

UNIVERSITÉ DU QUÉBEC

MÉMOIRE PRÉSENTÉ À  
L'UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

COMME EXIGENCE PARTIELLE  
DE LA MAÎTRISE EN INGÉNIERIE  
(CONCENTRATION EN GÉNIE MECANIQUE)

PAR  
NOFINIDY HO FANILO ANDRIAMINAHY

ESTIMATION OPTIMISÉE DE L'UTILISATION DE L'ÉNERGIE SUR UN  
VÉHICULE ÉLECTRIQUE

AVRIL 2021

Université du Québec à Trois-Rivières

Service de la bibliothèque

Avertissement

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

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 ou cette thèse. Notamment, la reproduction ou la publication de la totalité ou d'une partie importante de ce mémoire ou de cette thèse requiert son autorisation.

## Résumé

Les nouvelles normes pour réduire la pollution et les émissions de gaz à effet de serre pour les opérateurs dans les industries automobiles ont utilisé différentes technologies permettant la décarbonisation et la réduction des énergies. L'électrification des véhicules serait une solution efficace et fiable pour économiser du carburant et aussi pour diminuer la pollution de l'environnement. Bien que cela soit une issue prometteuse, l'électrification totale du groupe motopropulseur nécessite beaucoup d'attention sur l'estimation de l'autonomie de la batterie qui est la seule source d'énergie des véhicules électriques rechargeables à freinage régénératif. Le fait que la consommation de l'énergie dépend aussi de plusieurs facteurs externes dont le conducteur, les conditions de la route, les conditions météorologiques, cela impliquerait de connaître comment l'énergie est dispersée afin de pouvoir proposer une méthode de planification énergétique et de connaître jusqu'où le véhicule peut atteindre avec le reste d'énergie en sa possession.

Cette étude a pour but d'estimer l'autonomie d'un véhicule électrique en se basant sur l'apport de chaque force extérieure sur l'efficacité énergétique. Afin d'évaluer l'effet de chaque amélioration sur l'efficacité énergétique, il faut être en mesure de déterminer avec précision la consommation énergétique en route. Le défi actuel réside dans l'absence d'un système de mesure capable de fournir cette information. En effet, les différents capteurs installés sur le véhicule mesurent de manière indirecte et grossière la consommation d'énergie, principalement pour des fins de normes environnementales. Il est donc important de bien modéliser le véhicule en route de manière à pouvoir estimer précisément la consommation de l'énergie. Pour y arriver, il est nécessaire d'introduire des méthodes

d'estimation correcte des pertes aérodynamiques, des pertes par friction roues/routes et des pertes dues à la configuration de la route ainsi que la puissance électrique fournie par la batterie du véhicule. Dans ce projet, nous avons utilisé comme méthodes les moindres carrés récursifs ou Recursive Least Square (RLS) en anglais et le filtre de Kalman ou Filter Kalman (KF) en anglais pour l'estimation des paramètres influençant la consommation énergétique. Les résultats ont montré que le KF donne une bonne performance que le RLS. Le modèle NARX ou Nonlinear AutoRegressive eXogenous est utilisé pour estimer la puissance. Pour estimer l'autonomie, on s'est basé sur le même modèle NARX avec d'autres calculs basés sur des mises à jour de données. Les simulations faites ont montré que le modèle NARX donne une belle performance sur l'estimation de la puissance et de l'autonomie.

La validation de ces estimations a été réalisé sur un véhicule électrique à freinage régénératif : KIA SOUL EV, appartenant à l'Institut de Recherche sur l'Hydrogène (IRH) de l'Université du Québec à Trois-Rivières (UQTR).

**Mots clés** : force aérodynamique, résistance au roulement, moindres carrés récursifs, filtre de Kalman, modèle dynamique d'un véhicule, autonomie d'un véhicule électrique

## Dédicaces

### Je dédie ce mémoire :

*À ma très chère femme Francia Ravalison et mon fils Ethan Andriaminahy pour leur soutien, leur amour. Merci de toujours croire en moi, vous êtes ma source de motivation.*

*À mes chers parents Laurent et Noro Andriaminahy pour tous leurs sacrifices et leur soutien tout au long de mes études.*

*À mes chères sœurs et leurs maris ainsi que leurs enfants pour leurs encouragements permanents et leur soutien moral.*

*À ma belle-famille pour son encouragement et son appui.*

## Remerciements

C'est avec un grand plaisir que je résume en quelques lignes en guise de reconnaissance et de gratitude envers les personnes qui m'ont aidé à la réalisation de ce mémoire car tout n'aura pas été possible sans leurs contributions et leurs aides.

Je tiens à adresser en particulier ma gratitude envers mon directeur de recherche Sousso Kelouwani, Professeur à l'Université du Québec à Trois-Rivières, ainsi que mon codirecteur Hicham Chaoui, Professeur à l'Université de Carleton, pour avoir accepté de m'encadrer dans ce travail et de leurs recommandations qui m'ont été très utiles. Je souhaite leur rendre hommage pour leur amabilité, leurs disponibilités et leurs conseils dans la réalisation de ce travail.

Je tiens à remercier aussi mes collègues pour leurs conseils et leurs contributions dans ce travail.

Je tiens également à remercier toute l'équipe de l'Institut de Recherche sur l'Hydrogène pour leur accueil, cela m'a enrichi de conseils et de discussion me permettant de connaître d'autres cultures.

Enfin, je tiens à remercier les membres du jury qui ont pris la peine d'évaluer de travail.

# Table des matières

Résumé .....	ii
Dédicaces .....	iv
Remerciements .....	v
Table des matières .....	vi
Liste des tableaux .....	x
Liste des figures.....	xi
Liste des abréviations.....	xiii
Chapitre 1 - Introduction .....	1
1.1 Mise en contexte.....	1
1.2 Problématique.....	3
1.3 Questions relatives au sujet de recherche .....	5
1.4 Objectifs.....	5
1.5 Méthodologie.....	6
1.6 Organisation du mémoire.....	8
Chapitre 2 - Revue de la littérature.....	9
2.1 Type de véhicule selon la source d'énergie utilisée .....	9
2.1.1 Véhicule à combustion interne.....	9
2.1.2 Véhicule électrique rechargeable à batterie .....	10

2.1.3 Véhicule hybride .....	11
2.2 Les facteurs d'influence sur la consommation de l'énergie d'un véhicule électrique.....	14
2.2.1 Mode de conduite .....	14
2.2.2 Forces résistantes.....	16
2.2.3 Conditions météorologiques.....	18
2.3 Méthodes d'estimation.....	19
2.3.1 Estimations des paramètres.....	19
2.3.2 Estimation de l'énergie consommée – L'état de charge .....	23
Chapitre 3 - Modélisation de l'utilisation de l'énergie .....	27
3.1 Architecture d'un véhicule électrique.....	28
3.2 Modèle dynamique longitudinal d'un véhicule électrique.....	28
3.3 Modèle de la batterie d'un véhicule électrique .....	31
3.3.1 Modèle physico-chimique.....	31
3.3.2 Estimation de l'énergie consommée.....	33
Chapitre 4 - Estimation des coefficients aérodynamique et de la résistance au roulement – Puissance & énergie - Autonomie.....	35
4.1 Introduction .....	35
4.2 Estimations des coefficients aérodynamique et résistance au roulement .....	37
4.2.1 Description de la méthodologie d'estimation.....	37



4.2.2 Estimation par la méthode des moindres carrés récurrents (MCR ou RLS).....	40
4.2.3 Estimation avec le filtre de Kalman (KF) .....	41
4.3 Estimation de la puissance fournie par la batterie et de l'énergie consommée.....	43
4.4 Estimation de l'autonomie .....	47
4.5 Mesures de performances.....	50
Chapitre 5 - Expérimentations et simulations .....	51
5.1 Validation et simulation.....	51
5.1.1 Paramètres du véhicule .....	51
5.1.2 Expériences et tests.....	53
5.2 Résultats des expériences et des simulations .....	55
5.2.1 Estimations des coefficients aérodynamique et résistance au roulement .....	55
5.2.2 Estimation de la puissance fournie par la batterie et de l'énergie consommée.....	60
5.2.3 Estimation de l'autonomie .....	63
Chapitre 6 - Discussions, conclusions et perspectives.....	67
Références .....	70
Annexe A – Fiche technique du véhicule KIA SOUL EV 2017.....	77

Annexe B – Article publié.....	80
Annexe C – Utilisation du OBD Link et Torque Pro .....	85

## Liste des tableaux

<i>Tableau 1: Principales caractéristiques du réseau NARX (FeedForward) avec leurs valeurs typiques .....</i>	<i>46</i>
<i>Tableau 2: Caractéristiques du KIA Soul EV 2017 .....</i>	<i>52</i>
<i>Tableau 3: Valeurs de la résistance au roulement obtenues avec les tests Coast down .....</i>	<i>54</i>
<i>Tableau 4: Récapitulation des tests .....</i>	<i>54</i>
<i>Tableau 5: MSE et valeurs moyennes estimées .....</i>	<i>58</i>

## Liste des figures

<i>Figure 1: Diversification de l'utilisation du pétrole dans le monde [2] .....</i>	<i>2</i>
<i>Figure 2: Architecture d'un véhicule à combustion interne.....</i>	<i>10</i>
<i>Figure 3: Architecture d'un véhicule électrique rechargeable à batterie.....</i>	<i>11</i>
<i>Figure 4: Architecture d'un véhicule hybride série .....</i>	<i>12</i>
<i>Figure 5: Architecture d'un véhicule hybride parallèle.....</i>	<i>12</i>
<i>Figure 6: Architecture d'un véhicule hybride série/parallèle .....</i>	<i>13</i>
<i>Figure 7: Structure détaillée d'un véhicule électrique .....</i>	<i>28</i>
<i>Figure 8: Aperçu des forces externes appliquées au véhicule .....</i>	<i>29</i>
<i>Figure 9: Circuit électrique équivalent de la batterie .....</i>	<i>32</i>
<i>Figure 10: Dispersion des pertes énergétiques d'un véhicule à combustion sur des trajets: a) en ville, b) sur autoroute .....</i>	<i>36</i>
<i>Figure 11: Dispersion des pertes énergétiques des véhicules électriques à freinage régénératif sur des trajets: a) en ville, b) sur autoroute .....</i>	<i>36</i>
<i>Figure 12: Diagramme d'estimation des paramètres .....</i>	<i>38</i>
<i>Figure 13: Rendement du moteur électrique jusqu'aux roues .....</i>	<i>39</i>
<i>Figure 14: Représentation schématique de l'architecture NARX en boucle fermée (à gauche) et en boucle ouverte (à droite) .....</i>	<i>45</i>
<i>Figure 15: Diagramme schématique d'un réseau NARX implémenté avec un réseau à réaction contenant une couche cachée avec 10 neurones .....</i>	<i>46</i>
<i>Figure 16: Illustration de la distance mémoire et de la distance parcourue pour un test de conduite sur autoroute .....</i>	<i>49</i>
<i>Figure 17: KIA Soul EV 2017 : A) à l'intérieur de l'IRH, B) sur asphalte, C) sur neige .....</i>	<i>51</i>
<i>Figure 18: Coefficients estimés Vs valeurs réelles dans les conditions sans neige : a) coefficient aérodynamique, b) coefficient de résistance au roulement. ....</i>	<i>56</i>

<i>Figure 19: Coefficients estimés Vs valeurs réelles dans les conditions avec neige : a) coefficient aérodynamique, b) coefficient de résistance au roulement. ....</i>	<i>57</i>
<i>Figure 20: Carte énergétique des différents tests de conduite : a) route enneigée en ville, b) route sèche en ville, c) autoroute sèche (vitesse <math>\leq 100</math> km/h), d) campagne sèche (vitesse <math>\leq 70</math> km/h) .....</i>	<i>60</i>
<i>Figure 21: Profils de puissance mesurée vs estimée : a) condition enneigée, b) condition non-enneigée .....</i>	<i>61</i>
<i>Figure 22: Energie cumulée mesurée vs estimée : a) condition enneigée, b) condition non-enneigée .....</i>	<i>62</i>
<i>Figure 23: Calcul de l'efficacité de conduite pour un test de conduite sur autoroute (<math>V_{max} = 100</math> km/h).....</i>	<i>63</i>
<i>Figure 24: Efficacité de conduite pour un test de conduite dans une zone scolaire avec une présence de pente (<math>V_{max} = 30</math> km/h) .....</i>	<i>64</i>
<i>Figure 25: Estimation de l'autonomie restante via le NARX et l'historique des données de conduite .....</i>	<i>65</i>
<i>Figure 26: a) module OBD Link MX, b) logiciel Torque Pro.....</i>	<i>85</i>

## Liste des abréviations

AH : Ampère-Heure

ANN : Artificial Neural Network

AR : Autonomie Restante

CAN : Controller Area Network

CO<sub>2</sub> : Dioxyde de Carbone

cv: Cheval-Vapeur

EKF: Extended Filter Kalman

EV: Electric Vehicle

FFNN: FeedForward Neural Network

GES: Gaz à Effet de Serre

GPS : Global Position System

HEV : Hybrid Electric Vehicle

IRH : Institut de Recherche sur l'Hydrogène

KF: Kalman Filter

kg: Kilogramme

kW: Kilowatt

kWh: Kilowattheure

km: kilomètre

km/h: kilomètre par heure

LMS: Least Mean Square

MSE: Mean Squared Error

NARX: Nonlinear AutoRegressive eXogenous

NLMS: Normalized Least Mean Square

Nm: Newton-Mètre

OBD: On-Board Diagnostics

PID: Processus Identifier

PM: Puissance mécanique

RLS : Recursive Least Square

RNN : Recurrent Neural Network

s : Seconde

TPMS: Tire Pressure Monitoring System

UQTR: Université du Québec à Trois Rivières

# Chapitre 1 - Introduction


## 1.1 Mise en contexte

Le secteur du transport représente le plus grand défi à relever dans la lutte aux changements climatiques. Au Québec, près de 40% des émissions de gaz à effet de Serre (GES) et 25% de la consommation totale d'énergie lui sont attribuables. Les véhicules routiers sont responsables de plus de 80% des émissions de GES et de la consommation énergétique en transport. Le principal gaz à effet de serre émis par les véhicules est le dioxyde de carbone (CO<sub>2</sub>) [1].

