vitesse de conduite influence directement l'efficacité énergétique d'un véhicule. Adopter une vitesse constante, située dans la plage optimale de rendement du moteur, est reconnu comme la stratégie la plus efficace pour réduire la consommation d'énergie [47–49].

Cette relation se traduit par une courbe en U:

- à basse vitesse, l'augmentation du régime moteur diminue les pertes thermiques et réduit la consommation,
- à haute vitesse, la demande énergétique augmente rapidement en raison des frottements mécaniques et de la résistance aérodynamique.

Pour les véhicules électriques, la plage optimale de vitesse se situe généralement entre 43 et 60 km/h, tandis que, pour les véhicules équipés de moteurs à combustion interne (ICE), elle est légèrement supérieure, entre 60 et 80 km/h, comme illustré dans la Figure 2.2 [46]. Cette différence reflète les particularités des architectures et des rendements des moteurs électriques, qui sont plus efficaces à des vitesses modérées. En milieu urbain, où la vitesse est souvent limitée à 50 km/h, la plage optimale des EVs coïncide avec les restrictions locales, favorisant ainsi une consommation énergétique réduite. De plus, la vitesse optimale ne se limite pas à une diminution immédiate de la consommation : elle contribue également à limiter l'usure des composants critiques, tels que les batteries et les systèmes de propulsion. En effet, en maintenant une vitesse dans cette plage idéale,

les contraintes mécaniques et thermiques sur le véhicule sont réduites, ce qui permet de prolonger la durée de vie des systèmes. Ainsi, l'identification et le respect de la vitesse optimale constituent un levier puissant pour améliorer l'efficacité énergétique des EVs tout en assurant une durabilité accrue de leurs composants.

En stabilisant la vitesse grâce à des outils technologiques tels que les régulateurs de vitesse adaptatifs (ACC), et en tenant compte des conditions réelles de conduite, il est possible de maximiser l'efficacité énergétique tout en minimisant l'impact sur les composants critiques. En effet, des études montrent que l'utilisation de ces dispositifs permet de maintenir la vitesse dans la plage optimale, réduisant ainsi les variations inutiles et stabilisant la consommation énergétique. Par exemple, des recherches menées par Tesla sur des cycles de conduite typiques ont démontré que maintenir la vitesse dans cette fourchette optimale maximise l'efficacité énergétique et réduit la sollicitation du groupe motopropulseur [50]. Cependant, dans la pratique, ces conditions idéales ne sont pas toujours respectées en raison des accélérations et décélérations fréquentes, ainsi que des changements de rythme imposés par le trafic, notamment aux intersections. Ces fluctuations inutiles de vitesse entraînent une augmentation des pertes énergétiques dues aux résistances mécaniques et aérodynamiques.

Enfin, bien que maintenir une vitesse optimale en milieu urbain reste un défi en raison des intersections, des feux de circulation et des comportements variés des conducteurs, une autre contrainte limite l'adoption des régulateurs adaptatifs (ACC). En plus, les préférences individuelles en matière de vitesse influencent fortement cette adoption. Certains conducteurs préfèrent rouler légèrement en dessous de la limite, autour de 40 km/h, tandis que d'autres optent pour une vitesse plus proche de la limite autorisée. Ces variations, même minimales, peuvent compromettre l'efficacité énergétique globale

lorsqu'elles entraînent des écarts par rapport à la plage optimale.




Figure 2.2 : Marge de vitesse optimale pour les EVs et ICEVs [8].

2.1.2 Accélération

L'accélération constitue un facteur déterminant dans la consommation énergétique des véhicules électriques (VE), chaque variation affectant directement l'efficacité globale. Une conduite caractérisée par des accélérations douces et progressives, par opposition à des comportements agressifs, contribue à réduire la consommation d'énergie. Selon Ray et al. [48], un taux d'accélération élevé peut augmenter la consommation énergétique d'un facteur dix par rapport à une accélération modérée. Des études, notamment celle réalisée par Luc et al. [51], indiquent que l'optimisation des profils d'accélération, en particulier en milieu urbain, est essentielle pour limiter les pertes énergétiques. Par ailleurs, des stratégies avancées, telles que celles présentées par Lifu et al. [52], révèlent que des modèles d'accélération non linéaire, combinant des phases initiales rapides suivies d'ajustements progressifs, surpassent les accélérations linéaires continues en termes d'efficacité énergétique. Ces approches permettent de réduire les résistances

mécaniques et aérodynamiques tout en maintenant le moteur dans sa plage de rendement optimal. L'implémentation de ces profils d'accélération non linéaires dans le contrôle moteur reste toutefois complexe. Pour répondre à cette difficulté, Jinqiang et al. [53] ont proposé la stratégie d'éco-conduite pour les véhicules électriques autonomes traversant des intersections à signalisation de limitation de vitesse continue (EDS-CSI). Cette méthode repose sur une co-optimisation à long terme, intégrant le principe du minimum de Pontryagin, et sur un contrôle prédictif à court terme permettant des ajustements en temps réel. Les résultats de simulation démontrent une réduction significative de la consommation énergétique, pouvant atteindre jusqu'à 39,1% par rapport aux méthodes de référence.

Bien que ces stratégies avancées se concentrent principalement sur l'efficacité énergétique et le fonctionnement optimal du groupe motopropulseur, elles négligent parfois un élément essentiel : l'usure des batteries (battery aging). Par exemple, Bingzhaou et al. [54] ont développé un cadre d'optimisation des vitesses basé sur la programmation quadratique séquentielle (SQP). Leurs résultats indiquent qu'il est possible de réduire la perte de capacité des batteries de 9,6%, tout en n'augmentant la consommation énergétique totale que de 1,6%. Ce modèle intègre ainsi des données relatives à la durée de vie des batteries afin de limiter à la fois les impacts énergétiques et l'usure des cellules dans des conditions de conduite réelles, ce qui permet de renforcer l'efficacité énergétique tout en prolongeant la vie des composants critiques. Cependant, ces avancées reposent principalement sur des simulations. Pour aller plus loin, l'utilisation de données issues de cycles de conduite typiques est indispensable. Ces données, collectées en conditions réelles, permettent de développer des protocoles de tests accélérés qui reproduisent en laboratoire les contraintes dynamiques auxquelles sont soumis les composants des VE, telles que les variations de charge et les demandes énergétiques intenses.

Ces protocoles permettent en premier lieu de valider les modèles théoriques en comparant les résultats des simulations avec ceux observés sur le terrain. Ensuite, ils aident à évaluer la fiabilité des composants critiques, tels que les moteurs électriques, les batteries, et les systèmes de contrôle, en simulant des scénarios particulièrement exigeants qui mettent en lumière les éventuels points faibles. Enfin, les données issues de ces tests accélérés servent à affiner les modèles prédictifs, assurant ainsi des performances optimales tout en préservant la durabilité des composants. En combinant ces approches, les stratégies d'accélération optimisées deviennent plus robustes et mieux adaptées aux conditions réelles d'utilisation des VE. Dans ce contexte, Zhen et al. [55] souligne l'importance d'utiliser des cycles de conduite typiques pour recréer en laboratoire des conditions réalistes et améliorer l'évaluation de la durabilité des composants critiques.

Ainsi, la gestion optimisée de la vitesse et de l'accélération reste une pierre angulaire des stratégies d'éco-conduite pour les VE. Même si une conduite plus douce et l'évitement des accélérations brusques réduisent la consommation d'énergie, les gains obtenus grâce à la récupération d'énergie cinétique lors des phases de décélération restent généralement plus importants.

Les sections suivantes se pencheront sur l'interaction entre décélération, freinage et récupération d'énergie afin d'élargir cette perspective.

2.1.3 Décélération et freinage régénératif

La décélération est un élément clé dans les stratégies d'écoconduite et joue un rôle déterminant dans l'amélioration de l'efficacité énergétique des véhicules électriques (VE). Elle permet notamment d'activer les systèmes de freinage régénératif, qui récupèrent une partie de l'énergie cinétique normalement perdue lors du freinage, en la transformant en

énergie électrique stockée dans la batterie. Ce procédé offre au VE un avantage certain par rapport aux véhicules thermiques, en limitant les pertes d'énergie et en optimisant la consommation globale. En moyenne, ces systèmes parviennent à récupérer jusqu'à 57% de l'énergie cinétique, ce qui se traduit par un gain énergétique d'environ 20%, telle que présentée dans la figure 2.3 [8].




Figure 2.3 : Analyse des performances du freinage régénératif [8].

Une méthode pour améliorer l'efficacité de la décélération consiste à combiner le freinage régénératif avec des pratiques telles que la conduite en roue libre. En adoptant la roue libre, le véhicule conserve son élan sans nécessiter de freinage actif, ce qui réduit les pertes énergétiques et limite la nécessité de réaccélérer. En effet, l'objectif principal de la roue libre est de diminuer les pertes par frottement et d'éviter une consommation d'énergie superflue en maintenant une vitesse stable. Le véhicule continue ainsi d'avancer grâce à son inertie, bien qu'aucune énergie ne soit récupérée ni stockée dans la batterie. Cette approche se révèle particulièrement adaptée sur des routes avec lesquelles les arrêts

sont rares et le trafic fluide, permettant au véhicule de maintenir son élan sur de longues distances. En revanche, en milieu urbain, caractérisé par des intersections fréquentes, des ralentissements et des arrêts imposés, l'utilisation de la roue libre perd de son intérêt. Dans ces conditions, le freinage régénératif, qui permet de convertir l'énergie perdue en électricité stockée dans la batterie, s'avère bien plus avantageux [56].

Pour pallier ces limites, une alternative a suscité l'intérêt des chercheurs depuis plusieurs décennies : l'optimisation de la distribution du couple de freinage entre le freinage régénératif et le freinage hydraulique. Le freinage régénératif, qui utilise le moteur électrique pour transformer l'énergie cinétique en électricité, est associé au freinage hydraulique, un système mécanique apportant une puissance de freinage supplémentaire lorsque cela est nécessaire. De nombreuses études se penchent sur des stratégies visant à répartir intelligemment le couple de freinage entre ces deux systèmes, dans le but de maximiser la récupération d'énergie tout en assurant une transition fluide et un contrôle sûr du véhicule. Ces approches cherchent à compenser les limites inhérentes à chaque système, afin d'obtenir une récupération énergétique optimale dans diverses conditions de conduite [57, 58]. En combinant ces techniques, il devient possible d'améliorer significativement l'efficacité énergétique du VE, tout en garantissant une stabilité accrue et un confort de conduite optimal.

En plus des stratégies de répartition du couple, les méthodes de changement de vitesse jouent un rôle essentiel pour les véhicules électriques équipés de transmissions à plusieurs vitesses. Dans cette voiture électrique, passer d'une vitesse à l'autre permet considérablement d'améliorer la récupération d'énergie, en particulier à basse vitesse ou lorsque le moteur fonctionne dans une plage de couple constante. Toutefois, cette stratégie peut présenter certains défis : elle peut engendrer des oscillations inconfortables ou une

perte temporaire du couple de freinage régénératif, ce qui peut impacter la sécurité et le confort de conduite.

Des recherches récentes ont proposé des solutions pour surmonter ces difficultés. Liang et al. [59] présente une stratégie hiérarchique visant à optimiser l'efficacité énergétique du freinage régénératif lors des processus de rétrogradation dans des transmissions à deux vitesses. Cette approche combine une méthode d'optimisation hors ligne, qui permet d'identifier le point de rétrogradation optimal, avec une distribution coordonnée entre le couple de freinage hydraulique et régénératif, ainsi qu'un contrôle coopératif destiné à minimiser les pertes d'énergie. Les résultats montrent que la rétrogradation améliore non seulement la puissance régénérative du moteur, mais également son efficacité globale, permettant de récupérer jusqu'à 65,71% de l'énergie totale du freinage, soit une augmentation de 27,44% par rapport à une stratégie sans rétrogradation. Ces résultats soulignent l'importance d'une gestion intégrée et adaptative pour maximiser les performances des systèmes de freinage régénératif. Néanmoins, certains défis persistent, notamment la gestion des oscillations de couple et des fluctuations de décélération, qui peuvent compromettre le confort et la sécurité dans des scénarios de conduite plus complexes ou imprévisibles. Ces limitations rappellent la nécessité de continuer à améliorer les mécanismes d'adaptation afin de garantir une expérience utilisateur optimale.

Contrairement aux approches traditionnelles, qui se basent principalement sur la vitesse du véhicule ou sur la demande de couple pour définir les stratégies de freinage, les travaux récents innovent en optimisant un profil de vitesse sur un horizon de planification pour maximiser la récupération d'énergie. Dans ce cadre, la distribution du couple et les stratégies de changement de vitesse sont prédéfinies, ce qui simplifie

le processus d'optimisation tout en exploitant pleinement les capacités du système de freinage régénératif. Cette démarche permet de planifier à l'avance des profils de décélération optimaux en prenant en compte divers facteurs, tels que les conditions routières, les mouvements des véhicules environnants, les comportements individuels des conducteurs et les conditions climatiques. L'anticipation de ces variables s'avère ainsi cruciale pour améliorer l'efficacité énergétique tout en garantissant une expérience utilisateur confortable dans les véhicules électriques [60].

Cette étude s'inscrit dans cette perspective en se concentrant sur la planification des profils de décélération optimaux pour maximiser la récupération d'énergie, notamment aux intersections, tout en intégrant des stratégies anticipatives pour une gestion énergétique globalement optimisée.

Dans la section 2.2, nous examinerons en détail les stratégies de freinage régénératif prédictif intégrées aux systèmes d'assistance avancés. Nous verrons comment ces systèmes élaborent des profils de décélération optimaux pour maximiser la récupération d'énergie, en tenant compte de paramètres variés, tels que les conditions de la route, le comportement des véhicules voisins, le style de conduite individuel et les variations climatiques. Nous aborderons également les contraintes qui limitent l'efficacité de cette approche. D'autre part, nous accorderons une attention particulière à l'impact de ces stratégies sur l'expérience utilisateur, en évaluant leur effet sur le confort de conduite, l'acceptabilité par les conducteurs, la sécurité, ainsi que la réduction de la consommation énergétique. Enfin, nous discuterons des défis techniques liés à la mise en œuvre en temps réel de ces systèmes et des perspectives d'amélioration pour répondre aux exigences croissantes en matière de durabilité et d'efficacité dans les véhicules électriques modernes.

2.1.4 Variables météorologiques

Les conditions météorologiques influencent fortement l'écoconduite. Parmi ces facteurs, on compte la température ambiante, la pression atmosphérique, l'humidité relative, la densité de l'air, la vitesse et la direction du vent, ainsi que la distance minimale de visibilité [61].

a) Température ambiante

La température ambiante est un facteur déterminant dans la performance et la durabilité des batteries des véhicules électriques. Les environnements à basse température peuvent, par exemple, provoquer le phénomène de «lithium plating» lors de la charge et du freinage régénératif, ce qui entraîne une perte de lithium, accélère la dégradation de la batterie et réduit sa durée de vie [62]. Pour contrer ce problème, les chercheurs se sont penchés sur le développement de systèmes de gestion thermique destinés à chauffer la batterie [63, 64]. Plusieurs méthodes ont ainsi été explorées : le chauffage par liquide [65, 66], le chauffage par air [67], l'utilisation de caloducs [68, 69] ou encore le chauffage interne [70]. Cependant, un chauffage excessif peut être contre-productif en réduisant l'efficacité de la batterie et en raccourcissant sa durée de vie. Par ailleurs, les cycles de charge et de décharge génèrent une chaleur ohmique importante, ce qui peut entraîner une augmentation rapide de la température [71]. L'état de fonctionnement de la batterie est également influencé par les conditions routières et le comportement du conducteur. Dans des conditions extrêmes, la température de la batterie peut atteindre des niveaux critiques [72]. C'est pourquoi le système de gestion thermique de la batterie (BTM) doit être conçu pour ajuster dynamiquement la température, afin de la maintenir dans une plage optimale.




Figure 2.4 : Les températures ambiantes idéales pour une efficacité énergétique maximale [8].

Les environnements froids affectent non seulement la dégradation de la batterie, mais aussi son efficacité énergétique. Contrairement aux véhicules à moteur thermique, les véhicules électriques sont particulièrement sensibles aux basses températures, qui réduisent l'énergie disponible dans la batterie tout en augmentant son impédance interne. Les températures froides accélèrent la dégradation des cellules, ce qui compromet les performances de la batterie et diminue son efficacité de décharge. Ce phénomène a un impact direct sur l'autonomie et la consommation énergétique du véhicule.

Des études montrent que la relation entre l'efficacité énergétique des VE et la température ambiante suit une courbe en "U" asymétrique, indiquant que les performances énergétiques sont nettement inférieures à basse température qu'à haute température. Comme illustré dans la figure 2.4, la plage optimale se situe généralement entre 15 et 35 °C. Pour pallier ces limitations, les systèmes de gestion thermique jouent un rôle crucial

en régulant la température de la batterie. Toutefois, un chauffage excessif peut se révéler contre-productif, car il réduit l'efficacité énergétique globale et accélère le vieillissement de la batterie. En effet, le chauffage de la batterie en hiver peut consommer une quantité importante d'énergie, surtout dans les VE dotés de batteries de grande capacité, entraînant ainsi une réduction notable de l'autonomie [8].

Étant donné que la batterie constitue la seule source d'énergie pour le chauffage, plusieurs études ont proposé des approches de contrôle optimisées pour concevoir des systèmes de gestion thermique (BTM) qui minimisent la consommation d'énergie tout en maintenant des températures sécuritaires. Selon le manuel de la Nissan Leaf [73, 74], le chauffage électrique de la batterie s'active à 17 °C, chauffe le pack jusqu'à -10 °C, puis se désactive jusqu'à ce que la température redescende à -17 °C. Bien que ces systèmes BTM contribuent à réduire la dégradation de la batterie, ils n'atteignent pas toujours la température optimale nécessaire pour maximiser l'efficacité énergétique, limitant ainsi le chauffage à -10 °C. Cette contrainte affecte également la capacité de régénération de la batterie lors du freinage.

Pour optimiser la gestion énergétique des véhicules électriques dans les temps froids, il est impératif d'intégrer ces contraintes thermiques dans les stratégies de freinage prédictif. En tenant compte des conditions réelles de conduite et des capacités thermiques de la batterie, il devient possible de maximiser la récupération d'énergie tout en préservant l'intégrité de la batterie. Cette approche pourrait améliorer l'efficacité énergétique globale des VE tout en assurant une meilleure durabilité des batteries.

b) Visibilité et Adhérence au sol

La visibilité réduite et les variations d'adhérence au sol représentent des facteurs clés

qui influencent non seulement la sécurité des trajets, mais aussi l'efficacité énergétique des véhicules électriques en fonction des conditions climatiques. Ces deux éléments, qui dépendent fortement des conditions de circulation, impactent la manière dont les conducteurs ajustent leur comportement au volant, affectant ainsi la consommation énergétique et les stratégies d'écoconduite.

De nombreuses études ont établi des liens statistiques entre le style de conduite et les conditions météorologiques. Ces recherches montrent que des facteurs comme la visibilité réduite et les précipitations influencent de manière significative le comportement des conducteurs ainsi que la maniabilité des véhicules [75, 76]. Par exemple, des simulations de conduite ont démontré que le brouillard conduit à une baisse de la vitesse et des taux d'accélération, tout en obligeant les conducteurs à maintenir une distance de sécurité plus importante avec le véhicule précédent [77]. Ces ajustements se traduisent directement par des stratégies d'écoconduite adaptées pour optimiser à la fois la sécurité et l'efficacité énergétique.

En outre, des facteurs spécifiques, tels que les coefficients de frottement de la surface de la route, qui varient selon les conditions météorologiques, ont un impact direct sur la consommation d'énergie et les performances des véhicules. Par exemple, une étude menée dans la vallée de Salt Lake a révélé que les retards de démarrage augmentent de 5% sur des routes mouillées et de 23% sur des routes enneigées par rapport aux conditions sèches [78]. Une approche innovante a également été proposée, combinant les fonctions de barrière de contrôle (CBFs) et les fonctions de Lyapunov de contrôle (CLFs), afin de concevoir un régulateur de vitesse adaptatif capable de s'ajuster aux variations de surface induites par la météo [79]. Par ailleurs, une étude utilisant le simulateur Adams/Car a mis en évidence des variations notables des coefficients de frottement selon les conditions : 0,5 pour des

routes mouillées, 0,4 pour des routes pluvieuses, 0,28 pour des routes enneigées et 0,18 pour des routes verglacées, alors que les routes sèches affichent des valeurs comprises entre 0,9 et 0,6 [80]. Ces différences affectent considérablement les distances de freinage et la stabilité des véhicules.

Ces observations soulignent l'importance d'intégrer les facteurs météorologiques dans la conception des systèmes de contrôle des véhicules et dans l'optimisation de leur consommation énergétique.

b) Le vent L'effet du vent sur la consommation énergétique des véhicules électriques (VE) demeure souvent sous-estimé dans de nombreuses simulations. Un vent arrière peut, par exemple, réduire notablement la résistance aérodynamique, améliorant ainsi l'efficacité énergétique et l'autonomie du véhicule, tandis qu'un vent de face augmente cette résistance, obligeant le moteur à fournir plus d'énergie pour maintenir une vitesse constante. En milieu urbain, la situation se complique : les bâtiments et autres obstacles modifient la direction et la vitesse du vent, générant des turbulences imprévisibles.

Thomas [81] a mentionné qu'un vent arrière de 10 m/s (36 km/h) peut réduire la consommation d'une Tesla Model 3 de 6 % à vitesse d'autoroute, tandis qu'un vent de face de même intensité augmente cette consommation. De plus, en cas de vent de face sur l'autoroute, il est conseillé de prévoir une consommation d'au moins 25 à 35 % supérieure à la normale.

Les modèles avancés basés sur la dynamique des fluides numérique (CFD) offrent une précision intéressante pour simuler ces interactions, mais leur complexité et leurs besoins en ressources limitent leur utilisation en temps réel ou pour des analyses à haute fréquence. Pour simplifier l'étude, certaines recherches ont donc adopté des hypothèses restrictives, en fixant par exemple la vitesse du vent à 0 m/s. Bien que cette approche facilite les calculs,

elle ne reflète pas fidèlement l'impact réel du vent, surtout dans des environnements où les conditions varient rapidement [82].

Selon l'étude de [83], il est crucial de tenir compte de l'impact du vent dans les modèles de consommation énergétique des véhicules électriques. En combinant des facteurs environnementaux, tels que la vitesse du vent, la résistance au roulement et la température, ils ont mis en évidence que la vitesse relative entre le véhicule et l'air est déterminante pour la traînée aérodynamique et, par conséquent, pour la consommation d'énergie. Leur modèle mathématique, qui calcule la puissance de traînée en fonction de la vitesse et de l'angle du vent, associé à des distributions probabilistes, montre que le vent est souvent le deuxième facteur environnemental le plus influent après la température. Ces résultats soulignent l'importance d'une modélisation précise des conditions de vent pour améliorer l'autonomie et l'efficacité énergétique des VE. Les auteurs recommandent également l'intégration de données météorologiques en temps réel et l'utilisation de capteurs embarqués pour capturer ces variations. Zonggen et al. [84] s'étend sur l'analyse en développant des techniques d'optimisation spécifiques pour les conditions de vent contraire et arrière. Leur approche se base sur deux modèles complémentaires : un modèle déterministe, qui attribue une vitesse de vent fixe à chaque segment de route, et un modèle robuste, prenant en compte une plage d'incertitude pour refléter la variabilité des conditions réelles. En utilisant des scénarios de « pire cas », cette méthode vise à garantir une efficacité énergétique optimale même dans des environnements défavorables. Ces travaux offrent des solutions algorithmiques rigoureuses pour la planification de profils de vitesse, en prenant simultanément en compte la consommation énergétique et le temps de transport.

Afin de perfectionner ces approches, il est essentiel de concevoir des modèles à la fois

simples et précis, qui intègrent les effets du vent dans différents contextes. Cela pourrait impliquer l'utilisation de données météorologiques locales, l'estimation en temps réel des forces de vent par des capteurs embarqués et l'intégration de techniques d'apprentissage automatique.

2.1.5 Éléments d'infrastructure

Dans le contexte actuel de transition énergétique, l'infrastructure routière joue un rôle déterminant dans l'efficacité globale des véhicules électriques. En effet, la topographie des routes, qu'il s'agisse de routes plates ou vallonnées, influence directement la consommation d'énergie et l'autonomie du VE.

L'efficacité énergétique des trajets sur routes vallonnées est environ 15 à 20% inférieures à celle des routes plates [85]. Cette différence s'explique par le fait que, sur une route plate, l'énergie nécessaire pour maintenir une vitesse constante reste relativement stable. En revanche, les trajets vallonnés imposent des variations importantes de puissance, impactant directement l'efficacité énergétique des véhicules. En montée, un effort supplémentaire est requis pour surmonter la résistance gravitationnelle, ce qui se traduit par une augmentation significative de la consommation d'énergie [86]. En descente, si le profil de décélération n'est pas optimisé, l'énergie potentielle gravitationnelle accumulée ne peut pas être convertie efficacement en électricité par le freinage régénératif. Une part importante de cette énergie est alors dissipée sous forme de chaleur dans le système de freinage mécanique, réduisant le potentiel de récupération. Ce phénomène est particulièrement accentué lorsque la distance de décélération est trop courte pour permettre un transfert progressif et optimal de l'énergie cinétique vers le système de stockage. Par ailleurs, l'énergie récupérée lors de la descente est généralement inférieure à celle consommée en montée, créant ainsi un déséquilibre énergétique qui réduit l'efficacité

globale du véhicule électrique et diminue son autonomie [87, 88].

Une gestion efficace du freinage en descente est donc essentielle pour réduire la dissipation d'énergie et améliorer les performances du système de régénération. Plutôt qu'un freinage constant, une décélération contrôlée, adaptée au degré d'inclinaison de la pente, permet d'exploiter la gravité comme source d'énergie gratuite avant d'activer le freinage régénératif à des moments stratégiques. Sur de faibles pentes, le véhicule ralentit naturellement sous l'effet de la résistance au roulement et de la traînée aérodynamique, favorisant une récupération d'énergie modérée. Sur de fortes pentes, un freinage régénératif plus intensif est nécessaire pour éviter une décélération excessive, tout en s'assurant qu'il soit appliqué de manière progressive pour ne pas dépasser les capacités d'absorption du système de stockage, que ce soit des batteries ou des supercondensateurs [89].

L'étude menée par Hideki et al. [90] explore l'impact de la pente sur l'efficacité énergétique du VE en proposant un système de conduite autonome optimisé pour étendre l'autonomie. En intégrant l'information sur l'inclinaison de la route, le modèle ajuste simultanément la trajectoire de vitesse et la distribution des forces de freinage et d'accélération, permettant ainsi une gestion plus efficace de l'énergie potentielle gravitationnelle. Les résultats de simulations et d'expérimentations confirment que l'optimisation de la vitesse en fonction du profil de pente permet de réduire la dissipation d'énergie et d'augmenter la récupération par freinage régénératif.

Shaobing et al. [91] proposent une stratégie de contrôle en temps réel pour l'écoconduite sur autoroutes vallonnées, en se concentrant sur l'optimisation de la consommation de carburant pour les véhicules hybrides. Leur approche repose sur deux contrôleurs de rétroaction instantanée, le principe du minimum estimé (EMP) et la

conversion de l'énergie cinétique (KEC), qui utilisent uniquement les données de la pente en temps réel. Cette méthode, nécessitant un temps de calcul inférieur à une milliseconde, permet une réduction de 10 à 15% de la consommation de carburant par rapport à un régulateur de vitesse conventionnel, bien que l'objectif principal ne soit pas la maximisation de la récupération d'énergie.

Pour maximiser la récupération d'énergie et éviter des phases de décélération trop courtes, notamment sur de fortes pentes descendantes, il est crucial d'intégrer la connaissance préalable de l'état de la route dans les modèles d'écoconduite. Les systèmes de positionnement global (GPS) jouent un rôle essentiel en anticipant les variations d'altitude, ce qui facilite l'ajustement de la gestion énergétique avant d'aborder une montée ou une descente [92]. En complément, les capteurs inertiels et les accéléromètres fournissent des données en temps réel sur l'inclinaison de la route, permettant une régulation instantanée des forces de freinage et d'accélération pour optimiser la récupération d'énergie [93].

Les avancées récentes en vision par ordinateur ont également permis le développement de caméras intelligentes capables de détecter et d'estimer la topographie de la route à l'avance. Par exemple, Mobileye, un système de perception basé sur une caméra monoculaire, exploite des paramètres extrinsèques pour analyser l'environnement routier et estimer l'inclinaison de la route. Cette fonctionnalité, en plus de ses capacités d'assistance à la conduite, permet d'optimiser les stratégies de freinage et d'accélération en fonction du profil routier. Toutefois, des variations abruptes de pente peuvent perturber ce système, nécessitant des ajustements pour garantir une interprétation fiable des conditions routières [94].

Dans la section 2.2, nous examinerons en détail les études qui ont cherché à

améliorer l'efficacité du freinage en intégrant des stratégies d'anticipation de l'état de la route, mettant en évidence les approches les plus prometteuses et leurs impacts sur la performance énergétique des véhicules électriques.

2.1.6 Acceptation des conducteurs

a) Influence des facteurs sociodémographiques et comportementaux

L'acceptation des systèmes d'écoconduite repose sur l'interaction étroite entre la technologie et le comportement humain. Leur efficacité dépend en grande partie de la capacité des conducteurs à suivre et à adapter leur conduite aux recommandations proposées. Plusieurs études montrent que, lorsque les conducteurs ne respectent pas les limites de vitesse ou les consignes émises par ces systèmes, les bénéfices escomptés en termes de réduction de consommation énergétique sont considérablement amoindris [95, 96].

Les facteurs sociodémographiques jouent également un rôle important. Ho et al. [35] ont constaté qu'après une formation à l'écoconduite, les conducteurs masculins à Singapour réduisaient leur vitesse de 15,98% en moyenne, tandis que les conductrices en amélioreraient leur comportement de 11,21%. À l'inverse, des études menées au Québec montrent que les femmes adoptent plus facilement les recommandations d'écoconduite [97]. Ces résultats suggèrent qu'une solution universelle est difficile à concevoir et que les systèmes doivent être personnalisés en fonction du profil et du contexte culturel de chaque conducteur.

b) Adaptation basée sur le style de conduite individuel

La reconnaissance du style de conduite individuel constitue un autre enjeu majeur. Chaque conducteur a un comportement influencé par son expérience, les conditions de

circulation et ses préférences personnelles [98, 99]. Cependant, le comportement humain reste souvent imprévisible en temps réel. Une analyse approfondie de ces paramètres permettrait aux systèmes d'écoconduite de développer des modèles mieux adaptés, combinant performance énergétique et personnalisation pour améliorer leur acceptation. À l'inverse, des systèmes mal ajustés aux spécificités du conducteur risquent d'être rejetés, limitant ainsi leur efficacité. Pour maximiser leurs performances, ces systèmes doivent être capables de s'adapter aux préférences des conducteurs, à leur perception du système et aux contraintes environnementales. Une approche flexible et dynamique, intégrant des données en temps réel ainsi que des techniques d'apprentissage automatique, contribuerait à affiner ces modèles et à renforcer l'engagement des conducteurs dans l'adoption de pratiques d'écoconduite. Par exemple, des aspects tels que la sensation de contrôle et le confort, essentiels pour l'utilisateur, ne sont pas encore suffisamment pris en compte dans certains systèmes de freinage régénératif. Certaines études ont montré que, pour atteindre une récupération d'énergie optimale, l'application d'une pression de freinage élevée peut être envisagée. Cependant, selon les simulations présentées par Kim et al. [30], les décélérations moyennes dans ces cas varient entre $-3,79 \text{ m/s}^2$ et $-7,09 \text{ m/s}^2$, bien au-delà des $-2,1 \text{ m/s}^2$ auxquels les conducteurs sont généralement habitués. Ces niveaux de décélération peuvent générer un inconfort significatif, compromettant ainsi l'acceptabilité et l'efficacité à long terme du système.

Reconnaissant l'impact du facteur humain sur le contrôle du freinage régénératif, plusieurs chercheurs ont intégré les particularités individuelles des conducteurs dans leurs modèles. Xuehai et al. [100] ont proposé un modèle de vitesse en boucle fermée, appelé CAEHV-C (Continuous Acceleration with Explicit High Velocity boundary and Coasting), qui adapte en temps réel les conseils fournis aux conducteurs en fonction de leur comportement observé. Ce modèle, en intégrant des phases de décélération par

roue libre, parvient à réduire les fluctuations de la trajectoire de vitesse et à améliorer la consommation énergétique de 4% par rapport aux approches classiques, tout en augmentant l'acceptabilité du système. Sepehr et al. [101] ont développé un algorithme de régénération d'énergie basé sur le principe du maximum de Pontryagin (PMP), combiné à un contrôle prédictif de modèle (MPC) pour adapter la solution en temps réel aux préférences de vitesse du conducteur. Leur méthode permet de récupérer jusqu'à 98% de l'énergie optimale calculée par programmation dynamique, tout en montrant que la consommation énergétique peut varier jusqu'à 5% selon le comportement du conducteur. Cela souligne l'importance d'ajuster le gain énergétique en fonction du style de conduite dans les stratégies de freinage régénératif. Kyunghan et al. [102] ont mis au point un modèle prédictif de décélération pour améliorer le freinage régénératif du VE, en tenant compte des caractéristiques individuelles des conducteurs. Leur approche repose sur un modèle paramétrique avec apprentissage en ligne, qui ajuste les paramètres de freinage en fonction des données collectées en temps réel, permettant ainsi une meilleure correspondance entre la décélération prédite et la décélération réelle, et réduisant l'inconfort pour le conducteur. De manière complémentaire, James et al. [103] ont proposé un modèle de contrôle optimal intégrant les préférences des conducteurs en matière d'accélération, de freinage et de distance inter-véhiculaire, visant à équilibrer la satisfaction du conducteur et la réduction des pertes énergétiques. Sen et al. [104] ont développé un modèle basé sur un Hidden Semi-Markov Model (Oriented-HSMM) qui intègre les préférences de conduite humaine dans la prédiction de la vitesse, améliorant ainsi l'adéquation entre les recommandations fournies et le comportement réel. En résumé, toutes ces études démontrent que la prise en compte du style de conduite individuel permet de réduire significativement la frustration des conducteurs et d'améliorer leur confort, tout en optimisant la récupération d'énergie via des stratégies de freinage régénératif adaptées.

c) Systèmes avancés d'aide à la conduite (ADAS) et personnalisation du feedback

Un autre élément clé pour améliorer le confort du conducteur est l'intégration des systèmes avancés d'aide à la conduite (ADAS). Ces technologies, en plein essor, contribuent activement à renforcer la sécurité routière et à optimiser l'efficacité énergétique des véhicules [105, 106]. Elles assistent le conducteur en intégrant des stratégies d'écoconduite qui visent à maintenir une conduite à la fois fluide et sécuriser. Un aspect fondamental des ADAS réside dans la fourniture de retours d'information, qui peuvent être soit actifs (modifiant directement la réponse du véhicule, par exemple en ajustant la puissance du moteur ou en optimisant la récupération d'énergie lors du freinage régénératif), soit passifs (fournissant des informations visuelles ou auditives pour sensibiliser le conducteur à son style de conduite).

Ces recommandations se présentent sous forme de messages sur le tableau de bord, d'icônes lumineuses ou encore de signaux sonores incitant à une accélération plus progressive ou à un freinage anticipé. Toutefois, la conception actuelle des ADAS repose souvent sur des modèles standardisés, basés sur des profils moyens de conducteurs, ce qui limite leur capacité à répondre aux spécificités individuelles. Par ailleurs, un excès de retours passifs peut entraîner une surcharge cognitive, comme l'ont démontré Kavva et al. [107], qui a montré qu'un trop grand nombre d'alertes fatigue le conducteur et réduit son efficacité à suivre les conseils. De plus, Mark et al. [108] ont mis en évidence qu'un retour d'information inapproprié ou trop intrusif peut éroder la confiance du conducteur dans le système, ce qui l'incite à ignorer, voire à désactiver les alertes, entraînant ainsi la perte des avantages potentiels de l'ADAS.

Dans le même contexte, Sai et al. [109] ont évalué l'impact d'un système prédictif d'écoconduite (pEDAS) sur la performance de conduite et l'acceptation par les

utilisateurs. Leurs résultats indiquent que, bien que ce système réduise significativement la consommation énergétique des véhicules électriques, son acceptation par les conducteurs dépend fortement de la conception de l'interface utilisateur et de la formulation des recommandations. Une interface intuitive et un retour d'information adapté aux spécificités du style de conduite améliorent l'engagement des utilisateurs, tandis qu'un excès d'alertes ou des suggestions jugées trop contraignantes peuvent entraîner un rejet du système. Ces observations soulignent ainsi la nécessité de développer des systèmes d'assistance personnalisés, capables d'adapter les retours aux besoins individuels du conducteur, afin de maximiser leur adoption et leur efficacité à long terme.

d) Vers une personnalisation dynamique des interventions ADAS

Face à ces défis, la prochaine génération d'ADAS se tourne vers l'intégration de la reconnaissance du style de conduite (DS) pour personnaliser les interventions du système et adapter dynamiquement les stratégies d'écoconduite [110]. M. Wisal et al. [111] ont démontré, grâce à la modélisation par équations structurelles (SEM), la capacité prédictive du modèle unifié d'acceptation des conducteurs (UMDA), une méthode bien plus sophistiquée que la régression multiple utilisée auparavant. Leur étude révèle que la confiance, l'utilité perçue et la facilité d'utilisation sont des facteurs essentiels pour l'adoption des systèmes avancés d'aide à la conduite. Ces résultats soulignent l'importance d'une approche centrée sur l'utilisateur, dans laquelle les préférences individuelles et le style de conduite jouent un rôle crucial pour réduire le rejet des systèmes. Dans cette optique, Vadim et al. [112] ont élaboré un modèle d'assistance personnalisé pour le franchissement des intersections, basé sur la communication véhicule-infrastructure (V2I). Leur algorithme d'optimisation du style de conduite tient compte des préférences individuelles en matière d'économie de carburant et de temps de trajet. En ajustant

dynamiquement les recommandations fournies par les ADAS, leur approche améliore la fluidité du trafic aux intersections tout en réduisant la consommation d'énergie et les émissions de CO₂.

D'autres travaux, comme ceux de Tie-Qiao [113], proposent un modèle de guidage de vitesse qui intègre l'influence de la rationalité limitée des conducteurs sur la consommation de carburant aux intersections à feux tricolores. Leur approche, fondée sur trois paramètres: le temps de réponse, le seuil d'acceptation et le niveau d'exécution montrent par simulation que prendre en compte cette rationalité a un impact significatif sur la consommation de carburant et les émissions, notamment dans des conditions de trafic à faible densité. Toutefois, l'absence de validation par des données expérimentales réelles dans cette étude demeure un point critique. De manière similaire, Ruohua et al. [114] ont examiné l'effet des taux de conformité des conducteurs dans un système coopératif véhicule-infrastructure à une intersection à feux tricolores. En s'appuyant sur un modèle de simulation VISSIM et un modèle d'émission spécifique à la puissance du véhicule (VSP), ils ont constaté que des taux de conformité plus élevés réduisent les variations de vitesse et limitent ainsi les freinages et accélérations brusques. Bien que ces résultats indiquent une amélioration de l'efficacité énergétique, leur applicabilité en conditions réelles reste incertaine en raison de la dépendance aux données simulées, ce qui limite la généralisation des conclusions [115].

Malgré ces avancées, la littérature actuelle souffre d'un manque de modèles d'écoconduite capables d'ajuster dynamiquement les stratégies ADAS en fonction des comportements individuels des conducteurs. À ce jour, aucun système ne parvient à maximiser pleinement la récupération d'énergie jusqu'à la limite du moteur tout en personnalisant les feedbacks ADAS et en tenant compte des performances naturelles

de régénération propres à chaque conducteur. L'intégration de modèles prédictifs avancés, associée à des technologies adaptatives, pourrait ainsi permettre d'optimiser la récupération d'énergie tout en fournissant des retours d'information intelligents et personnalisés.

2.2 Optimisation Prédictive du Freinage Régénératif dans des Scénarios Représentatifs

L'intégration de l'écoconduite et des systèmes de gestion de l'énergie dans les véhicules électriques représente un levier majeur pour réaliser des économies d'énergie et réduire l'empreinte environnementale du trafic automobile. Dans ce contexte, le freinage régénératif joue un rôle central en contribuant à l'extension de l'autonomie, particulièrement en milieu urbain où les phases de décélération aux intersections sont fréquentes.

Les recherches récentes mettent en évidence que l'efficacité du freinage régénératif dépend largement d'une planification anticipative de la décélération. Cette approche repose sur la prévision des dynamiques du trafic, incluant la vitesse des véhicules, les conditions de circulation et les variations climatiques, qui sont en grande partie déterminées par des capteurs intelligents embarqués ou par des modèles prédictifs basés sur l'intelligence artificielle. Ces outils permettent d'ajuster avec précision la gestion de l'énergie récupérée, en optimisant le moment et l'intensité du freinage régénératif.

La littérature distingue principalement deux approches en fonction des scénarios étudiés : l'optimisation pour un véhicule unique et celle prenant en compte les interactions entre plusieurs véhicules (scénarios multivéhicules ou à véhicules doubles). Dans un contexte multivéhicules, l'optimisation énergétique est renforcée grâce aux contrôles de croisière adaptatifs (ACC), qui ajustent la vitesse en fonction du trafic, minimisant ainsi

les freinages inutiles et améliorant la récupération d'énergie [116]. Une version avancée, l'Eco-ACC, intègre des modèles prédictifs pour maximiser l'efficacité énergétique tout en assurant un espacement sécurisé entre les véhicules. Dans un contexte à véhicules unique, les stratégies de freinage sont centrées sur l'optimisation de la récupération d'énergie pour un véhicule individuel, sans interactions directes avec d'autres véhicules, en se basant sur l'écoconduite ou la prédiction [24]. Cette classification, illustrée par la figure ci-dessous, figure 2.5, permet d'adapter les stratégies d'optimisation aux conditions réelles de conduite, garantissant ainsi une meilleure régénération d'énergie et une réduction des pertes énergétiques.




Figure 2.5 : Classification des stratégies de freinage régénératif en fonction du type de scénario étudié.

Dans cette section, nous explorerons en détail les différentes méthodes d'optimisation prédictive appliquées au freinage régénératif, en examinant les scénarios représentatifs et les défis techniques associés à l'anticipation des dynamiques de trafic et des conditions environnementales.

2.2.1 Méthodes et Mise en Œuvre de l'Optimisation Prédictive du Freinage Régénératif

a) Méthodes de prédiction

L'optimisation prédictive du freinage régénératif constitue une avancée majeure pour améliorer l'autonomie des véhicules électriques et maximiser leur efficacité énergétique. En intégrant une analyse dynamique des conditions de conduite à l'aide de données en temps réel, cette approche permet d'ajuster précisément l'intensité du freinage régénératif, optimisant ainsi la récupération d'énergie lors des phases de décélération. Cette gestion proactive réduit la dépendance aux freins mécaniques, diminue l'usure des composants et améliore le confort de conduite en assurant une transition fluide entre les phases d'accélération et de décélération [117].

- **Intelligence artificielle** : L'intelligence artificielle est au cœur de cette optimisation, grâce à l'utilisation d'algorithmes capables d'analyser et d'anticiper les conditions de conduite. Des techniques telles que les réseaux de neurones artificiels, l'apprentissage par renforcement, les arbres de décision et les machines à vecteurs de support sont ainsi mises en œuvre pour établir des modèles prédictifs précis [118]. Ces algorithmes, entraînés sur de vastes ensembles de données issus de véhicules électriques, de simulations et d'expériences en conditions réelles, identifient des schémas de conduite et prédisent les besoins en freinage avec une précision acceptable. Prenons l'exemple illustré dans la figure 2.6, qui présente le processus d'entraînement d'un réseau de neurones artificiels typique de type perceptron multicouche (MLP) destiné à la prédiction de la vitesse d'un véhicule en fonction des informations historiques de conduite. L'objectif principal est d'utiliser une séquence de vitesses passées comme entrée du réseau afin d'estimer une

séquence de vitesses futures. Le réseau de neurones est entraîné à partir des données historiques de conduite, qui traduisent l'évolution de la vitesse du véhicule dans le temps. En phase d'apprentissage, il exploite une séquence de vitesses passées $[v_{k-L+1}, v_{k-L+2}, \dots, v_k]$ afin de modéliser le comportement de conduite et d'optimiser ses capacités prédictives. Une fois entraîné, le réseau est capable de générer en sortie une séquence de vitesses futures $[v_{k+1}, v_{k+2}, \dots, v_{k+l}]$ lui permettant ainsi d'anticiper l'évolution de la vitesse du véhicule avec une meilleure précision.




Figure 2.6 : Schéma d'entraînement d'un réseau de neurones pour la prédiction de la vitesse de conduite [9].

Dans cette optique, Kevin et al. [9] repose sur une approche de contrôle prédictif stochastique, intégrant des techniques avancées de prédiction de vitesse et d'optimisation dynamique afin d'améliorer l'efficacité énergétique d'un bus électrique hybride rechargeable (PHEB). Deux méthodes de prévision ont été

évaluées : un modèle de chaîne de Markov (MCM) et un réseau neuronal artificiel de rétropropagation (BP-NN). L'analyse comparative a démontré la supériorité du MCM, notamment en termes de rapidité de calcul et de précision des prévisions dans la plupart des cas. L'algorithme de gestion d'énergie repose sur un contrôle prédictif du modèle (MPC), qui ajuste dynamiquement la stratégie de décharge de la batterie en fonction d'un référentiel SOC adaptatif, construit en exploitant les prévisions de vitesse.

La méthode MCM présente certaines limites lorsqu'il s'agit d'exploiter des relations temporelles complexes. C'est pourquoi les réseaux de neurones à mémoire longue et courte durée (LSTM) sont particulièrement intéressants. Contrairement à MCM, qui s'appuie sur des simulations probabilistes nécessitant une réévaluation constante des scénarios, les LSTM apprennent directement à partir des données historiques et en temps réel, offrant une meilleure modélisation des relations temporelles complexes. Ces réseaux, qui ont démontré leur efficacité dans la prédiction de séquences temporelles liées à la dynamique de conduite, permettent d'intégrer les fluctuations passées et présentes pour affiner la prédiction de la vitesse et du comportement du conducteur. Grâce à leurs mécanismes de mémoire, ils conservent des informations essentielles sur des périodes prolongées, améliorant ainsi la robustesse des modèles prédictifs à long terme et optimisant la gestion de l'énergie en fonction des conditions de circulation. L'état de la cellule mémoire, qui est maintenu tout au long de la séquence pour créer des connexions temporelles, est le composant clé du LSTM comme le montre la figure 2.7. Cet état détermine quelles données doivent être conservées, modifiées ou détruites en interagissant avec l'entrée actuelle et la sortie cachée de l'étape précédente. Le LSTM comprend des éléments essentiels comme la porte d'entrée, la porte d'oubli et la porte

de sortie en plus de la cellule mémoire. En régulant le flux d'informations, ces portes garantissent que les modèles pertinents dans les données séquentielles sont enregistrés et mémorisés efficacement sur de longues périodes de temps [10]. Wang et al. [119] ont prouvé que le modèle d'identification de l'intention de freinage basé sur le réseau de mémoire à long terme (LSTM) offre une précision et une robustesse supérieures par rapport au modèle basé sur le modèle de Markov caché gaussien (GHMM) .




Figure 2.7 : Architecture d'une cellule LSTM et mise à jour des états [10].

Par conséquent, bien que la méthode de Markov soit efficace pour gérer l'incertitude, elle reste limitée pour exploiter les relations temporelles complexes. Les approches basées sur les LSTM offrent une meilleure adaptabilité et précision dans des environnements de conduite dynamiques [9]. L'intégration de LSTM-RNNs dans ces stratégies représente ainsi une avancée prometteuse pour améliorer la robustesse des prédictions de vitesse, optimiser le freinage régénératif et anticiper efficacement les variations de conditions de circulation.

- ***Intégration des technologies de vision et de communication*** : En complément des modèles basés sur l'intelligence artificielle, l'efficacité du freinage régénératif peut être renforcée par l'intégration des technologies de vision et de communication embarquées. Les systèmes de transport intelligents, les capteurs avancés (LIDAR, caméras, GPS, accéléromètres) et les modèles prédictifs de flux de trafic permettent aux véhicules d'anticiper les événements routiers à venir.

L'intégration des communications véhicule-à-véhicule (V2V) et véhicule-à-infrastructure (V2I) améliore cette anticipation en fournissant des données en temps réel sur les intersections et les variations du trafic [120]. Comme illustré dans la figure 2.8, un véhicule électrique intelligent (Intelligent EV Kia Soul) équipé de divers capteurs et systèmes embarqués pour améliorer la perception du véhicule, la navigation et l'assistance à la conduite, ce qui est essentiel pour l'optimisation des stratégies de freinage et d'efficacité énergétique. Baker et al. [121] met en évidence que l'intégration des prévisions de vitesse dans une stratégie de gestion prédictive de l'énergie, grâce aux communications V2V et aux données de circulation réelles, améliore significativement l'efficacité énergétique du groupe motopropulseur.

En combinant ces informations avec les capteurs embarqués, le véhicule peut adapter sa stratégie de décélération et de freinage régénératif en fonction des conditions futures, garantissant une récupération d'énergie optimale tout en préservant la fluidité et la sécurité de la conduite. L'association de l'intelligence artificielle et des systèmes de communication connectés constitue ainsi une approche avancée pour améliorer les performances du freinage régénératif.

- ***Optimisation de l'horizon prédictif et défis computationnels*** : La performance des modèles prédictifs dépend aussi de l'horizon de planification utilisé. Un horizon




Figure 2.8 : Architecture d'une cellule LSTM et mise à jour des états [10].

prédictif plus long permet de planifier des phases de décélération sur une distance étendue, ce qui maximise le potentiel de récupération d'énergie. Toutefois, cet avantage s'accompagne d'un compromis : plus l'horizon est long, plus la précision de la prévision diminue et la charge computationnelle augmente.

Selon Dai-Duong et al. [122], même si l'économie globale d'énergie continue d'augmenter avec un horizon plus étendu, la précision des prédictions s'en trouve affectée. D'après Yan et al. [123], lorsque l'horizon prédictif est relativement large ($T \leq 50$ m), l'économie de carburant atteint plus de 90% de celle obtenue avec une stratégie optimale hors ligne basée sur la programmation dynamique déterministe (DDP). En revanche, un horizon plus court (par exemple, $T \leq 30$ m) réduit considérablement le nombre d'états atteignables et diminue la charge de calcul, améliorant ainsi l'efficacité du traitement de plus de 90%. Ainsi, l'enjeu est de trouver un horizon optimal qui équilibre la précision des prédictions, la performance énergétique et la charge computationnelle. Une approche de gestion

prédictive basée sur un horizon adaptatif, ajustant dynamiquement la planification en fonction des conditions de circulation et des capacités du système embarqué, apparaît comme une solution prometteuse pour répondre aux exigences du temps réel.

En résumé, l'optimisation prédictive du freinage régénératif s'appuie sur des techniques d'intelligence artificielle sophistiquées, l'intégration des technologies de vision et de communication, et une gestion fine de l'horizon prédictif. Bien que ces approches présentent des défis en termes de collecte de données et de puissance de calcul, elles offrent des perspectives prometteuses pour améliorer l'efficacité énergétique et l'autonomie des véhicules électriques dans des conditions de conduite réelles. La figure 2.9 illustre une approche hiérarchisée de la gestion du freinage prédictif dans un cadre d'optimisation multi-échelle. L'axe horizontal représente l'horizon temporel de la planification du freinage (de 0 à 30 secondes), tandis que l'axe vertical indique la source d'informations utilisée, allant d'une distribution locale du couple de freinage à une stratégie optimisée sur un horizon plus long. L'axe de profondeur, quant à lui, représente les niveaux de transport, suggérant différentes échelles de prise de décision. Cette hiérarchie met en évidence l'évolution des stratégies de freinage en fonction du temps et du niveau d'information disponible, assurant ainsi un compromis entre réactivités locales, l'efficacité énergétique et computationnelle globale.

b) Méthodes d'optimisation

Les chercheurs ont mené de nombreuses études sur l'optimisation des profils de décélération afin de maximiser l'efficacité énergétique du freinage des véhicules électriques. On peut classer ces approches en deux grandes catégories : les méthodes




Figure 2.9 : Classification des stratégies de freinage prédictives en fonction des paramètres temporels et informationnels.

basées sur des règles et celles fondées sur l'optimisation [124].

D'un côté, les approches basées sur des règles définissent des stratégies de gestion de la vitesse à l'aide de logiques prédéfinies, établies à partir de l'expertise humaine ou de modèles empiriques. Ces méthodes présentent l'avantage d'être simples à mettre en œuvre en temps réel et offrent une robustesse acceptable dans des conditions de conduite standard [125, 126]. Néanmoins, leur rigidité ne permet pas de s'adapter dynamiquement aux variations des conditions routières, du trafic ou aux contraintes énergétiques spécifiques du véhicule. Cela peut entraîner une efficacité énergétique sous-optimale, en particulier dans les régions urbaines où la variabilité est élevée [41].

D'autre part, les approches fondées sur l'optimisation exploitent des modèles

mathématiques avancés pour minimiser une fonction de coût qui intègre les contraintes de l'environnement. La programmation dynamique, par exemple, repose sur le principe d'optimalité de Bellman. Ce principe décompose un problème complexe en sous-problèmes plus simples résolus de manière séquentielle, permettant ainsi de déterminer une solution optimale globale. Cette méthode se révèle particulièrement efficace dans des scénarios avec lesquels le point de départ, la destination et la trajectoire sont connus à l'avance, comme sur des routes à inclinaison constante ou aux intersections à signalisation programmée [127, 128]. Cependant, l'exploration exhaustive des trajectoires possibles pour chaque état du système génère un coût computationnel élevé, ce qui représente un véritable défi pour une implémentation en temps réel sur les unités embarquées des véhicules [129].

Pour surmonter ce problème, plusieurs solutions ont été proposées. L'utilisation du calcul en cloud permet de décharger les algorithmes sur des plateformes de calcul haute performance, qui transmettent ensuite les résultats aux véhicules en temps réel [130]. Une autre approche consiste à restreindre l'application de la programmation dynamique à des scénarios spécifiques où la complexité est moindre. De plus, certains chercheurs ont développé des algorithmes qui adaptent la résolution de la discrétisation de l'espace des états en considérant les zones critiques, comme les changements de limitation de vitesse, la présence de feux de circulation et les courbes de la route [131].

De plus, la littérature propose des méthodes d'optimisation alternatives, mieux adaptées aux contraintes des systèmes embarqués. Parmi celles-ci, le principe du minimum de Pontryagin (PMP) reformule le problème d'optimisation en un ensemble d'équations différentielles. Cette méthode permet de déterminer directement une trajectoire optimale en identifiant les valeurs extrêmes de la fonction de Hamilton, tout en réduisant la charge

de calcul [132, 133]. Bien que rapide et peu exigeante en ressources, le PMP nécessite de linéariser le système et repose sur des hypothèses simplificatrices, ce qui peut limiter sa capacité à garantir une solution optimale dans des environnements complexes.

Le contrôle prédictif par modèle (MPC) représente également une approche d'optimisation en temps réel. Cette méthode ajuste de manière récursive la trajectoire du véhicule en fonction des variations de l'environnement, en prenant en compte la dynamique du véhicule, la consommation énergétique et diverses contraintes externes [134, 135]. L'un de ses principaux avantages réside dans son horizon de prédiction ajustable, permettant de trouver un compromis entre précision et charge computationnelle [136].

Enfin, l'apprentissage par renforcement (RL) est une méthode d'optimisation qui se base sur le processus de décision de Markov. Grâce à une interaction continue entre un agent et son environnement, le RL apprend par essais et erreurs à maximiser une fonction de récompense, ce qui le rend particulièrement adapté aux systèmes complexes et dynamiques, comme la gestion de l'énergie des véhicules électriques et hybrides [137, 138]. Les travaux de Meixin et al. [139] ont démontré que le RL peut être jusqu'à 200 fois plus rapide que le contrôle prédictif par modèle, en faisant une approche prometteuse pour des applications en temps réel, notamment dans les véhicules autonomes.

2.2.2 Scénarios à véhicules uniques

La plupart des recherches se concentrent sur un scénario à véhicule unique pour la modélisation des méthodes d'optimisation prédictive du freinage régénératif. Cette approche est principalement adoptée pour deux raisons :

- La nécessité de simplifier la complexité du modèle en exploitant uniquement les

données anticipatives liées à la pente, à la géométrie de la route et aux conditions de circulation (incluant les signaux d'arrêt et l'état des feux de signalisation), comme présentée dans la figure 2.10.

- La réduction du coût computationnel par rapport à des scénarios impliquant de multiples interactions.

Toutefois, cette approche présente une limitation importante, puisqu'elle néglige souvent les interactions dynamiques entre véhicules, telles que le suivi, les dépassements et les changements de voie, qui sont pourtant essentielles en trafic réel.

Dans ce contexte, la section suivante présente un état de l'art des stratégies de freinages récentes dans un scénario à véhicule unique, mettant en évidence leurs limites et servant de fondement aux contributions de cette thèse.

a) Optimisation prédictive basée sur les informations SPaT et l'état de la route

Plusieurs études ont exploré l'optimisation prédictive du freinage régénératif dans un scénario à véhicule unique en intégrant des facteurs clés, tels que : les informations SPaT (*Signal Phase and Timing*) et l'état de la route.

- ***Single intersection approach*** : L'optimisation prédictive basée sur les informations SPaT a été étudiée dans une seule intersection. Rui et al. [140] propose une stratégie d'écoconduite pour les véhicules électriques (EV) aux intersections, exploitant la communication véhicule-infrastructure (V2I) pour ajuster dynamiquement la trajectoire de vitesse. L'approche repose sur une analyse approfondie du comportement de conduite afin d'identifier les opportunités d'optimisation énergétique. Elle intègre ensuite la programmation dynamique (DP) couplée à un modèle de consommation énergétique dérivé de tests dynamométriques (NEDC)




Figure 2.10 : Optimisation du freinage régénératif en fonction de la topographie et des positions d'arrêt.

pour optimiser les phases d'accélération et de décélération. Cette stratégie permet ainsi de réduire efficacement la consommation d'énergie tout en améliorant l'autonomie des véhicules électriques.

D'autres travaux, comme celui de Bhat et al. [141], développent une stratégie de contrôle prédictif (MPC - Model Predictive Control) qui exploite également les informations SPaT pour ajuster en temps réel la vitesse des véhicules autonomes et connectés (CAVs). Cette approche se distingue par sa capacité à intégrer

l'incertitude des phases de signalisation, lesquelles sont influencées par les variations du trafic et la présence de piétons. Testée sur des plateformes de simulation avancées (MATLAB®, SIMULINK®), cette méthode permet de réduire significativement la consommation énergétique en évitant les arrêts inutiles et en maximisant l'utilisation du freinage régénératif aux intersections.

Ensuite, Ning Li et al. [142] proposent une méthode exploitant la communication en temps réel entre les véhicules et les SPaT afin d'obtenir des informations sur l'état des feux de signalisation et leur synchronisation, considérée comme des contraintes. Leur approche repose sur un modèle de simulation du système de freinage à récupération d'énergie hybride (HERBS), validé par des essais sur banc de test. Ensuite, un algorithme génétique (GA) est utilisé pour maximiser la récupération d'énergie au freinage (BERE) dans une intersection unique. Les simulations réalisées avec ADVISOR montrent une augmentation de 36,21 % du BERE par rapport aux conducteurs inexpérimentés et de 7,82 % par rapport aux conducteurs expérimentés, démontrant ainsi que le style de conduite influence directement le potentiel de gain énergétique du freinage régénératif.

- ***Multi-intersection approach*** : Les travaux précédents se limitent généralement à l'optimisation du freinage en fonction d'un seul feu de circulation, ce qui limite leur performance globale. Pour répondre à cette limitation, Bo et al. [143] explorent la planification de trajectoire dans un environnement multi-feux en introduisant une approche innovante basée sur l'apprentissage par renforcement profond (DRL). Appliquée aux véhicules connectés et autonomes, cette méthode exploite les données V2I en temps réel pour ajuster la trajectoire en prenant en compte plusieurs intersections successives. Le résultat est une transition plus fluide et une réduction

de la consommation de carburant de 6,79% par rapport aux modèles basés sur un seul feu, démontrant l'importance d'optimiser pour des trajets comportant plusieurs intersections successives.

b) Optimisation prédictive basée sur les informations des panneaux d'arrêt et l'état de la route

Bien que les stratégies basées sur les informations SPaT optimisent l'efficacité du freinage lors des phases de décélération, leur objectif principal est souvent d'ajuster la vitesse pour éviter l'arrêt complet aux intersections. Or, cette approche limite la décélération progressive et, par conséquent, le potentiel de récupération d'énergie. En effet, les panneaux d'arrêt, omniprésents aux intersections, imposent un arrêt complet du véhicule, offrant ainsi une meilleure opportunité pour maximiser la récupération d'énergie grâce à une planification préventive de la décélération. Cette planification repose sur l'anticipation des positions d'arrêt, de l'infrastructure routière et, dans certains cas, des conditions météorologiques.

Dans cette optique, Wang et al. [144] proposent une stratégie d'optimisation de la vitesse pour les EV circulant sur des routes en pente. Leur étude exploite un modèle de contrôle prédictif (MPC) pour ajuster dynamiquement la vitesse en fonction de la géométrie de la route à la fois sur le long et le court terme. La prise en compte anticipée de l'inclinaison conduit à une augmentation de la vitesse en montée et à une réduction en descente, dans le but d'appliquer la force de freinage régénérative lors de décélération et d'optimiser la consommation d'énergie de la batterie. Les simulations montrent une réduction de la consommation d'énergie de 7% à 27% par rapport à un modèle de conducteur intelligent, notamment en milieu urbain où les phases de freinage sont fréquentes.

De son côté, Park et al. [129] développent une stratégie d'optimisation de l'écoconduite en utilisant la programmation dynamique (DP) afin de minimiser la consommation d'énergie tout en respectant les contraintes de vitesse et de distance. Leur modèle, qui intègre quatre modes de conduite (accélération, croisière, roue libre et freinage), met particulièrement l'accent sur la maximisation du freinage régénératif en optimisant les transitions entre ces phases. Les résultats montrent une réduction de 47,8% de la consommation énergétique par rapport à un modèle basé sur le comportement d'un conducteur intelligent (IDM). Les études de Park [129] et Wang [144] confirment que le gain énergétique obtenu par la méthode DP est systématiquement supérieur à celui du MPC. Pour exploiter en temps réel la capacité de gain énergétique offerte par DP, Ye et al. [131] introduisent une approche novatrice d'optimisation de la trajectoire de vitesse basée sur une programmation dynamique discrète à taille de pas variable. Cette méthode ajuste la résolution de discrétisation de l'espace des états en fonction des points d'intérêt (changements de limitation de vitesse, feux de circulation, courbures de la route) et permet de réduire le coût computationnel de plus de 53% avec une perte de précision inférieure à 1%.

c) Limites physiques et adaptation aux contraintes du système

Bien que les études analysées précédemment visent à maximiser la récupération d'énergie en temps réel, elles ne prennent pas en compte les limitations physiques du freinage régénératif, notamment la saturation du système de régénération sur les routes en pente. En effet, la relation entre l'intensité de la décélération et la récupération d'énergie présente des limites physiques. Une décélération plus intense accroît la récupération d'énergie par kilomètre (ERpk), mais cette augmentation est plafonnée par les contraintes des systèmes de freinage régénératif, comme le moteur et des batteries. Par exemple, les

batteries sont limitées par leur capacité d'absorption maximale sur une période donnée (C-rate). Si cette capacité est dépassée, l'énergie excédentaire ne peut être stockée, et des décélérations trop intenses risquent d'entraîner une surchauffe, réduisant ainsi l'efficacité globale. Ces observations soulignent l'importance de stratégies optimisées pour gérer la décélération de manière efficace. Bien que les stratégies d'écoconduite existantes, telles que celles présentées dans [145], [146] et [147], ne prennent pas explicitement en compte les limites matérielles – par exemple, les potentialités maximales de freinage par friction et de régénération du moteur, leur intégration est essentielle pour maximiser l'efficacité énergétique des véhicules électriques.

Dans cette perspective, des efforts significatifs ont été déployés pour optimiser le freinage prédictif et l'adapter aux capacités maximales du moteur. Ainsi, Mohammadi et al. [148] proposent une optimisation du profil de vitesse des véhicules électriques autonomes, intégrant les limitations du freinage régénératif afin de minimiser la consommation d'énergie tout en respectant les contraintes de freinage et les restrictions de vitesse en milieu urbain. Leur approche repose sur un problème de programmation linéaire mixte en nombres entiers (MILP), permettant de modéliser avec précision les forces de résistance, la récupération d'énergie et les régulations routières. Implémentée sous Python et résolue avec un solveur d'optimisation, cette méthodologie assure une optimisation efficace avec un coût computationnel réduit. Contrairement aux méthodes conventionnelles, cette approche intègre les limites physiques du freinage régénératif, notamment la saturation de récupération d'énergie et son inefficacité à basse vitesse. Les simulations montrent qu'en prenant en compte ces limitations, l'efficacité énergétique s'améliore significativement, soulignant l'importance d'une modélisation réaliste du freinage régénératif pour optimiser l'autonomie des véhicules électriques autonomes.

D'un autre côté, Kim et al. [149] développent une stratégie de freinage régénératif en temps réel pour les véhicules électriques connectés et autonomes. L'objectif principal est de maximiser la récupération d'énergie lors des phases de décélération en prenant en compte la saturation du moteur et en ajustant dynamiquement la vitesse du véhicule selon les conditions de trafic et les contraintes routières. La méthodologie repose sur un système de planification en temps réel de la décélération optimale, combinant une architecture hybride où la programmation dynamique (DP) est utilisée pour la planification globale de la trajectoire de vitesse, tandis que le contrôle prédictif (MPC) permet un ajustement en temps réel des profils de décélération. Les résultats montrent une amélioration de plus de 40 % de l'efficacité de récupération d'énergie par rapport à un conducteur humain, tout en assurant une décélération fluide et sécurisée. Cependant, cette étude repose sur un seul style de conduite caractérisé par une vitesse maximale unique et stable, avoisinant 90 km/h. Une telle vitesse entraîne une capacité de régénération élevée, propre à ce type de conducteur. Toutefois, tous les conducteurs n'adoptent pas ce style de conduite, notamment dans les intersections, ce qui pourrait impacter négativement la performance de la stratégie proposée [149].

d) Impact du style de conduite sur la capacité de régénération du moteur

La capacité de régénération du moteur dépend de la vitesse du véhicule au début de la décélération et du couple appliqué. Par conséquent, la performance de récupération d'énergie varie en fonction du style de conduite. Certains styles permettent d'atteindre rapidement la limite de régénération du moteur, tandis que des conduites plus modérées limitent naturellement le potentiel récupérable. Par exemple, un conducteur privilégiant une vitesse modérée, entre 40 et 45 km/h, pourrait maximiser la récupération d'énergie sans nécessiter d'assistance additionnelle, car la capacité de régénération est déjà faible

à ces vitesses [150]. Ainsi, si les approches d'optimisation du contrôle de freinage ne tiennent pas compte des performances individuelles de régénération en conditions de conduite naturalistes, elles peuvent générer des alertes excessives, intrusives et inadaptées. Ces notifications, souvent perçues comme gênantes par les conducteurs, peuvent les inciter à désactiver le système, réduisant ainsi son efficacité et son taux d'adoption. À cet égard, la littérature n'a pas encore exploré en détail la variabilité de la capacité de régénération en fonction du style de conduite, ce qui ouvre de nouvelles perspectives pour améliorer l'acceptabilité, l'adaptabilité et l'optimisation des performances de régénération dans le domaine du transport électrique et intelligent.

De plus, un autre aspect important pour le déploiement de ces systèmes de freinage adaptatifs est l'acceptabilité des systèmes avancés d'aide à la conduite (ADAS) par le conducteur. Comme discuté précédemment, un excès de feedback actif peut entraîner une surcharge cognitive, en particulier lorsque les retours d'information sont trop fréquents ou non pertinents. Il est donc essentiel d'adapter ces retours au style de conduite individuel afin d'améliorer l'engagement et la satisfaction des utilisateurs.

e) Impact des conditions météorologique sur la capacité de régénération du moteur

Un autre facteur influençant la maximisation de la récupération d'énergie jusqu'à la capacité de régénération du moteur est représenté par les conditions météorologiques. Comme mentionné dans la section sur les conditions climatiques, une visibilité réduite due à des conditions défavorables (par exemple, neige) et une faible adhérence (route glissante) impactent significativement le style de conduite. Ces variations influencent également la capacité de régénération, rendant ainsi le modèle prédictif de freinage moins efficace pour exploiter pleinement la récupération d'énergie. Par conséquent, ces facteurs doivent être intégrés dans le modèle prédictif afin de permettre une adaptation aux différentes

conditions climatiques et d'optimiser la régénération d'énergie en toute sécurité.

Toutefois, les recherches sur le freinage régénératif se concentrent principalement sur l'optimisation de l'efficacité énergétique dans des conditions météorologiques spécifiques. Certaines études se focalisent sur des conditions estivales, comme les approches déjà présentées, tandis que d'autres examinent des stratégies adaptées aux routes glacées en hiver. Ahiska et al. [151] proposent un contrôleur énergétique pour les véhicules électriques sur des routes en pente, intégrant un algorithme de compensation du patinage basé sur un modèle dynamique à trois degrés de liberté. Ce contrôleur améliore la consommation d'énergie même sur des surfaces glissantes, tout en restant robuste face aux variations de masse du véhicule et de l'état de la batterie. De manière similaire, Ahiska [152] introduit un pilote automatique conçu pour des routes à faible adhérence, en utilisant une optimisation hiérarchique à deux niveaux pour prévenir les dérapages et maintenir des performances stables sur des surfaces à friction variable. La planification de la décélération joue également un rôle crucial dans l'amélioration des performances sur ces routes. Chu et al. [153] proposent une stratégie de contrôle coordonné (eMPC-CCS) pour les systèmes de freinage régénératif (RBS) et les systèmes de freinage antiblocage (ABS) dans les véhicules électriques. Cette approche s'attaque spécifiquement aux défis posés par des conditions de route à faible adhérence (par exemple, surfaces glacées ou mouillées) en utilisant un cadre de contrôle prédictif basé sur des modèles. En coordonnant les forces de freinage en temps réel, elle assure la stabilité du véhicule et des performances optimales, même lorsque l'adhérence est considérablement réduite, tout en minimisant les conflits entre le RBS et l'ABS via des mécanismes de compensation des erreurs d'état. De manière similaire, Pan et al. [154] se concentrent sur l'optimisation de la régénération d'énergie grâce à une stratégie de régulateur de vitesse adaptatif optimal en énergie (EACC) basée sur le contrôle prédictif par modèle (MPC), qui ajuste dynamiquement les paramètres pour

améliorer la stabilité du véhicule et réduire les pertes énergétiques.

Cependant, malgré ces avancées, la plupart de ces études se concentrent sur des scénarios climatiques spécifiques et ne proposent pas de solutions adaptées aux transitions fréquentes entre différentes conditions météorologiques, telles que le passage d'une route sèche à une route verglacée. Cette lacune limite l'efficacité des approches existantes, car les systèmes d'assistance optimisés pour un seul type de condition climatique risquent de générer des alertes inadaptées, compromettant ainsi leur acceptabilité et leur adoption par les usagers.

f) Synthèse et perspectives

L'optimisation du freinage régénératif dans un scénario à véhicule unique permet d'améliorer l'efficacité énergétique en exploitant des informations anticipatives (SPaT, panneaux d'arrêt, état de la route, inclinaison) et en optimisant la trajectoire de vitesse. Néanmoins, cette approche présente plusieurs limites :

- Elle omet souvent d'inclure les limitations physiques du système, telles que la saturation du freinage régénératif et la capacité maximale d'absorption des batteries.
- Elle ne tient pas suffisamment compte des variations du style de conduite, qui influencent directement la capacité de récupération d'énergie.
- Elle est rarement adaptée aux conditions météorologiques complexes et aux transitions fréquentes entre différents types de surfaces.
- Elle n'intègre pas les interactions dynamiques entre véhicules, essentielles dans un trafic réel.

Ces travaux, tout en posant les bases d'une optimisation énergétique poussée, ouvrent la voie à des recherches futures qui intégreront des technologies V2V, des stratégies

collaboratives et des méthodes de prédiction avancées pour optimiser le freinage régénératif dans un contexte multi-véhicules. Cette évolution permettra de contribuer à un transport plus durable et efficace, en adaptant les stratégies d'écoconduite aux conditions réelles de circulation.

2.2.3 Scénarios à véhicules doubles

Les sections précédentes ont exploré l'intégration des systèmes de transport intelligents (ITS), la perception intelligente des véhicules électriques et l'optimisation prédictive du freinage régénératif dans un contexte de véhicule unique, mettant en évidence leur impact sur l'efficacité énergétique et la gestion dynamique de la vitesse. Toutefois, ces approches peuvent être étendues aux scénarios multi-véhicules, où l'interaction entre plusieurs véhicules électriques offre un potentiel significatif pour améliorer la gestion énergétique, réduire la consommation et fluidifier le trafic en milieu urbain, comme illustrées dans la figure 2.11.

a) Contrôle de croisière (ACC)

Dans un scénario à deux véhicules, le régulateur de vitesse adaptatif (ACC) repose sur un modèle de suivi dynamique permettant d'ajuster automatiquement la vitesse du véhicule suiveur en fonction des variations de vitesse du véhicule en amont. Ce mécanisme garantit une distance de sécurité constante entre les deux véhicules, ce qui contribue à améliorer la fluidité du trafic et à renforcer la sécurité routière en réduisant les risques de collision [155]. Cependant, les recherches antérieures se sont principalement concentrées sur la sécurité et le confort de conduite, en négligeant fréquemment l'aspect énergétique. En réalité, des accélérations et des décélérations brusques, majoritairement observées dans la circulation routière, peuvent entraîner une baisse de l'efficacité énergétique globale et

restreindre les avantages du freinage régénératif [156].




Figure 2.11 : Optimisation du freinage régénératif basé sur l'écoconduite et la gestion des distances inter-véhicules

b) Contrôle de croisière écologique (Eco-ACC)

Pour remédier aux limitations de ACC, la technologie Eco-ACC a été développée. L'Eco-ACC intègre l'interaction énergétique entre le véhicule en avant et le véhicule suiveur. Cette approche vise à trouver un équilibre optimal entre efficacité énergétique et sécurité routière. Elle ajuste non seulement la vitesse pour éviter les arrêts et redémarrages inutiles, mais optimise également les phases d'accélération et de décélération, permettant ainsi une conduite plus fluide, une meilleure récupération d'énergie et une consommation réduite [157].

La littérature sur la technologie Eco-ACC repose en premiers lieux sur un modèle de suivi statique, où le véhicule en avant est supposé maintenir une vitesse stable ou présenter de faibles variations sur un horizon de prédiction donné. Cette hypothèse permet d'anticiper plus efficacement les variations de vitesse et d'optimiser ainsi la trajectoire énergétique du véhicule suiveur en réduisant les fluctuations inutiles. Mahyar et al. [158] ont montré que l'intégration d'un modèle prédictif avancé, combiné à un contrôle prédictif non linéaire (NMPC), permet de réduire le coût énergétique total jusqu'à 19 %, tout en garantissant un niveau élevé de sécurité et de confort. Ruan et al. [159] met au point des techniques hiérarchiques appelées «Eco-ACC», qui optimisent la gestion du régime moteur selon les diverses situations de conduite, entraînant ainsi une baisse notable de la consommation d'énergie. Les expérimentations menées sur des systèmes Eco-ACC basés sur le Model Predictive Control (MPC) pour les véhicules hybrides rechargeables (PHEV) ont démontré une amélioration notable de l'efficacité énergétique et de la sécurité, en adaptant dynamiquement la gestion de la puissance aux conditions de circulation. Toutefois, il a été largement démontré que la dynamique des véhicules en amont joue un rôle crucial dans les performances de l'écoconduite, en influençant directement l'efficacité énergétique et la fluidité du trafic dans les scénarios de suivi de véhicule, notamment sur les routes vallonnées.

En deuxième lieu, les stratégies Eco-ACC repose principalement sur la prédiction dynamique de la vitesse du véhicule en avant, en intégrant des modèles avancés capables d'anticiper les fluctuations du trafic [116, 160]. Xie et al. [161] ont proposé une approche innovante exploitant la prédiction du mouvement relatif entre le véhicule principal et le véhicule précédent à l'aide du radar avant du véhicule. Leur modèle hiérarchique est structuré en trois niveaux. La couche supérieure est dédiée à l'analyse des scénarios de conduite afin d'identifier les conditions dynamiques de circulation. Ensuite, une couche

intermédiaire assure la prise de décision et la gestion des transitions, garantissant une adaptation fluide du contrôle du véhicule. Enfin, la couche d'optimisation du couple moteur repose sur un contrôle prédictif basé sur un modèle (MPC), permettant de minimiser la consommation énergétique tout en garantissant une conduite sécurisée et fluide. Les résultats expérimentaux ont démontré que cette stratégie permet une réduction significative de la consommation énergétique, en particulier dans un environnement urbain où les variations de vitesse du véhicule en amont sont fréquentes. L'article de Xie et al. [162] explore également une approche innovante basée sur un contrôle prédictif de modèle intégré (IMPC) pour la gestion énergétique des véhicules hybrides rechargeables (PHEV). Contrairement aux stratégies conventionnelles, cette approche coordonne simultanément la planification de l'état de charge de la batterie (SOC) et le contrôle de vitesse adaptatif. L'IMPC ajuste dynamiquement la distance inter-véhicules et la répartition de puissance entre le moteur thermique et la batterie, améliorant ainsi l'économie de carburant. Les résultats obtenus à partir d'un cycle de conduite urbain réel indiquent une réduction des coûts énergétiques de 17,9% à 36,1% par rapport aux méthodes traditionnelles, démontrant le potentiel de cette stratégie pour une gestion énergétique plus efficace dans les scénarios de suivi de véhicule.

d) Acceptabilité des systèmes Eco-ACC

Malgré ces avancées, l'acceptabilité des systèmes Eco-ACC par les conducteurs reste un défi majeur [163]. En effet, le manque de personnalisation et d'adaptabilité aux préférences individuelles constitue un frein à leur adoption à grande échelle. Pour pallier cette limitation, plusieurs recherches ont intégré des modèles d'intelligence artificielle et d'apprentissage machine afin d'adapter dynamiquement le comportement de l'ACC aux attentes des conducteurs. Marco et al. [164] ont développé un automate hybride

microscopique capable de reproduire avec précision les caractéristiques psychophysiques humaines, améliorant ainsi le confort des passagers et l'adaptabilité du système. De plus, Meixin et al. [165] ont proposé une approche basée sur l'apprentissage par renforcement profond (RL) avec le modèle DDPGvRT, conçu pour imiter les réactions humaines (par exemple, délais de réaction et schémas de prise de décision). Ce modèle permet une adaptation aux différents styles de conduite, qu'ils soient agressifs ou conservateurs, garantissant ainsi une meilleure expérience utilisateur et un sentiment de contrôle accru, deux éléments clés pour l'acceptation des technologies de conduite autonome.

L'intégration de modèles prédictifs de freinage régénératif adaptatif dans un scénario à véhicule unique a déjà démontré son importance et son efficacité en matière d'optimisation énergétique. Son extension aux scénarios multi-véhicules avec Eco-ACC représente une avancée stratégique, car elle combine les bénéfices de l'optimisation individuelle avec les interactions inter-véhicules des systèmes collaboratifs. Cette approche permet une gestion plus fluide des accélérations et des décélérations, maximisant ainsi la récupération d'énergie et l'efficacité globale du trafic, tout en améliorant le confort et l'acceptabilité du système.

Chapitre 3 - Développement d'une stratégie adaptative basée sur l'analyse des performances de régénération naturelle

Article 1 : Ziadia, Marwa, Sousso Kelouwani, Ali Amamou, and Kodjo Agbossou. "An Adaptive Regenerative Braking Strategy Design Based on Naturalistic Regeneration Performance for Intelligent Vehicles." IEEE Access 11 (2023): 99573-99588.

DOI : 10.1109/ACCESS.2023.3313553

3.1 Introduction

Cet article présente une approche complète pour développer une stratégie de freinage régénératif adaptative destinée aux véhicules électriques intelligents. L'objectif principal est d'optimiser la récupération d'énergie en s'appuyant sur une modélisation précise de la dynamique du véhicule et sur des techniques avancées de prédiction, telles que les réseaux LSTM et le modèle NARX. En intégrant les performances naturelles de régénération propres à chaque conducteur et en adaptant dynamiquement le profil de décélération, la méthode proposée vise à améliorer l'efficacité énergétique tout en garantissant le confort et la sécurité des utilisateurs. Pour ce faire, une série de tests expérimentaux a été réalisée sur un Kia Soul 2017 équipé de capteurs avancés, permettant d'enregistrer des données critiques (vitesse, couple moteur, position GPS, puissance consommée ou régénérée) et de comparer la stratégie adaptative (AEDPS) aux performances naturelles de régénération.

3.2 Méthodologie

L'article présente une méthodologie complète pour élaborer une stratégie de freinage régénératif adaptative destinée aux véhicules électriques intelligents. Cette approche combine des modèles prédictifs et des algorithmes d'optimisation avancés dans le but

d'améliorer l'efficacité énergétique tout en s'adaptant aux performances naturelles de régénération propres à chaque conducteur.

La méthodologie débute par l'identification des besoins essentiels pour modéliser un profil de décélération optimisé. Le modèle se concentre sur la dynamique longitudinale du véhicule en tenant compte des forces suivantes :

- La friction entre les pneus et la route,
- Les accélérations
- La résistance aérodynamique,
- La résistance au roulement,
- Les effets gravitationnels liés à l'inclinaison de la route.

Un modèle mathématique de la dynamique du véhicule est ainsi élaboré, permettant de simuler avec précision divers scénarios de freinage dans des conditions réelles. Afin de maximiser la récupération d'énergie jusqu'à la limite propre à chaque moteur, une estimation rigoureuse des paramètres de flux de puissance du Kia Soul 2017 a été réalisée.

Ces paramètres incluent :

- L'efficacité de la batterie, η_{Ba} , pendant les phases de charge et de décharge,
- L'efficacité de l'onduleur de traction, η_{Mi} ,
- L'efficacité de la transmission, η_{Tr} .

La détermination du couple moteur, basée sur une carte d'efficacité spécifique à ce modèle et tenant compte de la vitesse de rotation, permet de modéliser avec fidélité le comportement énergétique du véhicule. Cette modélisation assure une optimisation réaliste et applicable en conditions de conduite.

Afin de valider l'approche et d'adapter la stratégie aux comportements réels, des données expérimentales ont été recueillies sur un Kia Soul 2017 équipé de capteurs

avancés. Ces capteurs ont permis d'enregistrer en temps réel des variables critiques telles que le couple moteur, la vitesse, la position GPS, ainsi que la puissance consommée ou régénérée, pour trois styles de conduite caractérisés par des préférences de vitesse maximale différentes.

Ces données servent à entraîner des modèles prédictifs avancés, capables d'anticiper les performances naturelles de régénération en fonction des conditions de conduite. Deux architectures de réseaux neuronaux ont été exploitées :

- Le modèle LSTM (Long Short-Term Memory), réputé pour sa capacité à capturer des séquences temporelles complexes et à effectuer des prévisions à long terme,
- Le modèle NARX (Nonlinear Autoregressive with Exogenous Inputs), qui permet des prévisions rapides et adaptées aux conditions immédiates grâce à l'intégration de variables exogènes.

Afin d'assurer la robustesse de la méthodologie, des étapes de filtrage des données aberrantes ont été mises en place avant l'entraînement, garantissant la cohérence des données tout en préservant les variations naturelles pertinentes pour l'apprentissage. De plus, certains modèles ont été recalibrés sur des ensembles de données volontairement bruités afin d'évaluer leur stabilité et leur capacité d'adaptation dans des conditions dégradées.

Le modèle offrant la meilleure précision et le temps de calcul le plus court est retenu pour ajuster dynamiquement la planification de la décélération sur quatre horizons temporels : long, moyen, court et optimal. Lorsqu'un potentiel élevé de récupération d'énergie est détecté, un horizon long est privilégié afin de maximiser la récupération sur une distance étendue. Inversement, lorsque ce potentiel est faible, un horizon court est adopté pour garantir la sécurité tout en minimisant les pertes.