Aujourd'hui, 55 % de la production mondiale de pétrole est consommée par le secteur du transport (fig.1). Avec 93 % de son énergie utilisée provenant de produits pétroliers, il apparaît comme le moins diversifié de tous sur le plan énergétique. En effet, en raison de leur densité énergétique très élevée (~12 kWh/kg), liée à leur état sous forme liquide en condition atmosphérique, et de la quasi-absence de difficultés en matière d'approvisionnement, les carburants pétroliers ont été jusqu'à présent massivement utilisés par les principaux modes de transport (routier, aérien, maritime). Ainsi, au niveau mondial, le secteur du transport s'affiche comme le deuxième contributeur aux émissions anthropiques de GES, après celui de la production d'électricité.

Des efforts sont toutefois déployés pour réduire la dépendance du secteur du transport au pétrole en proposant des solutions énergétiques alternatives innovantes [2].





Source : AIE, 2016

Figure 1: Diversification de l'utilisation du pétrole dans le monde [2]

En 2013, l'essence, le principal produit pétrolier consommé au Québec, a représenté 47,4 % de la consommation totale des produits pétroliers énergétiques. Le carburant diesel s'est établi au deuxième rang avec une part de 27,2 %. Il a été suivi du carburéacteur (11,7 %), du mazout lourd (5,2 %) et du mazout léger (4,3 %) [3].

Aujourd'hui, plus d'un milliard de véhicules circulent dans les rues et les industriels produisent plus de 80 millions de nouveaux véhicules chaque année. Compte tenu de cette production en masse, les progrès du secteur du transport sont inévitables pour accommoder les besoins modernes de déplacement avec certaines contraintes comme l'épuisement des ressources fossiles et l'émission de gaz à effet de serre [4].

L'électrification du groupe motopropulseur a été identifiée comme un moyen efficace de résoudre deux problèmes:

- Efficacité énergétique: le moteur électrique est 3 fois plus efficace que les véhicules à essence et 2 fois plus efficace que le moteur diesel
- Émissions de gaz à effet de serre: un véhicule électrique propulsé par batterie ou pile à combustible ne produit aucun GES local par rapport aux véhicules à moteur à combustion interne

## 1.2 Problématique

La gestion de la consommation d'énergie d'un véhicule reste un défi complexe du fait que cela dépend de plusieurs facteurs que ce soit au niveau du véhicule ou de son environnement. Les paramètres qui affectent cette consommation peuvent être des inconnus ou difficiles à estimer. La consommation d'énergie des véhicules conventionnels dépend de plusieurs paramètres, tels que le poids du véhicule, l'efficacité du moteur et des paramètres dynamiques comme la résistance au roulement et la traînée aérodynamique du véhicule [5] et l'économie mondiale de carburant dans de tels systèmes est étroitement liée au contrôle du flux de puissance entre chacune des sources d'énergies et le groupe motopropulseur [6] [7]. L'estimation en ligne des paramètres du véhicule a été un domaine de recherche actif au cours des dernières décennies [8]. En raison de la différence de taille des véhicules, de la forme de la carrosserie et du nombre d'essieux, les valeurs de résistance au roulement et de résistance à l'air varient d'un véhicule à l'autre [9]. Cependant, ces facteurs sont normalement supposés les mêmes dans la littérature quelle que soit la configuration du véhicule. Le coefficient de résistance au roulement peut varier en fonction du type de pneumatique et de la surface de la route [10] [11] [12]. De plus, la masse du véhicule et le coefficient de traînée aérodynamique peuvent changer considérablement lorsqu'une remorque ou un autre véhicule non motorisé est attaché à la voiture. Par conséquent, l'estimation des paramètres en ligne est nécessaire

dans la formulation du contrôle du groupe motopropulseur dans les véhicules commerciaux, car elle réduit l'effort d'étalonnage initial. De plus, il aide le contrôleur du groupe motopropulseur à s'adapter rapidement aux différentes configurations de véhicules, ce qui se traduit par une meilleure économie de carburant. Par conséquent, la consommation de carburant du véhicule et les rejets de CO<sub>2</sub> dans l'atmosphère dépendent de manière significative des forces de résistance du véhicule [13].

De plus, pour les véhicules électriques, malgré tous ses avantages cités précédemment, les véhicules électriques nécessitent une recherche plus profonde car ces véhicules présentent quelques problèmes dont :

- Long temps de recharge par rapport au véhicule conventionnel
- Densité d'énergie limitée qui raccourcit la plage de fonctionnement
- Autonomie réduite en basse température
- Augmentation de l'anxiété en hiver.

Ainsi leur acceptation et leur adoption par les clients sur le marché est principalement entravée par leur densité énergétique limitée, le long temps de recharge et le déploiement insuffisant de l'infrastructure de charge. La plage de conduite limitée des véhicules électriques résultant de leur densité d'énergie limitée est considérablement réduite dans les conditions hivernales, où le véhicule dépense une quantité considérable de son énergie disponible pour chauffer les accessoires (en raison de la basse température) et surmonter les forces de résistance (traînée aérodynamique et roulement résistance) en raison des routes enneigées et verglacées. Ces inconvénients des VE entraînent ce que l'on appelle « l'anxiété d'autonomie », qui doit être sérieusement combattue par les constructeurs automobiles afin de faire accepter les véhicules électriques par les clients.

### 1.3 Questions relatives au sujet de recherche

Par rapport aux problèmes cités précédemment, on peut alors se questionner sur les points suivants :

- *Comment les véhicules électriques dépensent-ils l'énergie et comment gérer cette consommation d'énergie?*

Pour pouvoir être plus précis par rapport à la question précédente, on peut se demander :

- *Comment introduire une méthode d'estimation correcte des pertes aérodynamiques, des pertes par friction roues/routes et des pertes dues à la configuration de la route ainsi que les conditions climatiques?*
- *Comment prédire la consommation d'énergie sur un trajet défini en connaissant sa configuration ?*

### 1.4 Objectifs

Ce sujet de recherche propose une approche sur l'estimation de la consommation d'énergie de la famille des véhicules électriques afin que l'on puisse estimer l'autonomie de manière exacte.

Pour améliorer la précision dans les estimations de la consommation énergétique et de l'autonomie restante permettant de réduire l'anxiété de distances chez les usagers des véhicules électriques, notre travail de recherche consiste alors à inclure les valeurs des deux paramètres physiques du véhicule, qu'on a sélectionnés : les coefficients aérodynamique et de la résistance au roulement dans le modèle choisi.

En se basant sur la problématique, les objectifs secondaires de ce travail peuvent être définis comme suit :

- Établir un algorithme d'estimation en ligne des coefficients aérodynamique et de la résistance au roulement au roulement du véhicule.
- Établir un modèle de prédiction afin d'avoir une bonne précision sur l'estimation de la consommation d'énergie du véhicule sur un trajet déterminé.

### 1.5 Méthodologie

Le but de ce projet étant de donner des informations précises sur la prévision de la consommation énergétique ainsi que l'autonomie restante, tout en se basant sur l'estimation simultanée, et en temps réel des paramètres qui peuvent influencer la consommation d'énergie d'un véhicule électrique à batterie rechargeable.

Afin de répondre à nos objectifs et aux questions de recherche, la méthodologie a été organisée comme suit :

La première étape consiste à effectuer une revue de la littérature afin d'établir une modélisation du véhicule et de ses différents composants pour choisir les paramètres du véhicule qui peuvent influencer la consommation d'énergie. Ces paramètres sélectionnés vont être estimés et intégrés dans l'estimation de l'énergie consommée. Le coefficient aérodynamique et le coefficient de la résistance au roulement ont été choisi dans ce sujet. Dans la stratégie d'estimation de ces deux paramètres, le modèle dynamique longitudinal est considéré. La deuxième partie de la revue consiste à trouver les modèles et méthodes intéressants pour estimer la puissance fournie par la batterie- l'énergie consommée- l'autonomie du véhicule.

En premier lieu, afin de choisir les techniques d'estimation les plus adaptés à notre objectif, une recherche bibliographique des différentes techniques d'estimation des paramètres est une étape importante pour ce choix. Cela a permis de relever les limites de certaines méthodes des études antérieures et de développer, dans une deuxième étape, les algorithmes utiles pour cette étude. Les algorithmes d'estimation développés s'appuient sur deux approches différentes mais un peu similaires : l'approche des moindres carrés récursifs (MCR) ou Recursive least square (RLS) et le filtre de Kalman. Une comparaison entre les deux méthodes estimant les deux paramètres simultanément nous a permis d'identifier l'approche la plus appropriée à l'estimation en temps réel. Le filtre de Kalman s'est montré plus efficace.

Une fois que ces deux paramètres sont estimés, ils seront intégrés au fur et à mesure dans l'estimation de l'énergie fournie par la batterie dans un trajet défini.

La deuxième étape de notre méthodologie consiste à estimer la puissance fournie par batterie pour obtenir l'énergie électrique sur un trajet ainsi que l'estimation de l'autonomie restante. Pour cela, le modèle NARX ou Nonlinear AutoRegressive eXogenous est utilisé pour ces estimations. Ces estimations sont basées sur deux critères : *(i)* la configuration du réseau, et *(ii)* l'intégration des forces estimées dans le modèle. Ce scénario permettra de savoir quelles configurations sont adaptés pour ce travail et aussi s'il est nécessaire d'inclure les forces estimées dans le modèle.

La troisième étape consiste à valider les méthodes et modèles proposés tout en utilisant les données réelles et les résultats expérimentaux obtenus sur le véhicule électrique KIA SOUL EV de l'Institut de Recherche sur l'Hydrogène (IRH). Puis, finalement, les résultats

seront analysés et discutés tout en tenant compte des cycles de conduites et des itinéraires définis.

## **1.6 Organisation du mémoire**

Le contenu de ce mémoire est structuré comme suit :

Le chapitre 1 a été consacré à l'introduction au projet de recherche, en présentant le projet dans son contexte, en présentant la problématique, les objectifs et la méthodologie adoptée.

La revue bibliographique est illustrée dans le chapitre 2. Cette partie illustrera les différentes technologies de véhicule en termes de source d'énergie. Ce chapitre présentera aussi les facteurs influençant la consommation d'énergie d'un véhicule et aussi les différentes méthodes d'estimation des coefficients aérodynamique et de résistance au roulement

Le chapitre 3 présentera le modèle adopté pour la gestion énergétique d'un véhicule électrique. L'estimation des coefficients aérodynamique et de la résistance au roulement est présentée dans le chapitre 4 ainsi que les estimations de la puissance/énergie fournie par la batterie ainsi que de l'autonomie par la batterie.

Le chapitre 5 présentera les expériences et les résultats pour la validation de chaque estimation.

Le chapitre 6 conclut le mémoire par une discussion sur les résultats et les perspectives.

## Chapitre 2 - Revue de la littérature

De moteur à explosion à moteur 100% électrique, le domaine du transport continue sur sa lancée afin de donner satisfaction sur le plan environnemental et commercial. Cette innovation nécessite une continuité de travail pour l'efficacité énergétique et pour plus de sécurité. Le but de ce chapitre est de présenter, d'abord, des généralités sur les différentes technologies en termes de sources d'énergie existantes ainsi que les principaux organes constitutifs. La deuxième partie sera consacrée aux facteurs qui peuvent influencer la consommation d'énergie et la dernière partie de ce chapitre présentera les travaux antérieurs sur les méthodes d'estimations des coefficients aérodynamique et de résistance au roulement ainsi que la puissance/énergie fournie par batterie et l'état de charge.


### 2.1 Type de véhicule selon la source d'énergie utilisée

#### 2.1.1 *Véhicule à combustion interne*

Le moteur thermique désigne le cœur d'une automobile standard, c'est-à-dire alimentée par de l'essence ou du gazole (diesel). Le moteur produit de l'énergie en brûlant à très haute température (phase de combustion ou d'explosion) le carburant dont elle dispose. C'est le mode de fonctionnement de la plupart des véhicules de transport. Les gaz brûlés sont ensuite dégagés via la sortie d'échappement [14]



Un moteur à combustion interne (MCI) est un type de moteur à combustion dans lequel l'énergie thermique dégagée par la combustion est convertie en énergie mécanique à l'intérieur du moteur [15].



*Figure 2: Architecture d'un véhicule à combustion interne*

Les pistons du moteur descendent et aspirent le carburant et l'air par l'intermédiaire d'une pompe. Les pistons remontent et le mélange (carburant + air) est comprimé dans les cylindres du moteur produisant une combustion du mélange avec de l'étincelle. Cette explosion renvoie les pistons en bas et ces derniers remonteront pour pousser les gaz d'échappement vers l'extérieur du moteur. Le cycle de va et viens recommence et transférant ce mouvement par un système de bielles et de vilebrequins, vers l'arbre de transmission qui est connecté avec les autres organes de transmission (rapport de réduction, différentielle...) et propagera la puissance générée par le moteur vers les roues

### *2.1.2 Véhicule électrique rechargeable à batterie*

Un véhicule électrique rechargeable à batterie est un véhicule cent pour cent électrique doté d'une seule chaîne de traction électrique. Les véhicules électriques possèdent un chargeur utilisé comme interface entre le pack de batterie et le réseau électrique. Ce pack de

batterie alimente et transmet à l'onduleur le courant continu pour le transformer en courant alternatif pour le moteur [16].




Figure 3: Architecture d'un véhicule électrique rechargeable à batterie

### 2.1.3 Véhicule hybride

Un véhicule hybride est un véhicule qui utilise au moins deux sources d'énergie différentes pour se déplacer. Généralement, on désigne par voiture hybride une voiture qui recourt à un carburant et à l'électricité pour se mouvoir au moyen de deux moteurs : l'un thermique, l'autre électrique.

#### 2.1.3.1 Hybride série

Ce type de véhicule possédant deux sources dont le moteur thermique n'est pas couplé directement aux roues. La propulsion est assurée par le moteur électrique, lui qui est alimenté par une batterie ou/et par un autre système (groupe électrogène) [17].