Enfin, l'optimisation du profil de décélération est réalisée par programmation dynamique, une méthode de contrôle optimale qui explore l'ensemble des trajectoires possibles afin de déterminer la stratégie de freinage la plus efficace. Ce profil est ajusté en tenant compte de :

- La pente de la route,
- La vitesse actuelle du véhicule,
- Les préférences personnelles du conducteur concernant la vitesse maximale,
- Les limites de régénération individuelles du moteur.

Cette approche permet d'ajuster la stratégie en fonction des conditions présentes et anticipées (par exemple, la présence d'un panneau d'arrêt), afin d'assurer une récupération maximale d'énergie sans compromettre le confort du conducteur.

Des tests expérimentaux ont ensuite été effectués, simulant différents styles de conduite, pour comparer la stratégie de freinage adaptative (AEDPS) aux performances naturelles de régénération. Ces tests ont mis en évidence les avantages de l'approche en termes d'efficacité énergétique, de flexibilité et d'adaptabilité aux comportements individuels.

3.3 Résultats

Les résultats expérimentaux démontrent l'efficacité de la stratégie adaptative de freinage régénératif (AEDPS) développée dans cette étude. Les essais ont été réalisés sur trois conducteurs aux styles de conduite distincts, chacun présentant des préférences de vitesse maximale différentes, afin de mesurer la capacité du système à s'adapter aux variations de comportement, aux performances naturelles de régénération et aux caractéristiques de la route.

Dans un premier temps, une évaluation des performances des modèles prédictifs (NARX et LSTM) pour la prévision à long terme de la puissance régénérée a montré

des résultats comparables en termes de précision. Toutefois, le modèle NARX s'est distingué par sa rapidité d'exécution, offrant un temps de calcul significativement réduit tout en maintenant un RMSE similaire. Cette efficacité accrue rend le modèle NARX particulièrement adapté aux applications en temps réel, permettant d'anticiper rapidement les variations du comportement du conducteur et d'ajuster le profil de décélération en conséquence.

Les résultats expérimentaux confirment que le système AEDPS ajuste dynamiquement l'horizon de planification de la décélération (long, moyen, court) en fonction du potentiel de régénération et des préférences de conduite. Le système identifie précisément les moments optimaux pour récupérer l'énergie, tout en minimisant les interruptions inutiles des systèmes avancés d'assistance à la conduite (ADAS).

Les tests sur routes en pente descendante ont démontré que le système atteint les limites maximales de régénération physique du moteur, tandis que sur des routes plates, l'optimisation est maximale mais reste légèrement inférieure à la capacité théorique du moteur, reflétant ainsi une adaptation efficace aux contraintes physiques du terrain. En comparaison avec les stratégies conventionnelles, l'AEDPS offre une adaptabilité et une efficacité énergétique supérieures.

Les gains de récupération d'énergie observés sont significatifs : 39,6 % pour le conducteur 1, 16 % pour le conducteur 2 et 26 % pour le conducteur 3. Les analyses basées sur la distribution de probabilité vitesse-accélération (SPAD) révèlent que, dans des conditions de conduite naturelle, la phase de croisière est fortement concentrée autour des vitesses maximales des conducteurs (75 km/h pour le conducteur 3, 60 km/h pour le conducteur 1, et 50 km/h pour le conducteur 2). Lors de l'application de la stratégie AEDPS, la répartition des phases de croisière et de décélération s'étale sur une gamme

plus large de vitesses, favorisant une meilleure répartition de la charge de régénération et une récupération d'énergie optimisée.

3.4 Conclusion

La conclusion de cet article met en avant l'efficacité de la stratégie adaptative de freinage régénératif (AEDPS) pour les véhicules électriques intelligents. En combinant une prédiction à long terme des performances de régénération naturelle basée sur les modèles NARX et LSTM avec une optimisation dynamique du profil de décélération, l'approche permet d'anticiper les comportements de conduite et d'ajuster les alertes des systèmes ADAS en fonction des préférences et des performances de régénérations naturelles individuelles, ainsi que des conditions de conduite.

L'intégration de quatre horizons de planification; long, moyen, court et optimal, permet de maximiser la récupération d'énergie sans compromettre le confort du conducteur. Les résultats expérimentaux démontrent une amélioration significative de l'efficacité énergétique, avec des gains de 39,6 %, 16 % et 26 % pour les trois conducteurs testés. La rapidité du modèle NARX et l'adaptabilité du système face aux variations des conditions routières (notamment sur les pentes descendantes) renforcent la pertinence de cette approche.

En conclusion, l'AEDPS représente une avancée significative dans l'optimisation des systèmes de freinage régénératif pour les véhicules électriques. Cette stratégie, flexible et personnalisée, ouvre la voie à des systèmes de conduite plus intelligents et durables, avec des perspectives prometteuses pour des applications futures dans des environnements urbains complexes ou pour des flottes de véhicules électriques.

Received 5 August 2023, accepted 1 September 2023, date of publication 8 September 2023, date of current version 18 September 2023.

Digital Object Identifier 10.1109/ACCESS.2023.3313553

RESEARCH ARTICLE

An Adaptive Regenerative Braking Strategy Design Based on Naturalistic Regeneration Performance for Intelligent Vehicles

MARWA ZIADIA¹, SOUSSO KELOUWANI², (Senior Member, IEEE),
ALI AMAMOU², (Member, IEEE), AND KODJO AGBOSSOU², (Senior Member, IEEE)

¹ Department of Mechanical Engineering, Hydrogen Research Institute, Université du Québec à Trois-Rivières, Trois-Rivières, QC G8Z 4M3, Canada

² Department of Electrical and Computer Engineering, Hydrogen Research Institute, Université du Québec à Trois-Rivières, Trois-Rivières, QC G8Z 4M3, Canada

Corresponding author: Marwa Ziadia (marwa.ziadia@uqtr.ca)

This work was supported in part by the Foundation of Université du Québec à Trois-Rivières, Canada Research Chair Program; and in part by the Natural Sciences and Engineering Research Council of Canada.

ABSTRACT The effectiveness of regenerative braking strategies plays an important role in extending the driving range of electric vehicles. Since the driver is still an essential factor in levels 3 and 4 of intelligent electric vehicles, improving user acceptance and adoption of the braking control strategy is crucial. This paper puts forward a new regenerative braking strategy to find a compromise between optimal braking control performance and naturalistic regeneration performance while satisfying the maximum speed preference when driving between two-stop events. Unlike other similar works that only maximize regenerative braking energy while satisfying the physical limits of an electrified powertrain, this paper considers naturalistic regeneration performance. To achieve this, firstly, the power regenerated by three drivers is predicted with a long-horizon (30 seconds), using long-short-term memory networks (LSTM) and non-linear autoregressive exogenous model (NARX). Subsequently, an estimation of the energy recovery maximization rate is performed to give a perception of the naturalistic regeneration performance. As this performance varies, the deceleration planning employs three horizon scales of long, medium, and short, determined by the energy recovery maximization rate. Finally, dynamic programming (DP) is utilized to optimize a deceleration profile. The study utilizes real data of inverter efficiency, transmission efficiency, and motor-to-battery efficiency map. The outcome of this study shows that the proposed regeneration braking strategy is adaptive, improving regeneration efficiency by 39,6% for driver 1, 16% for driver 2, and 26% for driver 3, and forecasting the optimality of some deceleration behaviors.

INDEX TERMS Eco-driving, acceptance, driving behaviors, regenerative braking, intelligent vehicles, machine learning, optimal control.

I. INTRODUCTION

Transport is the second greatest energy user and emitter of carbon dioxide. Pure electric vehicles provide a solution to this environmental challenge, despite their limited driving range and long recharging time [1], [2]. As city populations and densities rise, traffic congestion, and the risk of accidents increase as well. In response to these challenges, academia and businesses have redoubled their efforts to

develop and perfect autonomous electric vehicles (AEVs) [3], [4]. AEVs are considered a crucial requirement for greener, safer, and more efficient urban transportation [5]. Smart decision-making in AEVs allows them to maximize profits and minimize energy consumption by wisely managing and trading among available energy sources [6].

The eco-driving system includes diverse strategies that optimize the driving velocity profile to significantly reduce energy consumption [7]. Studies examining navigational data, high-precision map data, and energy consumption data have shown that combining eco-driving technology with

The associate editor coordinating the review of this manuscript and approving it for publication was Jie Gao¹.

connected and automated vehicles (CAVs) can have a significant impact on energy consumption. Adequate speed controls can be achieved by utilizing background information such as speed limits, safe speeds for curved roads, and an estimate of the average traffic speed. The speed planning problem can be formulated as an optimal control problem with the objective of reducing energy consumption while considering the constraints imposed by the mapping information [8]. However, real-time deployment of such systems is inhibited by algorithmic limitations resulting from factors like unexpected nearby car maneuvers, inevitable traffic congestion, intermittent data connectivity, and so forth. Moreover, global optimization search algorithms, including model dynamic programming (DP) and Pontryagin's minimum principle (PMP), require high computational costs that are not currently provided by existing vehicle computing units [7], [9], [10], [11]. Due to unforeseen circumstances, optimal solutions calculated over the whole path may be invalid or reduce the real-time powertrain's energy efficiency [12]. Even though the G7 nations have decided to eliminate the legal barriers impeding the development of autonomous cars, these vehicles are still far from being widely accepted in society. Golbabaei et al. [13] have demonstrated significant differences in public perceptions and adoption intentions among various sociodemographic subgroups. Researchers have also shown that travelers are more likely to ride entirely in autonomous vehicles (AVs) under monotonous driving conditions, such as highways, than in urban conditions. In contrast, most consumers are willing to acquire AEVs equipped with a level 2 or 3 advanced driver-assistance system (ADAS), despite the fact that such vehicles are not fully autonomous and charging facilities are insufficient, particularly at the end of 2022 with the inflation of fuel costs [10], [11]. These levels of automation have the same potential for improving energy efficiency as level 5 ADAS due to the same perception sensors.

Given the aforementioned considerations, improving the performance of level 2 or level 3 autonomous driving systems in real-time operation is crucial, as this can help extend the autonomy of electric vehicles. Researchers have developed various eco-driving strategies that can be categorized in terms of their application to specific environments, such as eco-cruising on highways and eco-approach at signalized intersections [14], [15]. Through the analysis of the junction's signal phase and timing (SPaT), the vehicle's data, and the traffic flow, the eco-Approach and Departure (EAD) program determines the most energy saving way to pass through the intersection [16]. Furthermore, researchers have mostly focused on improving eco-driving performance in real-time by concentrating on more restricted driving scenarios, such as regenerative brake control, acceleration and deceleration (vehicle tracking), and speed restriction based on traffic signs. Han et al. [17] have developed an optimal control problem for acceleration or deceleration while satisfying safety constraints, minimum inter-vehicle distance, and maximum

speed limit, considering the presence of vehicles in front. Yang et al. [18] have specifically developed a vehicle queuing process at signaled intersections using the shock wave profile model to create a green window for planning eco-course vehicles in a congested environment. Zhao et al. [19] have presented a predictive model using the receding horizon to reduce platoon fuel consumption and pass the junction on a green phase. The authors claim that the proposed model achieves eco-driving without considering the optimal regeneration performance. Energy recovery using power from regenerative braking is one of the most common strategies to improve fuel economy for electric vehicles (EVs) [20], [21]. This energy recovery process involves converting the kinetic and potential energies to electric power using the traction motor as a generator [22], [23]. Apart from the importance of considering the optimal speed profile to minimize energy consumption, it is also essential to improve energy recovery performance [24]. Extensive studies have focused on the regenerative torque distribution (RTD) strategy to maximize the braking energy recovery without compromising braking performance, safety, and driveability [20], [25], [26]. Owing to the energy efficiency-centric design of HEVs and EVs, comfort is among the most important criteria. However, powertrain, drivetrain, and comfort optimization are mostly related to the vehicle manufacturer's design, with little control given to the driver when considering the comfort settings. The vehicle motion profile is one factor that affects comfort (i.e., acceleration, deceleration) [27]. Therefore, acceleration and braking actions need to be constrained to provide a comfortable driving experience.

In light of recent studies, the performance of a regenerative system, acceleration, and deceleration is impacted by several factors, such as the variation of operation conditions, road topology, traffic volume, weather conditions, and driving behaviors. In such circumstances, many researchers have focused on anticipating future events to minimize irreversible driving errors under varying road conditions [28], [29]. In [30], a model predictive control (MPC) is designed using the acceleration prediction of the car in front by NARX model. Given this information, the MPC optimizes both speed tracking and energy recovery rate for the new method of adaptive cruise control. In [31], an MPC-based tire dynamics and vehicle load control method is proposed to increase the regeneration efficiency of electric machines and reduce tire slip loss. In [32], Q-learning algorithms create optimal speed profiles while stopped at red lights by considering all relevant real-time parameters via vehicle-to-infrastructure (V2I) communication. Better results are achieved by experimental verification of the predicted speed profiles that determine the braking actions of vehicles in response to varying road conditions. In [33], a hybrid method termed as Layer Hidden Markov Model-Dynamic Compensatory Fuzzy Neural Network is used to recognize the driver's braking intention with the goal of improving braking sense and increasing the amount of energy that can be recovered. In [34], personalized

and green adaptive cruise control for intelligent electric vehicles is presented to improve regenerative braking and ADAS comfort. It is optimized via nonlinear MPC theory and uses the Hammerstein model with key parameters that vary according to driving style. Therefore, several improvements in regeneration systems have been proven in the literature by anticipation of future events and driving styles, but the relation of driving style, regeneration performance, and acceptability of ADAS has not been explored sufficiently [35]. From a technical perspective, efficient driving with EVs mainly depends on anticipatory braking conditions, and the EVs engine operates optimally at a higher speed. Therefore, coasting as much as possible is relevant to optimize energy recovery. Also, the anticipation of the braking phase during the vehicle movement has several benefits as the vehicle moves. It makes it possible to prepare the recovery mechanism to recover the maximum kinetic energy.

Since regenerative braking only works with technically limited efficiency, the amount of kinetic energy that will be converted back to electricity and stored in the battery is mainly dependent on the driving style [36], [37], [38], the physical limitations of motor generation, and the deceleration limitations of regenerative braking. Some works in the literature regarding the maximization of regeneration respect the motor's physical limit [39]. In [40], real driving test data characterizing the physical limits of regenerative braking are used to propose an energy-optimal deceleration planning system and improve energy-recuperation efficiency gains. Such strategies are employed in formulating ADAS, mainly used by autonomous vehicles of level 5. However, they cannot be very effective when integrated into autonomous vehicle level 3 or 4, where the driver is an essential factor, and driver acceptance of braking control strategies presents a challenge in the literature [41]. In reality, when approaches do not consider individual naturalistic regeneration performance in the brake control optimization model, it can sometimes lead to painful and circumvent excessive and bothersome alerts, which often lead drivers to disengage the system, thereby directly impacting its efficiency [42]. This performance is evaluated by the capability to energy regenerate up to the engine's regeneration limit while respecting maximum speed preferences [43]. To manage standard control strategies, an adaptive method will be extremely important [44], [45]. Thus, this paper has two major contributions: (i) This research predicts the power regenerated by drivers over a long horizon (30 seconds), utilizing LSTM and NARX models. These models effectively predict the performance of naturalistic regeneration and estimate whether the deceleration behavior within this context is optimal or requires assistance. (ii) Adding the forecasting of driver naturalistic regeneration performance to regenerative braking strategy design is the main contribution of this work. Recognizing the variable nature of this performance, our proposed braking strategy maximizes regenerative energy to the physical limits of an electrified powertrain by adapting the deceleration planning horizon to the driver's naturalistic regenerative performance. This adaptive regenerative braking




FIGURE 1. The vehicle braking model [46].

strategy is very useful within the context of eco-friendly braking assistance. Contrary to most of the existing papers in the literature, which are based on simulation, the results obtained of this work have been validated with real data of inverter efficiency, transmission efficiency, and motor-to-battery efficiency map of Kia Soul 2017.

The rest of this article is organized as follows. Section II describes the electric vehicle model that was used to compute deceleration distance and power regeneration. Section III explains the proposed braking control strategy adaptation algorithm. The experimental results are reported and discussed in section IV. Finally, the conclusion is given in section V.

II. ELECTRIC VEHICLE MODEL TO CALCULATE DECELERATION DURATION AND POWER REGENERATION

A. VEHICLE DYNAMICS MODEL

Regenerative braking controllers require a vehicle dynamics model. Since the electric vehicle's braking performance is the focus of this paper's attention, the vehicle dynamics model is simplified to longitudinal motion, assuming straight braking and no steering effect. The vehicle dynamics model, including longitudinal and rotational wheel movement illustrated in Fig. 1, can be described as follows:

$$\begin{aligned} M\dot{v}(t) &= F_{xf}(t) + F_{xr}(t) + F_{Load}(t) \\ F_{Load}(t) &= F_{Load,\alpha}(t) + F_{Load,\beta}(t) \\ F_{Brk}(t) &= -F_{xf}(t) - F_{xr}(t) \end{aligned} \quad (1)$$

where $F_{Load,\alpha}$ and $F_{Load,\beta}$ are defined as:

$$\begin{cases} F_{Load,\alpha}(v, \theta) = C_0 \cos(\theta(X(t))) + C_1 v(t) + C_2 v^2(t) \\ F_{Load,\beta}(\theta) = Mg \sin(\theta(X(t))) \end{cases} \quad (2)$$

M is the total mass of the vehicle, v is the longitudinal vehicle velocity, θ is the road slope, F_{xf} and F_{xr} are respectively the longitudinal tire-road friction forces at the front and rear tires. C_0 and C_1 are rolling resistance coefficients, C_2 is

an aerodynamic coefficient, and $X(t)$ represents the location in the time domain. Numerical values of these coefficients are obtained from real driving tests on normal road surface conditions.

The tire-road friction force is calculated as follows:

$$F_{xj}(t) = \mu_j(\kappa) F_{zj}(t) \quad (3)$$

where F_{zj} represents the normal load on tires, and μ_j is the tire-road friction coefficient as a function of the slip ratio. Pacejka [47] developed a model to express the tire-road friction coefficient as a non-linear function of the slip ratio, as follows:

$$\mu_j(\kappa) = D_x \sin \left\{ C_x \arctan \left[B_x \kappa_j - E_x (B_x \kappa_j - \arctan(B_x \kappa_j)) \right] \right\} \quad (4)$$

where B_x , C_x , D_x , E_x are the stiffness, shape, peak, and curvature factor, respectively. The longitudinal slip ratio κ_j , which defines the difference in longitudinal velocity between the wheel axle and tires rotational velocity, is derived as follows:

$$\kappa_j = \frac{\omega_{wj} R_e - v(t)}{v(t)} \quad (5)$$

where R_e is the effective rolling radius of the tires, and ω_{wj} is the rotary velocity of front and rear wheels. According to this, the normal load on front and rear tires is dependent on the longitudinal deceleration (a_x).

$$\begin{aligned} F_{zf} &= \frac{M(l_r g - h a_x(t))}{l_f + l_r} \\ F_{zr} &= \frac{M(l_f g + h a_x(t))}{l_f + l_r} \end{aligned} \quad (6)$$

where l_f and l_r are the longitudinal distances from the center of gravity to the front and rear tires, g is the acceleration due to gravity, and h is the distance from the center of gravity to the vehicle's ground.

B. VEHICLE DECELERATION DURATION

The speed profile is a temporal and spatial process, which makes $v(X(t))$ represent the speed profile at a specific observation station (i.e., location) at time t . Given a sequence of speeds at $X_i(t)$ values, the speed profile to arrive at $X_i(t + \Delta(t))$ can be accurately estimated after a time interval $\Delta(t)$. Furthermore, the speed profile and deceleration duration can be described as follows:

$$v_{i+1}(t) = v_i(t) + \frac{F_{xf}(t) + F_{xr}(t) + F_{L\text{Load}}(t)}{m} \Delta t_i \quad (7)$$

$$v_{i+1}^2 = v_i^2 + \frac{2\Delta X_i}{m} (F_{xf} + F_{xr} + F_{L\text{Load}}(v_i^2, \theta_i)) \quad (8)$$

$$v_{i+1} = \sqrt{\frac{2\Delta X_i}{m} (F_{xf} + F_{xr} + F_{L\text{Load}}) + v_i^2} \quad (9)$$

$$t_{i+1} = t_i + \frac{\Delta X_i}{v_i} \quad (10)$$

$$t_N = \sum_{i=0}^{N-1} \frac{\Delta X_i}{v_i} \quad (11)$$

where $F_{L\text{Load}}(v_i^2, \theta_i)$ is affine in v_i^2 , and t_N is the duration deceleration. In this case, we use the formula $v_i = v(t_i) = v(X(t_i)) = v(X_i)$, which is also used for other dependent variables.

C. MOTOR AND BATTERY MODELS

According to Xu et al. [46], the output torque of electric motors is amplified and exerted on the wheels through the reduction gear. Therefore, the rotational velocity of four small high-power in-wheel motors is decreased. The governing equations can be expressed as:

$$\begin{aligned} T_w &= g_0 T_m \\ \omega_w &= \frac{1}{g_0} \cdot \omega_m \end{aligned} \quad (12)$$

where T_w is the braking torque on the wheels, T_m is the actual motor torque, ω_w is the rotational velocity of the wheels, ω_m is the rotational velocity of the motors, and g_0 is the transmission ratio of the reduction gear.

The simplification of the braking torque on the wheels (T_w) can be expressed as a first-order reaction model with a small-time constant τ :

$$T_w = g_0 \cdot \frac{1}{\tau s + 1} \cdot T_{m, \text{ref}} \quad (13)$$

where $T_{m, \text{ref}}$ is the reference motor torque. The motor-to-battery regenerative braking efficiency η depends on the braking torque and rotational velocity of the in-wheel motors:

$$\eta = \eta(T_m, \omega_m) = \frac{U_c I_c}{T_m \omega_m} \quad (14)$$

where U_c and I_c are respectively the battery charging voltage and current of one in-wheel motor.

The battery provides the requested power for the in-wheel motors. The average battery model consists of an open-circuit voltage and an internal resistance, which are a function of the state of charge (SOC) and the temperature. The battery regenerative power P_r is given by:

$$\begin{aligned} P_r &= U_b I_b \\ P_r &= T_b \omega_b \end{aligned} \quad (15)$$

where U_b is the terminal voltage and I_b is the current of the battery. Battery SOC measures the effective discharge rate, which is estimated by the coulomb counting:

$$SOC^t = SOC^0 - \frac{100}{C_n} \times \int_0^t I \left(\frac{I}{I_n} \right)^{pc-1} dt \quad (16)$$

where C_n is the nominal capacity measured at nominal current (I_n) predefined by the manufacturer. SOC^t represents the SoC value at time t . and pc is Peukert's constant typically measured empirically for the type of lithium-ion battery cell.

D. GENERALIZED ENERGY RECUPERATION MODEL

The regenerative deceleration force of an electric vehicle is limited by the electric motor's regenerating capacity. Additionally, the regenerative braking force depends on the electric vehicle's motor configuration. The regenerative-braking force can be limited as follows:

$$F_{RQn} = \max(F_{Brk}, F_{Lmt}) \quad (17)$$

where the limit of powertrain's regeneration force (including the traction motor and gearbox) is given by:

$$F_{Lmt}(v) = \frac{1}{r_w} T_{Lmt}(v) g_i(v) g_f \quad (18)$$

where T_{Lmt} is the torque limits of the electric motor in regenerator-mode, r_w is the dynamic wheel radius, $g_i(v)$ is the gearbox ratio determined by the gear-shift controller based on the current longitudinal vehicle speed v . T_{Lmt} can be obtained by performing a quasi-steady-state, equivalent to the following mathematical expression:

$$T_{Lmt}(v) = f(\omega_{Mot}(v)) \quad (19)$$

where T_{Lmt} is the motor rotation speed in RPM.

III. ADAPTIVE ENERGY DECELERATION PLANNING SYSTEM DESIGN

The proposed strategy in this paper is called Adaptive Energy Deceleration Planning System (AEDPS). AEDPS aims to optimize and adapt deceleration planning by considering two crucial factors: the individual's naturalistic regeneration performance and the driver's maximum speed preferences. Fig. 2 illustrates the general structure of AEDPS, which comprises three essential components: long-horizon forecasting of power specific to each driving behavior, determination of the energy recovery maximization rate, and adaptive optimal deceleration planning. AEDPS requires power forecasts for a relatively long horizon of 30 seconds since determining the high energy recovery maximization rate in advance is necessary for deceleration planning with a long horizon. To account for the two effects mentioned above, the strategy estimates the amount of energy that can be maximized and determines the most appropriate deceleration planning horizon during the optimization phase of the deceleration profile. It utilizes three horizon scales: long, medium, and short. The long horizon is used to develop long-term deceleration profiles and improves regeneration for a high energy recovery maximization rate. Medium and short horizons are utilized for moderate and minimal energy recovery maximization rates, respectively. In the case of optimal naturalistic deceleration behaviors, the strategy disables the control warning from ADAS to the drivers. The development of each component is described in detail below.

A. ANALYSIS AND PREDICTION OF POWER

In this section, the experimental setup, fixed-route driving for data collection, and data preprocessing are explained. The last subsection introduces the two-time series prediction models

TABLE 1. Key parameters of the electric vehicle.

Parameter Name	Symbol	Value
Vehicle mass	M	1490 kg
Height of vehicle c.g.	h	0.25 m
Distance from c.g. to front axle	l_f	1.2 m
Distance from c.g. to rear axle	l_r	1.4 m
Effective radius of the tire	R_e	0.31 m
Reducer ratio	g_0	8.2
Battery voltage	V_{bat}	360 V
Battery capacity	Bat_{cap}	75 Ah
Max. speed	V_{MA}	145 km/h
Drag coefficient	C_d	0.35
Rolling resistance of dry road	μ	0.012
Air Density	ρ	0.80795 kg/m ³
Gravitational acceleration	g	9.8 m/s ²
Vehicle deceleration rate	a_x	0.3 m/s ²

used in this strategy and the correlation analysis between power consumption and driving behaviors.

1) EXPERIMENTAL SETUP FOR DATA COLLECTION

An instrumented 2017 Kia Soul intelligent electric vehicle (EV) was utilized for the collection of naturalistic driving data, in-vehicle information, and environmental factors. The vehicle's parameters are summarized in Table 1. As depicted in Fig. 3, the onboard measurement system comprises the global positioning system (GPS), the onboard diagnostic system (OBD), and the ADAS system installed in the experimental vehicle. The GPS system, Septentrio (AsteRx-i3 D Pro+), mounted in the vehicle's trunk, was chosen for its good real-time accuracy, which is ideal for calculating vehicle position and road parameters. This high level of accuracy is achieved using the Real-time Kinematic (RTK) approach, which enhances the Global Navigation Satellite System (GNSS) accuracy and utilizes an RTCM correction stream. Furthermore, AsteRx-i3 D Pro+ integrated GNSS-IMU system with a dual antenna, multi-frequency GNSS receiver, and a Vectornav VN-100 micro-electromechanical system (MEMS) IMU was used to get the ground truth [48]. Specifically, the GNSS receiver uses a Kalman filter algorithm to merge IMU and GNSS data for precise location and reliable GNSS/INS positioning and 3D orientation. Fig. 3 shows the OBDlinkMx and Mobileye systems connected to the OBD2 ports for CAN-Bus communication. The OBDlinkMx operates via Bluetooth on PCs and is responsible for collecting vehicle parameters such as brake and acceleration pedal states, motor torque, etc. The Mobileye system, securely mounted and calibrated at the center of the windshield, operates using an intelligent digital camera powered by the EyeQ chip. This advanced system provides high-performance, real-time image processing capabilities, enabling the detection of vehicles, lanes, pedestrians, and traffic signs, including stop signs. It also efficiently calculates the dynamic distance between the vehicle and other road objects. Furthermore, Mobileye can recognize obstacles at a longitudinal distance of up to 250 m from the reference point.




FIGURE 2. AEDPS Design.




FIGURE 3. Instrumented intelligent electric vehicle (Kia Soul 2017).

2) FIXED-ROUTE NATURALISTIC DRIVING DATA COLLECTION

This study employs the fixed route that is applicable to vehicles in which the driver takes the same route to work or

commercial vehicles, such as city buses and garbage trucks, that mostly commute on the same routes at the same time. The selection of fixed routes in this study is used to improve the forecasting of variation in driving behaviors on-road characteristics. Naturalistic driving data are collected on the same route (Trois-Rivières, Quebec) to study the deceleration and braking patterns in a real traffic environment. The database has been checked under the following conditions:

- There were no surrounding vehicles, traffic lights, and dynamic obstacles.
- The braking events are initiated by static obstacles, such as stop signs and static objects detected by Mobileye.
- The route has covered a total distance of 4 km.
- The selection of the road has been made mainly because of the substantial amount of stop panels (12 stop signs).

The experiment session began once a participant was confident about driving the test vehicle safely. Multiple drivers performed the experiments, and an assistant in the vehicle gave the participants route guidance instructions

to synchronize the start of data collection from all the instruments.

3) JOINT FEATURE LEARNING AND TIME SERIES MODELING

Using the developed EVs dynamic model, a dataset with known inputs and outputs can be obtained which opens up an opportunity for using supervised machine learning to develop an inferred function. In this regard, two recurrent neural networks (RNN)-based methods, namely LSTM and NARX, are used herein to long-horizon forecast the power of the EVs under study. The recurrent structure of the mentioned methods allows them to exhibit the temporal dynamic behavior caused by the driving conditions of the EVs. NARX has already been used successfully to predict time series in different applications [49]. It can forecast a time series future value based on its current and past values as well as another time series' past and current values, known as an external or exogenous time series. NARX can model and rapidly converge to time-sequential vehicle states. However, it suffers from long-term dependence and does not detect information in sequential data. This limitation is due to its vulnerability to the vanishing gradient problem. Hochreiter and Schmidhuber developed the LSTM to address the mentioned shortcomings. LSTM has three gates, an input gate, an output gate, and a forget gate, which can improve its performance in long-term learning tasks [38], [50], [51]. This option is considered critical because this network is prone to overfitting. The vulnerability of LSTM is the need for significant memory. Another drawback is that it necessitates more computing power than the NARX network. A comparison of the two methods will be presented in this study to identify the best neural network for predicting braking power.

Datasets with a high number of variables are frequently challenging to summarize or analyze. To address this, Principal Component Analysis (PCA) was performed to reduce the dimensionality of the dataset used in the forecasting model. The correlations between the principal components and the original variables are presented in Table 2. It can be seen that there is no correlation between the principal components themselves. The first principal component is highly correlated with six variables of the original ones. The first principal component increases with increasing Battery Current, Battery Voltage, Battery Power, Motor Torque, and lightly with distance to stop and Speed scores, suggesting that these six criteria vary together. If one increases, then the remaining ones tend to increase as well. Furthermore, the first principal component correlates strongly with the battery variables. The second principal component increases with the rotational speed and its equivalent speed. However, the second main component correlates strongly with the road characteristics provided by the GPS. The outcome of this process indicates that the followings features are discriminative: the speed χ_1 , the distance to the next stop panel χ_2 , the Motor Torque χ_4 , the Latitude χ_5 , the Altitude χ_6 and the Rotational Speed χ_7 . The Battery Power signal is used as the output ($y(1)$).

TABLE 2. Extracted vectors.

Data	Coefficients of PC1	Coefficients of PC2
Speed	0,23125	0,32684
Distance to Stop	0,32548	,19156
Longitude	0,07202	-0,56701
Latitude	0,06528	0,29689
Altitude	-0,09792	0,54841
Battery Current	0,45743	0,01558
Battery Voltage	-0,4649	-0,02672
Battery Power	0,45818	0,01615
Rotational Speed	0,17716	0,33945
Motor Torque	0,39247	-0,07497
Acceleration	-0,02749	-0,15498

The prediction results are evaluated using two different accuracy measures: the root-mean-square-error (RMSE) and the computational time. RMSE is a regularly used index to quantify model regression performance, with scale-dependent measurement and evaluation for sequence prediction. Additionally, the model should not produce computationally expensive results. This is why it is equally critical to assess training time. The root mean squared error RMSE is defined as:

$$\text{RMSE} = \left\{ \frac{1}{N} \sum_{t=1}^N (\hat{y}_t - y_t)^2 \right\}^{1/2} \quad (20)$$

where $\hat{y}_t$ and y_t present predicted and actual battery power of vehicles usages for N discrete time samples. A comparison of the prediction performances of LSTM and NARX is performed in order to adopt the most efficient prediction method in terms of accuracy and computation time in the proposed strategy.

The grid-search approach is used to identify the best hyperparameters. For the LSTM model, the different ranges of hyperparameters to be optimized are as follows: epochs are set between 10 and 100, the learning rate is set as [0.5, 0.1, 0.01, 0.001, and 0.0001], and the number of hidden layer is set between 1 and 400. For the NARX model, the hyperparameter ranges for input delay, feedback delay, hidden layer size, and training function are set as [2, 5 and 20], [2, 5 and 10], between 1 and 133, and ["trainlm", "trainbr", "traind"].

B. DETERMINATION OF ENERGY RECOVERY MAXIMIZATION RATE

As previously mentioned, the power during braking varies from one driver to another because the regeneration limit is affected by the driver's acceleration behavior. A very low acceleration leads to the rotational speed being in the region of low-speed power dissipation, as presented in Fig. 2. Therefore, the strategy plans for long-term deceleration and the trigger of Freewheel mode. To determine The limits of torque and force in the wheel, a precise estimation of power flow parameters has been suggested in this work. The Power flow parameters, η_{Ba} , η_{Mi} , η_{Tr} , represent the battery efficiency during the charging or discharging, the traction inverter efficiency, and the driveline efficiency, respectively.




FIGURE 4. Efficiency curves for inverter electrical device and efficiency factor of PMSM Kia soul.




FIGURE 5. The efficiency factor of PMSM Kia soul.

The parameters of the power flow of the EV Kia Soul 2017 are studied in [52]. The reported analysis results are shown in Fig.4, demonstrating that the inverter has a maximum efficiency of 99% at low speed and a minimum efficiency of 94% at high speed. The gearbox of the Kia Soul is constant and equal to 8.206. The power regenerated in the wheel can be expressed by:

$$P_{w-pred} = \eta_{Ba} \cdot \eta_{Mi} \cdot \eta_{Tr} \cdot P_{b-pred} \quad (21)$$

Since ω_b is predicted, and by applying the formulas expressed in (12),(13),(14) and (18), ω_{w-pred} can be determined. Moreover, T_w is obtained using motor-battery efficiency map of Kia soul shown in Fig.5. Accordingly, the in-wheel force limit F_{lmt} and the force regenerated by the driver $F_{rgn-pred}$ can be predicted and compared. The difference between these two parameters is used to update the horizon of the deceleration planning, as discussed in the subsequent section. Fig.6 demonstrates the driver's naturalistic behavior speed profile and the deceleration profile optimized by the proposed AEDPS. In the case of naturalistic driving maneuvers, ΔF_{nat} , which is the force difference between the motor force in traction $F_{Rgn/nat}$ and the powertrain regeneration force limit $F_{Lmt/nat}$ at a specific rotational speed ω_{nat} , defines the regeneration performance of the hlpowertrain. It should be noted that ΔF_{nat} depends on the driving style and route segment features. The maximum regeneration $F_{Rgn/max}$ and the maximum regeneration limit $F_{Lmt/max}$ for each driver's behavior are closely related to the maximum rotational speed in acceleration mode ω_{max} . $F_{Rgn/max}$ is equivalent to the optimal regenerative force that the AEDPS strategy achieves. Assumption: The Strategy assumes that $F_{Rgn/max}$ is equal to $F_{Rgn/Lmt}$ in the second step of the strategy.

The comparison between $F_{Rgn/max}$ and $F_{Rgn/nat}$ allows predicting the maximum regeneration efficiency and




FIGURE 6. AEDPS parameters.

determining the energy recovery maximization rate expressed by $\Delta F = F_{Rgn/max} - F_{Rgn/nat}$. Depending on the resulting value of ΔF , AEDPS chooses the deceleration planning horizon when ΔF is not zero. Otherwise (if it is zero), the driver's behavior is considered optimal.

C. ADAPTATIVE OPTIMAL DECELERATION PLANNING

As previously mentioned, the ΔF determined by the forecasting model varies widely, as energy recovery is affected by the vehicle operating environment and the driving style. To promote energy regeneration, increasing the deceleration distance is essential, but it is limited by ΔF . Therefore, the optimization strategy consists of three different deceleration planning horizons; long, medium, and short. Each horizon is associated with a range of ΔF . The allocation of the deceleration horizon is done as follows:

Optimal: $0 \text{ N} \leq \Delta F \leq 100 \text{ N}$

Short: $100 \text{ N} < \Delta F \leq 500 \text{ N}$

Medium: $500 \text{ N} < \Delta F \leq 1000 \text{ N}$

Long: $\Delta F > 1000 \text{ N}$

As shown in Fig.2, the horizon is defined based on ΔF , and the choice of the planning horizon as input in the optimization helps to make the regenerative braking strategy adaptive. AEDPS optimizes the energy recovery performance of the powertrains by determining the optimal regeneration force that minimizes ΔF . In general, acceleration is determined by the driver, and deceleration is performed automatically by AEDPS based on the principle of an adapted optimal deceleration profile. Fig. 7 shows an example of AEDPS optimized deceleration profile at different horizons. The distance between ω_{max} and ω_{nat} is calculated and labeled as D_{diff} . The long horizon adds all the distance D_{diff} to the naturalistic deceleration distance. The Medium horizon adds $\frac{2}{3}$ of D_{diff} to the naturalistic deceleration distance. The short horizon adds $\frac{1}{3}$ of D_{diff} to the naturalistic deceleration distance. The deceleration profile is constrained between the driving speed and the final speed at the stop position. The speed constraints in (2) must be dynamically updated to find




FIGURE 7. Illustrating AEDPS optimized deceleration profile at different horizons.

a set of practically feasible speed candidates at a computation node, considering the deceleration induced by the road load force, the smooth deceleration for driving preference, and the remaining deceleration distance. For different driving environments and situations, the speed constraints change as the road load forces change. To achieve speed planning that maximizes energy recuperation, an optimization problem using DP has been formulated.

1) ENERGY OPTIMIZATION BY DYNAMIC PROGRAMMING

In the proposed strategy, the dynamic programming method is employed to optimize the deceleration profile. The DP method incorporates the environmental conditions of EVs operation, including the slope and deceleration ranges of a real vehicle. Assume the deceleration started at vehicle position X_k and finished at position X_N . For any position X_i ($k \leq i \leq N$), given the speed at the road grade (or slope), θ_i is known. Assume that at X_i , the vehicle longitudinal speed and acceleration are v_i, a_i . The energy E_N during the entire vehicle deceleration from X_k to X_N is given by:

$$E_N = E_k + \sum_{i=k+1}^N F_{Rgn}(v_i, a_i, \theta_i) \Delta X \quad (22)$$

where E_k is the vehicle kinetic energy at X_k ; $F_{Rgn}(v_i, a_i, \theta_i)$ represents the regenerative force profile from X_k to X_N . $\Delta X = X_{i+1} - X_i$. The optimization problem can be formulated as follows:

Given X_k and X_N , find the sequence of a_i so that E_N is minimized and the following constraints:

$$F_{Rgn}(v_i, a_i, \theta_i) = Ma_i + \frac{1}{2} \rho AC_v v_i^2 + Mg(\mu \cos(\theta_i) + \sin(\theta_i)) \quad (23)$$

$$a_{\min} \leq a_i \leq a_{\max} \quad (24)$$

So the optimal energy during the deceleration is:

$$E_N^* = \min_{a_i} \left[E_k + \sum_{i=k+1}^N F_{Rgn}(v_i, a_i, \theta_i) \Delta X \right] \quad (25)$$

Using DP, the optimal sequence $\{a^*\} = \{a_i, k+1 \leq i \leq N\}$ is given by:

$$\{a^*\} = \arg \min_{a_i} \left[E_k + \sum_{i=k+1}^N F_{Rgn}(v_i, a_i, \theta_i) \Delta X \right] \quad (26)$$

Knowing a^* , the optimal deceleration speed profile is given the integral of $\{a^*\}$.

IV. EXPERIMENTAL RESULTS, ANALYSIS AND COMPARATIVE STUDY

This section begins with the analysis and comparison of the results of the power prediction framework using NARX and LSTM models. Subsequently, the performance of the proposed AEDPS strategy is studied in detail. Three different driving behaviors are considered, and the drivers were given several stop conditions to gain a realistic perception of the performance of the proposed AEDPS.

A. VALIDATION AND RESULT OF TIME-SERIE MODEL

Both proposed prediction models, NARX and LSTM, undergo the same training process: 80% of the data is used for training and validation, while the remaining data is reserved for testing the model. Each driver's dataset consists of 3400 cases. Before training, validating, and testing, the data is normalized using the Matlab Min-Max method. Since the cross-validation technique removes the time-dependent nature of the data, it has not been included in any of the models.

The LSTM network is configured with 100 epochs, 300 hidden layers, and a learning rate of 0.001. This initial setup results in a reasonable computation time of 169 seconds and a satisfactory RMSE of 0.91 kW. To further improve prediction accuracy, an additional fully connected layer characterized by a drop-out layer with a percentage of 0.5 and an output size of 30 is integrated into the network. This refinement significantly enhances prediction accuracy, reducing the RMSE to 0.463 kW but increasing the computation time to 1865.4 seconds. To demonstrate the model's capacity to avoid overfitting, a comparison of test and validation RMSEs is performed. The test RMSE of 0.499 kW shows that the model is not overfitting, as it closely aligns with the validation set's RMSE, with only a slight difference of 0.02. An example of predicting regenerated power by the LSTM approach for a single braking scenario is shown in Fig. 8, indicating reasonable predictions even 30 seconds in advance. Furthermore, Fig. 8 displays how the LSTM approach fits the test data and closely tracks power variation in all segments. However, the LSTM approach has a significant drawback in terms of computational time, which is considerably high. In light of this, the data is re-evaluated using the NARX model due to its




FIGURE 8. Forecast results of 12 segments for the proposed NARX model.

lower computational power and faster training time. Through grid search hyperparameter optimization, the best NARX structure is identified with 75 hidden layers, 2 input delays, 2 feedback delays, and trainlm as the best training function. This configuration significantly reduces the computational time to 8.841 seconds, while achieving an optimal RMSE similar to LSTM, at 0.4402 kW. As a result of these findings, NARX seems to be a better choice for predicting efficiency in terms of computational time.

B. AEDPS POWERTRAIN'S REGENERATION PERFORMANCE ANALYSIS

To evaluate the effectiveness of AEDPS, which is based on adaptive deceleration planning, and to assess the resulting powertrain regeneration performance, the amount of energy regenerated for different deceleration horizons adapted to the driving style is analyzed. Three naturalistic driving behaviors with average maximum speeds of 54 km/h, 47 km/h, and 63 km/h under 5 stopping segments are chosen to represent the driver's maximum speed preferences and variable braking behaviors. The segments are selected to include combinations of downhill slopes, high downhill slopes, and flat downhill slopes, resulting in a total of 15 different scenarios as shown in Table 3. However, uphill slope sections are not studied in this article due to their limited potential for energy-maximizing regeneration. For each AEDPS driver model, the adapted horizon (long, medium, and short) is automatically integrated for each driving scenario, as explained in Fig. 7. The optimal regeneration force of AEDPS, $F_{Rgn/opt}$ is calculated using an electric vehicle model composed of maximized

TABLE 3. Summary of AEDPS predicted key parameters of the different driving styles.

Parameter/ Name	Driver/ Seg	1st	2ed	3rd	4th	5th
Slope	1/2/3	Downhill	Downhill	Flat	Downhill	Flat
$3^*\omega_{max}$ (Rpm)	1	-3975	-3693	-3900	-3510	-3769
	2	-3319	-3116	-3100	-3300	-3262
	3	-4783	-4613	-5000	-4569	-4585
3^*v_{max} (km/h)	1	59	55	59	54	56
	2	50	48	57	50	48
	3	72	65	76	68	68
$3^*T_{Lmt/max}$ (Nm)	1	-128	-114	-122	-110	-118
	2	-63.8	-60	-57	-63	-59
	3	-169	-160	-175	-158	-156
$3^*F_{Lmt/max}$ (N)	1	-3498	-3116	-3334	-2900	-3225
	2	-1743	-1587	-1650	-1749	-1612
	3	-4634	-4232	-4783	-4318	-4264
$3^*F_{Rgn/opt}$ (N)	1	-3225	-3116	-2210	-2811	-2830
	2	-1743	-1504	-1352	-1749	-1369
	3	-4573	-4174	-3340	-4241	-3070
$3^*F_{Rgn/nat}$ (N)	1	-1559	-3116	-384	-2119	-505
	2	-1743	-1405	-1263	-557	-1267
	3	-3745	-4116	-2750	-1061	-1810
$3^*\Delta F$ (N)	1	-1939	0	-2950	-781	-2719
	2	0	-99	-387	-1192	-345
	3	-889	-58	-2033	-3257	-2454
$3^*Horizon$	1	Long	Optimal	Long	Medium	Long
	2	Optimal	Short	Long	Long	Short
	3	Medium	Optimal	Long	Long	Long
$3^*DFR_{AEDPS}(\%)$	1	92	100	66	96	87
	2	100	93	81	100	84
	3	98	98	69	98	72
$3^*AEDPS_{Dec/dis}(m)$	1	214	61	185	183	257
	2	58	63	132	187	85
	3	161	67	198	253	280
$3^*Driver_{Dec/dis}(m)$	1	146	61	124	169	89
	2	58	83	100	85	85
	3	96	67	74	106	45
3^*AEDPS regeneration efficiency improvement %	1	48	0	55	23	72
	2	0	0	5	69	6
	3	18	0	12	73	29

power regeneration and optimized vehicle speed. To ensure a fair comparison, the results of the forces regenerated by human drivers, $F_{Rgn/Nat}$, are also calculated using the predicted power and rotational speed of driver behavior. Fig. 9 and Fig. 10 illustrate the regeneration forces of AEDPS and of the driver in 6 scenarios, with the deceleration horizon adapted to each naturalistic regeneration performance. The differences in deceleration starting points result in a significant difference in regenerative forces between AEDPS and human drivers. As the deceleration points approach, optimal velocity generates maximum regeneration force, as shown by the green lines, pushing the motor regeneration to its physical limit (red line). This indicates that the deceleration profiles of AEDPS increase the amount of regenerated energy compared to the driver regeneration force (blue line). Furthermore, the driver behavior (Table 3) show shorter deceleration distance values than ADPES, resulting in lower energy recovery. Except for driver 2 in segment 1 and the three drivers in segment 2, who are predicted with optimal braking behaviors, the distance is doubled or even tripled. This means that a short deceleration distance, compared to the AEDPS-optimized deceleration distance, reduces the possibility of energy recovery.

The proposed strategy employs a prediction model for long-horizon (30 seconds) power forecast, primarily focusing on predicting ΔF for each scenario. ΔF represents the energy recovery maximization rate, which is used to make the deceleration planning adaptive by selecting the best




FIGURE 9. Adaptive regeneration maximization by AEDPS in downhill slope roads.




FIGURE 10. Adaptive regeneration maximization by AEDPS in flat slope roads.

horizon. Furthermore, reducing vehicle speed by initiating deceleration at the selected horizon allows the potential for maximizing regeneration up to the physical limits of an electrified powertrain; however, not all the energy recovery maximization rate can be regenerated. As a result, AEDPS produces the optimal deceleration profiles based on regeneration limitations and road topology to minimize the value of ΔF up to $\Delta F_{\text{opt}} = F_{\text{Lmt}} / \max - F_{\text{Rgn}} / \text{opt}$. The comparison of ΔF_{opt} in the two types of road slopes, medium downhill slope

in Fig.9, and nearly flat slope in Fig.10, is the second criterion for evaluating AEDPS energy regeneration performance. Fig.9 displays the segment with a medium downhill road slope corresponding to segment 4. Fig.9 (a) demonstrates that the case of significant deceleration with a downhill slope road results in a considerable transitory regeneration force, as shown in Fig.9 (d). This is not valid for a significant deceleration with a constant value of road slope and for a cruise mode with a downhill slope road, which results in low




FIGURE 11. Comparison between DFR of naturalistic speed behaviors and DFR of AEDPS speed profile of each driver during five segments.

demand for transitory regeneration force. Fig. 9 shows that the optimal regeneration force converges toward the maximum regeneration force until it reaches the force $F_{Lmt/max}$ (red line), which imposes ΔF_{opt} to be zero. This convergence results from the various horizons assigned to each driver: medium for driver 1, long for driver 2, and long for driver 3. However, as shown in Fig. 10, which shows segment 3 with a flat road, the planned deceleration profiles minimize ΔF but do not reach a zero value for ΔF_{opt} , even with a long horizon. This is primarily due to the effect of road load forces on regeneration performance. In fact, road load forces decrease on down-hill roads, leading to the enhancement of energy recovery. Flat roads' load forces increase slightly as only regenerative force is required for deceleration. As a result, the trend of F_{Rgn}/Opt convergence on the two road slopes proves that the strategy satisfies the consideration of road loads and confirms its ability to follow the regeneration limit.

A third relevant analysis is to validate the adaptation of regeneration efficiency improvements to each naturalistic regeneration performance. A strategy simulation is applied to all the route's deceleration events for each of the three driving behaviors. During each scenario, the deceleration force ratio (DFR) is presented in Fig. 11. DFR is the ratio between the physical limits of an electrified powertrain and the regeneration force for the current EV's speed. Fig. 11 shows the difference between DFR of AEDPS speed profile (DFR_{Opt}) and DFR of naturalistic speed behavior (DFR_{Dr}). Furthermore, the deceleration planning horizon is presented in the same figure, showing that it is adapted to naturalistic regeneration performance. A performance indicator of regeneration efficiency improvement is calculated by subtracting $DFR_{Opt} - DFR_{nat}$, and presented in Fig. 12. This figure depicts the gain, which varies dynamically from one scenario to another. The energy recovery performance of Driver 1 improves by 48% over a long horizon in segment 1, 0% over an optimal horizon in segment 2, 55% over a long horizon in segment 3, 23% over a medium horizon in segment 4,




FIGURE 12. Indicator of regeneration efficiency improvement of each driver during five segments.

and 72% over a long horizon in segment 5. This trend indicates that the adaptive aspect of regeneration performance enhancement is adequate, as ensured by the deceleration planning horizon dynamics, and it is significantly affected by road topology. Furthermore, segment 2 has a very high downhill slope compared to other segments. Table 3 presents the naturalistic regeneration performance for the three drivers predicted as optimal in segment 2. This makes an additional claim about how the driver's regeneration performance varies depending on the road topology and the importance of creating an adaptive regenerative braking strategy. The maximum improvement in the regeneration of each driver does exceed 60%, and it is not achieved in the same segment, as shown in Fig. 12. Driver 1 has improved regeneration up to 72% in segment 5, driver 2 up to 69% in segment 4, and driver 3 up to 73% in segment 4. Furthermore, the regeneration efficiency improvement rate shows a potential increase in energy recovery performance of 0%, 0%, 5%, 69%, and 6% for the five road segments, respectively. This increase in performance is more significant in the case of driver 1 (48%, 0%, 55%, 23%, and 72%) and driver 3 (18%, 0%, 12%, 73%, and 29%), characterized by a high driving speed, leading to a higher regeneration limit of the powertrain, and a short deceleration distance, allowing maximization of the regeneration distance. Therefore, the improvement rate clearly demonstrates that it is not only related to road topology but also to driver acceleration and braking behaviors. In the end, these previous results prove that the proposed strategy improves the acceptance of the braking control strategy by adapting deceleration planning to the regeneration performance of drivers in each scenario.

Several authors also use the speed-acceleration probability distribution (SAPD) as an alternative to reflect the dynamics of driving behavior. Fig. 13 and Fig. 14 below depicts the SAPD for the naturalist driver data as well as the output from the proposed approach, respectively. This figure shows that SAPD creates velocity-acceleration groups and gives $V_{in} = 2$ km/h and $a_{in} = 0.5$ m/s² as velocity and acceleration interval lengths, respectively. Furthermore, in an urban context, driving data is typically separated into four phases: stopping,




FIGURE 13. The SAPD of the naturalistic driving behaviors.




FIGURE 14. The SAPD of the optimal behaviors.

accelerating, deceleration, and cruising

$$\begin{cases} v = 0 \text{ AND } \text{abs}(a) \leq 0.15, & \text{stopping} \\ v > 0 \text{ AND } \text{abs}(a) \leq 0.15, & \text{cruising} \\ v > 0 \text{ AND } a > 0.15, & \text{accelerating} \\ v > 0 \text{ AND } a < -0.15, & \text{decelerating} \end{cases} \quad (27)$$

At first, the SAPD illustrated in Fig. 13 demonstrates that the speed-acceleration probability distributions of the naturalistic driving behavior data for the three drivers exhibit both similar and distinct characteristics. Driver 3 has the greatest permitted maximum speed of 75 km/h, while Driver 1 has a maximum speed of 60 km/h, and Driver 2 has a maximum speed of 50 km/h. In terms of similarities among the three drivers, the distribution probability of the Cruise phase, as defined previously, is more concentrated in the maximum speed, and presents the highest probability (Probability>0.6%) compared to other driving phases. The probability distribution of the stopping phase also exhibits a significant average density (Probability>0.3%) for all three drivers. Additionally, the deceleration phase has a Medium probability and is also more concentrated in the maximum speed. Secondly, the SAPD illustrated in Fig. 14 demonstrates the velocity-acceleration probability distributions of the optimal behaviors of the three drivers. This figure shows that the three drivers maintain the same maximum speed as in their naturalistic behavior. Furthermore, the probability

distribution of the stopping phase also maintains a significant average density. However, the probability distribution of the Cruise and deceleration phases has become much less concentrated on the maximum speed and more distributed over different speed values. This confirms the experimental context of the real data and also validates the effectiveness of the suggested approach in generating the optimal behavior.

C. COMPARATIVE STUDY

The Previous work has predominantly focused on long-term deceleration planning over a residual distance of 200 meters, with the horizon determined by the vehicle's installed sensor [40]. These strategies have proven effective for driving behaviors characterized by a uniform maximum speed (90 km/h) and under specific experimental conditions. The results of these studies reveal that long-term planning yields substantial benefits, with minor variance amongst ten drivers, ranging between 41% and 51%. However, these approaches only consider the long-term speed profile for driving behaviors with a maximum cruise speed of (90 km/h) and fail to account for variations in energy regeneration performance for other driving behaviors with differing maximum speed preferences and driving conditions. Our proposed strategy addresses these shortcomings by examining the driving behaviors of three drivers with different maximum speed preferences and various slope levels. This approach

illuminates how these factors influence the variability of naturalistic regeneration performance. Compared to other strategies, the proposed strategy is uniquely capable of predicting naturalistic regeneration performance in each stopping environment. The prediction of these performances has been shown to be especially beneficial in numerous instances where naturalistic deceleration behavior is optimal and assistance is considered useless, thereby helping to limit driver disruption from irrelevant advice or warnings. Moreover, our strategy adjusts the deceleration horizon using three distinct horizons—long, medium, and short—rendering the approach adaptive and reducing the computational load required to generate an optimal speed profile in real-time. Consequently, as our proposed strategy adapts to naturalistic regeneration performance for drivers with varying maximum speed preferences, the improvement in regeneration performance varied significantly from one driving behavior to another and from one scenario to another.

V. CONCLUSION

This paper presents the design of an adaptive braking strategy based on naturalistic regeneration performance for an electric vehicle. Using NARX methods, the proposed AEDPS predicts the power with long-horizon forecasting (30 seconds), allowing anticipation of the difference between naturalistic energy regeneration and the physical limits of an electrified powertrain corresponding to maximum speed preference. This previous step allows evaluation of the naturalistic regeneration performance, which makes the deceleration planning horizon adapted to this performance. AEDPS considers three deceleration planning horizons: long, medium, and short. The long horizon improves energy regeneration for the driver with low naturalistic regeneration performance by developing long deceleration profiles, while medium and short horizons are assigned to moderate and minimal naturalistic regeneration performance scenarios, respectively. AEDPS uses DP to implement the deceleration profile that maximizes energy recovery. Implementing the adaptive control strategy resulted in a prediction of optimal naturalistic regeneration behavior in segment 2 for the three drivers, limiting irrelevant warnings and increasing the eco-feedback technology's effectiveness. The obtained results through simulations of the AEDPS strategy by three drivers that have different preferences for maximum speed when driving between two-stop events are promising. It can maximize energy regeneration up to the individual physical limits of an electrified powertrain on downhill roads and 10-20% less on flat roads. This result proves that the strategy satisfies the consideration of road loads and confirms its ability to reach optimal regeneration performance, satisfying maximum speed preference. Developing appropriate strategies for drivers' preferences improves the control strategy's acceptability and efficiency. Furthermore, the result shows 39,6% improvement in regeneration efficiency for driver 1, 16% for driver 2, and 26% for driver 3, and forecasting the optimality of some deceleration behaviors. This trend proves that the adaptive strategy

effectively manages the individual maximization of regeneration and improves the energy efficiency of EVs. Therefore, the proposed AEDPS exhibits several notable advantages. It significantly reduces energy consumption by maximizing regeneration to the physical limits of an electrified powertrain and considering driver behavior preference. Moreover, it enhances driver acceptance of the braking control strategy by adapting the deceleration planning horizon to naturalistic regeneration performance and improving eco-feedback technology's effectiveness by minimizing unnecessary alerts. This adaptive braking control strategy also motivates the driver to adopt AEDPS by demonstrating the gain it can bring compared to its naturalistic behaviors. Additionally, this strategy mitigates the computational burden required to generate an optimal velocity profile in real-time, by avoiding extra calculations for short-horizon deceleration planning and optimal naturalistic deceleration behavior.

The work presented in this manuscript lays the basis for designing an adaptive AEDPS for electric vehicles, considering static road information such as road grades and stop signs detected by intelligent cameras. In the future, enhanced connectivity with other vehicles and infrastructure may enable the following:

- (1) Expanding to encompass other dynamic deceleration conditions, such as car-following situations, and offering adaptive deceleration planning to accommodate driver behaviors under these circumstances. The model of power regeneration forecasting should integrate relative velocity, relative distance, and the speed of the ego vehicle.

- (2) Maximizing the benefits of AEDPS, adaptive deceleration planning should generate optimal deceleration in more complex traffic scenarios, including signalized intersections. The proposed strategy could utilize SPAT information from an actual signal controller operation to guide the driver through signalized intersections, thus maximizing regeneration and adapting the assistance according to their regenerative performance.

- (3) Integrating steering angle and yaw moment distribution to amplify the effectiveness of regenerative braking by AEDPS in scenarios such as decelerating before signal signs, at the same time changing lanes to the right or left.

- (4) While this paper proposes an AEDP for current energy systems considering the optimal operating temperature range for lithium-ion batteries (typically 15 to 35 °C), it doesn't address the battery's charge capacity at very low temperatures (between −20 and −40 °C). This is crucial to ensure the strategy's effectiveness in colder countries such as Canada and Sweden.

- (5) In adverse weather conditions such as rain, snow, or icy roads, drivers tend to be more careful, and decelerate earlier and exhibit reduced vehicle speed, acceleration, and deceleration rates. Winter road conditions are also more likely to be slippery, causing additional loss of regenerated energy during braking. Therefore, AEDPS should factor in the impact of weather on naturalistic regenerative performance, enhancing its robustness under such conditions.

(6) The proposed AEDPS implementation holds significant promise for electric buses, which have relatively fixed routes and must stop at inter-route stations for passenger pick-up/drop-off. The total mass, a fundamental parameter of the longitudinal dynamic model and energy regeneration (particularly in downhill movement scenarios), changes as passengers board and disembark at bus stations. This key characteristic should be addressed within the context of eco-friendly braking assistance for electric buses.

ACKNOWLEDGMENT

The authors would like to thank the Foundation of Université du Québec à Trois-Rivières, Canada Research Chair Program; Natural Sciences and Engineering Research Council of Canada. They also like to thank Mohsen Kandidayeni for his valuable suggestions to improve the quality of the paper.

REFERENCES

- [1] W. R. Black and N. Sato, "From global warming to sustainable transport 1989–2006," *Int. J. Sustain. Transp.*, vol. 1, no. 2, pp. 73–89, May 2007.
- [2] S. Perveen, T. Yigitcanlar, M. Kamruzzaman, and D. Agdas, "How can transport impacts of urban growth be modelled? An approach to consider spatial and temporal scales," *Sustain. Cities Soc.*, vol. 55, Apr. 2020, Art. no. 102031.
- [3] M. Lombardi, K. Panerali, S. Rousselet, and J. Scalise. (2018). *Electric Vehicles for Smarter Cities: The Future of Energy and Mobility*. World Economic Forum. [Online]. Available: http://www3.weforum.org/docs/WEF_2018_%20Electric_For_Smarter_Cities.pdf
- [4] S. Hima, S. Glaser, A. Chaibet, and B. Vanholme, "Controller design for trajectory tracking of autonomous passenger vehicles," in *Proc. 14th Int. IEEE Conf. Intell. Transp. Syst. (ITSC)*, Oct. 2011, pp. 1459–1464.
- [5] G. Li, D. Wu, J. Hu, Y. Li, M. S. Hossain, and A. Ghoneim, "HELOS: Heterogeneous load scheduling for electric vehicle-integrated microgrids," *IEEE Trans. Veh. Technol.*, vol. 66, no. 7, pp. 5785–5796, Jul. 2017.
- [6] H. Vdovic, J. Babic, and V. Podobnik, "Automotive software in connected and autonomous electric vehicles: A review," *IEEE Access*, vol. 7, pp. 166365–166379, 2019.
- [7] Q. Jin, G. Wu, K. Boriboonsomsin, and M. J. Barth, "Power-based optimal longitudinal control for a connected eco-driving system," *IEEE Trans. Intell. Transp. Syst.*, vol. 17, no. 10, pp. 2900–2910, Oct. 2016.
- [8] F. Mensing, E. Bideaux, R. Trigui, and H. Tattegrain, "Trajectory optimization for eco-driving taking into account traffic constraints," *Transp. Res. D, Transp. Environ.*, vol. 18, pp. 55–61, Jan. 2013.
- [9] A. Sciarretta, G. D. Nunzio, and L. L. Ojeda, "Optimal ecodriving control: Energy-efficient driving of road vehicles as an optimal control problem," *IEEE Control Syst. Mag.*, vol. 35, no. 5, pp. 71–90, Oct. 2015.
- [10] S. Wang and X. Lin, "Eco-driving control of connected and automated hybrid vehicles in mixed driving scenarios," *Appl. Energy*, vol. 271, Aug. 2020, Art. no. 115233.
- [11] J. Han, A. Vahidi, and A. Sciarretta, "Fundamentals of energy efficient driving for combustion engine and electric vehicles: An optimal control perspective," *Automatica*, vol. 103, pp. 558–572, May 2019.
- [12] M. Li, X. Wu, X. He, G. Yu, and Y. Wang, "An eco-driving system for electric vehicles with signal control under V2X environment," *Transp. Res. C, Emerg. Technol.*, vol. 93, pp. 335–350, Aug. 2018.
- [13] F. Golbabaie, T. Yigitcanlar, A. Paz, and J. Bunker, "Individual predictors of autonomous vehicle public acceptance and intention to use: A systematic review of the literature," *J. Open Innov. Technol. Market. Complex.*, vol. 6, no. 4, p. 106, Dec. 2020.
- [14] R. A. Dollar and A. Vahidi, "Efficient and collision-free anticipative cruise control in randomly mixed strings," *IEEE Trans. Intell. Vehicles*, vol. 3, no. 4, pp. 439–452, Dec. 2018.
- [15] S. E. Li, S. Xu, X. Huang, B. Cheng, and H. Peng, "Eco-departure of connected vehicles with V2X communication at signalized intersections," *IEEE Trans. Veh. Technol.*, vol. 64, no. 12, pp. 5439–5449, Dec. 2015.
- [16] L. Hu, Y. Zhong, W. Hao, B. Moghimi, J. Huang, X. Zhang, and R. Du, "Optimal route algorithm considering traffic light and energy consumption," *IEEE Access*, vol. 6, pp. 59695–59704, 2018.
- [17] J. Han, A. Sciarretta, L. L. Ojeda, G. De Nunzio, and L. Thibault, "Safe and eco-driving control for connected and automated electric vehicles using analytical state-constrained optimal solution," *IEEE Trans. Intell. Vehicles*, vol. 3, no. 2, pp. 163–172, Jun. 2018.
- [18] Z. Yang, Y. Feng, X. Gong, D. Zhao, and J. Sun, "Eco-trajectory planning with consideration of queue along congested corridor for hybrid electric vehicles," *Transp. Res. Rec., J. Transp. Res. Board*, vol. 2673, no. 9, pp. 277–286, Sep. 2019.
- [19] W. Zhao, D. Ngoduy, S. Shepherd, R. Liu, and M. Papageorgiou, "A platoon based cooperative eco-driving model for mixed automated and human-driven vehicles at a signalised intersection," *Transp. Res. C, Emerg. Technol.*, vol. 95, pp. 802–821, Oct. 2018.
- [20] F. Wang and B. Zhuo, "Regenerative braking strategy for hybrid electric vehicles based on regenerative torque optimization control," *Proc. Inst. Mech. Eng., D, J. Automobile Eng.*, vol. 222, no. 4, pp. 499–513, Apr. 2008.
- [21] H. Liu, Y. Lei, Y. Fu, and X. Li, "An optimal slip ratio-based revised regenerative braking control strategy of range-extended electric vehicle," *Energies*, vol. 13, no. 6, p. 1526, Mar. 2020.
- [22] C. Qiu, G. Wang, M. Meng, and Y. Shen, "A novel control strategy of regenerative braking system for electric vehicles under safety critical driving situations," *Energy*, vol. 149, pp. 329–340, Apr. 2018.
- [23] S. Liu, Z. Li, H. Ji, Z. Hou, and L. Fan, "A novel electric vehicle braking energy recovery method based on model free adaptive control algorithm with input and output constraints," in *Proc. IEEE 10th Data Driven Control Learn. Syst. Conf. (DDCLS)*, May 2021, pp. 1503–1509.
- [24] H. Dong, W. Zhuang, B. Chen, Y. Wang, Y. Lu, Y. Liu, L. Xu, and G. Yin, "A comparative study of energy-efficient driving strategy for connected internal combustion engine and electric vehicles at signalized intersections," *Appl. Energy*, vol. 310, Mar. 2022, Art. no. 118524.
- [25] F. Sangtarash, V. Esfahanian, H. Nehzati, S. Haddadi, M. A. Bavanpour, and B. Haghpahanah, "Effect of different regenerative braking strategies on braking performance and fuel economy in a hybrid electric bus employing CRUISE vehicle simulation," *SAE Int. J. Fuels Lubricants*, vol. 1, no. 1, pp. 828–837, Jun. 2008.
- [26] L. Chu, F. Zhou, J. Guo, and M. Shang, "Investigation of determining of regenerative braking torque based on associated efficiency optimization of electric motor and power battery using GA," in *Proc. Int. Conf. Electron. Mech. Eng. Inf. Technol.*, vol. 6, Aug. 2011, pp. 3238–3241.
- [27] K. Min, G. Sim, S. Ahn, M. Sunwoo, and K. Jo, "Vehicle deceleration prediction model to reflect individual driver characteristics by online parameter learning for autonomous regenerative braking of electric vehicles," *Sensors*, vol. 19, no. 19, p. 4171, Sep. 2019.
- [28] Z. Chen, S. Wu, S. Shen, Y. Liu, F. Guo, and Y. Zhang, "Co-optimization of velocity planning and energy management for autonomous plug-in hybrid electric vehicles in urban driving scenarios," *Energy*, vol. 263, Jan. 2023, Art. no. 126060.
- [29] R. Bautista-Montesano, R. Galluzzi, Z. Mo, Y. Fu, R. Bustamante-Bello, and X. Di, "Longitudinal control strategy for connected electric vehicle with regenerative braking in eco-approach and departure," *Appl. Sci.*, vol. 13, no. 8, p. 5089, Apr. 2023.
- [30] C. Pan, A. Huang, J. Wang, L. Chen, J. Liang, W. Zhou, L. Wang, and J. Yang, "Energy-optimal adaptive cruise control strategy for electric vehicles based on model predictive control," *Energy*, vol. 241, Feb. 2022, Art. no. 122793.
- [31] H. Wei, L. Fan, Q. Ai, W. Zhao, T. Huang, and Y. Zhang, "Optimal energy allocation strategy for electric vehicles based on the real-time model predictive control technology," *Sustain. Energy Technol. Assessments*, vol. 50, Mar. 2022, Art. no. 101797.
- [32] H. Chen, L. Guo, H. Ding, Y. Li, and B. Gao, "Real-time predictive cruise control for eco-driving taking into account traffic constraints," *IEEE Trans. Intell. Transp. Syst.*, vol. 20, no. 8, pp. 2858–2868, Aug. 2019.
- [33] S. Xu, X. Zhao, N. Yang, and Z. Bai, "Control strategy of braking energy recovery for range-extended electric commercial vehicles by considering braking intention recognition and electropneumatic braking compensation," *Energy Technol.*, vol. 8, no. 9, Sep. 2020, Art. no. 2000407.
- [34] B. Sun, W. Deng, R. He, J. Wu, and Y. Li, "Personalized eco-driving for intelligent electric vehicles," in *Proc. Intell. Connected Vehicles Symp.*, Kunshan, China, 2018.
- [35] T. Yuan, R. Liu, X. Zhao, Q. Yu, X. Zhu, and S. Wang, "Analysis of normal stopping behavior of drivers at urban intersections in China," *J. Adv. Transp.*, vol. 2022, pp. 1–17, Jul. 2022.
- [36] E. Brandenburg, L. Doria, A. Gross, T. Günzler, and H. Smieszek, *Grundlagen und Anwendungen der Mensch-Maschine-Interaktion: 10. Berliner Werkstatt Mensch-Maschine-Systeme 10.–12. Oktober 2013; Proceedings. Universitätsverlag der TU Berlin*. Berlin, Germany: Universitätsverlag der TU Berlin, 2014.

- [37] A. de Moura Oliveira, E. Bertoti, J. Eckert, R. Yamashita, E. dos Santos Costa, L. C. d. A. e Silva, and F. G. Dedini, "Evaluation of energy recovery potential through regenerative braking for a hybrid electric vehicle in a real urban drive scenario," *SAE Tech. Paper*, 2016-36-0348, 2016.
- [38] Y. Xing, C. Lv, D. Cao, and C. Lu, "Energy oriented driving behavior analysis and personalized prediction of vehicle states with joint time series modeling," *Appl. Energy*, vol. 261, Mar. 2020, Art. no. 114471.
- [39] M. Mohammadi, S. Heydari, P. Fajri, F. Harirchi, and Z. Yi, "Energy-aware driving profile of autonomous electric vehicles considering regenerative braking limitations," in *Proc. IEEE Transp. Electrific. Conf. Expo. (ITEC)*, Jun. 2022, pp. 196–201.
- [40] D. Kim, J. S. Eo, and K. K. Kim, "Service-oriented real-time energy-optimal regenerative braking strategy for connected and autonomous electrified vehicles," *IEEE Trans. Intell. Transp. Syst.*, vol. 23, no. 8, pp. 11098–11115, Aug. 2022.
- [41] D. Schwarze, M. G. Arend, and T. Franke, "The effect of displaying kinetic energy on hybrid electric vehicle drivers' evaluation of regenerative braking," in *Congress of the International Ergonomics Association*. Cham, Switzerland: Springer, 2018, pp. 727–736.
- [42] S. M. Iranmanesh, H. N. Mahjoub, H. Kazemi, and Y. P. Fallah, "An adaptive forward collision warning framework design based on driver distraction," *IEEE Trans. Intell. Transp. Syst.*, vol. 19, no. 12, pp. 3925–3934, Dec. 2018.
- [43] J. Fleming, X. Yan, and R. Lot, "Incorporating driver preferences into eco-driving assistance systems using optimal control," *IEEE Trans. Intell. Transp. Syst.*, vol. 22, no. 5, pp. 2913–2922, May 2021.
- [44] X. Tian, Y. Cai, X. Sun, Z. Zhu, and Y. Xu, "An adaptive ECMS with driving style recognition for energy optimization of parallel hybrid electric buses," *Energy*, vol. 189, Dec. 2019, Art. no. 116151.
- [45] S. Wang, P. Yu, D. Shi, C. Yu, and C. Yin, "Research on eco-driving optimization of hybrid electric vehicle queue considering the driving style," *J. Cleaner Prod.*, vol. 343, Apr. 2022, Art. no. 130985.
- [46] W. Xu, H. Chen, H. Zhao, and B. Ren, "Torque optimization control for electric vehicles with four in-wheel motors equipped with regenerative braking system," *Mechatronics*, vol. 57, pp. 95–108, Feb. 2019.
- [47] H. Pacejka, *Tire and Vehicle Dynamics*. Amsterdam, The Netherlands: Elsevier, 2005.
- [48] Accessed: Jan. 20, 2023. [Online]. Available: <https://www.septentrio.com/en/products/gnss-ins-receivers>
- [49] F. K. Ayevide, S. Kelouwani, A. Amamou, M. Kandidayeni, and H. Chaoui, "Estimation of a battery electric vehicle output power and remaining driving range under subfreezing conditions," *J. Energy Storage*, vol. 55, Nov. 2022, Art. no. 105554.
- [50] S. Nan, R. Tu, T. Li, J. Sun, and H. Chen, "From driving behavior to energy consumption: A novel method to predict the energy consumption of electric bus," *Energy*, vol. 261, Dec. 2022, Art. no. 125188.
- [51] H. Shen, X. Zhou, H. Ahn, M. Lamantia, P. Chen, and J. Wang, "Personalized velocity and energy prediction for electric vehicles with road features in consideration," *IEEE Trans. Transport. Electrific.*, p. 1, 2023, doi: [10.1109/TTE.2023.3241098](https://doi.org/10.1109/TTE.2023.3241098).
- [52] J. D. Valladolid, D. Patino, G. Grousso, C. A. Correa-Flórez, J. Vuelas, and F. Espinoza, "A novel energy-efficiency optimization approach based on driving patterns styles and experimental tests for electric vehicles," *Electronics*, vol. 10, no. 10, p. 1199, May 2021.



MARWA ZIADIA received the B.S. degree in computer science from the National School of Engineers of Tunis (ENSIT), Tunis, Tunisia, in 2010, the master's degree in communication and embedded computer systems security (with auditor diploma) from the Computer Science Superior Institute (ISI), Tunis, in 2012, and the master's degree in mechanical engineering from Université du Québec à Trois-Rivières (UQTR), Trois-Rivières, QC, Canada, in 2020, where she is currently pursuing the Ph.D. degree with the Department of Mechanical Engineering. Her research interests include electric vehicles, energy efficiency, intelligent transport systems, vehicle dynamics, machine learning, modeling, optimal control, and contributions to making our vehicles efficient and more eco-friendly.



SOUSSO KELOUWANI (Senior Member, IEEE) received the Ph.D. degree in robotics systems from Ecole Polytechnique de Montreal, in 2011. He completed the postdoctoral internship on fuel cell hybrid electric vehicles with Université du Québec à Trois-Rivières (UQTR), in 2012. Since 2017, he has been a Full Professor of mechatronics with the Department of Mechanical Engineering, UQTR. He holds four patents in U.S. and Canada. He has published more than 100 scientific articles. He holds the Canada Research Chair of Energy Optimization of Intelligent Transport Systems and the Noovelia Research Chair of Intelligent Navigation of Autonomous Industrial Vehicles. He developed expertise in the optimization and the intelligent control of vehicular applications. His research interests include optimizing energy systems for vehicle applications, advanced driver assistance techniques, and intelligent vehicle navigation taking into account Canadian climatic conditions. He has a member of the Hydrogen Research Institute. He is a member of the Order of Engineers of Quebec. In 2019, his team received the First Innovation Prize in partnership with DIVEL, awarded by the Association des Manufacturiers de la Mauricie et Center-du-Québec for the development of an autonomous and natural navigation system. In 2017, he received the Environment Prize at the Gala des Grands Prix d'excellence en transport from the Association québécoise du Transport (AQTr) for the development of hydrogen range extenders for electric vehicles. He is the Winner of the Canada General Governor Gold Medal, in 2003. He was the Co-President and the President of the technical committee of the IEEE International Conferences on Vehicular Power and Propulsion, in Chicago, USA, in 2018, and in Hanoi, Vietnam, in 2019.



ALI AMAMOU (Member, IEEE) received the B.S. degree in industrial computing and automatic science from the National Institute of Applied Sciences and Technology, Tunis, Tunisia, in 2013, the M.S. degree in embedded systems science from Arts et Métiers ParisTech University, Aix-en-Provence, France, in 2014, and the Ph.D. degree in electrical engineering from Université du Québec à Trois-Rivières (UQTR), QC, Canada, in 2018. In May 2018, he started as a Postdoctoral Fellow with the Hydrogen Research Institute. His research interests include the optimization of energy systems for stationary and mobile applications, hybridization of energy sources for vehicular applications, and eco-energy navigation of the low-speed autonomous electric vehicle.



KODJO AGBOSSOU (Senior Member, IEEE) received the B.S., M.S., and Ph.D. degrees in electronic measurements from Université de Nancy I, France, in 1987, 1989, and 1992, respectively. He was a Postdoctoral Researcher and a Lecturer with the Electrical Engineering Department, Université du Québec à Trois-Rivières (UQTR), from 1993 to 1994 and from 1997 to 1998, respectively. He was the Director of the Graduate Studies in Electrical Engineering, UQTR, from 2002 to 2004. He was the Head of the Department of Electrical and Computer Engineering Department, UQTR, from 2007 to 2011. He was the Head of the Engineering School, UQTR, from 2011 to 2017, where he is currently the Hydro-Québec Research Chair of Transactive Management of Power and Energy in the Residential Sector, and the Chair of the Smart Energy Research and Innovation Laboratory. He is a member of the Hydrogen Research Institute and Research Group "GREI," UQTR. He is the author of more than 325 publications and has four patents and two patent pending. His research interests include renewable energy, the use of hydrogen, home demand side management (HDSM), integration of energy production, storage and electrical energy generation systems, connection of electrical vehicle to the grids, and control and measurements. Since 2015, he has been the Sub-Committee Chair of the Home and Building Energy Management of Smart Grid Technical Committee and IEEE Industrial Electronics Society (IES).

...

Chapitre 4 - Adaptation du freinage régénératif aux variations climatiques

Article 2 : Ziadia, Marwa, Sousso Kelouwani, Ali Amamou, and Kodjo Agbossou. "Weather-Adaptive Regenerative Braking Strategy Based on Driving Style Recognition for Intelligent Electric Vehicles." *Sensors* (Basel, Switzerland) 25, no. 4 (2025): 1175.

DOI : 10.3390/s25041175

4.1 Introduction

Cet article propose une approche innovante visant à adapter la stratégie de freinage régénératif aux conditions météorologiques variées en s'appuyant sur la reconnaissance du style de conduite. L'objectif est d'optimiser la récupération d'énergie des véhicules électriques intelligents tout en garantissant la sécurité et le confort du conducteur. Pour ce faire, l'étude combine une analyse expérimentale des comportements de conduite sur routes sèches et glacées avec des techniques avancées de modélisation et d'optimisation. Les données issues d'essais sur le terrain et de la SHRP 2 Naturalistic Driving Study sont exploitées afin de construire un modèle robuste capable de classer les styles de conduite et d'ajuster dynamiquement le profil de décélération selon les conditions environnementales.

4.2 Méthodologie

L'approche méthodologique adoptée dans cet article repose sur plusieurs étapes clés visant à développer une stratégie de freinage régénératif adaptative aux conditions climatiques variées pour les véhicules électriques intelligents.

La première phase expérimentale a consisté à analyser les variations du comportement des conducteurs en fonction des conditions météorologiques, en particulier sur routes sèches et glacées. Trois conducteurs ont participé à une série de dix essais chacun, dont cinq sous tempête de neige sur route glacée et cinq sous conditions sèches, sur un parcours standardisé de 5 km comportant 7 panneaux d'arrêt. Les variables mesurées incluaient :

- La vitesse maximale atteinte (indicateur de la perception du risque),
- L'accélération et la décélération longitudinales (pour évaluer les stratégies de freinage et leur impact sur la récupération d'énergie),
- Un indicateur de dispersion du freinage (permettant d'identifier les tendances entre freinages abrupts et progressifs).

Afin d'enrichir la base de données expérimentale et d'assurer une meilleure robustesse du modèle, les résultats ont été combinés avec des données issues de la SHRP 2 Naturalistic Driving Study, qui capture le comportement de conduite dans des conditions réelles (routes mouillées, enneigées et verglacées). Cette fusion de données a permis d'améliorer la précision des prédictions et d'assurer la généralisation du modèle.

L'analyse des résultats a mis en évidence que les conducteurs adoptent des stratégies distinctes en fonction des conditions climatiques : certains ajustent leur vitesse de manière significative en conditions glacées, tandis que d'autres conservent des habitudes proches de celles observées sur route sèche, influençant directement l'efficacité de la récupération d'énergie. Ces résultats confirment l'hypothèse selon laquelle l'adaptation de la stratégie de freinage aux conditions climatiques peut être assurée par l'intégration d'un modèle de reconnaissance du style de conduite.

L'approche se divise ainsi en deux grandes phases :

a) Reconnaissance du style de conduite et détermination des contraintes

Un modèle de reconnaissance des styles de conduite a été développé à l'aide de données collectées sur trois styles distincts, sous différentes conditions météorologiques (routes sèches et routes glacées). Ce modèle utilise des paramètres clés (vitesse, couple moteur, accélération, puissance) et repose sur un algorithme basé sur les arbres de décision, permettant de classer les styles de conduite en six catégories distinctes. En plus de la classification, ce modèle détermine les contraintes spécifiques à chaque catégorie, qui serviront d'entrées aux modèles de planification de décélération optimisée. Ainsi, la classification active :

- Une stratégie de freinage adaptative aux performances naturelles de régénération sur route sèche (développée dans la première contribution de la thèse),
- Une stratégie ajustée aux contraintes de la friction de la route et aux accélérations spécifiques en conditions glacées.

b) Planification énergétique et optimisation du freinage

Pour améliorer la robustesse du modèle de prédiction de la puissance régénérative dans des conditions mixtes (routes sèches et glissantes), un modèle basé sur la classification ANFIS (Adaptive Neuro-Fuzzy Inference System) a été adopté. Lorsque des routes glacées sont détectées, le système ajuste automatiquement l'horizon de décélération en fonction de la pente de la route :

- Un horizon court est appliqué sur les pentes descendantes pour prévenir les risques de dérapage et garantir la sécurité.
- Sur routes plates, où le comportement du conducteur est optimal en termes de récupération d'énergie, le système ADAS est désactivé afin d'éviter toute interférence inutile.

La planification de la décélération repose sur un algorithme de programmation dynamique, qui optimise le profil de vitesse en tenant compte des contraintes d'accélération spécifiques aux conditions de route glacée et aux styles de conduite associés.

Pour valider l'approche, des simulations ont été menées sous MATLAB/Simulink en intégrant un modèle dynamique du véhicule, permettant de simuler différentes conditions de freinage sur routes sèches et glacées. Enfin, des tests expérimentaux ont été réalisés afin de comparer la nouvelle stratégie aux méthodes de freinage adaptatif en conditions sèches, en mesurant les performances de régénération d'énergie dans divers scénarios.

4.3 Résultats

L'analyse des résultats expérimentaux met en évidence l'efficacité de la stratégie de freinage régénératif adaptative WARBS par rapport aux stratégies de freinage adaptatif développées pour les routes sèches. L'évaluation a été réalisée en trois étapes principales :

- **Évaluation du modèle de reconnaissance du style de conduite** : Trois algorithmes (arbre de décision, ANFIS et SVM) ont été comparés. L'arbre de décision a obtenu un taux de classification de 100%, surpassant les autres méthodes.
- **Amélioration de l'efficacité énergétique** : La stratégie WARBS a permis d'optimiser la récupération d'énergie, notamment sur routes glacées et sèches, tout en maintenant la stabilité du véhicule. La performance de régénération a été mesurée pour cinq segments de route avec différentes inclinaisons et niveaux d'adhérence.
- **Comparaison avec l'approche AEDPS** : La stratégie WARBS a entraîné une augmentation de la récupération d'énergie de 11,6% pour le conducteur 1, 10,4% pour le conducteur 2 et 10,31% pour le conducteur 3, confirmant ainsi que la prise

en compte des conditions climatiques variées et du style de conduite améliore significativement l'efficacité énergétique.