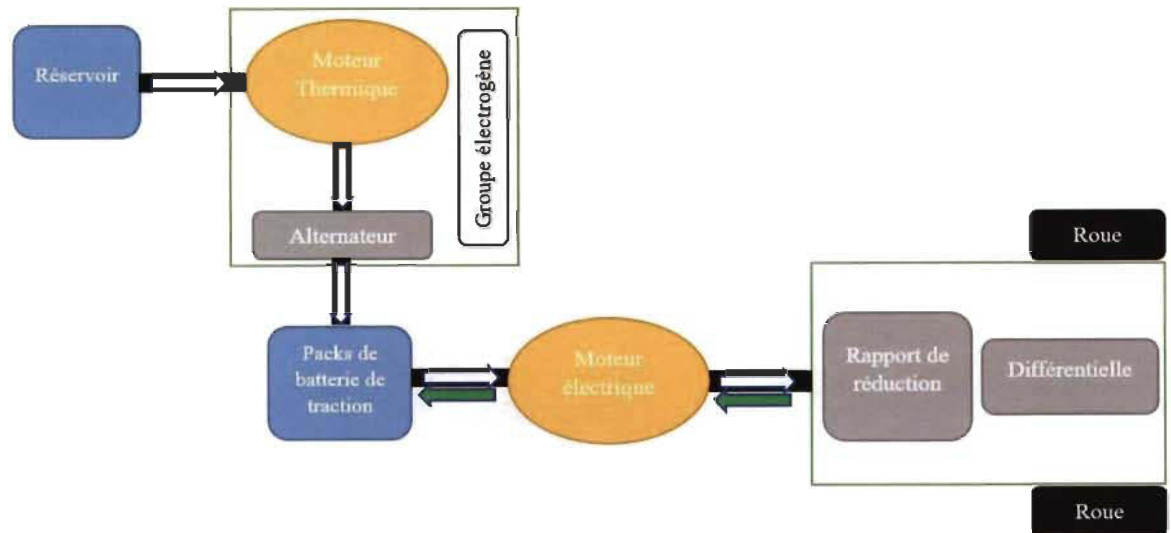


Figure 4: Architecture d'un véhicule hybride série

### 2.1.3.2 Hybride parallèle

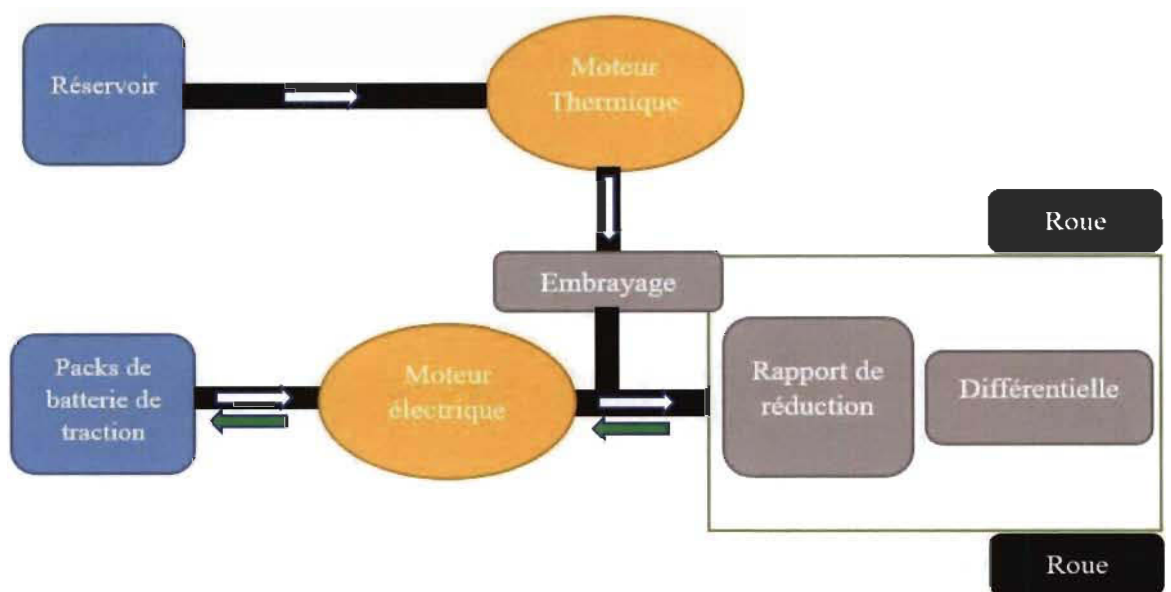


Figure 5: Architecture d'un véhicule hybride parallèle

Le type d'hybride parallèle possède deux sources d'énergie pour se propulser : le moteur thermique et le moteur électrique et qui sont associés aux roues. Les flux énergétiques

provenant de ces deux types de sources arrivent en parallèle aux roues pour assurer la traction du véhicule, que ce soit conjointement ou séparément [18].

### 2.1.3.3 Hybride série/parallèle

Dans ce type de véhicule, le fonctionnement est possible que ce soit indépendante ou simultanée, comme son nom l'indique. Conceptuellement, le moteur thermique et le moteur électrique sont connectés à la transmission par l'intermédiaire des voies séparées, permettant une propulsion entièrement indépendante via les deux moteurs.

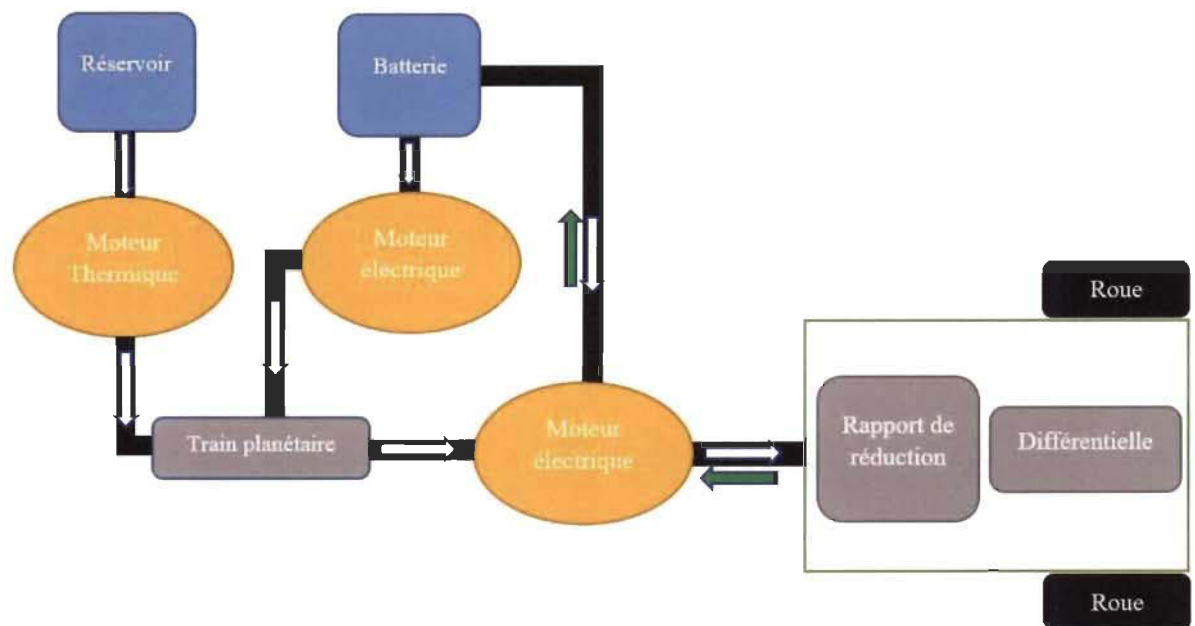


Figure 6: Architecture d'un véhicule hybride série/parallèle

L'alternance entre les deux moteurs s'opère suivant plusieurs modes (un moteur principal et un moteur de réserve ou suivant la vitesse...).

Dans ce modèle, les moteurs peuvent fonctionner de manière indépendante ou simultanée. Cela assure un usage sélectif du moteur thermique et électrique pour économiser la consommation [19].

## 2.2 Les facteurs d'influence sur la consommation de l'énergie d'un véhicule électrique

Pour pouvoir étudier comment l'énergie est utilisée, il faut savoir les facteurs qui influenceront sur la consommation de cette énergie afin de gérer l'énergie nécessaire pour un déplacement. Dans cette partie, on va présenter des facteurs que l'on ne peut pas négliger comme le mode de conduite du conducteur avec l'efficacité du moteur ainsi que les forces résistives telles que la force aérodynamique, la résistance au roulement sans oublier la masse et les conditions météorologiques qui peuvent faire varier la consommation de l'énergie d'un véhicule électrique.

### 2.2.1 *Mode de conduite*

Les modes de conduite peuvent influencer sur la consommation énergétique. La façon dont on joue avec les pédales de frein, accélérateur, etc, affectera sur l'énergie consommée. La conduite économique, écologique et sûre (écoconduite) vise à réduire la consommation de carburant, les émissions de gaz à effet de serre et les accidents [20]. La consommation d'énergie et les émissions de CO<sub>2</sub> peuvent être réduites grâce à une variété de stratégies qui réduisent la congestion, la fluidité du trafic et la vitesse excessive des véhicules. L'écoconduite peut réduire la consommation de carburant de 10%, en moyenne et dans le temps, réduisant ainsi les émissions de CO<sub>2</sub> de la conduite d'un pourcentage équivalent [21]. Cela consiste généralement à modifier le comportement de conduite d'une personne en fournissant des conseils statiques généraux au conducteur (par exemple, n'accélérez pas trop rapidement, ne réduisez pas la vitesse, etc.) [22]. En allant plus loin, il est possible de fournir des conseils en temps réel aux conducteurs en fonction de l'évolution du trafic et des conditions d'infrastructure pour des économies de carburant et d'émissions encore plus

importantes [23]. Une consommation de carburant excessive peut être évitée si une stratégie de conduite optimale est mise en œuvre en fonction de l'état environnant d'un véhicule et des contraintes existantes [24]. Selon l'étude faite dans [25], voici des conseils, en deux étapes, qui pourraient aider sur la façon de conduire afin d'optimiser la consommation d'énergie:

**Étape 1** : Avant de prendre la route

1. Alléger le plus possible son véhicule au niveau de la masse et l'aérodynamisme
2. Préparer son itinéraire permettant de choisir le trajet avec le moins de kilomètres ou le trajet le plus rapide. Sauf exception, il permet d'éviter les détours, empêche de se perdre (et donc de parcourir des kilomètres pour rien) et fait gagner un temps précieux.
3. Vérifier la pression des pneus chaque mois: rouler avec des pneus sous-gonflés accroît sensiblement la consommation d'énergie : 2,4% par 0,5 bar de déficit. Une pression trop basse affecte aussi la tenue de route et la distance de freinage.

Les pneus se dégonflent naturellement, il est donc nécessaire de contrôler leur pression au moins une fois par mois. Le contrôle doit s'effectuer à froid, c'est-à-dire après moins de 3 kilomètres de roulage, sinon il faut attendre 10 minutes pour laisser refroidir les pneus.

**Étape 2** : Sur la route

4. Utiliser les instruments de bord pour donner les informations instantanées.
5. Rouler moins vite: rouler autant que possible à vitesse modérée. Rouler moins vite permet également de ralentir plus facilement, en utilisant le frein moteur autant que possible. Le frein moteur permet non seulement de réduire sa consommation et l'usure des freins mais il améliore également la sécurité routière et le confort des passagers.

6. Éteindre le moteur du véhicule lorsqu'on est en stationnement ou dans une file d'attente

7. Anticiper les embouteillages afin d'éviter d'accélérer ou de freiner inutilement. Afin de pouvoir maintenir la vitesse la plus stable possible, anticiper le trafic est essentiel.

C'est aussi un conseil essentiel pour la sécurité : on est moins pris au dépourvu si on regarde le trafic au loin et qu'on anticipe les événements pouvant survenir (piéton qui va traverser, voiture qui va dépasser ou freiner, feu de signalisation qui passe au rouge...).

Conduire comme si on n'avait pas de freins : maintenir le plus possible une vitesse stable, en évitant de freiner et accélérer sans arrêt.

8. Utiliser la climatisation à bon escient: la climatisation peut être très utile lors de longues conduites en pleine chaleur mais n'est pas nécessaire la plupart du temps. On évite donc de la laisser allumer par défaut.

### 2.2.2 *Forces résistantes*

Pour pouvoir assurer la gestion de la consommation d'énergie, il est primordial de savoir les forces qui peuvent influencer la consommation. Cette sous-partie présentera les forces résistantes au mouvement d'un véhicule qui peuvent affecter la consommation comme la résistance au roulement, la force aérodynamique ainsi que la masse.

La résistance au roulement est la force qui résiste/s'oppose au mouvement d'un corps roulant sur une surface causée par des effets non-élastiques. Selon [26], la résistance au roulement des pneus est définie comme l'énergie consommée par unité de distance de déplacement lorsqu'un pneu roule sous une charge. Elle est importante pour le mouvement

des véhicules au sol [27] et le modèle de la résistance au roulement est essentiel à la modélisation de la dynamique globale d'un véhicule à des fins d'analyses, de contrôle, de simulation car le mouvement d'un véhicule au sol est principalement déterminé par les forces de frottement transmises par les routes via les pneus [28]. D'après [29], la résistance au roulement affecte non seulement la consommation d'énergie mais aussi le confort de conduite pour les passagers ainsi que les coûts d'exploitation du véhicule. Dans un contexte de progrès renouvelable et durable dans l'industrie automobile où le carburant et le respect de l'environnement sont au cœur de toutes les préoccupations, les pneumatiques écoénergétiques pourraient jouer un rôle important pour économiser de l'argent, limiter les gaz à effet de serre et contribuer à réduire la pollution locale [30].

D'autre part, d'un point de vue général, l'aérodynamique est la science qui étudie les phénomènes accompagnant tout mouvement entre un corps et l'air qui le baigne. Dans le domaine de l'automobile, l'aérodynamique est l'étude des phénomènes aérodynamiques induits par l'écoulement de l'air autour d'un véhicule automobile en mouvement. L'aérodynamique des véhicules joue un rôle beaucoup plus important dans les considérations de conception [31]. Les caractéristiques aérodynamiques des véhicules intéressent les chercheurs depuis de nombreuses années, principalement en vue de réduire la traînée et par conséquent d'améliorer le rendement énergétique [32].