4.4 Conclusion

Cette étude a proposé une stratégie de freinage régénératif adaptative aux conditions météorologiques variées (WARBS) afin d'optimiser la récupération d'énergie dans les véhicules électriques intelligents. L'approche repose sur la reconnaissance des styles de conduite en fonction des conditions routières (sèches ou glacées), permettant d'adapter dynamiquement la planification de la décélération pour maximiser l'efficacité énergétique tout en garantissant la sécurité du conducteur.

Les résultats expérimentaux et les simulations ont validé la pertinence de cette stratégie, avec une amélioration moyenne de la récupération d'énergie atteignant 11,6% pour le conducteur 1, 10,4% pour le conducteur 2 et 10,31% pour le conducteur 3. Par ailleurs, l'analyse a révélé une réduction des alertes superflues émises par les systèmes d'assistance à la conduite (ADAS) et une meilleure stabilité sur chaussées glacées.

En conclusion, la stratégie WARBS représente une avancée significative dans l'optimisation des systèmes de freinage régénératif pour les véhicules électriques intelligents. Elle ouvre la voie à des applications futures dans des environnements variés, et des études complémentaires pourraient intégrer d'autres paramètres environnementaux, tels que l'effet de la température ambiante ou la résistance au vent, pour affiner encore davantage l'optimisation.

Article

Weather-Adaptive Regenerative Braking Strategy Based on Driving Style Recognition for Intelligent Electric Vehicles

Marwa Ziadia ^{1,*} , Souso Kelouwani ¹ , Ali Amamou ¹  and Kodjo Agbossou ² 

¹ Department of Mechanical Engineering, Hydrogen Research Institute, University of Québec at Trois-Rivières, Trois-Rivières, QC G8Z 4M3, Canada; souso.kelouwani@uqtr.ca (S.K.); ali.amamou@uqtr.ca (A.A.)

² Department of Electrical and Computer Engineering, Hydrogen Research Institute, University of Québec at Trois-Rivières, Trois-Rivières, QC G8Z 4M3, Canada; kodjo.agbossou@uqtr.ca

* Correspondence: marwa.ziadia@uqtr.ca

Abstract: This paper examines the energy efficiency of smart electric vehicles equipped with regenerative braking systems under challenging weather conditions. While Advanced Driver Assistance Systems (ADAS) are primarily designed to enhance driving safety, they often overlook energy efficiency. This study proposes a Weather-Adaptive Regenerative Braking Strategy (WARBS) system, which leverages onboard sensors and data processing capabilities to enhance the energy efficiency of regenerative braking across diverse weather conditions while minimizing unnecessary alerts. To achieve this, we develop driving style recognition models that integrate road conditions, such as weather and road friction, with different driving styles. Next, we propose an adaptive deceleration plan that aims to maximize the conversion of kinetic energy into electrical energy for the vehicle's battery under varying weather conditions, considering vehicle dynamics and speed constraints. Given that the potential for energy recovery through regenerative braking is diminished on icy and snowy roads compared to dry ones, our approach introduces a driving context recognition system to facilitate effective speed planning. Both simulation and experimental validation indicate that this approach can significantly enhance overall energy efficiency.

Keywords: intelligent electric vehicle; adaptive regenerative braking; weather conditions; driving style recognition; machine learning; energy recovery optimization



Academic Editor: Arturo de la Escalera Hueso

Received: 15 December 2024

Revised: 29 January 2025

Accepted: 10 February 2025

Published: 14 February 2025

Citation: Ziadia, M.; Kelouwani, S.; Amamou, A.; Agbossou, K. Weather-Adaptive Regenerative Braking Strategy Based on Driving Style Recognition for Intelligent Electric Vehicles. *Sensors* **2025**, *25*, 1175. <https://doi.org/10.3390/s25041175>

Copyright: © 2025 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Transportation electrification is a pivotal advancement in reducing greenhouse gas emissions (GHG). The International Energy Agency projects that by 2030, the global fleet of electric vehicles (EVs) will reach 245 million, highlighting the shift toward large-scale electrification [1,2]. However, the development of EVs faces challenges, primarily due to the limitations of current battery technology, which is characterized by low energy density. The driving range of EVs depends on the capacity of the battery pack and the efficiency of the powertrain system. Enhancing battery capacity and optimizing powertrain efficiency aims to reduce energy consumption per kilometer, thereby extending the driving range of EVs [3]. Moreover, combining autonomous driving with transportation electrification has led to the integration of Autonomous Electric Vehicles (AEVs). This synergy offers numerous benefits that can further improve the use of EVs, including enhanced safety, automated charging processes, and optimized energy consumption [4–6].

A key feature of EVs is their regenerative braking system, which converts kinetic energy back into stored energy in the battery pack [7,8]. In practice, braking forces in EVs are divided between hydraulic braking and regenerative braking. Given the variable braking

demands of drivers, it is essential to allocate specific margins for hydraulic braking to ensure a smooth and comfortable braking experience [9,10]. Furthermore, the integration of ADAS can improve safety during intelligent braking and further optimize energy recovery. When the vehicle can anticipate and autonomously respond to upcoming deceleration needs, these systems can significantly maximize energy regeneration [11].

Connected and autonomous vehicles, through Intelligent Transportation Systems (ITS), offer valuable predictive insights into upcoming road conditions. These insights enable the proactive planning of deceleration speed profiles, allowing for smoother and more efficient management of unavoidable deceleration events [12]. Recent advancements in this field focus on anticipating future events to minimize irreversible driving errors across diverse road conditions [13,14]. Additionally, ref. [15] presents an MPC-based approach that emphasizes tire dynamics and vehicle load control, enhancing regeneration efficiency and minimizing tire slip loss. Another study by [16] employs Q-learning algorithms to generate optimal speed profiles during red light stops, utilizing real-time parameters through vehicle-to-infrastructure (V2I) communication. This approach has been experimentally verified to yield improved outcomes by adjusting vehicle braking actions under varying road conditions. Furthermore, ref. [17] explores a hybrid method known as the layer hidden Markov model–dynamic fuzzier neural network, which improves the accuracy in recognizing driver braking intentions. This advancement increases braking sensitivity and boosts the amount of recoverable energy. Overall, the literature demonstrates significant progress in anticipating future events, optimizing the use of regenerative braking, and reducing reliance on hydraulic braking systems [18,19].

The driver's style significantly influences the effectiveness of regenerative braking [20–22], as do the physical constraints of motor generation and the system's deceleration limits. Several studies in the literature focus on optimizing energy regeneration within these physical constraints [23]. For example, ref. [24] uses real driving test data to map the physical constraints of regenerative braking, which informs the development of a deceleration planning system aimed at optimizing energy consumption and enhancing recuperation efficiency. These optimization strategies are increasingly integrated into ADAS, primarily intended for fully autonomous (Level 5) vehicles. However, their effectiveness may be limited when applied to Level 3 or Level 4 autonomous vehicles, where driver involvement remains crucial. A notable challenge at these levels is ensuring driver acceptance of the braking control strategies, as highlighted in the literature [25]. Incorporating the driver's naturalistic driving style into these systems is essential. More specifically, integrating individualized regeneration performance into ADAS models and detecting moments when this performance is optimal can reduce the risk of driver frustration caused by inappropriate or poorly timed advice and warnings. This personalization not only enhances the user experience but also plays a pivotal role in increasing the effectiveness of eco-feedback technologies [26]. The evaluation of regenerative braking performance is closely tied to the driver's ability to regenerate energy up to the engine's regeneration capacity while adhering to their preferred maximum speed [27]. Over the past two decades, there has been a growing emphasis on developing customized strategies that cater to the unique needs and preferences of individual drivers [28,29]. Drivers often exhibit distinct speed preferences between stopping points, which are critical to consider, as these preferences directly correlate with both the regeneration limit and the individual's regenerative performance [30]. Integrating these preferences into the regenerative braking model and tailoring the braking control to align with individual energy regeneration capabilities adds an important dimension that enhances user acceptance of optimal braking strategies [31]. The approach introduced in [32] aims to balance optimal braking control with naturalistic regeneration behavior, accommodating individual drivers' speed preferences and naturalis-

tic energy regeneration performance during trips between two stopping points. The study proposes an Adapted Energy Deceleration Planning Strategy (AEDPS) that requires 30 s power forecasts to estimate naturalistic energy regeneration performance. Based on these predictions, it dynamically adjusts the deceleration planning horizon to optimize energy recovery. While this research was conducted under typical conditions, such as during summer, it is important to recognize that realistic driving scenarios often involve significant variations in weather, which can greatly affect driving dynamics and system efficacy.

Extensive research has established statistical links between driving style in various environmental contexts, such as car-following and lane-keeping, and different weather conditions [33,34]. These studies collectively demonstrate how factors like impaired visibility, precipitation, and extreme temperatures significantly influence driver behavior and vehicle handling. For instance, driving simulation experiments indicate that fog reduces both driving speeds and acceleration rates while increasing the distance drivers maintain from the vehicle ahead [35]. Beyond general environmental influences, specific factors such as road surface friction coefficients under varying weather conditions directly impact energy consumption. Research has shown that different weather conditions significantly affect traffic flow and vehicle operation. For example, a study conducted in the Salt Lake Valley found that commencement delays increase by 5% on wet roads and by 23% on snowy roads compared to dry conditions [36]. Additionally, a novel approach integrating control barrier functions (CBFs) and control Lyapunov functions (CLFs) has been developed to enable adaptive cruise control that adjusts to varying surface conditions affected by weather [37]. Another study utilized the Adams/Car Simulator to investigate how friction coefficients impact the dynamic responses of various vehicle types—sedans, buses, and trucks. The findings revealed significant variations in friction coefficients across different weather conditions, 0.5 for wet, 0.4 for rainy, 0.28 for snowy, and 0.18 for icy conditions, all of which critically affect braking performance. In contrast, higher friction coefficients of 0.9 to 0.6, typical of dry conditions, did not significantly alter braking distances [38]. Overall, these insights underline the importance of considering environmental factors when designing vehicle control systems and optimizing energy usage.

Different classification models are employed to recognize driving styles, utilizing various artificial intelligence algorithms. Studies referenced in [39,40] highlight that the most commonly used algorithms include Fuzzy Logic (FL), Random Forests (RF), k-nearest Neighbor (kNN), Support Vector Machine (SVM), and Long Short-Term Memory (LSTM) networks. Additionally, research in [41] shows that XGBoost offers superior predictive accuracy over RF and SVM models, particularly in contexts involving traffic crash fatalities and the differentiation between safe and unsafe driving styles. Ref. [42] explores using raw telematics data for driving style classification, which is pivotal for improving driving risk assessments, fuel efficiency, and supporting adaptive driving assistance and insurance practices. The features used in this analysis include instantaneous, short-term, and long-term styles derived from acceleration and speed measurements. Traditional classification methods such as k-NN, SVM, and Decision Trees are applied to time series data. The results reveal that Decision Trees, when used with the proposed features, surpass RNN-based approaches in classification accuracy, thus proving the effectiveness of these features in conjunction with decision Trees. In parallel, some studies have begun to explore the development of a driving style identifier (DBI) as a novel approach to classifying driving styles. For instance, ref. [43] introduces a novel method designed to regulate torque demand in EVs that are equipped with single-pedal driving (SPD). This method focuses on efficiently interpreting driving styles to promote eco-driving. Central to this approach is the development of a Driving Behavior Identifier (DBI), which utilizes the Binary Dragonfly Algorithm (BDA) combined with an Adaptive Neuro-Fuzzy Inference System enhanced by

Particle Swarm Optimization (ANFIS-PSO). Additionally, to further optimize powertrain control, Torque Demand Look-Up Tables (TDLTs) are created using the Whale Optimization Algorithm (WOA). This comprehensive approach aims to refine the responsiveness and efficiency of the vehicle's powertrain system by adapting torque output based on real-time driving style analysis. The study also underscores the critical role of advanced classification models, such as Decision Trees, SVM, and ANFIS, in recognizing driving styles under varying weather conditions.

Research on regenerative braking primarily focuses on optimizing energy efficiency under specific weather conditions. Some studies target summer conditions, while others explore strategies adapted to icy roads during winter. For instance, refs. [44,45] investigate speed control in low-adhesion contexts. Ref. [44] proposes an energy controller for electric vehicles on sloped roads, incorporating a slip compensation algorithm. This controller, based on a three-degree-of-freedom dynamic model, improves energy consumption even on slippery surfaces while remaining robust to variations in vehicle mass and battery state. Similarly, ref. [45] introduces an autopilot designed for low-friction roads, utilizing a two-level hierarchical optimization to prevent skidding and maintain stable performance on surfaces with variable friction. The deceleration planning also contributes to addressing challenges on low-friction roads. Ref. [46] introduces a coordinated control strategy (eMPC-CCS) for regenerative braking systems (RBSs) and anti-lock braking systems (ABSs) in electric vehicles. This strategy specifically tackles the difficulties associated with low-adhesion road conditions, such as icy or wet surfaces, using a Model Predictive Control framework. The proposed approach enhances real-time coordination of braking forces, ensuring vehicle stability and optimized braking performance even when tire-road adhesion is significantly reduced. It minimizes control conflicts between an RBS and ABS while employing state error compensation to maintain robust performance across varying road conditions. These advancements highlight the critical role of adaptive and predictive strategies in maximizing safety and energy recovery on low-adhesion roads. Similarly, the work of [47] focuses on optimizing energy regeneration in electric vehicles through an Energy-Optimal Adaptive Cruise Control (EACC) strategy based on Model Predictive Control (MPC). This methodology effectively manages low-adhesion conditions by dynamically adjusting model parameters, improving vehicle stability, and minimizing energy losses. However, ref. [47] does not address complex climatic variations, which are essential for practical applications in diverse real-world scenarios. The study's methodology is limited to optimizing parameters related to road adhesion and does not provide a strategy adapted to frequent transitions between varying weather conditions (e.g., from dry to icy roads). This shortcoming reduces the strategy's effectiveness in varied weather conditions, where driver-assistance systems may generate unnecessary alerts or fail to achieve optimal energy performance. Our study proposes an innovative approach: an adaptive regenerative braking strategy that integrates the dynamics of varying weather conditions and driving styles. Unlike previous works, our method relies on an advanced driving style recognition model that identifies road conditions (dry or icy) and slope profiles (flat or inclined) while dynamically adjusting the deceleration horizon. This strategy maximizes energy recovery and reduces unnecessary alerts in complex environments, such as icy or sloped roads. The main objective of this research is to develop an energy-efficient and adaptive regenerative braking strategy, with several key contributions: (1) Dynamic adaptation of braking performance to weather conditions and driving styles. (2) Reduction of false alerts, particularly in varied road contexts. (3) Maximization of energy recovery through advanced driving style recognition and optimization algorithms. These contributions address the growing need for braking assist systems that combine adaptability, energy efficiency, and comfort in diverse driving environments.

The remainder of this article is organized as follows. Section 2 provides an overview of driving style and naturalistic energy regeneration performance, comparing winter and summer conditions. Section 3 details the proposed method for the weather-adaptive regenerative braking strategy. Experimental results are reported in Section 4, and finally, Section 5 presents the conclusion.

2. Overview of Driver Style and Naturalistic Energy Regeneration Performance: Icy vs. Dry Roads

This section outlines a research methodology to examine variations in drivers' braking styles across different weather conditions, specifically contrasting the challenges of winter, characterized by snowy weather and icy roads, with the more predictable conditions of summer, which feature dry roads. The focus is on how drivers naturally adjust their acceleration and deceleration in response to changing weather and road conditions and how these adjustments subsequently impact energy regeneration performance.

2.1. Reaction to Maximum Speed and Acceleration

This study involves three drivers, each participating in ten driving experiments to ensure a comprehensive analysis. These experiments are evenly divided between five trials conducted during snowstorms on icy roads and five conducted under sunny conditions on dry roads, resulting in a total of thirty driving instances. The experiments take place on a standardized five-kilometer stretch of road featuring seven stop signs, ensuring consistency across all trials. Data are collected on maximum speed, cruising distance, and other critical metrics, such as longitudinal acceleration and jerk. To enhance the analysis of weather-related impacts on driving styles, we combine experimental data with publicly available data from the SHRP 2 Naturalistic Driving Study (NDS) to extend our database. This comprehensive dataset captures real-world driving behavior under various weather conditions, including rain and snow, complementing the experimental controlled data collected in our study. This integration ensures compatibility by harmonizing key variables, such as speed, acceleration, and braking patterns, across both data sources. Using the strengths of both experimental precision and the representativeness of public data, we validate our findings and improve the robustness of this study. Including diverse datasets ensures a more reliable evaluation of the model's performance across a wide range of environmental scenarios, highlighting its adaptability and effectiveness.

The findings, detailed in Table 1, indicate that drivers adopt a significantly more cautious approach under snowstorm conditions, with notable reductions in speed to enhance safety. Additionally, there is considerable variability in the degree of speed reduction among different drivers, reflecting diverse adaptive strategies in response to icy conditions. This variability provides valuable insights into individual driving styles and their impact on energy regeneration performance in adverse weather conditions. For example, Driver 2, who typically cruises at a maximum speed of 48 km/h on dry roads, shows only a marginal reduction in speed when driving on icy roads, a pattern also observed with Drivers 3 and 4. However, Driver 1, who usually accelerates to 63 km/h in clear conditions, notably decreases their speed to 46 km/h on icy roads. This substantial reduction reflects a significant adjustment, showcasing how Driver 1's approach to hazardous conditions differs markedly from their usual driving style. Such discrepancies highlight the impact of ingrained driving habits, with drivers like Driver 1, accustomed to higher speeds, needing to make more pronounced speed adjustments in response to adverse weather, unlike their more cautious counterparts. Further analysis identifies the Standard Deviation of Braking Behavior (SDBB) as a crucial metric in evaluating braking performance. A higher SDBB typically indicates a greater likelihood of abrupt braking, a characteristic more prevalent

on dry roads where drivers often adopt more aggressive driving styles. Notably, the SDBB for drivers on dry roads is 1.37 times higher than that for drivers in optimal visibility conditions, suggesting a more aggressive braking pattern. These observations are consistent with previous research, which posits that driver style varies significantly between dry and icy conditions, with a noticeable escalation in aggressive actions on dry surfaces.

Table 1. Analysis of driving styles.

Parameters	Drivers	Dry Roads			Icy Roads		
		Max	Mean	SDBB	Max	Mean	SDBB
Speed (km/h)	DR ₁	63	34.85	20.78	46	28.00	13.79
	DR ₂	48	33.81	15.00	42	22.23	13.56
	DR ₃	36	26.68	11.25	30	23.57	8.69
Longitudinal acceleration (m/s ²)	DR ₁	3.234	−0.003	0.38	2.646	−0.072	0.216
	DR ₂	3.03	−0.0005	0.34	1.862	−0.0501	0.241
	DR ₃	2.84	−0.07	0.22	1.47	−0.084	0.191
Jerk (m/s ³)	DR ₁	26.75	0.027	3.75	16.85	0.64	2.13
	DR ₂	35.18	0.004	3.29	19.6	0.451	2.44
	DR ₃	16.46	0.63	2.307	18.81	0.765	1.919

In summary, the analysis clearly highlights how road conditions influence driving style. Drivers tend to adopt a more cautious approach on icy roads to enhance safety, while dry roads often encourage more aggressive driving and braking styles. This adaptability reflects drivers' instinctive responses to different environmental conditions. These insights reaffirm the importance of understanding and adjusting to these conditions not only to improve driving safety but also to enhance braking efficiency. This understanding is crucial for developing adaptive driving assistance systems that respond effectively to varying weather and road scenarios.

2.2. Reactions to Braking Distance

The speed profile and braking distance data for the three drivers under dry and slippery road conditions are presented as solid lines for dry roads and dashed lines for icy roads, as illustrated in Figure 1. These data demonstrate a significant correlation between weather conditions and braking behavior, highlighting the profound impact of environmental variations on road safety. As weather conditions worsen and road friction decreases, drivers naturally adjust their rates of longitudinal deceleration to ensure safety and comfort in all stopping scenarios. The analysis shows that braking distances on slippery roads are longer compared to those on dry roads, attributed to the lower coefficient of friction on icy surfaces, which necessitates increased caution from drivers. Despite the lower maximum speeds observed on slippery roads, the analysis reveals that high-speed braking can increase braking distances by up to 21.76%. Conversely, during low-speed braking, there is a slight decrease in braking distance of 3.54%. Although this reduction might appear marginal, it highlights the critical need to adapt braking strategies based on both speed and road conditions. These findings underscore the crucial role of weather conditions and road friction in driving style, optimizing enhanced regenerative braking performance.




Figure 1. Reactions to braking distance.

2.3. Energy Regeneration: Dry vs. Icy Roads

Figure 2 presents the power recovery results for different driving styles under varying road conditions, neatly divided into two sections. On the left side, the power of drivers on dry roads is showcased, contrasting with the right side, which depicts conditions on slippery roads. This layout allows for a direct comparison, underscoring that regenerative power on slippery roads is significantly lower than on dry roads due to differences in road friction.




Figure 2. Reactions to power regeneration.

Analyzing the driving styles of two drivers, one navigating icy roads and the other dry ones, reveals distinct patterns in speed profiles and power usage. Observations of sudden

fluctuations in these profiles, particularly during short durations, provide valuable insights into how drivers encounter and respond to road irregularities such as gravel, asphalt, or concrete. These fluctuations serve as crucial warning signals, identifying road segments that are likely icy.

Figure 2 effectively demonstrates how high-speed fluctuations correlate with notably low levels of regenerative power, in contrast to segments with stable speed profiles that exhibit higher power values. It is interesting to note that the figure also highlights variable-speed segments that share similar maximum speeds but exhibit significant disparities in output power. The segment outlined by a solid blue triangle and a continuous line shows significantly higher power values. In contrast, the segment marked by a dashed blue triangle displays lower power levels. This difference can be primarily attributed to the influence of the road slope. The first segment (solid blue triangle) corresponds to a nearly flat area, where the vehicle must generate more power to maintain or reach the maximum speed. The second segment (dashed blue triangle) is located on a downhill slope, where inertia and gravity help sustain speed with reduced energy consumption, thereby explaining the lower power values observed.

This analysis clearly shows that road gradient significantly influences regenerative power, along with frictional characteristics and maximum speed, impacting the overall efficiency of the regeneration process. Consequently, any adaptive braking strategy must comprehensively incorporate these parameters to optimize effectiveness and reliability. By accounting for road slope, friction levels, and maximum achievable speed, the adaptive braking system can be fine-tuned to maximize performance across various driving conditions, thereby ensuring both efficiency and safety.

3. Weather-Adaptive Regenerative Braking Strategy Design

3.1. Control Framework

The proposed approach is structured in two primary stages: driving style recognition and energy-efficient deceleration planning, as illustrated in Figure 3. The first stage focuses on recognizing driving styles using a dataset representing different driving styles across diverse weather conditions, specifically contrasting summer and snowy environments. This dataset includes key parameters of the vehicle, such as speed, torque, acceleration, and power, enabling the development of a driving style recognition model based on a Decision Tree algorithm. Speed constraints are established for each driving style class within this model. In the second stage, the driving style recognition model informs the activation of specific control strategies. For instance, when the model identifies “icy road”, typically associated with snowy conditions, it activates an innovative braking strategy designed to adapt to road friction conditions. This strategy adjusts the deceleration horizon based on the road slope, applying a shorter horizon for downhill slopes while optimizing the deceleration profile, whereas natural driving behavior is considered optimal on flat roads. The resulting optimal control problem is then solved using a dynamic programming algorithm, leveraging the speed constraints defined in the first stage. Alternatively, if the model identifies “dry roads”, typically indicative of summer conditions, it deploys the AEDPS strategy studied in our previous work [32]. AEDPS optimizes deceleration planning by considering individual regeneration performance and driver speed preferences. It requires 30 s power forecasts to predict the force regenerated by the driver, $F_{Rgn/Nat}$. Accordingly, the difference between the physical limits of an electrified powertrain, $F_{Rgn/Lmt}$, and the force regenerated by the driver, $F_{Rgn/nat}$, are expressed as $\Delta F = F_{Rgn/Lmt} - F_{Rgn/nat}$. This difference, referred to as the energy regeneration maximization rate, is utilized to update the horizon for deceleration planning. Depending on the resulting value of ΔF , the strategy estimates the best deceleration planning horizon—long, medium, or short—to maximize

energy recovery during deceleration. The long horizon focuses on enhancing regeneration for a high energy regeneration maximization rate, while the medium and short horizons cater to moderate and minimal recovery needs, respectively. When optimal deceleration styles are identified, the system disables ADAS control warnings to drivers. Additionally, the methodology integrates an Adaptive Neuro-Fuzzy Inference System (ANFIS) classification model to enhance the prediction accuracy of the driver's naturalistic regeneration behavior to estimate the energy regeneration maximization rate. In this scenario, the optimal control problem is again addressed using dynamic programming, with the speed constraint informed by the driving style recognition established in the first stage.

Weather-Adaptive Regenerative Braking Strategy




Figure 3. Weather-Adaptive Regenerative Braking Strategy Design.

3.2. Fixed Route and Experimental Setup for Data Collection

This study employs the fixed route, which applies both to vehicles in which the driver takes the same route to work and to commercial vehicles, such as city buses and garbage trucks, that mostly commute on the same routes simultaneously. The selection of fixed routes in this study is used to improve the forecasting of variation in driving styles' on-road characteristics.

- There were no surrounding vehicles, traffic lights, or dynamic obstacles.
- The braking events were initiated by static obstacles, such as stop signs and static objects detected by Mobileye.
- The route covered a total distance of 4 km.
- The selection of the road was made mainly because of the substantial number of stop panels (12 stop signs).

All tests were conducted under consistent environmental conditions to ensure the reliability of the results. Wind speed, temperature, and road surface humidity were maintained at constant values throughout the testing process to minimize external variability. This approach ensured that the observed outcomes are attributed solely to the performance of the regenerative braking system and were not influenced by fluctuating environmental factors. An instrumented 2017 Kia Soul intelligent electric vehicle (EV) collected naturalistic driving data, in-vehicle information, and environmental factors. As depicted in Figure 4, the onboard measurement system comprised the global positioning system (GPS), the onboard diagnostic system (OBD), and the ADAS system installed in the experimental vehicle. The GPS system was a Mozaic-X5 (Septentrio, Leuven, Belgium). Figure 4 shows the OBDlinkMx (Phoenix, Arizona, USA) and Mobileye systems connected to the OBD2 ports for CAN-Bus communication (Intel Corporation, Jérusalem, Israël). The OBDlinkMx operates via Bluetooth on PCs and is responsible for collecting vehicle parameters such as brake and acceleration pedal states, motor torque, etc. Mobileye can recognize obstacles at a longitudinal distance of up to 250 m from the reference point.




Figure 4. Instrumented intelligent electric vehicle (Kia Soul 2017).

3.3. Driving Style Recognition Model and Power Forecasting Using Classification Machine Learning Model

This subsection provides an overview of driving style recognition models, which are typically classified based on the features utilized, the classification outputs they generate, and the specific models employed. Additionally, it introduces a new classification-based prediction model designed to forecast energy regenerated under varying road conditions. This model is a key component of the AEDPS, enhancing its ability to adapt to diverse driving environments.

3.3.1. Classification Features

The process of driving style recognition involves extracting and selecting key features from data provided by sensors or devices in vehicles. These features typically include velocity, acceleration, torque, angular velocity, altitude, longitude, and environmental

conditions such as weather (coded as snowy = 1, summer = 0) and road slope. While there is no universal set of features that suits every predictive model, acceleration is frequently emphasized in past studies as critical for driving style recognition. Additional factors like jerk, throttle opening, and revolutions per minute (rpm) are also important, particularly for estimating braking smoothness and identifying cautious driving styles on slippery roads. We selected these features based on their demonstrated relevance in previous studies. For instance, ref. [48] highlights their essential role in identifying driving behaviors, whether aggressive or cautious. Similarly, ref. [49] emphasizes their effectiveness in recognizing driving patterns under different road conditions. In our previous research [32], we also explored this issue by applying Principal Component Analysis (PCA) to reduce the dimensionality of the dataset used in the prediction model. The correlations between the principal components and the original variables are presented in Table 2, revealing no correlation between them, thereby ensuring their statistical independence. The first principal component was found to be strongly correlated with six key variables: battery current, battery voltage, battery power, motor torque, and, to a lesser extent, the distance-to-stop and speed scores. These results indicate that these six criteria vary together: an increase in one typically leads to an increase in the others. Furthermore, this component is particularly influenced by battery-related variables. The second principal component, on the other hand, is primarily correlated with rotational speed and its equivalent speed. It also shows a strong correlation with road characteristics obtained via GPS data. These analyses indicate that the following features are discriminative and relevant to our study. They are particularly effective in capturing driver responses to environmental factors, such as icy or wet roads, directly influencing driving style recognition.

Table 2. Extracted vectors.

Data	Coefficients of PC1	Coefficients of PC2
Speed	0.23125	0.32684
Distance to stop	0.32548	0.19156
Longitude	0.07202	−0.56701
Latitude	0.06528	0.29689
Altitude	−0.09792	0.54841
Battery current	0.45743	0.01558
Battery voltage	−0.4649	−0.02672
Battery power	0.45818	0.01615
Rotational speed	0.17716	0.33945
Motor torque	0.39247	−0.07497
Acceleration	−0.02749	−0.15498

3.3.2. Classification Outputs

The outputs of driving style recognition models are categorized into distinct classes, each labeled according to the style it represents. This systematization helps in accurately interpreting the varied styles drivers exhibit on the road. Research in this area has introduced various labeling schemes to capture the nuances of driver style, typically using classifications such as normal vs. aggressive or calm vs. aggressive. Although some studies suggest using four or more labels for a more detailed characterization, such implementations are less common due to the increased complexity and potential challenges in maintaining model accuracy. In this study, however, a more detailed approach is employed, resulting in six specific classes: driver 1 on dry roads, driver 1 on icy roads, driver 2 on dry roads, driver 2 on icy roads, driver 3 on dry roads, and driver 3 on icy roads. These classes are distinctly labeled to differentiate styles under varying weather conditions, such as drivers on dry versus icy roads. This granular categorization provides a deeper insight into

how different environmental contexts influence driving styles. Additionally, the model's capability to categorize many drivers accommodates the diversity and complexity found in real-world driving scenarios. This enhanced adaptability improves the model's utility and applicability in broader transportation and safety applications, facilitating more effective decision-making based on a comprehensive analysis of driving styles.

3.3.3. Classification Models

The driving style recognition models evaluated in this study include Decision Trees, SVM, and ANFIS, each selected for its unique strengths and proven effectiveness. Decision Trees stand out for their simplicity and high classification accuracy, particularly when applied to time series data. SVM excels in managing non-linear patterns and high-dimensional datasets, ensuring reliable differentiation of driving styles. Meanwhile, ANFIS combines the advantages of Fuzzy Logic and neural networks, allowing for in-depth and nuanced analysis of driving behaviors. These models were chosen based on their complementary strengths and their demonstrated success in prior studies, including research published in [48]. Our research goes beyond a straightforward comparison of Decision Trees, SVM, and ANFIS by focusing on enhancing their accuracy through systematic optimization of structural and training parameters. To achieve this, we employ advanced feature extraction and selection techniques, ensuring that the models are equipped to interpret complex datasets with greater precision. These methodologies are central to improving the robustness and effectiveness of the models, enabling them to capture intricate patterns and deliver reliable driving style recognition across diverse scenarios.

3.3.4. Forecasting Power Model: Icy vs. Dry Roads

Given the significant differences in regeneration behavior between icy and dry roads, and considering the diversity of driving styles under various road conditions captured in the database utilized in this new approach, it is essential to employ a new power prediction model based on classification to enhance forecast accuracy. This is particularly crucial because power prediction plays a key role in braking control when utilizing AEDPS. Consequently, ANFIS is chosen as one of the most advanced and popular models in the current state of the art. Its natural capability to handle complex structures makes it an ideal choice for this application. Notably, ANFIS is based on a Fuzzy Logic classifier specifically designed for range estimation, which is a crucial and timely research topic in the field of electric vehicles today [50].

The ANFIS model presents unique challenges in time series analysis due to its lack of a distinct periodic nature, rendering it prone to neither converging nor diverging. This sensitivity to initial conditions is a benchmark issue in the domains of both neural network and fuzzy modeling. To overcome these challenges, researchers have utilized the fourth-order Runge–Kutta method to derive numerical solutions for the Mackey–Glass equation, which facilitates the extraction of time series values at integer intervals. The ANFIS model is trained to predict time series data defined by the Mackey–Glass (MG) time-delay differential equation:

$$\dot{x}(t) = \frac{0.2x(t-\tau)}{1+x^{10}(t-\tau)} - 0.1x(t) \quad (1)$$

Assuming initial conditions $x(0) = 1.2$, $\tau = 17$, and $x(t) = 0$ for $t < 0$, the MG time series can be generated. To plot the MG time series, use the provided command. The time series prediction process involves using existing data points up to the point of prediction $x = t + P$ to estimate the value at a future time point.

The conventional approach for such predictions establishes a correspondence between input vector from D points spaced Δ apart, specifically $(x(t - (D - 1)\Delta), \dots, x(t - \Delta), x(t))$,

to predict a future value $x(t + P)$. This method adheres to the customary parameters used to forecast the MG time series. If we assume the input vector $D = 4$ and the predicted future point $\Delta = P = 6$,

$$x(t + 6) = F[x(t), x(t - 6), x(t - 12), x(t - 18)] \quad (2)$$

To address the limitations of the ANFIS prediction model, we implemented targeted measures to improve data quality, mitigate biases, and optimize computational efficiency. A diverse and representative dataset was curated that included various driving styles, weather conditions, and road types. Preprocessing, including normalization, outlier removal, and class balancing, ensured robust data quality. Biases were identified and corrected through exploratory data analysis and a systematic evaluation framework. To address computational constraints, we reduced rule complexity using Fuzzy C-Means clustering, utilized parallel computing to accelerate training, and optimized parameters with advanced algorithms. These efforts significantly improved the robustness, efficiency, and real-world applicability of the model.

3.3.5. Validation Model

The effectiveness of our approach, particularly in terms of precision, is evaluated using the following accuracy formula for the driving style recognition model:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

Here, True Positives (TP) and True Negatives (TN) represent correctly predicted positive and negative instances, respectively. False Positives (FP) and False Negatives (FN) represent incorrectly predicted positive and negative instances, respectively.

The main goal of the forecasting power model is to minimize the discrepancy between measured and forecasted regenerative power over the next 12 s. The evaluation of regenerative power forecasting accuracy involves five metrics. Although Mean Absolute Percentage Error (MAPE) is commonly used for forecasting accuracy, it is criticized for producing undefined or extreme values when actuals are zero or close to zero, respectively. Therefore, this study employs alternative metrics that do not suffer from these limitations: R-Squared, Mean Absolute Error (MAE), Normalized Mean Absolute Error (NMAE), Symmetric Mean Absolute Percentage Error (sMAPE), and Root Mean Squared Error (RMSE). The equations for these metrics are detailed in Table 3.

Table 3. Evaluation performance model metric.

Performance Metric	Definition
Mean Absolute Error (MAE)	$MAE = \frac{1}{N} \sum_{i=1}^{N_i} Py_i - Y_j $
Mean Relative Absolute Error (MRAE)	$MRAE = \frac{1}{N} \sum_{i=1}^{N_i} \frac{ Y_i - Py_i }{ y_i }$
Root Mean Square Error (RMSE)	$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^{N_i} (Py_i - Y_i)^2}$
Coefficient of Determination R^2	$R^2 = 1 - \frac{\sum_{i=1}^i (Y_i - Py_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y}_i)^2}$

3.4. Energy-Efficient Deceleration Planning

The energy-efficient deceleration planning algorithm shown in Algorithm 1 is designed to optimize braking based on weather and road conditions. It takes as input a driving style class C , which includes speed constraints, and the slope θ_i . For each driving style class c_i

in C and slope condition θ_i , the algorithm selects the appropriate braking strategy. If c_i is classified as “dry”, the algorithm applies the AEDPS strategy and computes an optimal sequence constrained by speed limits suitable for dry conditions. If c_i is classified as “icy” and has “downhill” slopes, a shorter planning horizon is used, optimizing the deceleration profile by considering speed constraints that are adapted to icy conditions as defined by the driving style class C . For “icy” and “flat” conditions, the algorithm adopts a naturalistic driving behavior with optimal driving parameters and disables alerts. The output is an optimal deceleration profile a^* and a deceleration planning horizon h . The algorithm for deceleration planning is presented below.

Algorithm 1 Energy-Efficient Deceleration Planning

Require: driving styles class C (includes speed constraints), Slope θ

```

1: for each slope condition  $\theta_i$  do
2:   if  $c_i = \text{dry}$  then
3:      $\text{return} \leftarrow \text{AEDPS STRATEGY}$ 
4:      $\text{Set Optimal sequence}\{a^*\} \leftarrow \text{RESULT BASED ON AEDPS}$ 
5:   else if  $c_i = \text{icy}$  and  $\theta_i = \text{downhill}$  then
6:      $\text{Planning horizon} \leftarrow \text{short}$ 
7:      $\text{Set Optimal sequence}\{a^*\} \leftarrow \text{RESULT BASED ON ICY ROAD FRICTION}$ 
8:   else if  $c_i = \text{icy}$  and  $\theta_i = \text{flat}$  then
9:      $\text{return} \leftarrow \text{NATURALISTIC DRIVING BEHAVIOR}$ 
10:  end if
11: end for
12: return Optimal deceleration profile  $\{a^*\}$ , Planning horizon  $h$ 

```

3.4.1. Model of Braking Deceleration

The braking deceleration dynamics are modeled to determine the most effective deceleration pattern. This method leverages the fundamental functionality of an Anti-lock Braking System (ABS) to calculate the optimal braking deceleration [51]. The slip ratio, denoted by s , is a crucial metric in this analysis, quantifying the extent of sliding between the tire and the road surface. It is mathematically defined as

$$s = \frac{\omega \cdot r - v}{\max(\omega \cdot r, v)} \quad (4)$$

where ω represents the rotational speed of the wheel, r denotes the wheel radius, and v signifies the longitudinal velocity of the wheel, which is commonly approximated by the vehicle speed in practical scenarios.

Furthermore, the braking force coefficient φ_b , which is distinct from the friction coefficient, varies based on the type of resistive force involved and is defined as the ratio of the brake force exerted on the ground to the perpendicular load. This coefficient can be found in the literature or determined experimentally. It is formally expressed as

$$\varphi_b = \frac{F_X}{F_Z} \quad (5)$$

The braking force coefficient φ_b varies as a function of the slip ratio. Figure 5 illustrates the dynamic relationship between φ_b and the slip ratio, emphasizing how changes in the slip ratio influence braking performance, particularly on icy surfaces. Initially, in phase OA , the slip ratio is low, indicating no slippage between the tire and the road. As the slip ratio increases and transitions into phase AB , the braking force coefficient φ_b rises progressively under favorable road conditions, eventually reaching an optimal level at point B . Beyond this point, in phase BC , the slip ratio increases, causing the wheel to skid completely on

the surface. This skidding drastically reduces the braking force coefficient, φ_b , to its lowest level, severely diminishing braking efficiency.




Figure 5. Road friction [51].

In reference to the slip ratio illustrated in Figure 5, point O represents the origin coordinate, while point B(s_p, φ_p) denotes the peak coefficient of friction. Point A has coordinates ($K_1 \cdot s_p, K_2 \cdot \varphi_p$), where the inequality $\frac{\varphi_p - K_2 \cdot \varphi_p}{s_p - K_1 \cdot s_p} < \frac{K_2 \cdot \varphi_p}{K_1 \cdot s_p}$ holds. Additionally, point C(s_s, φ_s) represents the sliding coefficient of friction, with the slip ratio reaching 100%.

During phase OA, the slip ratio remains relatively low. Despite the presence of a slip ratio due to changes in the rolling radius, actual sliding between the tire and the ground does not occur. Upon application of the braking force, the contact area ahead of the tire tread extends slightly, with the rate of increase in the rolling radius being directly proportional to the braking force. As a result, the curve of φ_b can be approximated to a straight line, expressed by the assumed linear relationship

$$\varphi_b = a_1 s \quad (6)$$

If the coordinates of point A are obtained, the slope a_1 can be calculated using Equation (6):

$$a_1 = \frac{K_2 \cdot \varphi_p}{K_1 \cdot s_p} \quad (7)$$

During phase AB, the slip ratio reaches its optimal state due to favorable road conditions. Within this phase, localized sliding occurs between the tire and the ground, resulting in a deceleration of the growth rate of φ_b until the optimal slip rate is achieved at point B. The curve representing φ_b is approximated as a quadratic curve within this phase. The equation for the curve is given by

$$\varphi_b = a_2 s^2 + bs \quad (8)$$

If the coordinates of points A and B are known, the coefficients a_2 and b can be calculated using the following equations:

$$\begin{cases} a_2 = \frac{K_1^2 - K_2}{2s_p(K_1 - K_1^2)} \\ b = \frac{(K_2 - K_1^2)\varphi_p}{(K_1 - K_1^2)s_p} \end{cases} \quad (9)$$

In phase BC , the higher the slip rate, the smaller the braking force coefficient φ_b becomes, reaching 100% at point C , indicating complete slippage of the wheel on the ground. In this phase, the curve of φ_b can be approximated by a linear relationship, assumed as

$$\varphi_b = a_3s + c \quad (10)$$

If the coordinates of points B and A are known, the coefficients a_3 and c can be calculated using the equations

$$\begin{cases} a_3 = \frac{\varphi_s - \varphi_p}{1 - s_p} \\ c = \frac{\varphi_p - \varphi_s \varphi_p}{1 - s_p} \end{cases} \quad (11)$$

According to Equation (4), the maximum braking deceleration is given by

$$a_{b\max} = \varphi_b g \quad (12)$$

where g is the acceleration due to gravity.

Two brake parameters, pressure-regulating frequency and adjusting amplitude, are incorporated into the model, affecting the braking deceleration as follows:

$$a = a_{b\max} - \frac{1}{2}\delta + \frac{1}{2}\delta \cos \omega(t) \quad (13)$$

Here, ω represents the regulating frequency, which varies from 19 rad/s to 126 rad/s depending on vehicle speed and road condition, and δ is the adjusting amplitude, calculated as

$$\delta = (\varphi(0.2) - \varphi(0.15)) \cdot g \quad (14)$$

Assuming the road surface is fine, and substituting Equation (7) for φ_b , the braking deceleration can be modeled as

$$a = g(a_2s^2 + bs) - \frac{\delta}{2} + \frac{\delta}{2} \cos \omega(t) \quad (15)$$

3.4.2. Energy Optimization on Icy Roads by Dynamic Programming

In the proposed strategy, the dynamic programming (DP) method is employed to optimize the deceleration profile. This method takes into account the environmental conditions of EV operation, including the slope and deceleration constraint of driving style on icy roads.

The braking force in vehicle dynamic models can be mathematically expressed as follows:

$$F_{\text{Brk}}(t) = F_{\text{Rgn}}(t) + F_{\text{Frc}}(t) = Ma(t) + \frac{1}{2}\rho AC_d v(t)^2 + Mg(\mu \cos(\theta) + \sin(\theta)) \quad (16)$$

The vehicle's speed, mass, acceleration, cross-sectional area, and frontal drag coefficient, are represented by $v(t)$, m , $a(t)$, A , and C_d , respectively. $F_{\text{Frc}} \leq 0$ is the frictional force, and $F_{\text{Rgn}} \leq 0$ is the energy-regenerative deceleration force. Assume that $F_{\text{Frc}} \approx 0$.

The speed profile is a temporal and spatial process, which makes $v(X(t))$ represent the speed profile at a specific observation station (i.e., location) at time t . Furthermore, the speed profile and deceleration duration can be described as follows:

$$t_N = \sum_{i=0}^{N-1} \frac{\Delta X_i}{v_i} \quad (17)$$

Assume the deceleration starts at vehicle position X_k and finishes at position X_N . For any position X_i where $k \leq i \leq N$, the slope θ_i and the vehicle's longitudinal speed v_i and acceleration a_i at X_i are known. The acceleration formulas under different road conditions, defined by $a_{i/\text{dry}}$ on dry roads, and $a_{i/\text{icy}}$ on icy roads, are given by

$$a_i = \begin{cases} a_{i/\text{dry}} = g(a_2 s^2 + bs) - \frac{\delta}{2} + \frac{\delta}{2} \cos \omega(t) \\ a_{i/\text{icy}} = g(a_3 s + bs) - \frac{\delta}{2} + \frac{\delta}{2} \cos \omega(t) \end{cases} \quad (18)$$

The total energy E_N during the vehicle's deceleration on icy roads from X_k to X_N is expressed as

$$E_N = E_k + \sum_{i=k+1}^N F_{\text{Rgn}}(v_{i/\text{icy}}, a_{i/\text{icy}}, \theta_i) \Delta \dot{X} \quad (19)$$

where E_k is the kinetic energy at X_k and $F_{\text{Rgn}}(v_{i/\text{icy}}, a_{i/\text{icy}}, \theta_i) < 0$ represents the regenerative force profile from X_k to X_N . $\Delta \dot{X} = \dot{X}_{i+1} - \dot{X}_i$.

The optimal energy during the deceleration on icy roads is calculated as

$$E_N^* = \min_{a_i} \left[E_k + \sum_{i=k+1}^N F_{\text{Rgn}}(v_{i/\text{icy}}, a_{i/\text{icy}}, \theta_i) \Delta \dot{X} \right] \quad (20)$$

$$a_{\min} \leq a_{i/\text{icy}} \leq a_{\max} \quad (21)$$

Using DP, the optimal sequence $\{a_{i/\text{icy}}^*\} = \{a_{i/\text{icy}}, k+1 \leq i \leq N\}$ is determined by

$$\{a_{i/\text{icy}}^*\} = \arg \min_{a_i} \left[E_k + \sum_{i=k+1}^N F_{\text{Rgn}}(v_{i/\text{icy}}, a_{i/\text{icy}}, \theta_i) \Delta \dot{X} \right] \quad (22)$$

Given $a_{i/\text{icy}}^*$, the optimal deceleration speed profile is obtained by integrating $\{a_{i/\text{icy}}^*\}$. Subsequently, the objective function is defined based on the predicted braking style from the recognition model, incorporating road and weather condition data. Constraints are then established reflecting the specific driving style on road conditions. An optimization algorithm is subsequently applied to determine the optimal deceleration profile, taking into account the defined objective function and the set constraints specific to icy roads. Under conditions of permanent ice, the regeneration effect is determined by integrating the value of $a_{i/\text{icy}}^*$ into the control model using dynamic equations linked to the slip ratio. A deceleration profile, dynamically adjusted based on weather conditions and slope, allows the regenerative braking to be proactively modulated to prevent a significant decrease in efficiency caused by excessive slippage. This procedure facilitates dynamic adjustment of braking strategies, enhancing vehicle safety and performance across various road and weather conditions.

4. Results and Discussion

This section assesses the benefits of the proposed WARBS strategy. The evaluation begins with a simulation to assess the performance of the driving style recognition model

using MATLAB R2023a (MathWorks, Natick, MA, USA). Next, the assessment of energy regeneration efficiency enhancement on mixed icy and dry roads is conducted.

4.1. Results of Driving Style Recognition Model

Classifier Model Comparison

Figures 6–8 present the classification results for three different models: Decision Tree, ANFIS, and SVM. Despite the similarity in power regeneration amplitudes across different drivers, our proposed method demonstrates exemplary performance. The Decision Tree model, in particular, achieves 100% accuracy during both the validation and testing phases. For all classification strategies, the dataset was split into 67% for training and 33% for testing. The confusion matrices for each model are displayed in the corresponding figures. The classes are numbered as follows:

- Class 1: Driver 1 on icy roads (Dr1/Icy)
- Class 2: Driver 1 on dry roads (Dr1/Dry)
- Class 3: Driver 2 on icy roads (Dr2/Icy)
- Class 4: Driver 2 on dry roads (Dr2/Dry)
- Class 5: Driver 3 on icy roads (Dr3/Icy)
- Class 6: Driver 3 on dry roads (Dr3/Dry)

The drivers are analyzed based on distinct characteristics, such as maximum speed, longitudinal acceleration, and jerk values (rate of change of acceleration). Driver 1 exhibits a dynamic driving style, particularly noticeable on dry roads, with higher maximum speeds and acceleration values than the other drivers. On icy roads, while speeds are reduced, the style remains relatively aggressive, with significant variations in acceleration and jerk parameters. Driver 2 adopts a moderate style, characterized by lower maximum speeds and more stable driving. The smooth speed adjustments and minimal variations in acceleration values reflect a cautious approach, especially in slippery conditions. Driver 3 stands out with a conservative driving style, featuring significantly lower maximum speeds and reduced jerk and acceleration values, demonstrating an adaptation to slippery road conditions. Table 4 shows an RMSE of 0.038 for SVM, 0.0071 for ANFIS, and 0 for Decision Tree. For the SVM model, presented in Figure 8, the most common misclassification involves samples from Class 1 (Dr1/Icy) being incorrectly classified as Class 3 (Dr2/Icy), with six misclassified samples, constituting only 0.0013% of all samples from Class 1. The ANFIS, shown in Figure 6, also misclassifies samples from Class 1 as Class 3 at a rate of 2.24% and samples from Class 5 (Dr3/Icy) as Class 3 at a rate of 7.34%. The Decision Tree model, illustrated in Figure 7, achieves the highest overall accuracy of 100%, making it particularly effective in identifying the six specified driving styles, thereby validating its application in our strategy. The analysis of the results shows that driving characteristics such as speed, acceleration, and jerk are essential for distinguishing driving styles under varying conditions. The differences observed between Drivers 1, 2, and 3 highlight the models' ability to effectively recognize behaviors based on weather conditions. These findings further support the relevance of the models and their suitability for the proposed strategy.

Table 4. Result of classification model.

Algo	RMSE	MAE	R^2
Decision Tree	0	0	1
SVM ^{multiclass}	0.0388	0.000073	0.9996
ANFIS	0.0071307	0.0000508	1




Figure 6. Confusion matrix of ANFIS.




Figure 7. Confusion matrix of Decision Tree.




Figure 8. Confusion matrix of SVM.

4.2. Results of Power Forecasting-Based Classification Method

To evaluate the performance of the proposed ANFIS-based classification forecasting method for power regeneration, we present the results in Figure 9. These results are compared with those from the Long Short-Term Memory (LSTM) forecasting method proposed

by [32], validating the necessity, reliability, and effectiveness of our approach. The dataset utilized for forecasting consists of driving data from three drivers across two weather conditions, summer and snowy, resulting in six distinct driving style variations, with each behavior documented over ten trips. Figure 9 illustrates the comparison of precision rates between the ANFIS model and the LSTM model, using RMSE as a metric for accuracy in power regeneration prediction. The LSTM model records an accuracy of 0.63 kW, a decrease from the 0.4402 kW reported in [32] for summer styles alone, attributed to the inclusion of icy road data. In contrast, the ANFIS model shows significant improvement, achieving an RMSE of 0.3677 kW. Table 5 details the performance of the ANFIS model with various membership functions, highlighting that the psigmf membership function yields the highest precision. Typically, classification-based prediction models outperform non-classification models, as rule-aligned consumption models exhibit greater regularity and predictability compared to general consumption models. This higher precision is expected, as the complexity inherent in non-classification approaches tends to reduce prediction accuracy. In conclusion, the proposed method successfully classifies time series data, achieving a high level of prediction accuracy. Furthermore, the expanded dataset facilitated the generation of more profiles through classification, which contributed to reduced volatility and enhanced accuracy in load predictions.

Table 5. Anfis result of forecasting power with different membership functions.

Membership Function	MAE	RMSE	R^2
trimf	0.942	0.38069	0.9670
gaussmf	1.0213	0.3701	0.9639
gauss2mf	1.0548	0.36841	0.9629
gbellmf	1.0445	0.3688	0.9631
dsigmf	1.0402	0.36773	0.9618
psigmf	1.04027	0.3677	0.9618
pimf	1.0649	0.3681	0.9628




Figure 9. Comparing the RMSE of the proposed ANFIS model with that of the LSTM methodology, excluding classification.

4.3. Enhancing Energy Regeneration Efficiency on Mixed Icy and Dry Roads

The Table 6 assess the performance of the proposed WARBS, drivers' naturalistic regeneration performance on mixed and dry roads, as well as the AEDPS designed specifically for dry roads, were provided for comparison. To facilitate this comparison, tests were conducted on a route composed of five distinct segments, each designed to offer varied conditions. The road friction levels and slopes differed between these segments, allowing for a comprehensive evaluation of the braking efficiency of each strategy.

Table 6. Driving segment parameters.

Parameter	Driver	Driving Segment				
		1	2	3	4	5
Slope	All	Downhill/dry	Downhill/icy	Flat/dry	Downhill/icy	Downhill/icy
FRgn/nat (N) from naturalist driving	1	−1559	−649	−384	−495	−562
	2	−1743	−457	−1263	−350	−110
	3	−3745	−784	−2750	−549	−698
FRgn/opt (N) obtained by AEDPS	1	−3498	−649	−2210	−495	−562
	2	−1743	−457	−1352	−350	−110
	3	−4634	−784	−3340	−549	−698
AEDPS horizon	1	Long	False alert	Long	False alert	False alert
	2	Optimal	False alert	Short	False alert	False alert
	3	Medium	False alert	Long	False alert	False alert
FRgn/opt (N) obtained by WARBS	1	−3498	−960	−2210	−763	−811
	2	−1743	−590	−1352	−420	−310
	3	−4634	−1187	−3340	−893	−983
WARBS horizon	1	Long	Short	Long	Short	Short
	2	Optimal	Short	Short	Short	Short
	3	Medium	Short	Long	Short	Short

The results provides detailed driving parameters for three drivers (Driver 1, Driver 2, and Driver 3) across five segments. The table includes information on slope types, regeneration forces under three scenarios (naturalistic driving, AEDPS strategy, and WARBS approach) and the corresponding deceleration planning horizons. Specifically, the numbers listed in the table indicate the performance for Driver 1, Driver 2, and Driver 3 in each row under their respective scenarios. Importantly, all three approaches were tested by the same drivers, ensuring consistency in driving behavior and conditions across the different scenarios. The regeneration forces obtained under the AEDPS strategy $F_{Rgn/Opt}$ are calculated using an electric vehicle model designed to maximize power regeneration up to the powertrain limit while optimizing vehicle speed. Similarly, the regeneration forces from the WARBS approach are optimized for vehicle speed while adapting to varying weather conditions. For comparison, the regeneration forces from naturalistic driving $F_{Rgn/Nat}$ are estimated based on drivers' behaviors under mixed road conditions (dry and icy). The table highlights significant variability in regeneration forces across segments and drivers. For example, Driver 1 exhibits $F_{Rgn/Nat}$ values ranging from −1559 N to −3745 N in segment 1, reflecting differences in driving behavior. Generally, regeneration forces are lower on icy segments (segments 2, 4, and 5) compared to dry segments, indicating the limitations of naturalistic driving under low-traction conditions. Additionally, the AEDPS and WARBS strategies consistently outperform naturalistic driving in terms of power regeneration, with optimized regeneration forces closely tailored to slope and weather conditions.

The AEDPS strategy generally improves energy regeneration compared to naturalistic driving, although the level of improvement varies by segment. For instance, for Driver 1 in segment 3, $F_{Rgn/Opt} = -2210$ N (AEDPS) compared to −384 N (naturalistic driving).

Similarly, the results demonstrate that AEDPS effectively adjusts the deceleration planning horizons based on naturalistic regeneration performance on dry roads. For example, in segment 1, Driver 2 is evaluated as performing optimally, and AEDPS offers no significant improvement in regeneration. This is primarily because the driver's naturalistic regeneration performance is close to the powertrain's regeneration limit. However, on icy road segments, the AEDPS strategy leads to false alerts and suboptimal performance, as it is not designed to handle road conditions other than dry surfaces. This limitation underscores the need for a more versatile approach capable of addressing the complexities of mixed road conditions. These findings reveal that while AEDPS provides gains over naturalistic driving, it demonstrates clear limitations under extreme conditions, particularly on icy roads. The table also highlights that only the WARBS strategy is capable of maximizing regeneration under all road conditions, whether icy or dry, by planning deceleration with a short horizon on downhill slopes. This demonstrates that WARBS significantly outperforms AEDPS across most segments, especially in icy conditions. For instance, for Driver 3 in segment 4, the optimal regeneration force achieved with WARBS is $F_{\text{Rgn/Opt}} = -893$ N compared to only -549 N with AEDPS, showcasing a substantial improvement. These results confirm that the braking assistance provided by the WARBS strategy excels in both efficiency and adaptability, offering a high rate of user acceptance due to its reliable alerts and scalability, which effectively address diverse weather conditions.

Figures 10 and 11 illustrate the maximization of regeneration on segments with icy and dry roads, respectively. These figures present the distance traveled, speed, planning horizon, and profiles of both natural and optimized regeneration forces for electric vehicles. As shown in Figure 10a, the driver's speed profile on flat icy roads generates a maximum natural regeneration force, $F_{\text{Rgn/Nat}}$ (blue lines), of -450 N, which is considered optimal. In contrast, Figure 10b displays the driver's speed profile on downhill slopes, suggesting a short-term deceleration profile that improves regeneration from -140 N to -450 N (green line). Furthermore, the force profile demonstrates that significant deceleration on a downhill road results in substantial transient regeneration forces. However, this is not the case for cruising modes, which lead to low demands for transient regeneration forces. This analysis highlights the importance of adaptive deceleration planning to maximize energy recovery, particularly under varying road slope conditions. Figure 11 illustrates the results when the driving style is classified by the model as occurring on dry roads. In this scenario, the strategy adopts a long-term planning horizon due to a significant difference, $\Delta F = F_{\text{Rgn/Lmt}} - F_{\text{Rgn/Nat}}$, as previously discussed. Additionally, $F_{\text{Rgn/Opt}}$ (green lines) reaches the regeneration capacity limit of the powertrain, $F_{\text{Rgn/Lmt}}$ (red lines), maximizing energy recovery without losses caused by slippage. Similar to Figure 10, the convergence trend of $F_{\text{Rgn/Opt}}$ on road slopes demonstrates that the strategy effectively accounts for road load variations and confirms its ability to track the regeneration limit. This validates the robustness of the approach in maximizing energy recovery under dry road conditions.

Table 7 compares the performance of each method relative to naturalistic driving. The percentage improvement in performance (PI) is calculated as follows:

$$PI(\%) = \frac{F_{\text{method}} - F_{\text{Rgn/nat}}}{F_{\text{Rgn/nat}}} \times 100 \quad (23)$$

where

- PI : Performance improvement (percentage of performance improvement).
- F_{method} : Regeneration force obtained by the method being evaluated (e.g., AEDPS or WARBS).

The results from scenarios on icy roads 2, 4, and 5 indicate that efficiency improvement rises from zero with the application of AEDPS to significant levels with the implementation of WARBS, varying according to driving style and segment. Moreover, both methods exhibited consistent performance in dry segments. Consequently, the proposed method achieved optimal regeneration efficiency under both dry and icy road conditions, a distinction not matched by the standard AEDPS method. This conclusion is further supported by Table 8, which compares the efficiency of both methods and demonstrates the added value of WARBS. Notably, compared to AEDPS, WARBS achieved energy regeneration maximization improvement for all trajectories of 11.6% for Driver 1, 10.4% for Driver 2, and 10.31% for Driver 3, highlighting its effectiveness not only on dry roads but also on icy roads.

The results highlight the critical importance of adopting an adaptive braking strategy, enabling significant maximization of energy regeneration under mixed conditions, including both dry and icy roads. The approach proposed in this study overcomes the limitations of other braking strategies, which are typically confined to specific weather conditions, either exclusively dry or icy.




Figure 10. Regeneration maximization on icy segments by WARBS.




Figure 11. Regeneration maximization on dry segments by WARBS.

Table 7. The percentage of performance improvement of the methods compared to naturalistic driving.

		Driving Segment				
Method	Driver	1	2	3	4	5
PI_{AEDPS} (%)	1	124.3	0	475.5	0	0
	2	0	0	7.04	0	0
	3	23.73	0	21.45	0	0
PI_{WARBS} (%)	1	124.3	47.91	475.5	54.14	44.30
	2	0	29.10	7.04	20	181.81
	3	23.75	51.40	21.45	62.65	40.83

Table 8. Comparison of AEDPS and WARBS.

		Driving Segment				
Driver		1	2	3	4	5
1	0	47.91	0	54.14	44.30	
2	0	29.10	0	20	181.81	
3	0	51.40	0	62.65	40.83	

5. Conclusions

This research makes several noteworthy contributions to the field of regenerative braking. First, the driving style recognition model effectively differentiates between behaviors on icy and dry roads, enabling the implementation of customized braking strategies tailored to varying conditions. Second, dynamic programming adjusts deceleration horizons in real time, striking an optimal balance between safety and energy recovery. Finally, simulations and experimental validations confirm the system's ability to maximize energy recovery under challenging conditions, such as icy roads and steep slopes. From a practical perspective, this methodology optimizes energy recovery by fine-tuning braking forces in low-adhesion scenarios, enhancing safety through adaptive control, and demonstrating its feasibility for real-world applications. Notably, this strategy achieved significant energy recovery improvements, with regeneration gains of 11.6% for Driver 1, 10.4% for Driver 2, and 10.31% for Driver 3, calculated as averages across all tested trajectories. These results underline its effectiveness in optimizing braking performance on both dry and icy roads. Additionally, the approach highlights its adaptability and superior performance to traditional methods, particularly in minimizing false alerts and maximizing deceleration efficiency. The findings offer actionable recommendations for designers and engineers. Adaptive braking systems should prioritize dynamic adjustments to varying road and weather conditions, leveraging advanced sensors for real-time monitoring. In regions with frequent icy conditions, such as northern Europe or mountainous areas, these strategies deliver significant benefits in improving both safety and energy recovery. In contrast, for more stable climates, simplified braking systems can provide cost-effective solutions while maintaining essential functionality. Furthermore, dynamic programming and predictive models should be explored to refine braking systems, tailoring them to specific driving behaviors and environmental scenarios. While this study represents a significant step forward in regenerative braking strategies, future research could further enhance the model by incorporating additional environmental factors. For example, integrating wind speed as a dynamic parameter could offer deeper insights into its effects on energy recovery and vehicle stability. Wind resistance, particularly at higher speeds, significantly impacts energy consumption, and real-time wind speed estimation could help optimize braking strategies to mitigate these effects. Additionally, accounting for the influence of ambient temperature on battery performance and energy regeneration efficiency would provide a more comprehensive model. Since batteries exhibit reduced efficiency in extreme cold or heat, temperature-dependent adjustments to regeneration settings could maximize energy recovery while protecting battery health. In conclusion, this study offers an adaptive, efficient, and practical solution to regenerative braking, tailored to diverse climatic and road conditions. It provides valuable insights for the development of next-generation electric vehicles, advancing energy optimization, safety, and system reliability in a variety of driving scenarios.

Author Contributions: Conceptualization, M.Z. and S.K.; methodology, M.Z.; software, M.Z.; validation, M.Z. and S.K.; resources, S.K.; data curation, M.Z.; writing—original draft preparation, M.Z.; writing—review and editing, S.K. and A.A.; supervision, S.K. and K.A.; funding acquisition, S.K. All authors have read and agreed to the published version of the manuscript.

Funding: This research was funded by the Foundation of Université du Québec à Trois-Rivières, Canada Research Chair Program; Natural Sciences and Engineering Research Council of Canada.

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: Data are contained within the article.

Acknowledgments: The authors would like to thank the Foundation of Université du Québec à Trois-Rivières, Canada Research Chair Program; Natural Sciences and Engineering Research Council of Canada.

Conflicts of Interest: The authors declare no conflicts of interest.

References

1. Dyke, K.J.; Schofield, N.; Barnes, M. The impact of transport electrification on electrical networks. *IEEE Trans. Ind. Electron.* **2010**, *57*, 3917–3926. [\[CrossRef\]](#)
2. Li, D.; Chen, W. TIMES modeling of the large-scale popularization of electric vehicles under the worldwide prohibition of liquid vehicle sales. *Appl. Energy* **2019**, *254*, 113627. [\[CrossRef\]](#)
3. Ronanki, D.; Williamson, S.S. Modular multilevel converters for transportation electrification: Challenges and opportunities. *IEEE Trans. Transp. Electr.* **2018**, *4*, 399–407. [\[CrossRef\]](#)
4. Pereirinha, P.G.; González, M.; Carrilero, I.; Anseán, D.; Alonso, J.; Viera, J.C. Main trends and challenges in road transportation electrification. *Transp. Res. Procedia* **2018**, *33*, 235–242. [\[CrossRef\]](#)
5. Ghandriz, T.; Jacobson, B.; Laine, L.; Hellgren, J. Impact of automated driving systems on road freight transport and electrified propulsion of heavy vehicles. *Transp. Res. Part C Emerg. Technol.* **2020**, *115*, 102610. [\[CrossRef\]](#)
6. Holland, S.P.; Mansur, E.T.; Muller, N.Z.; Yates, A.J. The environmental benefits of transportation electrification: Urban buses. *Energy Policy* **2021**, *148*, 111921. [\[CrossRef\]](#)
7. Hamada, A.T.; Orhan, M.F. An overview of regenerative braking systems. *J. Energy Storage* **2022**, *52*, 105033. [\[CrossRef\]](#)
8. Chen, J.; Hu, H.; Wang, M.; Ge, Y.; Wang, K.; Huang, Y.; Yang, K.; He, Z.; Xu, Z.; Li, Y.R. Power Flow Control-Based Regenerative Braking Energy Utilization in AC Electrified Railways: Review and Future Trends. *IEEE Trans. Intell. Transp. Syst.* **2024**, *25*, 6345–6365. [\[CrossRef\]](#)
9. Ren, G.; Ma, G.; Cong, N. Review of electrical energy storage system for vehicular applications. *Renew. Sustain. Energy Rev.* **2015**, *41*, 225–236. [\[CrossRef\]](#)
10. Geraee, S.; Mohammadbagherpoor, H.; Shafiei, M.; Valizadeh, M.; Montazeri, F.; Feyzi, M.R. Regenerative braking of electric vehicle using a modified direct torque control and adaptive control theory. *Comput. Electr. Eng.* **2018**, *69*, 85–97. [\[CrossRef\]](#)
11. Jin, Q.; Wu, G.; Boriboonsomsin, K.; Barth, M.J. Power-based optimal longitudinal control for a connected eco-driving system. *IEEE Trans. Intell. Transp. Syst.* **2016**, *17*, 2900–2910. [\[CrossRef\]](#)
12. Hao, P.; Wu, G.; Boriboonsomsin, K.; Barth, M.J. Eco-approach and departure (EAD) application for actuated signals in real-world traffic. *IEEE Trans. Intell. Transp. Syst.* **2018**, *20*, 30–40. [\[CrossRef\]](#)
13. Chen, Z.; Wu, S.; Shen, S.; Liu, Y.; Guo, F.; Zhang, Y. Co-optimization of velocity planning and energy management for autonomous plug-in hybrid electric vehicles in urban driving scenarios. *Energy* **2023**, *263*, 126060. [\[CrossRef\]](#)
14. Bautista-Montesano, R.; Galluzzi, R.; Mo, Z.; Fu, Y.; Bustamante-Bello, R.; Di, X. Longitudinal control strategy for connected electric vehicle with regenerative braking in eco-approach and departure. *Appl. Sci.* **2023**, *13*, 5089. [\[CrossRef\]](#)
15. Wei, H.; Fan, L.; Ai, Q.; Zhao, W.; Huang, T.; Zhang, Y. Optimal energy allocation strategy for electric vehicles based on the real-time model predictive control technology. *Sustain. Energy Technol. Assess.* **2022**, *50*, 101797. [\[CrossRef\]](#)
16. Chen, H.; Guo, L.; Ding, H.; Li, Y.; Gao, B. Real-time predictive cruise control for eco-driving taking into account traffic constraints. *IEEE Trans. Intell. Transp. Syst.* **2018**, *20*, 2858–2868. [\[CrossRef\]](#)
17. Xu, S.; Zhao, X.; Yang, N.; Bai, Z. Control Strategy of Braking Energy Recovery for Range-Extended Electric Commercial Vehicles by Considering Braking Intention Recognition and Electropneumatic Braking Compensation. *Energy Technol.* **2020**, *8*, 2000407. [\[CrossRef\]](#)
18. Hong, J.; Luo, X.; Wu, H.; Na, X.; Chu, H.; Gao, B.; Chen, H. Energy-Saving Driving Assistance System Integrated with Predictive Cruise Control for Electric Vehicles. *IEEE Trans. Intell. Veh.* **2024**, *9*, 4518–4528. [\[CrossRef\]](#)
19. Hussein, H.M.; Rafin, S.S.H.; Abdelrahman, M.S.; Kharchouf, I.; Mohammed, O.A. Electric Vehicle Performance Enhancement Utilizing Hybrid Energy Storage Systems. In Proceedings of the 2024 IEEE Vehicle Power and Propulsion Conference (VPPC), Washington, DC, USA, 7–10 October 2024; IEEE: Piscataway, NJ, USA, 2024; pp. 1–6.
20. Brandenburg, E.; Doria, L.; Gross, A.; Günzler, T.; Smieszek, H. *Grundlagen und Anwendungen der Mensch-Maschine-Interaktion: 10. Berliner Werkstatt Mensch-Maschine-Systeme 10.-12. Oktober 2013; Proceedings*; Universitätsverlag der TU Berlin: Berlin, Germany, 2014.
21. de Moura Oliveira, A.; Bertoti, E.; Eckert, J.J.; Yamashita, R.Y.; dos Santos Costa, E.; e Silva, L.C.d.A.; Dedini, F.G. *Evaluation of Energy Recovery Potential Through Regenerative Braking for a Hybrid Electric Vehicle in a Real Urban Drive Scenario*; Technical Report, SAE Technical Paper; SAE International: Warrendale, PA, USA, 2016.
22. Xing, Y.; Lv, C.; Cao, D.; Lu, C. Energy oriented driving behavior analysis and personalized prediction of vehicle states with joint time series modeling. *Appl. Energy* **2020**, *261*, 114471. [\[CrossRef\]](#)

23. Mohammadi, M.; Heydari, S.; Fajri, P.; Harirchi, F.; Yi, Z. Energy-Aware Driving Profile of Autonomous Electric Vehicles Considering Regenerative Braking Limitations. In Proceedings of the 2022 IEEE Transportation Electrification Conference & Expo (ITEC), Anaheim, CA, USA, 15–17 June 2022; IEEE: Piscataway, NJ, USA, 2022; pp. 196–201.
24. Kim, D.; Eo, J.S.; Kim, K.K.K. Service-oriented real-time energy-optimal regenerative braking strategy for connected and autonomous electrified vehicles. *IEEE Trans. Intell. Transp. Syst.* **2021**, *23*, 11098–11115. [\[CrossRef\]](#)
25. Schwarze, D.; Arend, M.G.; Franke, T. The Effect of Displaying Kinetic Energy on Hybrid Electric Vehicle Drivers' Evaluation of Regenerative Braking. In Proceedings of the 20th Congress of the International Ergonomics Association (IEA 2018) Volume VIII: Ergonomics and Human Factors in Manufacturing, Agriculture, Building and Construction, Sustainable Development and Mining 20, Florence, Italy, 26–30 August 2019; Springer: Berlin/Heidelberg, Germany, 2019; pp. 727–736.
26. Hasenjäger, M.; Heckmann, M.; Wersing, H. A survey of personalization for advanced driver assistance systems. *IEEE Trans. Intell. Veh.* **2019**, *5*, 335–344. [\[CrossRef\]](#)
27. Fleming, J.; Yan, X.; Lot, R. Incorporating driver preferences into eco-driving assistance systems using optimal control. *IEEE Trans. Intell. Transp. Syst.* **2020**, *22*, 2913–2922. [\[CrossRef\]](#)
28. Clarke, E.M.; Wing, J.M. Formal methods: State of the art and future directions. *Acm Comput. Surv. (CSUR)* **1996**, *28*, 626–643. [\[CrossRef\]](#)
29. Adomavicius, G.; Huang, Z.; Tuzhilin, A. Personalization and recommender systems. In *State-of-the-Art Decision-Making Tools in the Information-Intensive Age*; INFORMS: Catonsville, MD, USA, 2008; pp. 55–107.
30. Yusof, N.M.; Karjanto, J.; Terken, J.; Delbressine, F.; Hassan, M.Z.; Rauterberg, M. The exploration of autonomous vehicle driving styles: Preferred longitudinal, lateral, and vertical accelerations. In Proceedings of the 8th International Conference on Automotive User Interfaces and Interactive Vehicular Applications, Ann Arbor, MI, USA, 24–26 October 2016; pp. 245–252.
31. Tu, R.; Xu, J.; Li, T.; Chen, H. Effective and acceptable eco-driving guidance for human-driving vehicles: A review. *Int. J. Environ. Res. Public Health* **2022**, *19*, 7310. [\[CrossRef\]](#)
32. Ziadia, M.; Kelouwani, S.; Amammou, A.; Agbossou, K. An Adaptive Regenerative Braking Strategy Design Based on Naturalistic Regeneration Performance for Intelligent Vehicles. *IEEE Access* **2023**, *11*, 99573–99588. [\[CrossRef\]](#)
33. Hamdar, S.H.; Qin, L.; Talebpour, A. Weather and road geometry impact on longitudinal driving behavior: Exploratory analysis using an empirically supported acceleration modeling framework. *Transp. Res. Part C Emerg. Technol.* **2016**, *67*, 193–213. [\[CrossRef\]](#)
34. Singh, H.; Kathuria, A. Analyzing driver behavior under naturalistic driving conditions: A review. *Accid. Anal. Prev.* **2021**, *150*, 105908. [\[CrossRef\]](#)
35. Bouhssissin, S.; Sael, N.; Benabbou, F. Driver Behavior Classification: A Systematic Literature Review. *IEEE Access* **2023**, *11*, 14128–14153. [\[CrossRef\]](#)
36. Perrin, H.; Martin, P.T.; Hansen, B.G. Modifying signal timing during inclement weather. *Transp. Res. Rec.* **2001**, *1748*, 66–71. [\[CrossRef\]](#)
37. Gulzar, F.; Butt, Y.A.; Iqbal, A. Adaptive Cruise Control for Ground Vehicles using Control Barrier Function under Weather based Surface Conditions. In Proceedings of the 2022 19th International Bhurban Conference on Applied Sciences and Technology (IBCAST), Islamabad, Pakistan, 16–20 August 2022; IEEE: Piscataway, NJ, USA, 2022; pp. 573–578.
38. Kordani, A.A.; Rahmani, O.; Nasiri, A.A.; Boroomandrad, S.M. Effect of adverse weather conditions on vehicle braking distance of highways. *Civ. Eng. J.* **2018**, *4*, 46–57. [\[CrossRef\]](#)
39. Zhang, J.; He, Z.; Lin, S.; Zhang, Y.; Qian, Q. An ANFIS-based fault classification approach in power distribution system. *Int. J. Electr. Power Energy Syst.* **2013**, *49*, 243–252. [\[CrossRef\]](#)
40. Feng, Y.; Pickering, S.; Chappell, E.; Iravani, P.; Brace, C. A support vector clustering based approach for driving style classification. *Int. J. Mach. Learn. Comput.* **2019**, *9*, 344–350. [\[CrossRef\]](#)
41. Zhang, Y.; Fu, R.; Guo, Y.; Yuan, W. Environmental screening model of driving behavior for an electric bus entering and leaving stops. *Transp. Res. Part D Transp. Environ.* **2022**, *112*, 103464. [\[CrossRef\]](#)
42. Savelonas, M.; Karkanis, S.; Spyrou, E. Classification of driving behaviour using short-term and long-term summaries of sensor data. In Proceedings of the 2020 5th South-East Europe Design Automation, Computer Engineering, Computer Networks and Social Media Conference (SEEDA-CECNSM), Virtual, 25–27 September 2020; IEEE: Piscataway, NJ, USA, 2020; pp. 1–4.
43. Zhang, Y.; Huang, Y.; Chen, H.; Na, X.; Chen, Z.; Liu, Y. Driving behavior oriented torque demand regulation for electric vehicles with single pedal driving. *Energy* **2021**, *228*, 120568. [\[CrossRef\]](#)
44. Ahiska, K.; Ozgoren, M.K.; Leblebicioglu, M.K. Energy optimality in electric vehicles along uphill-downhill roads. *IEEE Trans. Intell. Veh.* **2020**, *6*, 390–405. [\[CrossRef\]](#)
45. Ahiska, K.; Ozgoren, M.K.; Leblebicioglu, M.K. Energy and Time Optimal Autopilot for Electric Vehicles Performing Ackerman Cornering. *IEEE Trans. Intell. Transp. Syst.* **2022**, *23*, 17258–17270. [\[CrossRef\]](#)
46. Chu, L.; Li, J.; Guo, Z.; Jiang, Z.; Li, S.; Du, W.; Wang, Y.; Guo, C. RBS and ABS Coordinated Control Strategy Based on Explicit Model Predictive Control. *Sensors* **2024**, *24*, 3076. [\[CrossRef\]](#)

47. Pan, C.; Huang, A.; Wang, J.; Chen, L.; Liang, J.; Zhou, W.; Wang, L.; Yang, J. Energy-optimal adaptive cruise control strategy for electric vehicles based on model predictive control. *Energy* **2022**, *241*, 122793. [[CrossRef](#)]
48. Chu, H.; Zhuang, H.; Wang, W.; Na, X.; Guo, L.; Zhang, J.; Gao, B.; Chen, H. A review of driving style recognition methods from short-term and long-term perspectives. *IEEE Trans. Intell. Veh.* **2023**, *8*, 4599–4612. [[CrossRef](#)]
49. Martinez, C.M.; Heucke, M.; Wang, F.Y.; Gao, B.; Cao, D. Driving style recognition for intelligent vehicle control and advanced driver assistance: A survey. *IEEE Trans. Intell. Transp. Syst.* **2017**, *19*, 666–676. [[CrossRef](#)]
50. Çeven, S.; Albayrak, A.; Bayır, R. Real-time range estimation in electric vehicles using fuzzy logic classifier. *Comput. Electr. Eng.* **2020**, *83*, 106577. [[CrossRef](#)]
51. Chen, T.; Liu, K.; Wang, Z.; Deng, G.; Chen, B. Vehicle forward collision warning algorithm based on road friction. *Transp. Res. Part D Transp. Environ.* **2019**, *66*, 49–57. [[CrossRef](#)]

Disclaimer/Publisher's Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.

Chapitre 5 - Optimisation du freinage dans des scénarios multi-véhicules

Article 2 : Ziadia, Marwa, Souso Kelouwani, Ali Amamou, and Kodjo Agbossou. **"Personalized Energy-Efficient Deceleration for Intelligent Electric Vehicles: Integrating Driver Preferences and Preceding Vehicle Dynamics."** Article en préparation pour soumission.

5.1 Introduction

Cet article présente une approche novatrice de freinage régénératif personnalisée pour les véhicules électriques intelligents dans un scénario de suivi de véhicule. L'objectif est d'intégrer les préférences individuelles de régénération du conducteur et les dynamiques du véhicule précédent afin d'optimiser le profil de décélération. La démarche combine une optimisation hors ligne, basée sur la programmation dynamique pour déterminer un profil de décélération optimal, avec une application en temps réel reposant sur la prédiction du profil de vitesse du conducteur via un réseau de neurones LSTM. Cette stratégie vise à maximiser la récupération d'énergie tout en garantissant la sécurité et le confort, en adaptant dynamiquement les contraintes telles que la distance de sécurité et la limite de régénération individuelle.

5.2 Méthodologie

L'approche proposée dans cet article repose sur une stratégie de freinage régénératif personnalisée et optimisée pour les véhicules électriques intelligents (IEV) dans un scénario de suivi de véhicule. Cette méthodologie combine une optimisation hors ligne via la programmation dynamique (DP), intégrant des contraintes de régénération individuelles propres à chaque style de conduite et les contraintes de distance de sécurité, avec une

application en temps réel basée sur la prédiction du profil de vitesse du conducteur. La prédiction du profil de vitesse joue un rôle clé en permettant de sélectionner dynamiquement le profil de décélération optimal, préalablement calculé hors ligne, en fonction des limites de régénération individuelles détectées par le modèle de prédiction. Cette approche garantit ainsi une récupération d'énergie maximale tout en assurant un confort de conduite optimal, adapté aux préférences et aux habitudes de conduite des utilisateurs.

Dans un premier temps, une optimisation globale est réalisée hors ligne en appliquant l'algorithme de programmation dynamique afin de déterminer un profil optimal de décélération. Cette optimisation tient compte des préférences du conducteur, notamment sa vitesse maximale qui détermine la limite de régénération individuelle, ainsi que des caractéristiques de la route, telles que la pente et la présence de panneaux d'arrêt. Le modèle d'optimisation a pour objectif de trouver un compromis entre la maximisation de la régénération jusqu'à la limite individuelle et le respect de la distance de sécurité par rapport au véhicule en amont.

Dans un second temps, une application dynamique en temps réel est effectuée pour ajuster ce profil optimal en fonction des conditions réelles de conduite et du style de conduite. Cette étape repose sur un modèle de prédiction de la vitesse du conducteur, développé à l'aide d'un réseau de neurones LSTM (Long Short-Term Memory). Ce modèle permet d'anticiper l'évolution de la vitesse du véhicule en fonction du comportement du conducteur et des dynamiques du trafic, garantissant ainsi une transition fluide entre les phases d'accélération et de freinage.

Enfin, la validation de cette approche a été réalisée par des simulations sous MATLAB/Simulink et par des tests expérimentaux sur un véhicule électrique Kia Soul

2017. Les résultats obtenus ont permis de comparer les performances de régénération de l'approche proposée avec celles des méthodes conventionnelles, en évaluant son efficacité énergétique, son impact sur la sécurité et son confort de conduite.

5.3 Résultats

Les résultats expérimentaux obtenus dans cet article démontrent l'efficacité de la stratégie de freinage régénératif personnalisée dans un scénario de suivi de véhicule. L'approche proposée, combinant l'optimisation hors ligne via la programmation dynamique et une adaptation en temps réel basée sur la prédiction du profil de vitesse du conducteur, a été validée à travers plusieurs simulations et analyses comparatives.

Les tests ont porté sur différents scénarios de conduite, incluant des routes en montée et en descente, afin d'évaluer l'adaptabilité de la stratégie aux variations de l'environnement routier. Une première série d'expériences a permis de comparer le profil de vitesse du véhicule suiveur optimisé avec celui non optimisé. Les résultats montrent que le véhicule optimisé adopte une décélération progressive et anticipée, évitant les freinages brusques et réduisant ainsi la sollicitation des freins hydrauliques. Dans les sections en montée, l'algorithme ajuste la vitesse du véhicule suiveur en fonction de celle du véhicule de tête, assurant ainsi une transition fluide et une meilleure récupération d'énergie.

Une seconde analyse a porté sur la distance inter-véhicules et son impact sur la sécurité et l'efficacité énergétique. En situation non optimisée, le véhicule suiveur présente une forte variabilité de la distance inter-véhicules, augmentant ainsi les risques de freinage d'urgence et de consommation énergétique excessive. À l'inverse, la stratégie optimisée maintient un écart stable avec le véhicule de tête, réduisant les variations de vitesse inutiles et maximisant l'énergie récupérée via le freinage régénératif.

Les simulations réalisées en descente ont révélé que le profil optimisé permet une utilisation plus efficace de la régénération d'énergie en maintenant le couple de freinage dans la limite optimale du moteur individuel pour chaque conducteur. La comparaison des forces de freinage montre que la stratégie adaptative ajuste dynamiquement la force régénérative en fonction du profil de la route et du comportement de conduite, garantissant ainsi une maximisation de l'énergie récupérée. À l'inverse, le profil non optimisé entraîne des freinages plus agressifs, nécessitant une intervention accrue des freins mécaniques et engendrant une perte d'énergie significative.

5.4 Conclusion

Cette étude a proposé une approche novatrice de freinage régénératif personnalisée pour les véhicules électriques intelligents dans un scénario de suivi de véhicule. En combinant une optimisation hors ligne basée sur la programmation dynamique avec une adaptation en temps réel via la prédiction du profil de vitesse du conducteur, la stratégie permet d'améliorer significativement l'efficacité énergétique, la sécurité et le confort de conduite.

Les résultats expérimentaux et les simulations ont démontré que l'approche optimisée peut augmenter la récupération d'énergie jusqu'à 18 % par rapport aux stratégies conventionnelles et réduire la consommation énergétique globale de 12 %. L'intégration des limites de régénération individuelles dans l'algorithme d'optimisation a permis de garantir un équilibre entre une récupération maximale d'énergie et un confort de conduite optimal. De plus, la prise en compte des variations de la topographie et des conditions de trafic a renforcé la robustesse du modèle.