De même que les deux cités précédemment, la masse est un élément clé dans la gestion de la consommation. La réduction de la masse est l'un des moyens les plus pratiques dans la diminution de la consommation d'énergie du véhicule [33]. Ce dernier évalue l'impact de la réduction de la masse des véhicules pour plusieurs plates-formes de véhicules et des technologies de groupe motopropulseur avancées, y compris les véhicules électriques



hybrides (HEV) à moteur à combustion interne et les VEH à pile à combustible, par rapport aux véhicules conventionnels. Les résultats dans [34] ont confirmé que la consommation de carburant augmente à mesure que la masse augmente et est différente pour différentes combinaisons de types de carburant et de transmission. De plus, l'augmentation de la masse du véhicule diminue généralement le risque de blessure pour le conducteur d'un véhicule donné en cas de collision. Une réduction de la masse des véhicules de 10% (en supposant une masse de charge utile constante) se traduit par une amélioration de 2% de la consommation de carburant pour les trains et les camions légers, moyens et lourds, 4% pour les bus et 7% pour les avions [35].

### *2.2.3 Conditions météorologiques*

La consommation d'énergie dépend aussi de l'environnement par lequel le véhicule se trouve ou y va afin d'estimer son autonomie: la température, pluvieux/non-pluvieux, etc... [36] a fait une étude selon laquelle la température affecte l'autonomie d'un véhicule. La voiture en question est une Nissan Leaf. La consommation d'énergie et l'autonomie varient considérablement en fonction de la température. Aux températures les plus froides, le Leaf a complété le parcours en utilisant 467 Wh/mile d'énergie électrique en courant continu provenant de la batterie. Sur la base de ce test et des tests ultérieurs effectués ce jour-là (qui avait une température moyenne de 14 ° F), l'autonomie estimée du véhicule était de 50 miles. À mesure que la température ambiante augmentait, la consommation d'énergie avait tendance à diminuer, ce qui augmentait l'autonomie. La période d'essai la plus chaude était en moyenne de 71 ° F et les tests ont abouti à une autonomie estimée à 91 miles. Tous les tests ont été terminés avec la commande de climatisation du véhicule réglée sur automatique 72 ° F.

Durant le trajet, le véhicule nécessite plus d'énergie pour le confort des passagers comme la climatisation, la ventilation, le chauffage, etc... Or, des facteurs tels que la température ambiante locale, le rayonnement solaire local, l'humidité locale, la durée du trajet et le trempage thermique avec ces confort ont été identifiés comme les principaux facteurs des charges de conditionnement de l'habitacle et donc de l'autonomie du véhicule [37].

En prenant exemple sur la trainée aérodynamique, la vitesse et la direction du vent, la direction, la densité de l'air varie en fonction de la température, de l'humidité, etc... La référence [38] est un tableau montrant la variation de la densité de l'air en fonction de la température et de l'humidité. Ainsi, on peut dire que ces conditions sont non-négligeables en termes de gestion énergétique et dans l'analyse de la consommation.

## 2.3 Méthodes d'estimation

### 2.3.1 *Estimations des paramètres*

L'estimation des coefficients aérodynamiques et de la résistance au roulement dans le cadre de l'utilisation de l'énergie est primordiale dans l'optimisation de la consommation énergétique du fait que ces deux paramètres peuvent influencer la consommation mais pourtant cette partie n'est pas vraiment prise en compte dans la littérature.

Plusieurs méthodes ont été rapportées dans la littérature et peuvent être classées comme suit : le « Event-seeking » ou la recherche d'évènements et le « Averaging » ou le calcul de la moyenne.

- **Recherche d'événements :**

Cette catégorie regroupe les méthodes dont les conditions de conduite assurent une situation suffisante pour l'estimation des paramètres.

L'étude [39] compare les coefficients de force aérodynamique obtenus par les expériences respectives afin d'évaluer les effets des coefficients de force aérodynamique sur la vitesse critique du vent. L'influence de chaque coefficient aérodynamique sur la vitesse critique du vent est examinée en calculant la vitesse critique du vent pour des quantités données de changement des coefficients de force aérodynamique. Les coefficients de force aérodynamique utilisés dans cette étude ont été obtenus à partir d'expériences en soufflerie. Cette étude a été faite dans le cadre de la sécurité ferroviaire.

D'autre part, [40] montre une étude sur l'économie de carburant d'un véhicule lourd par la réduction de la traînée aérodynamique. Les opérations routières réalistes sont prises en compte en simulant des itinéraires de conduite typiques sur les distributions long-courriers et urbaines; les variations de poids du véhicule sont également prises en compte. Les résultats montrent que les performances de ces dispositifs aérodynamiques dépendent à la fois de leurs fonctions et du fonctionnement des véhicules. Les véhicules long-courriers économisent généralement deux fois plus de carburant que ceux conduits dans les zones urbaines. Les réductions de carburant résultant de l'utilisation d'appareils sélectionnés individuellement sur un grand camion vont de moins de 1% à près de 9% du coût du carburant d'un véhicule effectuant un kilométrage annuel est de 80 000 miles.

[41] présente des algorithmes d'estimation du coefficient de frottement qui fonctionnent avec des capteurs qui sont principalement disponibles dans les voitures particulières typiques. Ils sont développés sur la base de la dynamique latérale ou de la dynamique longitudinale, mais étendus plus tard pour couvrir les cas de glissement combinés. En ce qui concerne les méthodes basées sur la dynamique latérale, plus robustes aux bruits haute fréquence, un observateur non linéaire a été proposé. En outre, un processus de conception d'observateurs

non linéaires robustes a été développé en utilisant la mise en œuvre numérique des conditions de stabilité de Lyapunov. En ce qui concerne les méthodes basées sur la dynamique longitudinale, la rigidité longitudinale des pneus est utilisée pour déduire le frottement de la route. Les méthodes originales basées sur la dynamique latérale et longitudinale ne fonctionnent bien que dans des conditions d'excitation par glissement pur. Pour augmenter la plage de travail, une logique d'intégration a été développée pour basculer entre les algorithmes développés en fonction de la nature et du niveau des excitations.

Dans [42], ils ont utilisé la méthode Coast down afin de comprendre les améliorations potentielles ou aérodynamiques par l'application de différents panneaux de plancher qui pourraient être masqués par les essais traditionnels en soufflerie sur sol fixe. L'intégration de la méthode d'analyse de l'équation du mouvement semble insensible aux influences de l'environnement, et la moyenne des effets stochastiques donne des résultats reproductibles avec seulement quelques paires d'essais par configuration.

- **Calcul de la moyenne :**

Au contraire de la méthode de recherche d'événements, la méthode de calcul de la moyenne surveille en permanence la dynamique du véhicule afin d'estimer directement les coefficients aérodynamique et résistance au roulement à partir de différentes méthodes comme la méthode récursive des moindres carrés ou le filtre de Kalman ou des méthodes d'estimation non linéaires. En effet, certaines études ont présenté une estimation simultanée, directe et en ligne des coefficients aérodynamique et résistance au roulement.

En effet, l'étude dans [8] présente une estimation simultanée des coefficients aérodynamique et de résistance au roulement en utilisant la méthode des moindres carrés récursifs. Des données expérimentales d'un véhicule lourd ont été utilisées pour tester

l'algorithme dans une simulation. L'estimateur proposé a montré une précision adéquate dans la prédiction de la charge routière. De même que dans les études [43] et [44] qui estiment les frottements routiers en utilisant la méthode des moindres carrés récursifs.

De son côté, [9] présente une estimation des deux coefficients : en premier lieu simultanément, et puis séquentiellement avec deux méthodes en ligne basées sur le filtre de Kalman : le modèle de base et l'étendu. Les expériences ont montré la difficulté de séparer la résistance au roulement et la traînée de l'air. Il est montré que des estimations simultanées des deux sont possibles, mais en pratique une trop grande variation de vitesse est nécessaire pour obtenir des estimations précises avec les méthodes étudiées. Il est également montré que lors de l'estimation d'un paramètre à la fois, des estimations précises peuvent être générées. Cependant, il s'est avéré difficile de baser ces estimations les unes sur les autres, en raison de la grande dépendance à la température de la résistance au roulement

Basé sur la dynamique longitudinale d'un véhicule, l'étude [45] a proposé d'estimer les paramètres qui peuvent varier durant un trajet par simulation y compris les coefficients aérodynamique et résistance au roulement à l'aide d'observateurs non linéaires basés sur le filtre de Kalman Non-parfumé. Sur la base de la simulation et des résultats expérimentaux, les conclusions suivantes peuvent être tirées: Les limites des estimateurs basés sur la cinématique et les modèles disponibles conduisent à un schéma d'observateur robuste aux changements de frottement de la route pour estimer la vitesse longitudinale à chaque pneu.

L'étude dans [46] utilise un réseau de neurones RBF pour compenser l'influence négative des incertitudes du modèle de friction sur la précision de l'estimation de la force. En divisant la non-linéarité du modèle de friction en deux parties, l'entrée du réseau RBF ne comprend qu'une seule variable, ce qui permet que les centres et les étendues des neurones de la couche

cachée puissent être mis hors ligne d'une manière très simple. Les poids des couches de sortie sont adaptés en ligne par une loi d'adaptation dérivée de l'analyse de stabilité de Lyapunov. Une telle approche garantit une estimation rapide et robuste de la force de frottement pneu / route, même dans les cas où des changements larges et brusques des paramètres de frottement se produisent.

### *2.3.2 Estimation de l'énergie consommée – L'état de charge*

L'estimation de l'énergie électrique peut se faire de différentes manières. On peut savoir l'énergie consommée selon la puissance fournie par la batterie ou l'état de charge de la batterie ou l'autonomie restante fournie par le véhicule. Pourtant, cette estimation nécessite une recherche plus profonde sur le fait que tout se base sur l'énergie restante ou l'énergie consommée.

La mesure et l'estimation de la consommation d'électricité des VE est une exigence importante pour l'amélioration future de l'efficacité énergétique du système de transport des VE. L'une des caractéristiques les plus avancées d'un véhicule électrique, par rapport aux véhicules ICE conventionnels, est sa capacité à capter et à stocker de l'énergie grâce au système de freinage régénératif (RBS). L'étude dans [47] propose une approche d'estimation de l'état de charge utilisant un système neuro-flou basé sur le regroupement soustractif est présentée et évaluée par les expériences de simulation utilisant un simulateur de véhicule avancé en comparaison avec le réseau neuronal à propagation arrière et les réseaux neuronaux Elman. Les paramètres d'entrée pour modéliser l'approche d'estimation de l'état de charge en utilisant un système neuro-flou basé sur le regroupement soustractif sont le courant, la température, la perte de puissance réelle, la puissance disponible et demandée, la température de l'air de refroidissement et le facteur thermique de la batterie. Les résultats expérimentaux

ont montré que le modèle proposé présente une précision suffisante et surpasse les modèles basés sur les réseaux neuronaux et les réseaux neuronaux Elman. Ainsi, le modèle proposé sous différents cycles de pilotage montre une avancée remarquable dans l'estimation de l'état de charge avec un potentiel élevé pour surmonter les inconvénients des méthodes traditionnelles et fournit donc une approche alternative dans l'estimation de l'état de charge.

Selon [48], pour assurer une gestion fiable de la batterie dans les véhicules électriques (VE), un estimateur avancé de l'état de charge (SOC) via une méthodologie d'apprentissage automatique a été développé. Une nouvelle technique de regroupement FCM (Fuzzy C-means) basée sur un algorithme génétique est d'abord utilisée pour partitionner les données d'entraînement échantillonnées dans le test basé sur le cycle de conduite d'une batterie lithium-ion. Le résultat du regroupement est appliqué pour apprendre la topologie et les paramètres antécédents du modèle. L'algorithme des moindres carrés récurrents est ensuite utilisé pour extraire ses paramètres conséquents. Pour assurer une bonne précision et une bonne résilience, l'algorithme d'apprentissage de rétropropagation est finalement adopté pour optimiser simultanément les parties antécédente et conséquente. Les résultats expérimentaux vérifient que l'estimateur proposé présente une précision suffisante et surpasse ceux construits par les méthodes conventionnelles de modélisation floue.

[49] présente et compare diverses approches pour la prédiction personnalisée de la consommation d'énergie des véhicules, y compris un cadre de boîte noire qui identifie les facteurs dépendant du conducteur / véhicule / environnement et une approche de filtrage collaborative basée sur la factorisation matricielle. En outre, une étude de cas de prédiction de la distance à vide pour les véhicules électriques par des données de détection participative

est menée et évaluée de manière empirique, ce qui montre que les approches peuvent améliorer considérablement la précision de la prédiction.

Avec l'étude dans [50], des paramètres influençant la consommation d'énergie ont été utilisés afin de les implémenter dans le modèle dynamique longitudinal d'un véhicule pour estimer la puissance fournie par la batterie et ainsi la puissance sera dérivée par rapport au temps afin d'obtenir l'énergie électrique. Le modèle d'estimation énergétique présenté semble bien fonctionner et a un potentiel à la fois comme outil de recherche et comme ressource pour les utilisateurs de VE. Cependant, l'ensemble de données dans cette recherche est limité car il contient des données d'un seul conducteur, un véhicule, qui n'est pas l'un des véhicules actuellement produits dans le commerce, et comprend une conduite sur autoroute limitée. L'estimation de l'état de charge est l'un des facteurs les plus critiques pour résoudre les principaux problèmes de surveillance et de sécurité d'une batterie d'alimentation de véhicule électrique.

Les travaux dans [51] sont basés sur le modèle VT-CPEM ou Virginia Tech Comprehensive Power-based Energy Consumption Model. Il s'agit d'un modèle polynomial de second ordre. Le modèle calcule la consommation d'énergie instantanée des véhicules électriques en utilisant la puissance instantanée exercée. Plus précisément, le profil de vitesse (vitesse instantanée du véhicule et niveau d'accélération) est utilisé comme variables d'entrée. Ce modèle complète les simulateurs des véhicules disponibles dans la littérature ouverte en modélisant l'efficacité énergétique du freinage régénératif instantané en fonction du niveau de décélération. Le modèle proposé estime avec précision la consommation d'énergie, produisant une erreur moyenne de 5,9% par rapport aux données empiriques. Les résultats démontrent que dans les cycles de conduite urbaine, il est possible de récupérer plus d'énergie



en raison de la présence de plusieurs épisodes de freinage non agressifs dans le cycle de conduite. L'étude a confirmé que l'avantage énergétique des véhicules électriques dans la conduite urbaine pourrait avoir un impact significatif sur les choix d'itinéraire des gens et ébranler davantage les fondements des théories conventionnelles de la répartition du trafic

### **Conclusion :**

D'après les études que nous avons citées précédemment dans cette même section, nous avons pu trouver les lacunes dans les autres études et ainsi pour délimiter les différents axes de recherches sur lesquels nous allons contribuer.