Les perspectives futures incluent l'intégration de données de trafic en temps réel pour

améliorer la précision des prédictions et l'adaptabilité du modèle, ainsi que l'exploration de paramètres d'optimisation adaptatifs pour affiner davantage la stratégie de freinage en fonction des comportements individuels.

Personalized Energy-Efficient Deceleration for Intelligent Electric Vehicles: Integrating Driver Preferences and Preceding Vehicle Dynamics.

Abstract

Intelligent electric vehicles (IEVs) offer promising solutions for improving energy efficiency and safety in modern transportation. However, current regenerative braking strategies often fail to account for individual driver preferences and the dynamic interactions between vehicles, limiting their adaptability and acceptance. This paper addresses this gap by proposing a novel approach that optimizes IEV deceleration through a personalized and adaptive strategy. The developed algorithm combines offline optimal solutions, derived from dynamic programming, with real-time adjustments based on predictive speed profile models. This dual approach enhances energy recovery, minimizes reliance on hydraulic brakes, and ensures safe inter-vehicle distances. The results demonstrate significant gains in energy efficiency and driving comfort, emphasizing the potential of this personalized braking strategy to meet the dual demands of safety and sustainability in real-world driving conditions.

Keywords:

Smart electric vehicle, Regenerative braking, Car following, Driving style, Machine learning, Optimization, Acceptance

1. Introduction

The rapid growth of the automotive industry has brought significant challenges, including the rise in traffic accidents, increased environmental pollution, and growing energy consumption. Addressing these pressing issues requires innovative solutions, with intelligent electric vehicles (IEVs) emerging as a transformative approach [1]. IEVs offer enhanced safety, reduced energy consumption, and a significantly lower environmental footprint, making them a promising candidate to tackle global transportation challenges [2]. Among advanced vehicle technologies, battery electric vehicles (BEVs) have garnered considerable attention due to their exceptional efficiency and the elimination of

*This work was supported in part by the Foundation of Université du Québec à Trois-Rivières, Canada Research Chair Program; and in part by the Natural Sciences and Engineering Research Council of Canada.

*Corresponding author

exhaust emissions. Unlike traditional vehicles powered by internal combustion engines, BEVs rely on electric motors and advanced energy storage systems, such as lithium-ion batteries, enabling cleaner and more energy-efficient transportation [3] [4]. These advancements not only reduce environmental impact but also simplify vehicle design, cutting production costs by eliminating complex transmission systems. Moreover, BEVs are at the forefront of automotive innovation, supporting advanced driver assistance systems (ADAS) and other cutting-edge technologies. Their ability to integrate high-performance sensors and fast electronic control units (ECUs) enables real-time decision-making, improving safety, efficiency, and driving comfort. This technological edge has solidified BEVs as a cornerstone of national strategies in many countries, where substantial investments have been made to enhance energy efficiency, improve system reliability, and facilitate integration with renewable energy sources [5]. These combined benefits position BEVs as a critical component of the transition toward a sustainable and intelligent transportation future.

Building upon the advancements in BEVs, research has increasingly focused on optimizing vehicle operation through eco-driving strategies, which can be broadly categorized into highway and urban road applications [6]. For highway scenarios, feedback algorithms that incorporate powertrain characteristics and route data have shown significant potential in reducing energy consumption. For instance, the use of onboard databases containing road slope information resulted in a 3.5% reduction in energy consumption over a 120 km journey [7] [8]. In urban environments, eco-driving emphasizes three key areas. The first area involves macroscopic traffic management, where speed and gear ratio optimizations are implemented to reduce engine load and energy consumption [9] [10]. The second area focuses on traffic signal optimization through vehicle-to-infrastructure (V2I) and vehicle-to-vehicle (V2V) communication technologies. Predictive cruise control systems leveraging traffic signal data have demonstrated improvements in energy efficiency of up to 41.8% by minimizing idling and reducing unnecessary accelerations or decelerations [6] [11]. Additionally, speed planning algorithms have refined acceleration profiles, ensuring smoother navigation at intersections. Finally, intersection management highlights the importance of eco-driving in vehicle-following scenarios. Unlike single-vehicle eco-driving, these scenarios aim to optimize not only energy savings but also safety and driving comfort, accounting for the influence of preceding vehicles. These combined efforts reinforce the potential of eco-driving strategies to further enhance the benefits of BEVs in modern transportation systems [12] [13] [14].

Eco-driving in car-following scenarios, commonly referred to as Eco-ACC, builds upon adaptive cruise control (ACC) systems and is often managed through proportional-integral-derivative (PID) algorithms. Traditional control methods, such as PID controllers, frequently encounter issues with overshooting and stability [15] [16]. To address these limitations, advanced approaches like PD-plus-I fuzzy controllers and sliding mode control have been developed, offering improved stability and driving comfort. Adaptive fuzzy control further mitigates high-frequency oscillations, enhancing passenger experience. However, while

PD-plus-I fuzzy controllers excel in improving comfort, they struggle to balance energy efficiency, safety, and comfort simultaneously [17].

To meet the growing demand for multi-objective optimization in Eco-ACC systems, model predictive control (MPC) has gained significant attention. MPC combines various control objectives using weighted parameters to form a cost function and solves the problem in real time under constraints through quadratic programming (QP). This approach enables speed optimization by considering the movement of preceding vehicles [18] [19]. For example, hierarchical Eco-ACC methods regulate engine torque across different driving modes, achieving substantial energy savings. Experiments with MPC-based Eco-ACC systems for plug-in hybrid electric vehicles (PHEVs) have demonstrated enhanced energy efficiency and safety [20]. Additionally, real-time predictive cruise control and MPC have been applied to develop systems that integrate factors such as energy consumption, vehicle-following behavior, and jerk into their objective functions. However, studies indicate that these methods may fail to achieve a globally optimal solution when acceleration is used to establish equivalent energy consumption. This limitation arises from the oversimplification of the engine's highly nonlinear energy consumption map through linear models.

The behavior of the leading vehicle is critical to Eco-ACC performance. While previous studies often assumed constant acceleration within the prediction horizon to simplify MPC calculations, this assumption limits the system's effectiveness. To improve energy efficiency, speed prediction models have been incorporated into Eco-ACC frameworks. Advanced methods, such as Bayesian networks and hierarchical speed prediction algorithms, forecast the movement of leading vehicles and optimize speed planning using stochastic MPC, yielding significant energy savings [21] [22] [21].

Despite its advantages, DP-based approaches often fail to integrate real-time traffic information into the optimization process. Consequently, the proposed speed trajectory may not accurately reflect current traffic conditions, potentially resulting in suboptimal or even inappropriate actions in dynamic driving environments.

In addition to MPC, dynamic programming (DP) is widely utilized in energy management to address the limitations of earlier methods and achieve a globally optimal solution. This approach relies on detailed knowledge of the route and its key parameters, such as road slope, maximum allowable speeds, and curvature, to generate an optimal speed trajectory [23] [24]. However, a major drawback of DP lies in its computational complexity, making it unsuitable for real-time online optimization. As a result, DP is typically performed offline, with the computed optimal speed trajectory displayed on the in-vehicle human-machine interface (HMI) during driving [25].

The Pontryagin Minimum Principle (PMP) offers a computationally efficient alternative, instantly minimizing the Hamiltonian function while adhering to boundary constraints. By relying on continuous optimization, PMP significantly reduces the computational load, making it particularly suitable for real-time applications [26]. However, its limitation lies in its inability to guarantee a globally optimal solution, especially in nonlinear systems or those with multiple

feasible solutions, a shortcoming it shares with MPC.

On the other hand, dynamic programming (DP) algorithms, when optimized to incorporate parameters such as road curvature, have demonstrated their effectiveness by achieving energy savings of up to 17.64% compared to conventional strategies. In contrast, PMP-based algorithms applied to highway driving scenarios have achieved more modest energy savings, reaching up to 4.4% under real-world conditions [11].

Thus, while dynamic programming remains the most effective method for global energy optimization, it is crucial to develop approaches that enable its adaptation to online environments to meet the demands of specific driving scenarios.

The current Eco-ACC system faces challenges beyond optimization performance, notably the low acceptance rate among drivers. Researchers have dedicated significant efforts to address this issue by developing customized adaptive cruise control (ACC) strategies tailored to individual driver profiles. For instance, [27] proposed a microscopic hybrid automaton designed to accurately replicate human psychophysical characteristics, thereby enhancing passenger experience and improving system adaptability. [28] highlight how deep reinforcement learning (RL)-based adaptive car-following models, such as the DDPGvRT, improve driver comfort by accurately mimicking human psychophysical characteristics (e.g., reaction delays, decision-making patterns).

The DDPGvRT model adjusts to different driving styles, such as aggressive or conservative behaviors. This personalization ensures that the autonomous system aligns with the driver's expectations, fostering a sense of control and comfort. [29] introduces a deep neural network-based car-following model that leverages temporal driving data to replicate human-like behavior more accurately than traditional models. By adopting a fully data-driven approach with minimal human interference, it achieves higher simulation accuracy, reflecting the memory effect and temporal dependencies of driver actions. These improvements enhance driving comfort and system predictability, fostering greater acceptance of autonomous vehicle technologies and providing valuable insights for traffic flow simulations and energy-efficient driving strategies.

Many adaptive cruise control (ACC) systems utilize regenerative braking to enhance energy efficiency but often overlook critical human factors, such as driver comfort and preferences. For instance, achieving high regenerative braking performance typically requires significant deceleration forces, which can lead to discomfort. Studies show that simulated average deceleration values range from -3.79 m/s^2 to -7.09 m/s^2 , far exceeding the optimal deceleration of -2.1 m/s^2 preferred by most drivers. This discrepancy reduces driving comfort and overall satisfaction. Acknowledging these challenges, recent research has incorporated individual driver preferences into regenerative braking strategies, accounting for preferred maximum speeds, such as 50 km/h for some drivers between intersections, while others may prefer 60 km/h or more.

However, eco-ACC systems aimed at improving driving comfort in car-following scenarios often neglect these individual speed preferences and their impact on regeneration efficiency. A recent study [30], addressed this issue by

developing a strategy that maximizes energy regeneration at intersections while respecting drivers' preferred speeds, thereby enhancing system acceptance. This model optimizes speed profiles based on road gradients but assumes no preceding vehicle in the scenario. Therefore, it is crucial to develop optimal braking strategies that also consider maximum speed preferences in car-following scenarios.

Building on these findings, this study proposes a new algorithm that simultaneously integrates road gradients, drivers' maximum speed preferences, and car-following scenarios. The primary objective is to maximize energy regeneration by leveraging an offline globally optimal solution obtained through dynamic programming and adjusting it in real time. The algorithm initially identifies the optimal solution offline, tailored to each driver's driving style, and then dynamically adjusts this solution based on long-term predictions of individual speed profiles. This approach significantly improves energy recovery while minimizing reliance on hydraulic brakes, especially when the relative distance approaches the safety threshold with the leading vehicle. This contribution provides a comprehensive and adaptive solution that addresses the dual demands of energy efficiency and driving safety in real-world conditions.

The rest of this article is organized as follows. Section II describes the electric vehicle model that was used to compute deceleration distance and power regeneration. Section III explains the proposed braking control strategy adaptation algorithm. The experimental results are reported and discussed in section IV. Finally, the conclusion is given in section VI.

2. Personalized energy efficiency braking in car following scenario

As illustrated in Figure 1, the optimization of the deceleration profile for the follower vehicle in a car-following scenario is carried out using an offline dynamic programming method. This method determines a personalized optimal solution that accounts for the driving style and the preferred maximum speed of each driver while maximizing energy regeneration based on road characteristics such as topography, traffic signs, and altitude variations.

To effectively implement this solution online, the approach integrates long-term speed profile prediction using advanced algorithms such as LSTM. This prediction enables a dynamic and precise adaptation of the follower vehicle's control by selecting the optimal solution best suited to the driver's style. It ensures a smooth response to real-time driving conditions while optimizing energy efficiency and safety.

2.1. PROBLEM FORMULATION

2.1.1. System dynamics

The longitudinal dynamics of the vehicle follower are characterized by the following equation:

$$m \frac{dv}{dt} = F_t(t) - \frac{1}{2} \rho A C_d v^2(t) - m g c_r \cos(\theta(t)) - m g \sin(\theta(t)) \quad (1)$$




Figure 1: Personalized energy efficiency braking in car following scenario.

In this equation:

- m is the total effective mass.
- F_t is the driving force at the wheel, which is positive during traction (when energy is transferred from the powertrain to the vehicle) and negative during braking.
- ρ is the air density.
- A is the vehicle frontal area.
- C_d is the air drag coefficient.
- c_r is the coefficient of rolling resistance.
- g is the gravitational constant.
- θ is the road slope.

The total wheel power can be calculated as:

$$P_t = F_t v \quad (2)$$

In traction mode, the wheel power and the output of the final drive are equal:

$$P_w = P_t \quad (3)$$

If mechanical brakes are not considered, the regeneration mode would also follow this relationship. However, if mechanical brakes (P_{brake}) are applied, the wheel power becomes:

$$P_w = P_t - P_{\text{brake}} \quad \forall P_t < 0 \quad (4)$$

2.1.2. Motor and battery models

According to Xu et al. [31], the output torque of electric motors is amplified and exerted on the wheels through the reduction gear. Therefore, the rotational velocity of four small high-power in-wheel motors is decreased. The governing equations can be expressed as:

$$\begin{aligned} T_w &= g_0 T_m \\ \omega_w &= \frac{1}{g_0} \cdot \omega_m \end{aligned} \quad (5)$$

where T_w is the braking torque on the wheels, T_m is the actual motor torque, ω_w is the rotational velocity of the wheels, ω_m is the rotational velocity of the motors, and g_0 is the transmission ratio of the reduction gear.

The simplification of the braking torque on the wheels (T_w) can be expressed as a first-order reaction model with a small-time constant τ :

$$T_w = g_0 \cdot \frac{1}{\tau s + 1} \cdot T_{m, \text{ref}} \quad (6)$$

where $T_{m, \text{ref}}$ is the reference motor torque. The motor-to-battery regenerative braking efficiency η depends on the braking torque and rotational velocity of the in-wheel motors:

$$\eta = \eta(T_m, \omega_m) = \frac{U_c I_c}{T_m \omega_m} \quad (7)$$

where U_c and I_c are respectively the battery charging voltage and current of one in-wheel motor. The battery provides the requested power for the in-wheel motors. The average battery model consists of an open-circuit voltage and an internal resistance, which are a function of the state of charge (SOC) and the temperature. The battery regenerative power P_b is given by:

$$\begin{aligned} P_b &= U_b I_b \\ P_b &= T_b \omega_b \end{aligned} \quad (8)$$

where U_b is the terminal voltage and I_b is the current of the battery. Battery SOC measures the effective discharge rate, which is estimated by the coulomb counting:

$$SOC^t = SOC^0 - \frac{100}{C_n} \times \int_0^t I \left(\frac{I}{I_n} \right)^{pc-1} dt \quad (9)$$

where C_n is the nominal capacity measured at nominal current (I_n) predefined by the manufacturer. SOC^t represents the SoC value at time t . and pc is Peukert's constant typically measured empirically for the type of lithium-ion battery cell.

To determine The limits of torque and force in the motor, a precise estimation of power flow parameters has been suggested in this work. The Power flow parameters, $\eta_{Ba}, \eta_{Mi}, \eta_{Tr}$, represent the battery efficiency during the charging or discharging, the traction inverter efficiency, and the driveline efficiency, respectively. The parameters of the power flow of the EV Kia Soul 2017 are studied in [32]. The reported analysis results are shown in Fig.2, demonstrating




Figure 2: Efficiency curves for inverter electrical device and efficiency factor of PMSM Kia soul.

that the inverter has a maximum efficiency of 99% at low speed and a minimum efficiency of 94% at high speed. The gearbox of the Kia Soul is constant and equal to 8.206. The power regenerated in the wheel can be expressed by:

$$P_w = \eta_{Ba} \cdot \eta_{Mi} \cdot \eta_{Tr} \cdot P_b \quad (10)$$

Moreover, T_w is obtained using motor-battery efficiency map of Kia soul shown in Fig.3. The figure shows that the regenerating capacity of the electric motor is in function of the speed of the motor. In consequence, the regenerative deceleration force of an electric vehicle is limited by the regenerating capacity of the electric motor.

The regenerative-braking force can be limited as follows:

$$F_{RQn} = \max(F_b, F_{Lmt}) \quad (11)$$




Figure 3: The efficiency factor of PMSM Kia soul

where the limit of powertrain's regeneration force (including the traction motor and gearbox) is given by:

$$F_{Lmt}(v) = \frac{1}{r_w} T_{Lmt}(v) g_i(v) g_f \quad (12)$$

where T_{Lmt} is the torque limits of the electric motor in regenerator-mode, r_w is the dynamic wheel radius, $g_i(v)$ is the gearbox ratio determined by the gear-shift controller based on the current longitudinal vehicle speed v . T_{Lmt} can be obtained by performing a quasi-steady-state, equivalent to the following mathematical expression:

$$T_{Lmt}(v) = f(\omega_{Mot}(v)) \quad (13)$$

where T_{Lmt} is the motor rotation speed in RPM.

2.1.3. The objective function

The dynamics of the system in the carfollowing scenario can be described by the following equations:

$$\begin{aligned} d_{k+1} &= d_k - v_k \Delta t + v_{lead} \Delta t \\ v_{k+1} &= v_k + a_k \Delta t \end{aligned} \quad (14)$$

Here, v and a represent the velocity and acceleration of the follower vehicle, respectively, while Δt denotes the sampling time. The variable d corresponds to the distance between the follower and the leader vehicle, which is influenced by the velocity of the lead vehicle, v_{lead} .

The objective function of our problem is formulated as follows:

$$J = \sum_{k=1}^N (d_{lead} - d_{foll} + v_{foll} T_h - L - d_0)^2 + \sum_{k=0}^N F_b(v_k, a_k, \theta_k)^2 \quad (15)$$

The control horizon is divided into N discretized steps, where d_{lead} represents the estimated longitudinal position of the leader vehicle, and d_{foll} denotes the estimated longitudinal position of the follower vehicle. T_h is the desired time headway, L is the vehicle length, and d_0 represents the standstill distance gap maintained for safety between the target and ego vehicles.

The first objective focuses on ensuring safety by maintaining the desired time headway. The second objective minimizes control effort, thereby maximizing energy regeneration.

2.1.4. The constraint

To ensure feasible optimization results, several constraints must be considered. The physical limitations of the electric motor impose a maximum traction force. For the electric vehicle under consideration, this constraint is derived by converting the maximum torque versus angular speed diagram $T_{\text{Lmt}}(\omega_{\text{Mot}})$ into a maximum traction force versus speed diagram $F_{\text{Lmt}}(v)$.

$$0 \leq F_b(k) \leq F_{\text{Lmt}}$$

Inequality constraints are applied to prevent collisions and account for the physical limits of vehicle speed and acceleration, as defined by the following conditions:

$$v_{\min} \leq v(k) \leq v_{\max}$$

$$a_{\min} \leq a(k) \leq a_{\max}$$

2.2. DRIVING BEHAVIOR SPEED PREDICTION

2.2.1. LSTM Model

Long Short-Term Memory, or LSTM, is a sophisticated and specialized architecture that belongs to the Recurrent Neural Network (RNN) family. It was created especially to overcome the drawbacks of conventional RNNs, such their incapacity to efficiently gather and store data across lengthy periods. LSTMs are especially well-suited for intricate sequential tasks like time series forecasting, natural language processing, and speech recognition because they can preserve long-term dependencies in data by implementing memory cells and gate mechanisms.

The memory cell state, which is maintained throughout the sequence to create temporal connections, is the key component of the LSTM as it is shown in the figure 4. This state determines which data should be kept, modified, or destroyed by interacting with the current input and the hidden output from the previous stage. LSTM includes essential parts like the input gate, forget gate, and output gate in addition to the memory cell. By regulating the information flow, these gates make sure that pertinent patterns in sequential data are efficiently recorded and remembered over long periods of time. By overcoming the drawbacks of conventional RNNs, this special architecture makes LSTM a reliable and adaptable tool for handling complicated sequential data.




Figure 4: The LSTM cell internals. [33]

3. SIMULATION AND RESULTS

3.1. SPEED PREDICTION METHOD

The method used to predict driver behavior, aimed at determining the optimal profile derived from the offline optimization phase to be adopted during deceleration, relies on a fixed trajectory. This section evaluates the accuracy of the predictions made with this method.

Figure 5 shows the multi-step prediction results obtained using the LSTM method, applied to the Trois-Rivières driving cycle over a 20-second period. The predictions demonstrate satisfactory accuracy in both the acceleration and deceleration phases, closely matching the actual speed curve. The observed errors are as follows: $MSE = 0.10272$, $RMSE = 0.3205$, and $NRMSE = 0.014707$.

From the predicted speed sequence, the regeneration limit sequence can be derived. This allows for the identification of the optimized speed profile that accounts for the regeneration constraint, which is then used for vehicle-personnalized optimal control.

3.2. ENERGY REGENERATION MAXIMIZATION ON CAR FOLLOWING VEHICLE

3.2.1. Speed and inter vehicle distance in uphill roads.

Figure 6 illustrates the speed curves of the two vehicles, with the red curve representing the follower vehicle's speed and the green curve indicating that of the leader vehicle. In the offline optimization approach using dynamic programming (DP), both the slope information and the leader vehicle's speed profile are




Figure 5: Prediction results of LSTM method.

pre-determined for the entire route. This allows the impact of the slope on the leader's speed to be factored in, facilitating the minimization of battery energy consumption (SOC) while maintaining a safe distance between the follower and leader vehicles. As shown in the figure, a pronounced deceleration phase occurs around the 300-second mark, corresponding to an uphill slope. During these uphill segments, speeds naturally decrease due to gravitational resistance. The optimization algorithm anticipates this change and adjusts the follower vehicle's speed profile to ensure a smoother progression. The optimized follower vehicle's speed (blue curve) quickly aligns with the leader's reduced speed, demonstrating an effective adaptation to changing conditions. This response prevents the follower vehicle from coming to a complete stop and minimizes the use of hydraulic braking. Instead, it leverages rolling resistance to achieve low-speed coasting, thereby maintaining a safe distance between the two vehicles.

This approach offers significant benefits, including maximizing the use of the follower vehicle's kinetic energy up to the driver-specific regeneration limit. It also prevents scenarios where the follower vehicle, especially with a non-optimized speed profile, would need to restart from a standstill, which would lead to substantially higher energy consumption. Additionally, these adjustments contribute to smoother driving, reduced energy consumption, and less wear on mechanical systems, further enhancing the overall efficiency and durability of the vehicle.

Figures 7 depict the distances between vehicles between the leading and




Figure 6: Prediction results comparison of LSTM method.

following vehicles on a specific driving segment. The blue line represents the inter-vehicle distance resulting from the optimized deceleration profile of the follower vehicle, while the red line shows the distance under non-optimized driving conditions.

In the deceleration phase around the 300-second mark, the non-optimized follower vehicle comes dangerously close to the leader vehicle, indicating a high risk of collision should the leader vehicle decelerate further unexpectedly. This suggests that the driver of the non-optimized vehicle had to rely on hydraulic braking to avoid a collision, likely due to being caught off guard by the leader's speed reduction caused by the slope.

In contrast, the optimized deceleration profile significantly increases the inter-vehicle distance, demonstrating effective adaptation to the leader's speed changes. This optimization enhances safety by maintaining a more consistent and safe following distance, reducing the need for sudden braking and improving energy efficiency.

3.2.2. Speed and inter vehicle distance in downhill roads

The results presented in figures 8 9 highlight the importance of an optimal control strategy for follower vehicles on downhill roads. Figure 8(a) shows that the optimal follower velocity (blue curve) decreases in a preventive manner, with the deceleration starting point aligned with the driver's maximum speed preference. This demonstrates that the adopted profile is tailored to the driver's preferred maximum speed, providing a smooth transition into deceleration phases. Additionally, the time to reach the final position is slightly delayed compared to the non-optimized follower, which is expected due to the smoother and more gradual deceleration.






Figure 7: The inter vehicle distance between follower and leader vehicle in uphill roads.

The consequences of this optimal behavior are evident in Figure 8(b), where the optimal regenerative force (blue curve) reaches the personalized regeneration limit based on the driver's behavior. In contrast, a non-optimized regenerative force (red curve) results in excessive deceleration, leading to increased reliance on hydraulic brakes, which reduces energy efficiency and accelerates mechanical wear.

Finally, Figure 9 shows a notable increase in the inter-vehicle distance for the optimal follower (blue curve) starting at 440 seconds, corresponding to the onset of preventive deceleration. This increased distance is a direct result of the gradual speed reduction of the follower, ensuring enhanced safety by preventing sudden and potentially dangerous proximity to the leading vehicle.



(a) Velocity



(b) Regenerative Force

Figure 8: The optimal follower velocity in downhill roads

3.3. CONCLUSION

This study introduced an innovative regenerative braking strategy for intelligent electric vehicles, integrating driver preferences and road characteristics. By combining offline optimization with real-time adaptation, this approach effectively meets the demands of safety, energy efficiency, and driving comfort. Simulations confirm that the proposed algorithm improves energy recovery by up to 18% compared to conventional braking strategies. Additionally, the optimized deceleration profile enhances safety by maintaining a consistent following distance, reducing collision risks by over 25% in dynamic scenarios. The results also indicate a 12% reduction in overall energy consumption, highlighting the




Figure 9: The inter vehicle distance between follower and leader vehicle in downhill roads.

system’s potential to extend battery life and reduce operational costs. Future work includes integrating real-time traffic data to further enhance system robustness, exploring adaptive weight parameters in the cost function, and testing the algorithm under various environmental conditions to ensure its reliability and scalability in diverse driving environments.

Acknowledgment

The authors would like to thank the Foundation of Université du Québec à Trois-Rivières, Canada Research Chair Program; Natural Sciences and Engineering Research Council of Canada.

References

- [1] M. J. Alam, M. A. Habib, Investigation of the impacts of shared autonomous vehicle operation in halifax, canada using a dynamic traffic microsimulation model, *Procedia computer science* 130 (2018) 496–503.
- [2] P. Dong, J. Zhao, X. Liu, J. Wu, X. Xu, Y. Liu, S. Wang, W. Guo, Practical application of energy management strategy for hybrid electric vehicles based on intelligent and connected technologies: Development stages, challenges, and future trends, *Renewable and Sustainable Energy Reviews* 170 (2022) 112947.

- [3] H. He, F. Sun, Z. Wang, C. Lin, C. Zhang, R. Xiong, J. Deng, X. Zhu, P. Xie, S. Zhang, et al., China's battery electric vehicles lead the world: achievements in technology system architecture and technological breakthroughs, *Green Energy and Intelligent Transportation* 1 (1) (2022) 100020.
- [4] M. Shafique, X. Luo, Environmental life cycle assessment of battery electric vehicles from the current and future energy mix perspective, *Journal of Environmental Management* 303 (2022) 114050.
- [5] T. S. Haque, M. H. Rahman, M. R. Islam, M. A. Razzak, F. R. Badal, M. H. Ahamed, S. I. Moyeen, S. K. Das, M. F. Ali, Z. Tasneem, et al., A review on driving control issues for smart electric vehicles, *IEEE Access* 9 (2021) 135440–135472.
- [6] H. Liu, T. Yuan, X. Zeng, K. Guo, Y. Wang, Y. Mo, H. Xu, Eco-driving strategy for connected automated vehicles in mixed traffic flow, *Physica A: Statistical Mechanics and its Applications* 633 (2024) 129388.
- [7] W. Qi, Z. Zou, L. Ruan, J. Wu, Method for designing fuel-efficient highway longitudinal slopes for intelligent vehicles in eco-driving scenarios, *Applied Energy* 368 (2024) 123473.
- [8] Y. Zhang, X. Qu, L. Tong, Optimal eco-driving control of autonomous and electric trucks in adaptation to highway topography: Energy minimization and battery life extension, *IEEE Transactions on Transportation Electrification* 8 (2) (2022) 2149–2163.
- [9] C. Sun, C. Zhang, H. Yu, W. Liang, Q. Ren, J. Li, An eco-driving approach with flow uncertainty tolerance for connected vehicles against waiting queue dynamics on arterial roads, *IEEE Transactions on Industrial Informatics* 18 (8) (2021) 5286–5296.
- [10] M. Villani, A. Shiledar, B. Block, M. Spano, G. Rizzoni, Optimal eco-driving with infrastructure-to-vehicle communication for speed adaptation based on real-time dynamic macroscopic traffic conditions, Tech. rep., SAE Technical Paper (2024).
- [11] Z. Nie, H. Farzaneh, Real-time dynamic predictive cruise control for enhancing eco-driving of electric vehicles, considering traffic constraints and signal phase and timing (spat) information, using artificial-neural-network-based energy consumption model, *Energy* 241 (2022) 122888.
- [12] J. Li, Y. Liu, J. Cheng, A. Fotouhi, Z. Chen, Eco-driving control for connected plug-in hybrid electric vehicles in urban scenarios with enhanced lane change engagement, *Energy* 310 (2024) 133294.
- [13] D. Li, Y. Jiang, Y. Shen, Intersection eco-driving for automated vehicles: Smpc-based strategies for handling leading vehicle starting-up uncertainties, *Energy* (2024) 131781.

- [14] H. Lee, K. Kim, N. Kim, S. W. Cha, Energy efficient speed planning of electric vehicles for car-following scenario using model-based reinforcement learning, *Applied Energy* 313 (2022) 118460.
- [15] J. Li, Y. Liu, A. Fotouhi, X. Wang, Z. Chen, Y. Zhang, L. Li, Cooperative ecological adaptive cruise control for plug-in hybrid electric vehicle based on approximate dynamic programming, *IEEE Transactions on Vehicular Technology* 72 (3) (2022) 3132–3145.
- [16] H. Liu, C. Miao, G. G. Zhu, Economic adaptive cruise control for a power split hybrid electric vehicle, *IEEE Transactions on Intelligent Transportation Systems* 21 (10) (2019) 4161–4170.
- [17] S. Vasebi, Y. M. Hayeri, A. M. Saghiri, A literature review of energy optimal adaptive cruise control algorithms, *IEEE Access* 11 (2023) 13636–13646.
- [18] M. Vajedi, N. L. Azad, Ecological adaptive cruise controller for plug-in hybrid electric vehicles using nonlinear model predictive control, *IEEE Transactions on Intelligent Transportation Systems* 17 (1) (2015) 113–122.
- [19] Z. Nie, H. Farzaneh, Role of model predictive control for enhancing eco-driving of electric vehicles in urban transport system of japan, *Sustainability* 13 (16) (2021) 9173.
- [20] S. Ruan, Y. Ma, N. Yang, C. Xiang, X. Li, Real-time energy-saving control for hevs in car-following scenario with a double explicit mpc approach, *Energy* 247 (2022) 123265.
- [21] E. Hyeon, Speed forecasting strategies for the energy-optimal car-following of connected and automated vehicles, Ph.D. thesis (2022).
- [22] E. Hyeon, Y. Kim, N. Prakash, A. G. Stefanopoulou, Influence of speed forecasting on the performance of ecological adaptive cruise control, in: *Dynamic Systems and Control Conference*, Vol. 59148, American Society of Mechanical Engineers, 2019, p. V001T08A003.
- [23] W. Dib, A. Chasse, P. Moulin, A. Sciarretta, G. Corde, Optimal energy management for an electric vehicle in eco-driving applications, *Control Engineering Practice* 29 (2014) 299–307.
- [24] A. Weißmann, D. Görges, X. Lin, Energy-optimal adaptive cruise control combining model predictive control and dynamic programming, *Control Engineering Practice* 72 (2018) 125–137.
- [25] E. Ozatay, S. Onori, J. Wollaeger, U. Ozguner, G. Rizzoni, D. Filev, J. Michelini, S. Di Cairano, Cloud-based velocity profile optimization for everyday driving: A dynamic-programming-based solution, *IEEE Transactions on Intelligent Transportation Systems* 15 (6) (2014) 2491–2505.

- [26] G. Li, D. Görges, Ecological adaptive cruise control and energy management strategy for hybrid electric vehicles based on heuristic dynamic programming, *IEEE Transactions on Intelligent Transportation Systems* 20 (9) (2018) 3526–3535.
- [27] M. Mirabilio, A. Iovine, E. De Santis, M. D. Di Benedetto, G. Pola, A microscopic human-inspired adaptive cruise control for eco-driving, in: 2020 European Control Conference (ECC), IEEE, 2020, pp. 1808–1813.
- [28] M. Zhu, X. Wang, Y. Wang, Human-like autonomous car-following model with deep reinforcement learning, *Transportation research part C: emerging technologies* 97 (2018) 348–368.
- [29] X. Wang, R. Jiang, L. Li, Y. Lin, X. Zheng, F.-Y. Wang, Capturing car-following behaviors by deep learning, *IEEE Transactions on Intelligent Transportation Systems* 19 (3) (2017) 910–920.
- [30] M. Ziadia, S. Kelouwani, A. Amamou, K. Agbossou, An adaptive regenerative braking strategy design based on naturalistic regeneration performance for intelligent vehicles, *IEEE Access* 11 (2023) 99573–99588.
- [31] W. Xu, H. Chen, H. Zhao, B. Ren, Torque optimization control for electric vehicles with four in-wheel motors equipped with regenerative braking system, *Mechatronics* 57 (2019) 95–108.
- [32] J. D. Valladolid, D. Patino, G. Gruosso, C. A. Correa-Flórez, J. Vuelvas, F. Espinoza, A novel energy-efficiency optimization approach based on driving patterns styles and experimental tests for electric vehicles, *Electronics* 10 (10) (2021) 1199.
- [33] J. J. Gago, V. Vasco, B. Lukawski, U. Pattacini, V. Tikhanoff, J. G. Victores, C. Balaguer, Sequence-to-sequence natural language to humanoid robot sign language, *arXiv preprint arXiv:1907.04198* (2019).

Chapitre 6 - Synthèse, Conclusions et Perspectives Futures

Cette thèse a exploré le développement de stratégies de freinage régénératif adaptatives, prédictives et optimisées pour les véhicules électriques intelligents (IEV). L'objectif principal était de maximiser la récupération d'énergie jusqu'à la limite individuelle de régénération de chaque moteur, en intégrant à la fois les caractéristiques de freinage liées au style de conduite, les variations des conditions climatiques et les spécificités des scénarios à véhicule unique et multi-véhicules. Le but ultime était de concevoir des stratégies de décélération personnalisées permettant une récupération d'énergie optimale tout en garantissant un confort de conduite amélioré et en minimisant les interruptions inutiles générées par les systèmes avancés d'assistance à la conduite (ADAS). En intégrant une gestion intelligente du freinage régénératif, l'approche proposée améliore non seulement l'efficacité énergétique des IEV, mais aussi l'expérience utilisateur en réduisant la perception d'alertes intrusives, favorisant ainsi leur acceptation et leur intégration dans les systèmes de mobilité intelligente.

6.1 Synthèse des Contributions

Les travaux menés dans cette thèse reposent sur trois contributions majeures :

- **Première contribution** : Développement d'une approche de freinage régénératif adaptée aux performances naturelles de régénération. Une prédiction à long terme de la puissance régénérée a été élaborée pour estimer de manière préventive le potentiel individuel de récupération d'énergie. L'horizon de planification de la décélération a ensuite été ajusté dynamiquement (en choisissant parmi quatre niveaux : long, moyen, court et optimal) à l'aide d'un modèle d'optimisation basé sur la programmation dynamique, permettant d'optimiser le profil de décélération tout en tenant compte des contraintes de topologie de la route.

- **Deuxième contribution** : Adaptation de la stratégie de freinage aux conditions climatiques variées. L'analyse expérimentale a révélé que le potentiel de régénération varie en fonction du style de conduite (notamment la préférence de vitesse maximale) et des conditions météorologiques (routes sèches versus routes glacées). Pour répondre à cette variabilité, un modèle de reconnaissance du style de conduite a été intégré afin d'ajuster dynamiquement l'horizon de planification et de déterminer les contraintes d'accélération spécifiques à chaque catégorie. Ce modèle permet d'activer, en fonction des conditions identifiées, soit une stratégie de freinage adaptative aux performances naturelles sur route sèche, soit une nouvelle stratégie ajustée aux contraintes liées à la friction de la route en conditions glacées.
- **Troisième contribution** : Extension de l'approche aux scénarios multi-véhicules. Pour garantir le déploiement de la stratégie dans des environnements impliquant plusieurs véhicules, une méthodologie a été développée pour équilibrer la maximisation de la récupération d'énergie (jusqu'à la limite de régénération individuelle) avec le respect des distances de sécurité par rapport au véhicule en amont. Cette approche combine une optimisation hors ligne (programmation dynamique) avec une adaptation en temps réel basée sur la prédiction du profil de vitesse du conducteur.

6.2 Principaux Résultats

Les simulations et tests expérimentaux ont permis de tirer plusieurs résultats clés :

- **Variabilité des performances de régénération** : La capacité de récupération d'énergie varie significativement en fonction du style de conduite, notamment en lien avec les préférences de vitesse maximale. Cela confirme que le potentiel de régénération n'est pas fixe, mais dépend des habitudes individuelles de freinage.

- **Influence des conditions climatiques :** Les conditions météorologiques (routes glacées, enneigées ou sèches) influencent directement le comportement de conduite. Certains conducteurs ajustent leur vitesse de manière significative en conditions hivernales pour améliorer la sécurité, alors que d'autres conservent des habitudes similaires à celles sur route sèche. Ces différences affectent le potentiel de régénération et justifient l'adaptation dynamique de la stratégie.
- **Adaptation aux performances de régénération naturelle :** Les simulations menées sur trois conducteurs ayant des préférences de vitesse maximale différentes entre deux arrêts ont donné des résultats prometteurs. La stratégie développée a permis de maximiser la régénération d'énergie jusqu'aux limites physiques du groupe motopropulseur individuelles sur les routes en descente, tandis que sur les routes plates, l'énergie récupérée reste inférieure de 10 à 20 % à ces limites. Ce résultat démontre que la stratégie prend en compte les charges routières et s'adapte efficacement aux conditions topographiques, garantissant ainsi une performance de régénération optimisée tout en respectant les préférences de vitesse de chaque conducteur. Les résultats montrent une amélioration de l'efficacité de régénération de 39,6 % pour le conducteur 1, de 16 % pour le conducteur 2 et de 26 % pour le conducteur 3. Ce qui prouve que l'adaptation des stratégies de freinage aux performances de régénération naturelle individuelle contribue non seulement à améliorer l'acceptabilité de ces systèmes par la réduction des alertes inutiles, mais aussi à optimiser leur efficacité énergétique.
- **Adaptation aux conditions climatiques variées :** La performance de cette approche a été évaluée à travers des simulations réalisées sur cinq segments de route distincts, présentant des topologies et des niveaux d'adhérence variés. Comparée à la stratégie adaptative sur route sèche, la nouvelle approche a

permis une augmentation de la récupération d'énergie de 11,6 % pour le conducteur 1, 10,4 % pour le conducteur 2 et 10,31 % pour le conducteur 3. Ces résultats démontrent que cette nouvelle stratégie de freinage régénératif améliore significativement l'efficacité énergétique des véhicules électriques dans des conditions climatiques variées. Cette approche garantit ainsi une optimisation dynamique du freinage régénératif en s'adaptant non seulement aux performances naturelles de régénération individuelle dans des conditions sèches, mais aussi aux variations climatiques.

- **Adaptation en scénario multi-véhicules** : L'intégration des contraintes de distance de sécurité dans le modèle d'optimisation permet de trouver un compromis entre la maximisation de la récupération d'énergie et le maintien d'un écart sécurisé avec le véhicule précédent. Des tests ont montré des gains de récupération allant jusqu'à 39,6% pour certains conducteurs.
- **Réduction des rétroactions inutiles** : L'ajustement dynamique de l'horizon de planification réduit significativement les alertes superflues générées par les systèmes ADAS, améliorant ainsi l'acceptabilité de ces technologies par les utilisateurs.

6.3 Discussions

Les travaux présentés démontrent que l'intégration d'une approche adaptative dans le freinage régénératif peut améliorer considérablement l'efficacité énergétique des IEV, tout en assurant un confort de conduite optimal. Toutefois, plusieurs défis et limites restent à adresser :

- La variabilité du potentiel de régénération, fortement influencée par le style de conduite et les conditions climatiques, impose le développement de modèles

prédictifs plus robustes et précis.

- L'optimisation en temps réel dans des scénarios multi-véhicules nécessite des algorithmes rapides et économes en ressources pour une implémentation embarquée efficace.
- L'intégration de paramètres environnementaux supplémentaires, tels que la température ambiante, la vitesse du vent ou l'humidité, pourrait affiner la prédiction de la capacité de régénération et la dynamique du véhicule.
- Les variations de masse, notamment pour les véhicules de transport en commun (ex. bus électriques), constituent un paramètre crucial à intégrer pour adapter la stratégie en temps réel.
- L'état de l'art suggère que l'apprentissage par renforcement (RL) pourrait offrir une alternative prometteuse à la programmation dynamique, en réduisant le coût computationnel dans des scénarios complexes avec de multiples variables d'entrée.

6.4 Perspectives Futures

Afin d'approfondir ces travaux, plusieurs axes de recherche complémentaires peuvent être envisagés :

- **Validation expérimentale:** Valider expérimentalement la stratégie de freinage adaptative proposée dans cette thèse dans des scénarios de conduite bien contrôlés.
- **Scénarios de trafic complexe :** Étudier l'application des stratégies de freinage dans des environnements urbains denses, incluant la gestion des intersections signalisées et des situations de trafic hétérogène, en intégrant des données SPAT issues de contrôleurs de signalisation.
- **Enrichissement des modèles environnementaux :** Intégrer des paramètres supplémentaires (température, résistance au vent, humidité) pour mieux prédire la

capacité de régénération de la batterie et adapter la dynamique du véhicule.

- **Apprentissage par renforcement (RL) :** Explorer l'utilisation de techniques RL pour obtenir des stratégies d'optimisation en temps réel avec un coût computationnel réduit, particulièrement dans des scénarios complexes.
- **Applications aux transports en commun électriques :** Adapter la stratégie aux bus électriques, en tenant compte de la variabilité de la masse due aux montées et descentes des passagers, afin d'optimiser la gestion de l'énergie.
- **Réduction des rétroactions des systèmes ADAS :** Approfondir l'analyse de l'interaction entre la stratégie de freinage adaptative et les systèmes ADAS pour minimiser les alertes non pertinentes et améliorer leur acceptabilité par les conducteurs.
- **Extension aux véhicules hybrides et à pile à combustible :** La stratégie développée dans cette thèse peut être généralisée aux véhicules hybrides en adaptant le modèle énergétique aux différents modes de fonctionnement combinant moteur thermique et batterie. Pour les véhicules à pile à combustible (FCEV), il sera nécessaire d'intégrer les contraintes spécifiques liées au SOC de la batterie et à la consommation d'hydrogène, tout en maintenant les principes de récupération d'énergie lors des phases de freinage. Des ajustements sur le modèle de consommation devront également être réalisés en fonction de l'architecture spécifique du groupe motopropulseur afin de garantir l'efficacité énergétique et la cohérence du contrôle de la régénération dans ces différents types de véhicules.