Dans la littérature, on a remarqué la plupart des paramètres estimés sont la masse, la pente, et le coefficient de résistance au roulement. Le coefficient aérodynamique est le moins cité dans la littérature. Ainsi, nous allons nous concentrer sur l'estimation du coefficient aérodynamique avec le coefficient de résistance au roulement.

D'un autre côté, nous allons nous focaliser aussi sur l'amélioration de l'estimation/prédiction de la puissance fournie par la batterie à partir d'un modèle plus efficace pour pouvoir donner une meilleure estimation de l'autonomie restant si on connaît tous les paramètres qui peuvent influencer la consommation d'énergie.

## **Chapitre 3 - Modélisation de l'utilisation de l'énergie**

Selon le chapitre précédent, la chaîne de conversion énergétique d'un véhicule électrique est composée d'un réseau d'alimentation alternatif, d'un chargeur de batteries, d'une source embarquée d'énergie électrique (pack de batterie), d'un ensemble convertisseur électronique et de la transmission mécanique.

Dans ce chapitre, l'ensemble des principes physiques associant le comportement de la dynamique d'un véhicule et les paramètres physiques de ses composants seront présentés. La modélisation des composants du véhicule qui décrivent la dynamique longitudinale est utilisée pour développer les méthodes d'estimation des coefficients aérodynamique et de résistance au roulement. De plus, un modèle physique de la batterie sera aussi décrit dans cette partie.

### 3.1 Architecture d'un véhicule électrique




Figure 7: Structure détaillée d'un véhicule électrique [52]

### 3.2 Modèle dynamique longitudinal d'un véhicule électrique

Selon la deuxième loi de Newton, ou principe fondamental de la dynamique, une force résultante exercée sur un objet est toujours égale au produit de la masse de cet objet par son accélération. De plus, l'accélération produite et la force résultante ont la même orientation.

Chaque force appliquée sur un objet entraîne cet objet à accélérer dans la direction de la force appliquée. Or, lorsque plusieurs forces sont appliquées sur un objet, il faut déterminer la force résultante, soit la force équivalente à la somme vectorielle de toutes les forces agissant sur cet objet [53]. La deuxième loi de Newton se résume par l'application de l'équation suivante:

$$\sum \vec{F}_{ext} = M\vec{a} \quad (1)$$

Dans le cas des véhicules, voici une figure montrant les forces externes appliquées sur le véhicule permettant l'analyse sur la consommation d'énergie par le modèle dynamique longitudinale :




Figure 8: Aperçu des forces externes appliquées au véhicule

A partir de la figure présentée précédemment, on peut écrire le modèle dynamique longitudinale d'un véhicule projeté suivant la sens du mouvement :

$$Ma = F_{tr} - F_{roll} - F_{aero} - F_{grade} - F_{freinage} \quad (2)$$

Où  $M$  et  $a$  sont respectivement la masse du véhicule et l'accélération longitudinale.

La force de traction ( $F_{tr}$ ) résulte de la conversion de l'énergie électrique du moteur en énergie mécanique nécessaire pour faire tourner les roues. Elle peut être exprimée comme suit :

$$F_{tr} = \frac{\eta P_b}{v} \quad (3)$$

Où  $P_b$ ,  $\eta$  et  $v$  sont respectivement la puissance fournie par la batterie, le rendement global de la chaîne cinématique et la vitesse du véhicule.

La résistance au roulement ( $F_{roll}$ ), résultant de la perte d'énergie à la suite de la déformation instantanée des pneumatiques lors de leur contact avec la route, peut être exprimée comme suit:

$$F_{roll} = \mu M g \cos(\Theta) \quad (4)$$

Où  $\mu$ ,  $M$ ,  $g$ ,  $\Theta$  sont respectivement le coefficient de résistance au roulement, la masse du véhicule, l'accélération gravitationnelle ( $9,81\text{m/s}^2$ ) et la pente ou l'inclinaison de la route.

La force de traînée aérodynamique représente l'action globale de l'air sur l'essieu du véhicule et s'exprime comme suit:

$$F_{aero} = \frac{1}{2} \rho A C_d (v + v_{vent})^2 \quad (5)$$

Dans l'équation (4),  $\rho$  est la densité de l'air qui dépend de la température, tandis que  $A$  et  $C_d$  sont respectivement la surface avant du véhicule et le coefficient de traînée aérodynamique. Le paramètre  $v_{vent}$  dans l'équation 5 est la vitesse de l'air ambiant qui a une valeur négative pour le vent arrière et une valeur positive pour le vent de face.

La force au niveau du sol exprime l'influence de la force gravitationnelle sur le véhicule, en particulier lorsque l'inclinaison  $\Theta$  n'est pas négligeable. Elle peut être calculée à partir de l'équation suivante:

$$F_{grade} = mg \sin(\Theta) \quad (6)$$

La force de freinage ( $F_{freinage}$ ) est liée étroitement à la force d'accélération. Elle permet d'absorber le surplus d'énergie généré par la force d'accélération en la convertissant en chaleur. À partir du théorème de l'énergie cinétique, on peut obtenir cette force avec l'équation suivante :

$$F_{freinage} = \frac{1}{2d} mv^2 \quad (7)$$

Où  $d$  est la distance de freinage du véhicule.

Afin d'estimer la consommation d'énergie, le modèle dynamique du véhicule est implémenté en sens inverse, c'est-à-dire que la puissance de sortie de la batterie est calculée en fonction du profil de vitesse  $v$  ainsi que des forces externes constitutives, en utilisant l'équation 7:

$$P_b = \frac{v}{\eta} \left( Ma + Mg \mu \cos(\Theta) + Mg \sin(\Theta) + \frac{1}{2} \rho A C_d (v + v_{vent})^2 + \frac{1}{2d} mv^2 \right) \quad (8)$$

### 3.3 Modèle de la batterie d'un véhicule électrique

#### 3.3.1 Modèle physico-chimique

Une approche utilisant la représentation de la batterie a été développée afin d'alléger la modélisation exacte des batteries qui est difficile à concevoir et difficile à calculer au cours des simulations.

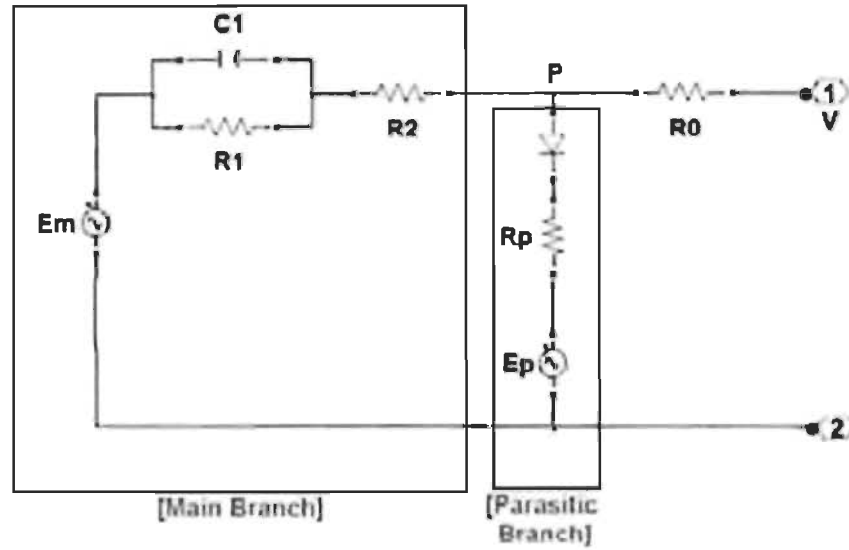


Figure 9: Circuit électrique équivalent de la batterie [54]

Les équations (8), (9) et (10) du modèle décrivent le comportement de la batterie et fournissent des informations pertinentes sur son fonctionnement, dans lesquelles se trouvent la tension, la température, la profondeur de la charge et décharge (DOD) et l'état de charge (SOC) pour une intensité donnée et en mode de charge ou décharge.

$$V_b = E_m = E_{m0} - K_e \theta (1 - SOC) \quad (9)$$

$$R_0 = R_{00} (1 + A_0 (1 - SOC)) \quad (10)$$

$$E_{(R_1, C_1)} = R_1 (1 + s R_1 C_1) I_m \quad (11)$$

$V_b$  : tension de la branche principale (V),

$E_{m0}$  : tension du circuit ouvert à charge pleine (V),

$K_e$  : constante (V/°C)

$\theta$  : température interne (°K)

$R_0$  : résistance aux bornes de la batterie ( $\Omega$ ),

$R_{00}$  : résistance constante ( $\Omega$ ),

$A_0$  : constante (N/A),

$E_{(R_1, C_1)}$  : tension aux bornes du circuit (V),

$R_1$  : résistance du processus chimique ( $\Omega$ ),

$C_1$  : valeur de la capacité (F),

$I_m$  : courant dans la branche principale.

La batterie est modélisée par une analogie du circuit équivalent. Ainsi, la tension aux bornes de la batterie est alors reformulée comme suit :

$$V_B(t) = E_{m0}(SOC(t)) - R_0(SOC(t))I_B - K_e\theta(SOC(t)) \quad (12)$$

### 3.3.2 Estimation de l'énergie consommée

La prévision des conditions futures des parcours et de la consommation potentielle d'énergie nécessaire pour parcourir les trajets peut être possible avec les informations des itinéraires avec les destinations finales fixes et les durées des trajets avant les parcours en utilisant le modèle dynamique longitudinale de l'équation (7). Donc, l'équation discrète de l'énergie des batterie (équation (14)) nécessaire à chaque temps d'échantillonnage ( $t$ ) est obtenue par combinaison des équations (12) et (13) :

$$E^B(t+1) = E^B(t) + \frac{1}{\eta_B}(t)P^B(t)\Delta T \quad (13)$$

$$P_m = \eta_m(P_m(t-1), P_e(t)) \quad (14)$$

$$E^B(t+1) = E^B(t) + \frac{1}{\eta_B\eta_m}(t)P_m(t)\Delta T \quad (15)$$

Avec  $\Delta T$  : la période d'échantillonnage,



$P_m$  : la puissance mécanique,

$P_e = P^B$  : la puissance électrique fournie par la batterie.

Donc, l'énergie jusqu'à la destination finale peut être estimée comme suit :

$$E^B(N) = \sum_{k=t+1}^N E^B(k) + \sum_{k=t+1}^N \left[ \frac{1}{\eta_B \eta_m} P_m(k) \Delta T \right] \quad (16)$$

Avec N : le nombre total d'échantillons.

## **Chapitre 4 - Estimation des coefficients aérodynamique et de la résistance au roulement – Puissance & énergie - Autonomie**

### **4.1 Introduction**

L'estimation des paramètres dynamiques d'un véhicule est une solution afin de savoir sur quelle partie du véhicule consomme le plus d'énergie afin d'optimiser sa consommation.

La dynamique longitudinale d'un véhicule est affectée par le paramètre d'inertie du véhicule : la masse ainsi que les conditions de roulages telles que les coefficients aérodynamique et résistance au roulement, la vitesse du véhicule, la vitesse du vent et la pente de la route. L'aérodynamique et la résistance au roulement d'un véhicule font partie des paramètres les plus influents dans la consommation d'énergie. Estimer ces paramètres permettra d'augmenter l'efficacité dans l'optimisation de la consommation d'énergie. Selon [55] et [56], l'aérodynamique et la résistance au roulement présentent une grande partie non-négligeable en termes de pourcentage des pertes sur l'efficacité énergétique selon les figures ci-après : en premier lieu pour les véhicules à combustion et en deuxième les véhicules électriques à freinage régénératif.

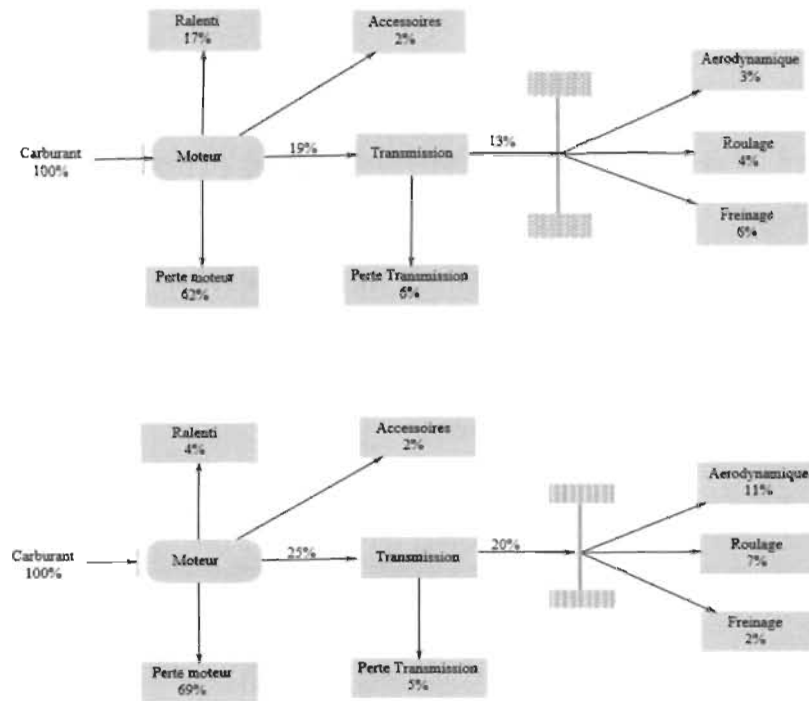


Figure 10: Dispersion des pertes énergétiques d'un véhicule à combustion sur des trajets: a) en ville, b) sur autoroute

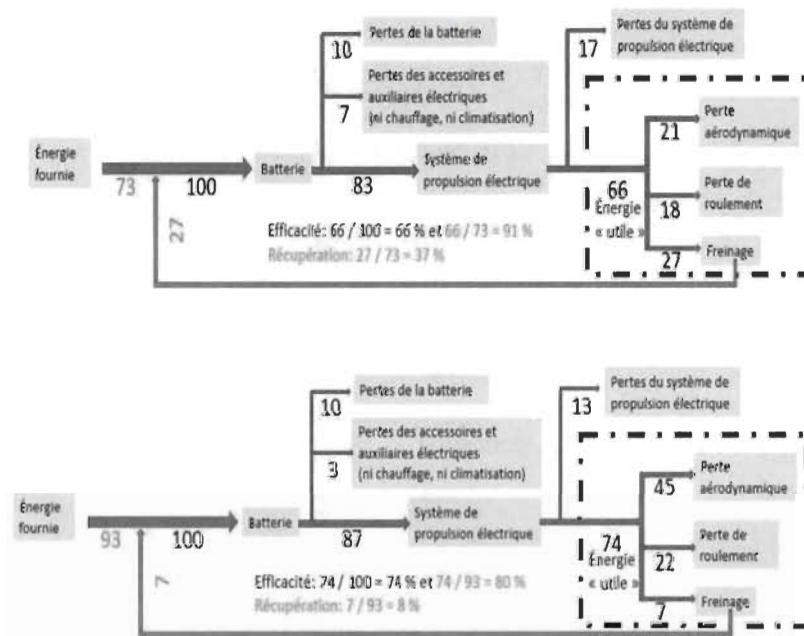


Figure 11: Dispersion des pertes énergétiques des véhicules électriques à freinage régénératif sur des trajets: a) en ville, b) sur autoroute

## 4.2 Estimations des coefficients aérodynamique et résistance au roulement

D'après la revue de littérature citée dans le chapitre 2 sur l'estimation des coefficients aérodynamique et de résistance au roulement, la majorité des travaux effectués ont utilisé les méthodes des moindres carrés récurrents et le filtre de Kalman tout en se basant sur l'équation dynamique longitudinale d'un véhicule.

### 4.2.1 Description de la méthodologie d'estimation

La problématique de l'étude consiste à considérer un véhicule électrique comprenant un banc de batteries. Ces batteries fournissent la puissance électrique nécessaire pour le fonctionnement du système de propulsion, à travers une interface de puissance bidirectionnelle. Le système de propulsion est principalement composé d'un moteur électrique et un réducteur, avec un rapport de réduction de la vitesse fixe. Celui-ci produit la puissance mécanique ( $P_m$ ) pour la traction du véhicule. Dans ce cas, l'énergie des batteries est mise sous contrôle en permanence.

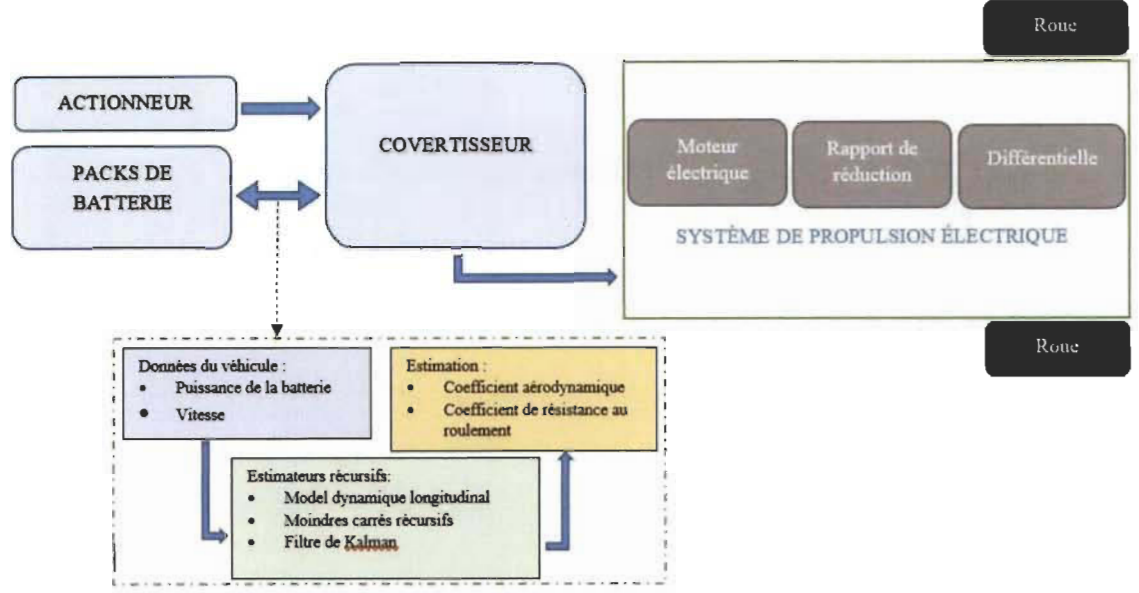


Figure 12: Diagramme d'estimation des paramètres

Ci-dessus un diagramme montrant la méthodologie sur l'estimation en ligne de ces coefficients

À partir de l'équation (8), on obtient

$$Mav + Mgsin(\Theta)v + \frac{1}{2d}mv^2 = \eta P_b - \mu Mgc\cos(\Theta)v - C_d \frac{1}{2}\rho A(v + v_{wind})^2 \quad (17)$$

On peut arranger l'équation (16) sous la forme :

$$\begin{aligned} & \left[ Mav + Mgsin(\Theta)v + \frac{1}{2d}mv^2 \right] \\ &= \left[ P_b \quad -Mgc\cos(\Theta)v \quad -\frac{1}{2}\rho A(v + v_{wind})^2 \right] [\eta \quad \mu \quad C_d]^T \end{aligned} \quad (18)$$

Puisque la puissance est appliquée sur l'axe du véhicule au niveau des roues, il est nécessaire de connaître les pertes de puissance entre le moteur et les roues. Les pertes d'énergie au niveau du moteur et des roues sont des pertes électriques générées par le moteur

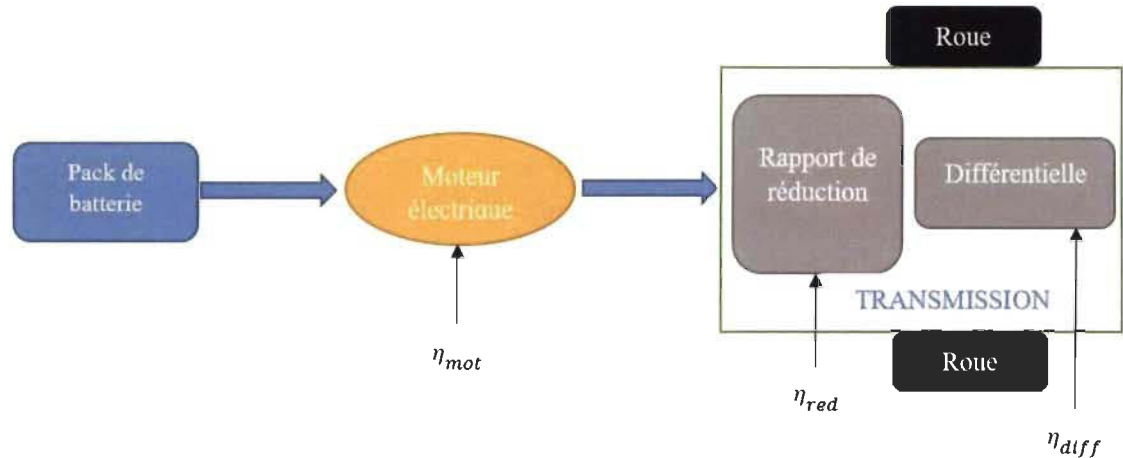


Figure 13: Rendement du moteur électrique jusqu'aux roues

et des pertes mécaniques dues à la transmission de puissance mécanique selon le schéma suivant :

Ainsi, nous obtenons :

$$\eta = \eta_{mot} * \eta_{red} * \eta_{diff} \quad (19)$$

Donc, il est nécessaire d'estimer le rendement final ( $\eta$ ) du fait que le rendement varie selon avec la conduite.

Les algorithmes d'estimation récursive sont plus utilisés pour les applications en ligne, en raison de la limitation de la mémoire et de la puissance de calcul des contrôleurs embarqués. Plusieurs algorithmes couramment utilisés sont le RLS, le RLS avec facteur d'oubli, le KF et le Extended Kalman Filter (EKF).

Dans cette partie, pour estimer les coefficients aérodynamique et résistance au roulement, nous avons opté pour deux méthodes : le RLS et le KF. Ces deux méthodes sont étroitement liées.

#### 4.2.2 Estimation par la méthode des moindres carrés récurrents (MCR ou RLS)

Le RLS est un filtre adaptatif qui estime de manière récursive certains paramètres pour minimiser une fonction de coût des moindres carrés linéaires pondérés. Cette fonction de coût est associée aux signaux d'entrée. Le RLS donne des performances de qualité lorsqu'il fonctionne dans des conditions variant dans le temps [57]. On peut dire que le RLS est un filtre adaptatif déterministe car il considère que le signal va avoir la même réponse à la même impulsion d'entrée. Cette méthode se rapproche d'une estimation des moindres carrés avec une fonction de coût. Cette fonction de coût inclut un facteur d'oubli  $\lambda$  qui donne plus d'importance aux nouvelles valeurs de la fonction de coût.

Cela permet de suivre le signal souhaité plus rapidement, en revanche, il est plus complexe par rapport aux autres comme le LMS, NLMS. Le facteur d'oubli est lié à la vitesse de convergence; si c'est un, cela signifie que le système a une mémoire infinie.

Dans cette approche, le vecteur de paramètre inconnu est mis à jour de manière itérative à chaque pas de temps en utilisant les données mesurées d'entrée et de sortie précédentes. L'algorithme RLS peut être formulé comme suit :

$$\begin{cases} y = \phi\theta \\ y = [Mav + Mgsin(\Theta)v] \\ \phi = [P_b \quad -Mgcos(\Theta)v \quad -\frac{1}{2}\rho A(v + v_{wind})^2] \\ \theta = [\eta \quad \mu \quad C_d]^T \end{cases} \quad (20)$$

ALGORITHME :

$$g(n) = P(n-1) * \phi(n) \quad (21)$$

$$k(n) = \frac{g(n)}{\lambda + \phi^T(n) * g(n)} \quad (22)$$

$$e(n) = d(n) - \theta^T(n-1) * \phi(n) \quad (23)$$

$$\theta(n) = \theta(n-1) + k(n) * e(n) \quad (24)$$

$$P(n) = P(n-1) * \lambda^{-1} - k(n) * \phi^T(n) * P(n-1) * \lambda^{-1} \quad (25)$$

Nous avons divisé en deux étapes le calcul du vecteur de gain variable dans le temps  $k(n)$  pour réduire la complexité du calcul. La première partie utilise la valeur passée de l'équation de Riccati  $P(n)$  multipliée par le vecteur d'entrée. Pour calculer le vecteur de poids  $w(n)$ , nous utilisons  $e(n)$  la différence entre le signal souhaité  $d(n)$  et le signal estimé, multiplié par le gain de Kalman  $k(n)$ .

La valeur de  $\lambda$  est reliée au rapport signal bruit (SNR).  $\delta$  a une valeur faible pour un SNR élevé et une valeur élevée pour un SNR faible. La gamme de  $\lambda$  est  $0 < \lambda < 1$ .

#### 4.2.3 Estimation avec le filtre de Kalman (KF)

Le filtre de Kalman peut être utilisé si la dynamique des paramètres est connue.

Il est perçu comme un estimateur optimal, qui fonctionne selon un processus en deux étapes pour estimer les paramètres d'intérêt. Ce filtre estime d'abord les variables d'état courant puis les met à jour à la réception de la mesure suivante [58]. La structure du KF utilisé dans ce travail est la suivante :



$$\begin{cases} y = [Mav + Mgsin(\Theta)v] \\ H = [P_b \quad -Mgcos(\Theta)v \quad -\frac{1}{2}v\rho A(v + v_{wind})^2] \\ x = [\eta \quad \mu \quad C_d]^T \end{cases} \quad (26)$$

Le filtre de Kalman fonctionne avec un vecteur d'état; c'est l'ensemble minimal de données pour décrire le comportement du système. Il ne stocke que les données précédemment estimées, car cela est plus efficace en termes de calcul. Le filtre de Kalman va estimer les variables d'état avec les mesures pour minimiser l'erreur quadratique. Ce filtre convient au traitement numérique en temps réel lorsque les données d'entrée présentent du bruit. Le modèle doit être représenté dans l'espace d'états:

$$x(k) = Ax(k-1) + Bu(k) \quad (27)$$

$$y(k) = H(k)x(k) + v(k) \quad (28)$$

Algorithme du filtre de Kalman :

Prédiction :

$$\hat{x}(k) = A\hat{x}(k-1) + Bu(k) \quad (29)$$

$$P(k) = AP(k-1)A^T + P_0 \quad (30)$$

Correction :

$$K(k) = P(k)H^T [HP(k)H^T + R] \quad (31)$$

$$\hat{x}(k) = \hat{x}(k) + K(k)[y(k) - H\hat{x}(k)] \quad (32)$$

$$P(k) = (I - K(k)H) P(k) \quad (33)$$

### **4.3 Estimation de la puissance fournie par la batterie et de l'énergie consommée**

Dans cette partie, les réseaux de neurones artificiels ou Artificial NeuralNetwork (ANN) ont été utilisés pour l'estimation de la puissance/énergie fournie par la batterie. D'après [59], les réseaux de neurones ont été suggérés comme outils pour la solution de problèmes d'optimisation combinatoire difficiles. De plus, [60] affirme que l'avantage des modèles ANN est qu'ils n'ont pas besoin de plus de paramètres ou ne compliquent pas les calculs contrairement aux modèles implicites.

Les ANN sont des outils informatiques qui imitent le flux de traitement de l'information des réseaux de neurones biologiques. Par exemple, les ANN sont constituées de plusieurs neurones interconnectés qui peuvent apprendre, stocker et rappeler des informations.

La tâche d'apprentissage est réalisée en mappant un espace de données d'entrée sur l'espace de sortie, où la relation entre l'entrée et la sortie est suffisamment complexe pour être modélisée. Fondamentalement, chaque interconnexion entre les neurones se voit attribuer un poids qui est modifié de manière itérative par l'algorithme ANN afin de minimiser la différence entre la sortie connue (cible) et la prédiction. Les architectures ANN peuvent être subdivisées en trois catégories principales: le réseau de neurones à réaction (FFNN) et le réseau de neurones récurrents (RNN). Dans le FFNN, les informations sont propagées à travers le réseau dans une direction de l'entrée vers la sortie, contrairement au RNN où les sorties précédentes peuvent être réutilisées comme entrées sur le réseau. Le choix d'un réseau spécifique dépend de la connaissance préalable du système.