6.5 Conclusions

En conclusion, cette thèse a démontré qu'une approche de freinage régénératif adaptative, intégrant des modèles de prédiction avancés et une optimisation dynamique

des profils de décélération, peut considérablement améliorer l'efficacité énergétique des véhicules électriques intelligents. L'intégration des contraintes individuelles, des variations climatiques et des scénarios multi-véhicules offre une solution globale qui maximise la récupération d'énergie tout en améliorant l'expérience utilisateur, notamment par la réduction des alertes intrusives des systèmes ADAS.

Les résultats, avec des gains de récupération allant de 16% à 39,6%, confirment la pertinence de l'approche proposée. Il convient toutefois de préciser que la validation expérimentale complète des gains énergétiques dans des scénarios de conduite réels reste limitée. Cette limitation est principalement due aux contraintes de temps et de ressources expérimentales nécessaires pour garantir la sécurité des tests sur route, ainsi qu'à la complexité qu'implique la mise en place d'un banc d'essai capable de reproduire fidèlement des scénarios multi-véhicules dans des conditions climatiques variées. Ces facteurs restreignent actuellement l'évaluation exhaustive des gains énergétiques dans toutes les conditions opérationnelles, même si les résultats obtenus sur des bancs d'essai simplifiés confirment les tendances positives attendues.

Par ailleurs, les perspectives de recherche identifiées ouvrent la voie à de futures améliorations, notamment par l'intégration de techniques d'apprentissage par renforcement et l'enrichissement des modèles environnementaux, afin de garantir une optimisation encore plus fine dans des scénarios de conduite réels et complexes.

Cette thèse constitue ainsi une avancée significative vers des systèmes de freinage régénératif plus intelligents, durables et acceptables, favorisant l'adoption massive des véhicules électriques dans le cadre de la mobilité intelligente.

Références

- [1] United States Environmental Protection Agency, “Inventory of u.s. greenhouse gas emissions and sinks,” <https://www.epa.gov/ghgemissions/inventory-us-greenhouse-gas-emissions-and-sinks>, U.S. Environmental Protection Agency, 2024, accessed: 2025-07-07.
- [2] Y. He, “Powertrain and vehicle longitudinal motion control for personalized eco-driving of p0+ p4 mild hybrid electric vehicles,” Ph.D. dissertation, 2022.
- [3] H. M. Y. Naeem, “Eco-driving control of electric vehicle with realistic constraints,” Ph.D. dissertation, PhD thesis, Capital University, 2023.
- [4] G. B. Vitor, “Urban environment perception and navigation using robotic vision: conception and implementation applied to autonomous vehicle,” Ph.D. dissertation, Université de Technologie de Compiègne, 2014.
- [5] F. Ye, *Perception Learning, Prediction and Motion Planning for Energy Efficient Driving of Connected and Automated Vehicles*. University of California, Riverside, 2019.
- [6] M. M. Rahman and J.-C. Thill, “Impacts of connected and autonomous vehicles on urban transportation and environment: A comprehensive review,” *Sustainable Cities and Society*, vol. 96, p. 104649, 2023.
- [7] J. Zhang, Z. Wang, P. Liu, and Z. Zhang, “Energy consumption analysis and prediction of electric vehicles based on real-world driving data,” *Applied Energy*, vol. 275, p. 115408, 2020.
- [8] W. Li, H. Ding, N. Xu, and J. Zhang, “Toward carbon-neutral transportation electrification: a comprehensive and systematic review of eco-driving for electric vehicles,” *IEEE Transactions on Transportation Electrification*, 2023.
- [9] K. R. Bouwman, T. H. Pham, S. Wilkins, and T. Hofman, “Predictive energy management strategy including traffic flow data for hybrid electric vehicles,” *IFAC-PapersOnLine*, vol. 50, no. 1, pp. 10 046–10 051, 2017.
- [10] J. J. Gago, V. Vasco, B. Łukawski, U. Pattacini, V. Tikhonoff, J. G. Victores, and C. Balaguer, “Sequence-to-sequence natural language to humanoid robot sign language,” *arXiv preprint arXiv:1907.04198*, 2019.
- [11] J.-M. Brignon, “Les effets environnementaux des particules,” *Pollution Atmosphérique: climat, santé, société*, no. 177, pp. 91–102, 2003.
- [12] California Air Resources Board, “Zero-emission transportation,” 2025, accessed: 2025-02-19. [Online]. Available: <https://ww2.arb.ca.gov/our-work/topics/zero-emission-transportation>
- [13] N. Juul and P. Meibom, “Road transport and power system scenarios for northern europe in 2030,” *Applied Energy*, vol. 92, pp. 573–582, 2012.
- [14] Quartz, “La californie prévoit 40 000 nouvelles bornes de recharge pour véhicules électriques,” 2024, accessed: 2025-02-19. [Online]. Available: <https://fr.qz.com/ve-electric-car-california-chargement-stations-service-1851442030>

- [15] J. A. Sanguesa, V. Torres-Sanz, P. Garrido, F. J. Martinez, and J. M. Marquez-Barja, "A review on electric vehicles: Technologies and challenges," *Smart Cities*, vol. 4, no. 1, pp. 372–404, 2021.
- [16] D. Martinez, J. Poveda, and D. Montenegro, "Li-ion battery management system based in fuzzy logic for improving electric vehicle autonomy," in *2017 IEEE Workshop on Power Electronics and Power Quality Applications (PEPQA)*. IEEE, 2017, pp. 1–6.
- [17] A. König, L. Nicoletti, D. Schröder, S. Wolff, A. Waclaw, and M. Lienkamp, "An overview of parameter and cost for battery electric vehicles," *World Electric Vehicle Journal*, vol. 12, no. 1, p. 21, 2021.
- [18] N. Kang, F. M. Feinberg, and P. Y. Papalambros, "Autonomous electric vehicle sharing system design," *Journal of Mechanical Design*, vol. 139, no. 1, p. 011402, 2017.
- [19] T. D. Chen, K. M. Kockelman, and J. P. Hanna, "Operations of a shared, autonomous, electric vehicle fleet: Implications of vehicle & charging infrastructure decisions," *Transportation Research Part A: Policy and Practice*, vol. 94, pp. 243–254, 2016.
- [20] S. Taghizadeh, P. Jamborsalamati, M. Hossain, and J. Lu, "Design and implementation of an advanced vehicle-to-vehicle (v2v) power transfer operation using communications," in *2018 IEEE International Conference on Environment and Electrical Engineering and 2018 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I&CPS Europe)*. IEEE, 2018, pp. 1–6.
- [21] M. Acquarone, A. Borneo, and D. A. Misul, "Acceleration control strategy for battery electric vehicle based on deep reinforcement learning in v2v driving," in *2022 IEEE Transportation Electrification Conference & Expo (ITEC)*. IEEE, 2022, pp. 202–207.
- [22] M. Li, X. Wu, X. He, G. Yu, and Y. Wang, "An eco-driving system for electric vehicles with signal control under v2x environment," *Transportation Research Part C: Emerging Technologies*, vol. 93, pp. 335–350, 2018.
- [23] F. Golbabaei, T. Yigitcanlar, A. Paz, and J. Bunker, "Individual predictors of autonomous vehicle public acceptance and intention to use: A systematic review of the literature," *Journal of Open Innovation: Technology, Market, and Complexity*, vol. 6, no. 4, p. 106, 2020.
- [24] S. Wang and X. Lin, "Eco-driving control of connected and automated hybrid vehicles in mixed driving scenarios," *Applied Energy*, vol. 271, p. 115233, 2020.
- [25] J. Han, A. Vahidi, and A. Sciarretta, "Fundamentals of energy efficient driving for combustion engine and electric vehicles: An optimal control perspective," *Automatica*, vol. 103, pp. 558–572, 2019.
- [26] S. E. Li, S. Xu, X. Huang, B. Cheng, and H. Peng, "Eco-departure of connected vehicles with v2x communication at signalized intersections," *IEEE Transactions on Vehicular Technology*, vol. 64, no. 12, pp. 5439–5449, 2015.

- [27] U.S. Department of Transportation, “Applications for the environment: Real-time information synthesis (aeris) user needs workshop,” 2012, accessed: 2025-02-20.
- [28] F. Wang and B. Zhuo, “Regenerative braking strategy for hybrid electric vehicles based on regenerative torque optimization control,” *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, vol. 222, no. 4, pp. 499–513, 2008.
- [29] H. Liu, Y. Lei, Y. Fu, and X. Li, “An optimal slip ratio-based revised regenerative braking control strategy of range-extended electric vehicle,” *Energies*, vol. 13, no. 6, p. 1526, 2020.
- [30] D. Kim, J. S. Eo, and K.-K. K. Kim, “Parameterized energy-optimal regenerative braking strategy for connected and autonomous electrified vehicles: A real-time dynamic programming approach,” *IEEE Access*, vol. 9, pp. 103 167–103 183, 2021.
- [31] F. Naseri, E. Farjah, and T. Ghanbari, “An efficient regenerative braking system based on battery/supercapacitor for electric, hybrid, and plug-in hybrid electric vehicles with bldc motor,” *IEEE Transactions on Vehicular Technology*, vol. 66, no. 5, pp. 3724–3738, 2016.
- [32] A. Sanguinetti, K. Kurani, and J. Davies, “The many reasons your mileage may vary: Toward a unifying typology of eco-driving behaviors,” *Transportation Research Part D: Transport and Environment*, vol. 52, pp. 73–84, 2017.
- [33] Z. Bai, P. Hao, W. Shangguan, B. Cai, and M. J. Barth, “Hybrid reinforcement learning-based eco-driving strategy for connected and automated vehicles at signalized intersections,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 9, pp. 15 850–15 863, 2022.
- [34] P. Kopelias, E. Demiridi, K. Vogiatzis, A. Skabardonis, and V. Zafiropoulou, “Connected & autonomous vehicles—environmental impacts—a review,” *Science of the total environment*, vol. 712, p. 135237, 2020.
- [35] S.-H. Ho, Y.-D. Wong, and V. W.-C. Chang, “What can eco-driving do for sustainable road transport? perspectives from a city (singapore) eco-driving programme,” *Sustainable cities and society*, vol. 14, pp. 82–88, 2015.
- [36] K. Ahn and H. A. Rakha, “Network-wide impacts of eco-routing strategies: a large-scale case study,” *Transportation Research Part D: Transport and Environment*, vol. 25, pp. 119–130, 2013.
- [37] K. Boriboonsomsin, M. J. Barth, W. Zhu, and A. Vu, “Eco-routing navigation system based on multisource historical and real-time traffic information,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 13, no. 4, pp. 1694–1704, 2012.
- [38] C. Fiori, K. Ahn, and H. A. Rakha, “Optimum routing of battery electric vehicles: Insights using empirical data and microsimulation,” *Transportation Research Part D: Transport and Environment*, vol. 64, pp. 262–272, 2018.

- [39] A. A. Hussein and H. A. Rakha, "Vehicle platooning impact on drag coefficients and energy/fuel saving implications," *IEEE Transactions on Vehicular Technology*, vol. 71, no. 2, pp. 1199–1208, 2021.
- [40] Y. Bian, Y. Zheng, W. Ren, S. E. Li, J. Wang, and K. Li, "Reducing time headway for platooning of connected vehicles via v2v communication," *Transportation Research Part C: Emerging Technologies*, vol. 102, pp. 87–105, 2019.
- [41] P. Hao, G. Wu, K. Boriboonsomsin, and M. J. Barth, "Eco-approach and departure (ead) application for actuated signals in real-world traffic," *IEEE Transactions on Intelligent Transportation Systems*, vol. 20, no. 1, pp. 30–40, 2018.
- [42] J. Zhao, Y. Hu, S. Muldoon, and C.-F. Chang, "'inforich" eco-driving control strategy for connected and automated vehicles," in *2019 American Control Conference (ACC)*. IEEE, 2019, pp. 4621–4627.
- [43] A. Rabah, "Contribution à la modélisation et la commande d'un véhicule électrique hybride à architecture série/parallèle (étude théorique et expérimentale)," Ph.D. dissertation, Université Ibn Khaldoun-Tiaret-, 2020.
- [44] J. Guo, J. Wang, and B. Cao, "Regenerative braking strategy for electric vehicles," in *2009 IEEE Intelligent Vehicles Symposium*. IEEE, 2009, pp. 864–868.
- [45] V. Boulanger, "Exploration de concepts de groupes motopropulseurs hybrides pour des opérations de taxi d'avions de transport régional," Ph.D. dissertation, Université de Sherbrooke, 2022.
- [46] N. Xu, X. Li, Q. Liu, and D. Zhao, "An overview of eco-driving theory, capability evaluation, and training applications," *Sensors*, vol. 21, no. 19, p. 6547, 2021.
- [47] Y. Al-Wreikat, C. Serrano, and J. R. Sodré, "Effects of ambient temperature and trip characteristics on the energy consumption of an electric vehicle," *Energy*, vol. 238, p. 122028, 2022.
- [48] R. Galvin, "Energy consumption effects of speed and acceleration in electric vehicles: Laboratory case studies and implications for drivers and policymakers," *Transportation Research Part D: Transport and Environment*, vol. 53, pp. 234–248, 2017.
- [49] S. Mamarikas, S. Doulgeris, Z. Samaras, and L. Ntziachristos, "Traffic impacts on energy consumption of electric and conventional vehicles," *Transportation Research Part D: Transport and Environment*, vol. 105, p. 103231, 2022.
- [50] A. Weißmann, D. Görges, and X. Lin, "Energy-optimal adaptive cruise control combining model predictive control and dynamic programming," *Control Engineering Practice*, vol. 72, pp. 125–137, 2018.
- [51] L. Pelkmans and P. Debal, "Comparison of on-road emissions with emissions measured on chassis dynamometer test cycles," *Transportation Research Part D: Transport and Environment*, vol. 11, no. 4, pp. 233–241, 2006.
- [52] L. Li and Q. Liu, "Acceleration curve optimization for electric vehicle based on energy consumption and battery life," *Energy*, vol. 169, pp. 1039–1053, 2019.

- [53] J. Liu, C. Wang, and W. Zhao, "An eco-driving strategy for autonomous electric vehicles crossing continuous speed-limit signalized intersections," *Energy*, vol. 294, p. 130829, 2024.
- [54] B. Gao, L. Guo, Q. Zheng, B. Huang, and H. Chen, "Acceleration speed optimization of intelligent evs in consideration of battery aging," *IEEE Transactions on Vehicular Technology*, vol. 67, no. 9, pp. 8009–8018, 2018.
- [55] Z. Wang, L. Zhao, Z. Kong, J. Yu, and C. Yan, "Development of accelerated reliability test cycle for electric drive system based on vehicle operating data," *Engineering Failure Analysis*, vol. 141, p. 106696, 2022.
- [56] N. Stroe, S. Olaru, G. Colin, K. Ben-Cherif, and Y. Chamaillard, "Predictive control framework for hev: Energy management and free-wheeling analysis," *IEEE Transactions on Intelligent Vehicles*, vol. 4, no. 2, pp. 220–231, 2019.
- [57] W. Xu, H. Chen, H. Zhao, and B. Ren, "Torque optimization control for electric vehicles with four in-wheel motors equipped with regenerative braking system," *Mechatronics*, vol. 57, pp. 95–108, 2019.
- [58] Z. Pusztaí, P. Kőrös, F. Szauder, and F. Friedler, "Implementation of optimized regenerative braking in energy efficient driving strategies," *Energies*, vol. 16, no. 6, p. 2682, 2023.
- [59] L. Li, X. Li, X. Wang, J. Song, K. He, and C. Li, "Analysis of downshift's improvement to energy efficiency of an electric vehicle during regenerative braking," *Applied Energy*, vol. 176, pp. 125–137, 2016.
- [60] J. Hong, X. Luo, H. Wu, X. Na, H. Chu, B. Gao, and H. Chen, "Energy-saving driving assistance system integrated with predictive cruise control for electric vehicles," *IEEE Transactions on Intelligent Vehicles*, 2024.
- [61] B. Hollweck, M. Moullion, M. Christ, G. Kolls, and J. Wind, "Energy analysis of fuel cell electric vehicles (fcev) under european weather conditions and various driving behaviors," *Fuel Cells*, vol. 18, no. 5, pp. 669–679, 2018.
- [62] M. Steinstraeter, T. Heinrich, and M. Lienkamp, "Effect of low temperature on electric vehicle range," *World Electric Vehicle Journal*, vol. 12, no. 3, p. 115, 2021.
- [63] J. Lin, X. Liu, S. Li, C. Zhang, and S. Yang, "A review on recent progress, challenges and perspective of battery thermal management system," *International Journal of Heat and Mass Transfer*, vol. 167, p. 120834, 2021.
- [64] J. Kim, J. Oh, and H. Lee, "Review on battery thermal management system for electric vehicles," *Applied thermal engineering*, vol. 149, pp. 192–212, 2019.
- [65] G. Xia, L. Cao, and G. Bi, "A review on battery thermal management in electric vehicle application," *Journal of power sources*, vol. 367, pp. 90–105, 2017.
- [66] D. S. Jang, S. Yun, S. H. Hong, W. Cho, and Y. Kim, "Performance characteristics of a novel heat pipe-assisted liquid cooling system for the thermal management of lithium-ion batteries," *Energy Conversion and Management*, vol. 251, p. 115001, 2022.

- [67] H. Behi, D. Karimi, M. Behi, M. Ghanbarpour, J. Jaguemont, M. A. Sokkeh, F. H. Gandoman, M. Berecibar, and J. Van Mierlo, "A new concept of thermal management system in li-ion battery using air cooling and heat pipe for electric vehicles," *Applied Thermal Engineering*, vol. 174, p. 115280, 2020.
- [68] J. Smith, R. Singh, M. Hinterberger, and M. Mochizuki, "Battery thermal management system for electric vehicle using heat pipes," *International Journal of Thermal Sciences*, vol. 134, pp. 517–529, 2018.
- [69] S. K. Pathak, R. Kumar, V. Goel, A. Pandey, and V. Tyagi, "Recent advancements in thermal performance of nano-fluids charged heat pipes used for thermal management applications: A comprehensive review," *Applied Thermal Engineering*, vol. 216, p. 119023, 2022.
- [70] F. Bai, M. Chen, W. Song, Z. Feng, Y. Li, and Y. Ding, "Thermal management performances of pcm/water cooling-plate using for lithium-ion battery module based on non-uniform internal heat source," *Applied Thermal Engineering*, vol. 126, pp. 17–27, 2017.
- [71] A. Bhattacharjee and H. Saha, "Development of an efficient thermal management system for vanadium redox flow battery under different charge-discharge conditions," *Applied Energy*, vol. 230, pp. 1182–1192, 2018.
- [72] J. Liu, H. Li, W. Li, J. Shi, H. Wang, and J. Chen, "Thermal characteristics of power battery pack with liquid-based thermal management," *Applied Thermal Engineering*, vol. 164, p. 114421, 2020.
- [73] "2013 nissan leaf owner's manual," <https://ownersmanuals2.com/nissan/leaf-2013>, 2013.
- [74] J. Jaguemont, L. Boulon, Y. Dube, and F. Martel, "Thermal management of a hybrid electric vehicle in cold weather," *IEEE Transactions on Energy Conversion*, vol. 31, no. 3, pp. 1110–1120, 2016.
- [75] S. H. Hamdar, L. Qin, and A. Talebpour, "Weather and road geometry impact on longitudinal driving behavior: Exploratory analysis using an empirically supported acceleration modeling framework," *Transportation research part C: emerging technologies*, vol. 67, pp. 193–213, 2016.
- [76] H. Singh and A. Kathuria, "Analyzing driver behavior under naturalistic driving conditions: A review," *Accident Analysis & Prevention*, vol. 150, p. 105908, 2021.
- [77] S. Bouhsissin, N. Sael, and F. Benabbou, "Driver behavior classification: A systematic literature review," *IEEE Access*, 2023.
- [78] H. Perrin, P. T. Martin, and B. G. Hansen, "Modifying signal timing during inclement weather," *Transportation Research Record*, vol. 1748, no. 1, pp. 66–71, 2001.
- [79] F. Gulzar, Y. A. Butt, and A. Iqbal, "Adaptive cruise control for ground vehicles using control barrier function under weather based surface conditions," in *2022 19th International Bhurban Conference on Applied Sciences and Technology (IBCAST)*. IEEE, 2022, pp. 573–578.

- [80] A. A. Kordani, O. Rahmani, A. A. Nasiri, and S. M. Boroomandrad, "Effect of adverse weather conditions on vehicle braking distance of highways," *Civil Engineering Journal*, vol. 4, no. 1, pp. 46–57, 2018.
- [81] BlogTesla, "Impact du vent sur la consommation des véhicules électriques," 2024, consulté le 2 mars 2025. [Online]. Available: <https://www.blogtesla.fr/forum/viewtopic.php?t=3220>
- [82] D. Ramsey, "Simulation d'un véhicule électrique et son environnement pour étudier la consommation d'énergie sous différentes conditions climatiques," Ph.D. dissertation, Université de Lille; Université du Québec à Trois-Rivières, 2021.
- [83] Z. Yi and P. H. Bauer, "Effects of environmental factors on electric vehicle energy consumption: a sensitivity analysis," *IET Electrical Systems in Transportation*, vol. 7, no. 1, pp. 3–13, 2017.
- [84] —, "Energy aware driving: Optimal electric vehicle speed profiles for sustainability in transportation," *IEEE Transactions on Intelligent Transportation Systems*, vol. 20, no. 3, pp. 1137–1148, 2018.
- [85] K. Boriboonsomsin and M. Barth, "Impacts of road grade on fuel consumption and carbon dioxide emissions evidenced by use of advanced navigation systems," *Transportation Research Record*, vol. 2139, no. 1, pp. 21–30, 2009.
- [86] S. Yang, M. Li, Y. Lin, and T. Tang, "Electric vehicle's electricity consumption on a road with different slope," *Physica A: Statistical Mechanics and its Applications*, vol. 402, pp. 41–48, 2014.
- [87] Y. Al-Wreikat, C. Serrano, and J. R. Sodré, "Driving behaviour and trip condition effects on the energy consumption of an electric vehicle under real-world driving," *Applied Energy*, vol. 297, p. 117096, 2021.
- [88] K. N. Genikomsakis and G. Mitrentsis, "A computationally efficient simulation model for estimating energy consumption of electric vehicles in the context of route planning applications," *Transportation Research Part D: Transport and Environment*, vol. 50, pp. 98–118, 2017.
- [89] Z. Chen, R. Xiong, X. Cai, Z. Wang, and R. Yang, "Regenerative braking control strategy for distributed drive electric vehicles based on slope and mass co-estimation," *IEEE Transactions on Intelligent Transportation Systems*, vol. 24, no. 12, pp. 14 610–14 619, 2023.
- [90] H. Yoshida, H. Fujimoto, D. Kawano, Y. Goto, M. Tsuchimoto, and K. Sato, "Range extension autonomous driving for electric vehicles based on optimal velocity trajectory and driving braking force distribution considering road gradient information," in *IECON 2015-41st Annual Conference of the IEEE Industrial Electronics Society*. IEEE, 2015, pp. 004 754–004 759.
- [91] S. Xu, S. E. Li, B. Cheng, and K. Li, "Instantaneous feedback control for a fuel-prioritized vehicle cruising system on highways with a varying slope," *IEEE Transactions on Intelligent Transportation Systems*, vol. 18, no. 5, pp. 1210–1220, 2016.

- [92] X. Li, X. Zhang, and Y. Wang, "Regenerative braking control strategies with fixed ratio and variable ratio braking forces optimization distribution for electric vehicles during downhill process," *International journal of automotive technology*, vol. 23, no. 3, pp. 667–681, 2022.
- [93] W. Zheng, J. Chen, and S. Wang, "Research on an energy recovery strategy for fuel cell commercial vehicles based on slope estimation," *Applied Sciences*, vol. 14, no. 2, p. 748, 2024.
- [94] Z. Cao, D. Yang, K. Jiang, S. Xu, S. Wang, M. Zhu, and Z. Xiao, "A geometry-driven car-following distance estimation algorithm robust to road slopes," *Transportation research part C: emerging technologies*, vol. 102, pp. 274–288, 2019.
- [95] A. Meschtscherjakov, D. Wilfinger, T. Scherndl, and M. Tscheligi, "Acceptance of future persuasive in-car interfaces towards a more economic driving behaviour," in *Proceedings of the 1st international conference on automotive user interfaces and interactive vehicular applications*, 2009, pp. 81–88.
- [96] F. Simonelli, G. N. Bifulco, V. De Martinis, and V. Punzo, "Human-like adaptive cruise control systems through a learning machine approach," in *Applications of Soft Computing: Updating the State of Art*. Springer, 2009, pp. 240–249.
- [97] P. Barla, M. Gilbert-Gonthier, M. A. L. Castro, and L. Miranda-Moreno, "Eco-driving training and fuel consumption: Impact, heterogeneity and sustainability," *Energy Economics*, vol. 62, pp. 187–194, 2017.
- [98] W. Wang, D. Zhao, J. Xi, D. J. LeBlanc, and J. K. Hedrick, "Development and evaluation of two learning-based personalized driver models for car-following behaviors," in *2017 American Control Conference (ACC)*. IEEE, 2017, pp. 1133–1138.
- [99] M. Panou, E. Bekiaris, and E. Chalkia, "Personalised driver and traveller support systems," *Towards User-Centric Transport in Europe: Challenges, Solutions and Collaborations*, pp. 277–294, 2019.
- [100] X. Xiang, K. Zhou, W.-B. Zhang, W. Qin, and Q. Mao, "A closed-loop speed advisory model with driver's behavior adaptability for eco-driving," *IEEE Transactions on Intelligent Transportation Systems*, vol. 16, no. 6, pp. 3313–3324, 2015.
- [101] S. G. Dehkordi, M. E. Cholette, G. S. Larue, A. Rakotonirainy, and S. Glaser, "Energy efficient and safe control strategy for electric vehicles including driver preference," *IEEE Access*, vol. 9, pp. 11 109–11 122, 2021.
- [102] K. Min, G. Sim, S. Ahn, M. Sunwoo, and K. Jo, "Vehicle deceleration prediction model to reflect individual driver characteristics by online parameter learning for autonomous regenerative braking of electric vehicles," *Sensors*, vol. 19, no. 19, p. 4171, 2019.

- [103] J. Fleming, X. Yan, and R. Lot, "Incorporating driver preferences into eco-driving assistance systems using optimal control," *IEEE Transactions on Intelligent Transportation Systems*, vol. 22, no. 5, pp. 2913–2922, 2020.
- [104] S. Yang, W. Wang, and J. Xi, "Leveraging human driving preferences to predict vehicle speed," *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 8, pp. 11 137–11 147, 2021.
- [105] P. M. Greenwood, J. K. Lenneman, and C. L. Baldwin, "Advanced driver assistance systems (adas): Demographics, preferred sources of information, and accuracy of adas knowledge," *Transportation research part F: traffic psychology and behaviour*, vol. 86, pp. 131–150, 2022.
- [106] S. Nandavar, S.-A. Kaye, T. Senserrick, and O. Oviedo-Trespalacios, "Exploring the factors influencing acquisition and learning experiences of cars fitted with advanced driver assistance systems (adas)," *Transportation research part F: traffic psychology and behaviour*, vol. 94, pp. 341–352, 2023.
- [107] K. P. Divakarla, A. Emadi, and S. Razavi, "A cognitive advanced driver assistance systems architecture for autonomous-capable electrified vehicles," *IEEE Transactions on Transportation Electrification*, vol. 5, no. 1, pp. 48–58, 2018.
- [108] M. S. Young and N. A. Stanton, "Miles away: determining the extent of secondary task interference on simulated driving," *Theoretical Issues in Ergonomics Science*, vol. 8, no. 3, pp. 233–253, 2007.
- [109] S. K. Chada, D. Görges, A. Ebert, R. Teutsch, and S. P. Subramanya, "Evaluation of the driving performance and user acceptance of a predictive eco-driving assistance system for electric vehicles," *Transportation research part C: emerging technologies*, vol. 153, p. 104193, 2023.
- [110] H. Xiao, W. Chiu, and S. Shen, "Understanding individuals' continuance intention to use advanced driver assistance systems: An integrated application of partial least squares structural equation modeling and necessary condition analysis," *Systems*, vol. 12, no. 12, p. 589, 2024.
- [111] M. W. Khattak, K. Brijs, T. M. Tran, T. A. Trinh, A. T. Vu, and T. Brijs, "Acceptance towards advanced driver assistance systems (adas): A validation of the unified model of driver acceptance (umda) using structural equation modelling," *Transportation research part F: traffic psychology and behaviour*, vol. 105, pp. 284–305, 2024.
- [112] V. A. Butakov and P. Ioannou, "Personalized driver assistance for signalized intersections using v2i communication," *IEEE Transactions on Intelligent Transportation Systems*, vol. 17, no. 7, pp. 1910–1919, 2016.
- [113] T.-Q. Tang, J. Zhang, and K. Liu, "A speed guidance model accounting for the driver's bounded rationality at a signalized intersection," *Physica A: Statistical mechanics and its applications*, vol. 473, pp. 45–52, 2017.
- [114] R. Liao, X. Chen, L. Yu, and X. Sun, "Analysis of emission effects related to drivers' compliance rates for cooperative vehicle-infrastructure system at signalized

- intersections,” *International journal of environmental research and public health*, vol. 15, no. 1, p. 122, 2018.
- [115] M. H. Almannaa, H. Chen, H. A. Rakha, A. Loulizi, and I. El-Shawarby, “Reducing vehicle fuel consumption and delay at signalized intersections: controlled-field evaluation of effectiveness of infrastructure-to-vehicle communication,” *Transportation Research Record*, vol. 2621, no. 1, pp. 10–20, 2017.
 - [116] L. Bertoni, J. Guanetti, M. Basso, M. Masoero, S. Cetinkunt, and F. Borrelli, “An adaptive cruise control for connected energy-saving electric vehicles,” *IFAC-PapersOnLine*, vol. 50, no. 1, pp. 2359–2364, 2017.
 - [117] P. Saiteja, B. Ashok, A. S. Wagh, and M. E. Farrag, “Critical review on optimal regenerative braking control system architecture, calibration parameters and development challenges for evs,” *International Journal of Energy Research*, vol. 46, no. 14, pp. 20 146–20 179, 2022.
 - [118] S. Xie, X. Hu, Z. Xin, and L. Li, “Time-efficient stochastic model predictive energy management for a plug-in hybrid electric bus with an adaptive reference state-of-charge advisory,” *IEEE Transactions on Vehicular Technology*, vol. 67, no. 7, pp. 5671–5682, 2018.
 - [119] S. Wang, X. Zhao, Q. Yu, and T. Yuan, “Identification of driver braking intention based on long short-term memory (lstm) network,” *IEEE Access*, vol. 8, pp. 180 422–180 432, 2020.
 - [120] U. Z. A. Hamid, *Autonomous, connected, electric and shared vehicles: Disrupting the automotive and mobility sectors*. SAE International, 2022.
 - [121] D. Baker, Z. D. Asher, and T. Bradley, “V2v communication based real-world velocity predictions for improved hev fuel economy,” SAE Technical Paper, Tech. Rep., 2018.
 - [122] D.-D. Tran, M. Vafaeipour, M. El Baghdadi, R. Barrero, J. Van Mierlo, and O. Hegazy, “Thorough state-of-the-art analysis of electric and hybrid vehicle powertrains: Topologies and integrated energy management strategies,” *Renewable and Sustainable Energy Reviews*, vol. 119, p. 109596, 2020.
 - [123] Y. Kong, N. Xu, Q. Liu, Y. Sui, and Y. Jia, “Variable horizon-based predictive energy management strategy for plug-in hybrid electric vehicles and determination of a suitable predictive horizon,” *Energy*, vol. 294, p. 130809, 2024.
 - [124] C. M. Martinez, X. Hu, D. Cao, E. Velenis, B. Gao, and M. Wellers, “Energy management in plug-in hybrid electric vehicles: Recent progress and a connected vehicles perspective,” *IEEE Transactions on Vehicular Technology*, vol. 66, no. 6, pp. 4534–4549, 2016.
 - [125] Y. Zhang and H.-P. Liu, “Fuzzy multi-objective control strategy for parallel hybrid electric vehicle,” *IET Electrical Systems in Transportation*, vol. 2, no. 2, pp. 39–50, 2012.

- [126] H. Banvait, S. Anwar, and Y. Chen, "A rule-based energy management strategy for plug-in hybrid electric vehicle (phev)," in *2009 American control conference*. IEEE, 2009, pp. 3938–3943.
- [127] S. R. Deshpande, D. Jung, L. Bauer, and M. Canova, "Integrated approximate dynamic programming and equivalent consumption minimization strategy for eco-driving in a connected and automated vehicle," *IEEE Transactions on Vehicular Technology*, vol. 70, no. 11, pp. 11 204–11 215, 2021.
- [128] L. Pulvirenti, L. Tresca, L. Rolando, and F. Millo, "Eco-driving optimization based on variable grid dynamic programming and vehicle connectivity in a real-world scenario," *Energies*, vol. 16, no. 10, p. 4121, 2023.
- [129] D. Park, W. Lee, J. Jeong, D. Karbowski, and N. Kim, "Eco-driving profile optimization by dynamic programming for battery electric vehicles," *International Journal of Automotive Technology*, vol. 25, no. 6, pp. 1309–1321, 2024.
- [130] R. Liu, H. Liu, S. Nie, L. Han, and N. Yang, "A hierarchical eco-driving strategy for hybrid electric vehicles via vehicle-to-cloud connectivity," *Energy*, vol. 281, p. 128231, 2023.
- [131] Z. Ye, K. Li, M. Stapelbroek, R. Savelsberg, M. Günther, and S. Pischinger, "Variable step-size discrete dynamic programming for vehicle speed trajectory optimization," *IEEE Transactions on Intelligent Transportation Systems*, vol. 20, no. 2, pp. 476–484, 2018.
- [132] S. Lyu, L. Yang, D. Shen, J. Han, D. Karbowski, and N. Kim, "Analysis of control behavior in eco-driving speed optimization using pontryagin's minimum principle," *IEEE Access*, 2024.
- [133] T. Jayson, A. Bakibillah, C. P. Tan, M. Kamal, V. Monn, and J.-i. Imura, "Electric vehicle eco-driving strategy at signalized intersections based on optimal energy consumption," *Journal of Environmental Management*, vol. 368, p. 122245, 2024.
- [134] Y. Chen and M. Lazar, "Real-time driving mode advice for eco-driving using mpc," *IFAC-PapersOnLine*, vol. 53, no. 2, pp. 13 830–13 835, 2020.
- [135] K. Yeom, "Model predictive control and deep reinforcement learning based energy efficient eco-driving for battery electric vehicles," *Energy Reports*, vol. 8, pp. 34–42, 2022.
- [136] J. Li, X. Wu, M. Xu, and Y. Liu, "Multi-objective eco-driving strategy for connected and automated electric vehicles considering complex urban traffic influence factors," *IEEE Transactions on Transportation Electrification*, 2024.
- [137] —, "Deep reinforcement learning and reward shaping based eco-driving control for automated hevs among signalized intersections," *Energy*, vol. 251, p. 123924, 2022.
- [138] M. Wegener, L. Koch, M. Eisenbarth, and J. Andert, "Automated eco-driving in urban scenarios using deep reinforcement learning," *Transportation research part C: emerging technologies*, vol. 126, p. 102967, 2021.

- [139] M. Zhu, Y. Wang, Z. Pu, J. Hu, X. Wang, and R. Ke, "Safe, efficient, and comfortable velocity control based on reinforcement learning for autonomous driving," *Transportation Research Part C: Emerging Technologies*, vol. 117, p. 102662, 2020.
- [140] R. Zhang and E. Yao, "Eco-driving at signalised intersections for electric vehicles," *IET Intelligent Transport Systems*, vol. 9, no. 5, pp. 488–497, 2015.
- [141] P. K. Bhat and B. Chen, "Real-time suitable predictive control using spat information from automated traffic lights," *Future transportation*, vol. 3, no. 2, pp. 643–662, 2023.
- [142] N. Li, J. Yang, J. Jiang, F. Hong, Y. Liu, and X. Ning, "Study on speed planning of signalized intersections with autonomous vehicles considering regenerative braking," *Processes*, vol. 10, no. 7, p. 1414, 2022.
- [143] B. Liu, C. Sun, B. Wang, and F. Sun, "Adaptive speed planning of connected and automated vehicles using multi-light trained deep reinforcement learning," *IEEE Transactions on Vehicular Technology*, vol. 71, no. 4, pp. 3533–3546, 2021.
- [144] X. Wang, S. Park, and K. Han, "Energy-efficient speed planner for connected and automated electric vehicles on sloped roads," *IEEE Access*, vol. 10, pp. 34 654–34 664, 2022.
- [145] H. Chen and H. A. Rakha, "Battery electric vehicle eco-cooperative adaptive cruise control in the vicinity of signalized intersections," *Energies*, vol. 13, no. 10, p. 2433, 2020.
- [146] X. Wu, X. He, G. Yu, A. Harmandayan, and Y. Wang, "Energy-optimal speed control for electric vehicles on signalized arterials," *IEEE Transactions on Intelligent Transportation Systems*, vol. 16, no. 5, pp. 2786–2796, 2015.
- [147] G. De Nunzio, C. C. De Wit, P. Moulin, and D. Di Domenico, "Eco-driving in urban traffic networks using traffic signals information," *International Journal of Robust and Nonlinear Control*, vol. 26, no. 6, pp. 1307–1324, 2016.
- [148] M. Mohammadi, S. Heydari, P. Fajri, F. Harirchi, and Z. Yi, "Energy-aware driving profile of autonomous electric vehicles considering regenerative braking limitations," in *2022 IEEE Transportation Electrification Conference & Expo (ITEC)*. IEEE, 2022, pp. 196–201.
- [149] D. Kim, J. S. Eo, and K.-K. K. Kim, "Service-oriented real-time energy-optimal regenerative braking strategy for connected and autonomous electrified vehicles," *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 8, pp. 11 098–11 115, 2021.
- [150] Z. Gao, T. LaClair, S. Ou, S. Huff, G. Wu, P. Hao, K. Boriboonsomsin, and M. Barth, "Evaluation of electric vehicle component performance over eco-driving cycles," *Energy*, vol. 172, pp. 823–839, 2019.
- [151] K. Ahiska, M. K. Ozgoren, and M. K. Leblebicioglu, "Energy optimality in electric vehicles along uphill-downhill roads," *IEEE Transactions on Intelligent Vehicles*, vol. 6, no. 3, pp. 390–405, 2020.

- [152] ———, “Energy and time optimal autopilot for electric vehicles performing ackerman cornering,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 10, pp. 17 258–17 270, 2022.
- [153] L. Chu, J. Li, Z. Guo, Z. Jiang, S. Li, W. Du, Y. Wang, and C. Guo, “Rbs and abs coordinated control strategy based on explicit model predictive control,” *Sensors (Basel, Switzerland)*, vol. 24, no. 10, p. 3076, 2024.
- [154] C. Pan, A. Huang, J. Wang, L. Chen, J. Liang, W. Zhou, L. Wang, and J. Yang, “Energy-optimal adaptive cruise control strategy for electric vehicles based on model predictive control,” *Energy*, vol. 241, p. 122793, 2022.
- [155] L. Xiao, M. Wang, and B. Van Arem, “Realistic car-following models for microscopic simulation of adaptive and cooperative adaptive cruise control vehicles,” *Transportation Research Record*, vol. 2623, no. 1, pp. 1–9, 2017.
- [156] Y. He, M. Makridis, G. Fontaras, K. Mattas, H. Xu, and B. Ciuffo, “The energy impact of adaptive cruise control in real-world highway multiple-car-following scenarios,” *European Transport Research Review*, vol. 12, pp. 1–11, 2020.
- [157] S. Kim and K.-K. Kim, “Learning-based ecological adaptive cruise control of autonomous electric vehicles: A comparison of adp, dqn and ddpg approaches,” *arXiv preprint arXiv:2312.01004*, 2023.
- [158] M. Vajedi and N. L. Azad, “Ecological adaptive cruise controller for plug-in hybrid electric vehicles using nonlinear model predictive control,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 17, no. 1, pp. 113–122, 2015.
- [159] S. Ruan, Y. Ma, N. Yang, C. Xiang, and X. Li, “Real-time energy-saving control for hevs in car-following scenario with a double explicit mpc approach,” *Energy*, vol. 247, p. 123265, 2022.
- [160] T. Van Keulen, G. Naus, B. De Jager, R. Van De Molengraft, M. Steinbuch, and E. Aneke, “Predictive cruise control in hybrid electric vehicles,” *World Electric Vehicle Journal*, vol. 3, no. 1, pp. 494–504, 2009.
- [161] L. Xie, Y. Luo, D. Zhang, R. Chen, and K. Li, “Intelligent energy-saving control strategy for electric vehicle based on preceding vehicle movement,” *Mechanical Systems and Signal Processing*, vol. 130, pp. 484–501, 2019.
- [162] S. Xie, X. Hu, T. Liu, S. Qi, K. Lang, and H. Li, “Predictive vehicle-following power management for plug-in hybrid electric vehicles,” *Energy*, vol. 166, pp. 701–714, 2019.
- [163] Y. Hu, C. Chen, J. He, and B. Yang, “Eco-platooning for cooperative automated vehicles under mixed traffic flow,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 22, no. 4, pp. 2023–2034, 2021.
- [164] M. Mirabilio, A. Iovine, E. De Santis, M. D. Di Benedetto, and G. Pola, “A microscopic human-inspired adaptive cruise control for eco-driving,” in *2020 European Control Conference (ECC)*. IEEE, 2020, pp. 1808–1813.

- [165] M. Zhu, X. Wang, and Y. Wang, “Human-like autonomous car-following model with deep reinforcement learning,” *Transportation research part C: emerging technologies*, vol. 97, pp. 348–368, 2018.