Dans ce travail, nous avons sélectionné l'auto-régression non linéaire avec entrées exogènes (NARX) en raison de sa capacité à gérer efficacement les données de séries

chronologiques, telles que le profil de puissance de la batterie et l'autonomie restante du véhicule.

Le réseau NARX est une architecture neuronale dynamique couramment utilisée pour la modélisation entrée-sortie des systèmes dynamiques non-linéaires. En fait, plusieurs études dans la littérature ont démontré la supériorité du réseau NARX sur les réseaux de neurones traditionnels dans la modélisation efficace des systèmes dynamiques, la reconnaissance de formes en ligne et la conception de contrôleurs. Selon [61], le réseau NARX est une architecture neuronale dynamique couramment utilisée pour la modélisation entrée-sortie de systèmes dynamiques non linéaires. Le réseau NARX peut être facilement et efficacement appliquée à la prédiction à long terme et surpasse systématiquement les prédicteurs standards basés sur les réseaux neuronaux, tels que les architectures TDNN et Elman.

NARX appartient à la classe des réseaux récurrents, où les entrées sont constituées des valeurs passées de la sortie ainsi que de certaines entrées exogènes. De manière analogue au réseau à anticipation traditionnel, les entrées exogènes peuvent être considérées comme les caractéristiques susceptibles d'influencer les sorties. L'architecture NARX est si flexible que les entrées peuvent être soit les valeurs vraies passées de la cible (NARX en boucle ouverte), soit les valeurs prédites passées des sorties (NARX en boucle fermée). Dans l'étape d'apprentissage, nous avons utilisé le NARX en boucle ouverte pour accélérer le calcul, tandis que dans l'étape de test, le NARX en boucle fermée est utilisé afin de faire des prédictions en temps réel, c'est-à-dire lorsque les données arrivent. Les NARX en boucle ouverte et en boucle fermée sont présentés dans la figure 14, où  $u(t)$  est l'entrée exogène.




Figure 14: Représentation schématique de l'architecture NARX en boucle fermée (à gauche) et en boucle ouverte (à droite)

L'équation fondamentale sous-jacente au réseau NARX est présentée dans l'équation suivante :

$$y(t) = f(y(t-1), y(t-2), \dots, y(t-d_y), u(t-1), u(t-2), \dots, u(t-d_u)) \quad (36)$$

Où

- $y(t)$ : les données de série chronologique représentant la sortie
- $u(t)$  : les données de série chronologique représentant l'entrée exogène.

Une autre flexibilité du réseau NARX réside dans le fait que la fonction  $f$  peut prendre plusieurs formes. Dans ce travail,  $f$  est représenté par la fonction de réseau d'anticipation. Par exemple, un réseau NARX implémenté avec un réseau FeedForward avec une couche cachée contenant 10 neurones peut être représenté par la figure 15.

Comme le montre la figure 15, le réseau NARX implémenté dans ce travail peut être représenté par les caractéristiques typiques d'un réseau FeedForward (couches cachées, neurones, etc.) et le délai. Les principales caractéristiques du réseau NARX utilisé dans ce travail ainsi que leurs valeurs typiques sont présentées dans le tableau 1. Il est à noter que nous ne présentons dans le tableau 4 que les paramètres typiques utilisés dans ce travail. En fait, dans nos simulations préliminaires, nous avons testé plusieurs autres configurations afin d'explorer toutes les possibilités du réseau.




Figure 15: Diagramme schématique d'un réseau NARX implémenté avec un réseau à réaction contenant une couche cachée avec 10 neurones

Tableau1: Principales caractéristiques du réseau NARX (FeedForward) avec leurs valeurs typiques

Nombres d'entrées exogenes	N
Nombre de couche cachée	1
Nombre de neurones dans la couche	$2n+1$
Fonction d'activation	purelin
Temporisation dans l'entrée	1
Temporisation dans la sortie	1

Le réseau NARX tel que conçu est formé à l'aide de données de séries chronologiques avec une sortie connue (cible) ainsi que certaines fonctionnalités (exogènes). Dans l'étape de formation, la fonction de coût utilisée dans ce travail est l'erreur quadratique moyenne.

La formation a été réalisée en utilisant l'algorithme de Levenberg-Marquardt pour sa convergence rapide.

Le réseau NARX est utilisé dans ce travail pour modéliser le profil de puissance électrique ainsi que l'autonomie restante. En général, le choix de l'entrée réseau dépend de leur influence connue sur les données de sortie. Par exemple, dans le cas de la modélisation du profil de puissance électrique, les caractéristiques sont la vitesse, la température, la traînée aérodynamique, la résistance au roulement et les forces de nivellement de la route. La sortie

du réseau est évidemment le signal d'alimentation de la batterie du bus CAN du véhicule. Pour l'estimation de l'autonomie restante, les entrées sont la vitesse du véhicule, l'énergie totale de la batterie et les forces de traînée externes, à savoir l'aérodynamique, la résistance au roulement et les forces au niveau de la route estimées à partir de l'algorithme du filtre de Kalman présenté dans la section précédente.

Les données utilisées dans ce travail sont enregistrées lors de plusieurs tests de conduite qui ont été réalisés dans de nombreuses conditions afin d'analyser leur effet sur la consommation d'énergie et les estimations d'autonomie restante. L'ensemble de données est divisé en deux parties principales: la formation et les ensembles de données de test. Pour mettre en évidence la capacité de généralisation du réseau NARX, nous avons utilisé jusqu'à deux données de tests de conduite comme ensemble d'entraînement, dont 75% sont utilisés pour la formation tandis que le pourcentage restant (25%) est utilisé pour la validation. En tant que tel, le but de l'ensemble de données de validation est d'ajuster le réseau pour l'étape de prédiction. D'autre part, l'ensemble de données de test se compose des données de trajets restantes (10 tests de conduite). En termes simples, notre objectif est de montrer que le réseau NARX conçu ne nécessite que quelques données d'entraînement afin de prédire la consommation d'énergie et l'autonomie restante dans des situations de conduite réelles. Toutes les données utilisées dans ce travail ont été enregistrées à partir du bus CAN du véhicule.

#### 4.4 Estimation de l'autonomie

Généralement, l'autonomie restante (AR) d'un véhicule peut être estimée en se basant sur l'énergie restant de la batterie ( $E_{res}$ ) (kWh) et la future consommation d'énergie spécifique ou efficacité de conduite ( $\widehat{e_{ff}}$ ) (km / kWh), à travers la relation:

$$AR = \widehat{e_{ff}} * E_{res} \quad (35)$$

En raison de la simplicité de l'équation (34), la plupart des recherches sur le reste aboutissent à une estimation de la consommation d'énergie et affirment généralement que l'estimation de la plage restante est simple en connaissant le profil de puissance. Cependant, un examen plus approfondi de cette équation ne montre qu'aucun des termes impliqués n'est mesuré expérimentalement, ni facile à estimer. Par exemple, l'énergie totale restante de la batterie  $E_{res}$  est à peine estimée à partir du modèle de batterie complexe, tandis que l'efficacité de conduite future  $\widehat{e_{ff}}$  est généralement supposée être égale à l'efficacité passée la plus proche. L'efficacité de conduite peut être décrite par la relation générale suivante:

$$\widehat{e_{ff}} = \frac{E(\Delta d)}{\Delta d} \quad (36)$$

Où  $E(\Delta d)$  est l'énergie consommée pendant la dernière distance mémoire, c'est-à-dire la distance historique passée comme illustré sur la figure 16 montrant le profil de vitesse d'un test de conduite sur route.




Figure 16: Illustration de la distance mémoire et de la distance parcourue pour un test de conduite sur autoroute

Le profil de  $(\widehat{e}_{ff})$  dépend principalement du choix de la distance mémoire  $\Delta d$ . Par exemple, lorsque  $\Delta d$  est égal à la distance de conduite cumulée ( $d_i$ ), l'efficacité de conduite se réduit au rapport de l'énergie cumulée sur la distance totale parcourue.

C'est ce que l'on appellera l'efficacité de conduite cumulée. Pour un enregistrement de courte durée, c'est-à-dire  $\Delta d < d_i$ , l'efficacité de conduite est appelée efficacité historique.

Intuitivement, on peut affirmer que lorsque le  $\Delta d$  diminue, l'efficacité de conduite sera plus instable en raison de la capacité de récupération d'énergie de l'EV. Ce fait induit un défi important dans le choix de la valeur appropriée de  $\Delta d$  afin d'éviter une sous-estimation ou une surestimation de la plage restante qui, à son tour, peut augmenter l'anxiété de la plage.



Pour résoudre ce problème, nous proposons l'utilisation du réseau NARX pour apprendre directement l'autonomie réelle restante. Dans ce cas, nous utilisons la vitesse du véhicule, la puissance de la batterie, l'énergie restante et les forces de traînée comme caractéristiques, et l'autonomie réelle restante est utilisée comme cible. La véritable autonomie restante est obtenue en soustrayant la distance parcourue ( $d_i$ ) de la distance totale jusqu'à la décharge complète de la batterie. Le réseau formé est ensuite utilisé pour fournir l'estimation en ligne de l'autonomie restante pour les autres tests de conduite.

#### 4.5 Mesures de performances

Afin de déterminer la précision des estimations, l'erreur quadratique moyenne ou le Mean Squared Error (MSE) est utilisée. Il est donné par :

$$MSE = \frac{1}{N} \sum_1^N (x_t - \hat{x}_t)^2 \quad (37)$$

Où N est le nombre de points de données,  $\hat{x}$  l'état estimé et x l'état de référence. Cette méthode ne peut donc être utilisée que lorsque la vraie valeur de l'état est connue.

## Chapitre 5 - Expérimentations et simulations

Dans ce chapitre, les expérimentations et les résultats seront décrits afin de valider les modèles élaborés cités dans les chapitres précédents.

### 5.1 Validation et simulation

#### 5.1.1 Paramètres du véhicule

L'Institut de Recherche sur l'Hydrogène (IRH) de l'Université du Québec à Trois-Rivières (UQTR) dans lequel est réalisé ce travail dispose d'un véhicule électrique : KIA Soul EV 2017 avec une vitesse maximum de 145 km/h. Tous les tests de conduite présentés dans ce travail ont été réalisés en utilisant ce véhicule. La figure 17 montre une image du véhicule d'essai. Dans le tableau 2, nous présentons les paramètres du véhicule tels que fournis par le constructeur.



Figure 17: KIA Soul EV 2017 : A) à l'intérieur de l'IRH, B) sur asphalte, C) sur neige

*Tableau 2: Caractéristiques du KIA Soul EV 2017*

**Physique**

Dimensions	L = 4.140 m; l = 1.801m; 1.6 m
Roues	205/60R16 92H
Masse	1492 kg

**Performances**

Type de batterie	Polymère de lithium-ion
Puissance maximum du moteur	81.4 kW
Couple maximum	285 Nm
Rapport de transmission final	8.206 :1
Vitesse maximum	145 km/h
Capacité de la batterie	45 Ah
Autonomie sur ville	193 km
Autonomie sur autoroute	148 km
Autonomie combinée	168 km

**Paramètres**

$A$	$2.88 \text{ m}^2$
$c_d$	0.35
$\rho$	$1.22 \text{ kg m}^{-3}$
$\mu$	0.018

*5.1.2 Expériences et tests*

Nous avons effectué plusieurs tests avec le véhicule KIA Soul EV 2017 pour récupérer des données afin de valider les algorithmes d'estimations proposés. Les données expérimentales incluant la température ambiante et les positions du véhicule ont été acquises à partir du bus de données CAN en utilisant le module **OBDLink Mx** du véhicule via un logiciel dédié: **Torque Pro**, avec une fréquence  $f = 1 \text{ Hz}$ . (**Voir Annexe C**).

Des tests coast-down ont été faits afin de trouver les valeurs du coefficient de résistance au roulement. Ce test est un procédé fréquemment utilisé et nécessaire pour évaluer les valeurs expérimentales des forces résistantes et par conséquent les valeurs expérimentales du coefficient de résistance au roulement correspondantes aux types de route utilisés (avec/sans neige avec un sol asphalte pour notre cas). Le principe de base de cet essai est le suivant : accélérer le véhicule à une certaine vitesse, puis le laisser décélérer en vitesse point mort jusqu'à une autre vitesse prédéterminée et enregistrer finalement la durée de ce processus. La résistance totale à l'avancement est alors calculée à partir de la deuxième loi de Newton (équation 1). Ci-dessous un tableau montrant les valeurs du coefficient de la résistance au roulement obtenues à partir du test coast-down.

*Tableau 3: Valeurs de la résistance au roulement obtenues avec les tests Coast down*

<i>Type de sol</i>	<i>Asphalte sec</i>	<i>Asphalte mouillé</i>	<i>Asphalte enneigé</i>
<i>Valeurs du coefficient de résistance au roulement</i>	0.019	0.022	0.0257

*Tableau 4: Récapitulation des tests*

<i>Trajet</i>	<i>Type de route</i>	<i>Température ambiante (°C)</i>	<i>Vitesse moyenne (km/h)</i>	<i>Distance (km)</i>	<i>Zone</i>
<b>1</b>	Sans neige	-19°C	33.7481	5.33	Ville
<b>2</b>	Sans neige	-20°C	34.5397	5.32	Ville
<b>3</b>	Sans neige	-20°C	30.1590	5.3069	Ville
<b>4</b>	Avec neige	-10°C	30.0844	5.4331	Ville
<b>5</b>	Avec neige	-10°C	30.4388	5.3842	Ville
<b>6</b>	Avec neige	-10°C	31.6260	5.3706	Ville
<b>7</b>	Avec neige	-10°C	26.7578	5.3731	Ville
<b>8</b>	Avec neige	-10°C	28.0011	5.4392	Ville
<b>9</b>	Avec neige	-10°C	27.5066	5.4114	Ville
<b>10</b>	Avec neige	-10°C	28.6225	5.4511	Ville


11	Sans neige	-19°C	48.4350	27.4178	Campagne
12	Sans neige	-19°C	87.1688	36.2033	Autoroute
13	Sans neige	-20°C	34.7239	11.2072	Ville
14	Sans neige	-17°C	26.6550	1.0731	Scolaire

Pour valider les estimations, on a fait des tests dans différentes places avec différentes conditions : type de zone, type de sol, .... (Voir le tableau récapitulatif ci-dessus)

## 5.2 Résultats des expériences et des simulations

### 5.2.1 Estimations des coefficients aérodynamique et résistance au roulement

Dans cette partie, on illustre les résultats sur l'estimation des coefficients aérodynamique et résistance au roulement dans différentes conditions dont le type de sol, de température, conduites, ... Il s'agit d'estimer simultanément des coefficients à partir des méthodes proposées : les moindres carrés récurrents (RLS) et le filtre de Kalman (KF). Pour chaque méthode, on a utilisé les valeurs du coefficient de résistance au roulement obtenu avec les tests du coast-down ainsi que le coefficient aérodynamique du manufacturier.



(a)






Figure 18: Coefficients estimés Vs valeurs réelles dans les conditions sans neige :  
a) coefficient aérodynamique, b) coefficient de résistance au roulement.

La figure 18 représente les résultats des estimations des coefficients obtenus à partir d'un test effectué dans des conditions sans neige. Comme on peut le voir sur cette figure, les coefficients estimés par différentes approches convergent vers les valeurs réelles du coefficient de traînée aérodynamique ( $C_{aero} = 0,35$ ) et du coefficient de résistance au roulement pour une route asphaltée sec ( $\mu = 0,019$ ). La valeur de  $\mu$  est supposée être la valeur mesurée à partir du coast-down du coefficient de résistance au roulement sur l'asphalte sec. Ces résultats montrent que les coefficients estimés par toutes les méthodes sont presque dans la même gamme. Cependant, les valeurs estimées par KF sont plus précises que RLS.

Pareil qu'avec les tests sans neige, les coefficients aérodynamique et résistance au roulement convergent vers les valeurs obtenues à partir du coast down dans les conditions enneigées ( $C_{aero} = 0.35$ ,  $\mu = 0,025$ ).



(a)



(b)

Figure 19: Coefficients estimés Vs valeurs réelles dans les conditions avec neige :  
 a) coefficient aérodynamique, b) coefficient de résistance au roulement.

La convergence significative des valeurs estimées vers les valeurs réelles illustrées dans les figures 18 et 19 valide les estimateurs choisis.

En comparant les résultats des simulations, selon les figures, on remarque que les valeurs estimées à partir du filtre de Kalman sont plus proches des valeurs réelles que celles du RLS.



Tableau 5: MSE et valeurs moyennes estimées

Trajets	Type de route	Coefficient aérodynamique				Coefficient de résistance au roulement			
		MSE-RLS	MSE-KF	Valeurs-RLS	Valeurs-KF	MSE-RLS	MSE-KF	Valeurs-RLS	Valeurs-KF
1	Sans neige	0.0011	2.4205 e-4	0.3626	0.3516	7.1797 e-7	6.4158 e-8	0.018	0.019
2	Sans neige	0.0093 e-3	0.0013	0.3531	0.3550	1.2943 e-6	6.4671 e-7	0.0189	0.019
3	Sans neige	0.0012	1.9941 e-4	0.3633	0.3516	5.9337 e-7	5.7551 e-8	0.0188	0.019
4	Avec neige	3.1002 e-4	5.7619 e-4	0.3407	0.3538	1.1224 e-6	1.1140 e-6	0.0250	0.0250
5	Avec neige	2.5665 e-4	6.6577 e-4	0.3441	0.3537	1.1375 e-6	1.1339 e-4	0.0250	0.0250
6	Avec neige	1.6265 e-4	8.3625 e-4	0.3499	0.3545	7.9022 e-7	7.9412 e-7	0.0250	0.0250
7	Avec neige	2.3276 e-4	5.6984 e-4	0.3453	0.3535	1.0749 e-6	1.0739 e-6	0.0250	0.0250
8	Avec neige	1.4136 e-4	9.5087 e-4	0.3493	0.3556	7.0072 e-7	7.0624 e-7	0.0250	0.0250
9	Avec neige	2.1427 e-4	7.9605 e-4	0.3462	0.3545	1.0305 e-6	1.0311 e-6	0.0250	0.0250
10	Avec neige	2.3541 e-4	7.4813 e-4	0.3442	0.3546	1.0430 e-6	1.0435 e-6	0.0250	0.0250
11	Sans neige	0.0014	5.9646 e-4	0.3517	0.3523	1.2418 e-6	1.8089 e-8	0.0189	0.0190
12	Sans neige	2.2694 e-5	4.9607 e-4	0.3515	0.3524	3.3519 e-8	7.2025 e-8	0.0189	0.0190
13	Sans neige	0.0045	0.0036	0.3458	0.3612	1.0194 e-5	3.1568 e-8	0.0184	0.0190
14	Sans neige	0.0110	0.0064	0.3782	0.3737	2.6892 e-7	2.5291 e-7	0.0189	0.0180

On remarque qu'il y a plus de fluctuations des valeurs estimées dans le cas de la conduite réelle probablement en raison des erreurs dans les signaux mesurés ou de petits changements soudains des conditions routières. De plus, ces résultats indiquent que l'estimation du coefficient de résistance au roulement est plus précise et plus stable que le coefficient de

traînée aérodynamique. Cela peut être dû à la variation de facteurs inconnus tels que le vent pendant le voyage.

Sur le fait que les résultats obtenus à partir du filtre de Kalman sont plus précis, on utilisera ces valeurs dans la suite des calculs.

À partir des paramètres estimés, nous avons effectué une analyse de la contribution de chaque force pour créer une carte énergétique des forces externes appliquées au véhicule. La figure 20 montre les résultats des tests sur route enneigée et sur route sèche effectués sur le même itinéraire : en ville.. Les résultats indiquent que la contribution de la force de résistance au roulement est plus élevée pour la route enneigée que pour les essais sur route sèche. Ce résultat est tout à fait attendu puisque la présence de neige augmente la résistance au roulement du véhicule. En revanche, la contribution de la force de traînée aérodynamique est plus élevée dans le test de conduite sur route que dans l'état de la route en ville, principalement en raison de la différence de vitesse. Cependant, malgré la différence de vitesse, la contribution de la résistance au roulement ne varie pas beaucoup pour le test sur route sèche

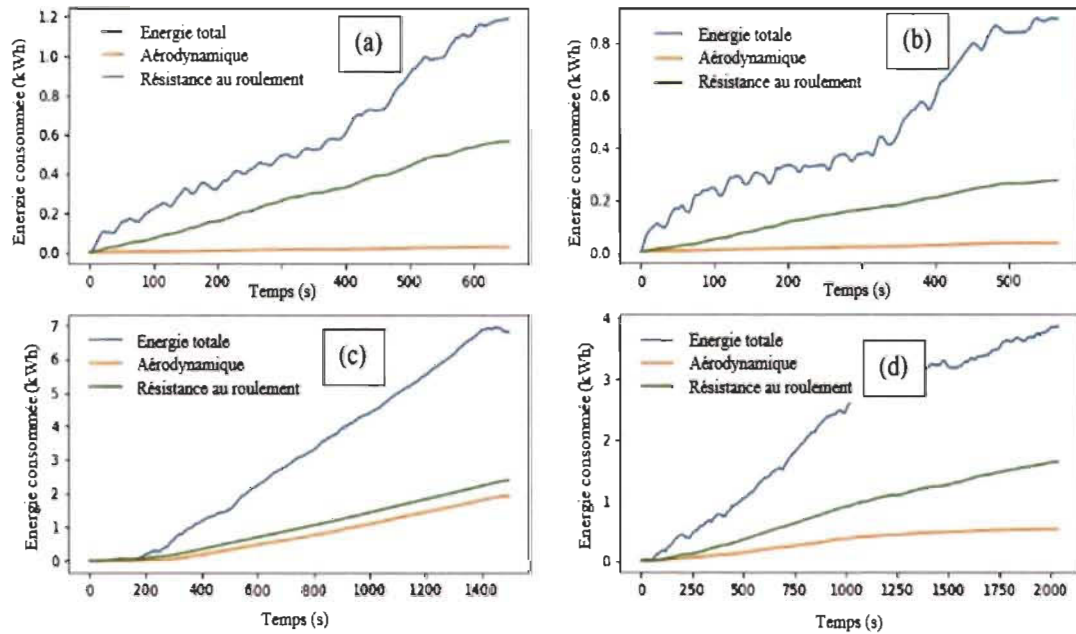



Figure 20: Carte énergétique des différents tests de conduite : a) route enneigée en ville, b) route sèche en ville, c) autoroute sèche (vitesse  $\leq 100$  km/h), d) campagne sèche (vitesse  $\leq 70$  km/h)


### 5.2.2 Estimation de la puissance fournie par la batterie et de l'énergie consommée

Dans cette partie, nous allons illustrer les résultats obtenus sur l'estimation de la puissance fournie par la batterie ainsi que l'énergie consommée. En fait, la puissance est un paramètre énergétique fondamental des véhicules électriques à partir duquel la plupart des variables de performance du véhicule peuvent être dérivées.

Nous avons utilisé les valeurs des coefficients obtenues à partir du filtre de Kalman pour calculer les forces. Dans cette étape, on peut montrer qu'en introduisant les forces, on peut améliorer l'estimation de la puissance et de l'énergie consommée.




(a)

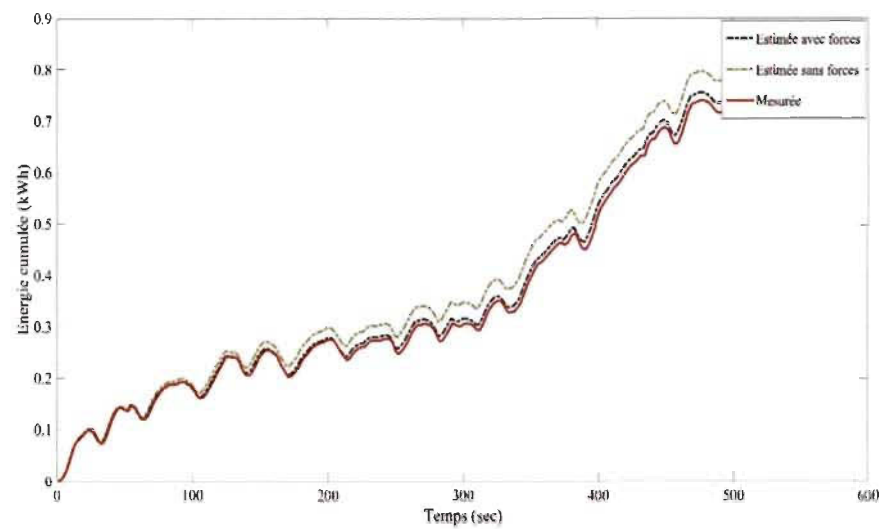


(b)

Figure 21: Profils de puissance mesurée vs estimée : a) condition enneigée, b) condition non-enneigée



(a)



(b)

Figure 22: Energie cumulée mesurée vs estimée : a) condition enneigée, b) condition non-enneigée

Ces figures ci-dessus nous montrent la capacité du NARX à estimer le profil de puissance instantanée de la batterie. Ces estimations ont été faites en temps réel : aucune donnée du test n'a été utilisée pendant la phase d'entraînement et les prédictions sont effectuées au fur et à mesure que les données arrivent.

### 5.2.3 Estimation de l'autonomie

Dans cette section, nous présentons les analyses sur l'estimation de l'autonomie. Cela passe par l'évaluation de l'efficacité de conduite. C'est une étape critique dans l'estimation de l'autonomie restante. Dans cette partie, on remplacera le temps par la distance sur les axes des abscisses des figures.

La figure ci-dessous (figure 23) montre l'efficacité de conduite pour un test de conduite sur autoroute. On constate que l'efficacité de conduite cumulée est presque constante (5 km/kWh) pour des longs trajets parce que les conditions de conduite comme la vitesse ne changent pas beaucoup durant tout le trajet.

D'autre part, les fluctuations des efficacités d'enregistrement de courte durée s'atténuent lorsque la distance d'enregistrement augmente. Cette figure est très pertinente et illustre toute la problématique d'anxiété des véhicules électriques.

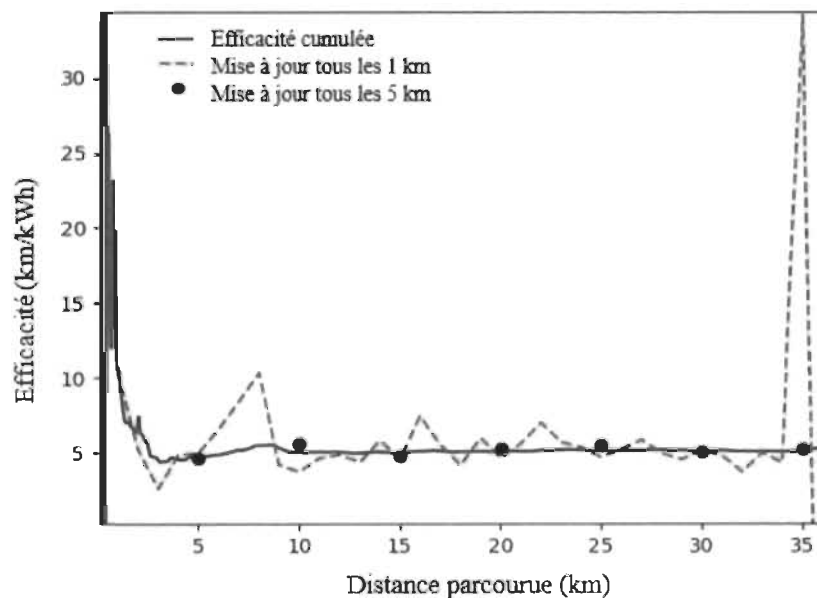


Figure 23: Calcul de l'efficacité de conduite pour un test de conduite sur autoroute ( $V_{max} = 100 \text{ km/h}$ )

Les différents rendements de conduite présentés dans cette même figure sont estimés à partir des informations énergétiques et ne diffèrent que par la distance de mise à jour.

Cependant, une mise à jour tous les 1 km est susceptible d'augmenter l'anxiété par rapport à une mise à jour tous les 5 km qui est plus stable. Le fait est que l'estimation de l'autonomie n'est pas aussi simple qu'elle semble. De plus, il faut faire attention au choix de la distance de mise à jour afin de fournir une bonne estimation plus précise de la distance restante.

Afin de prendre en compte chaque force sur la consommation énergétique, la pente d'une route peut affecter l'efficacité de la conduite. La figure 24 illustre cet effet dans les conditions d'une route vallonnée dont la pente positive correspond à une descente et une pente négative correspond à une montée.

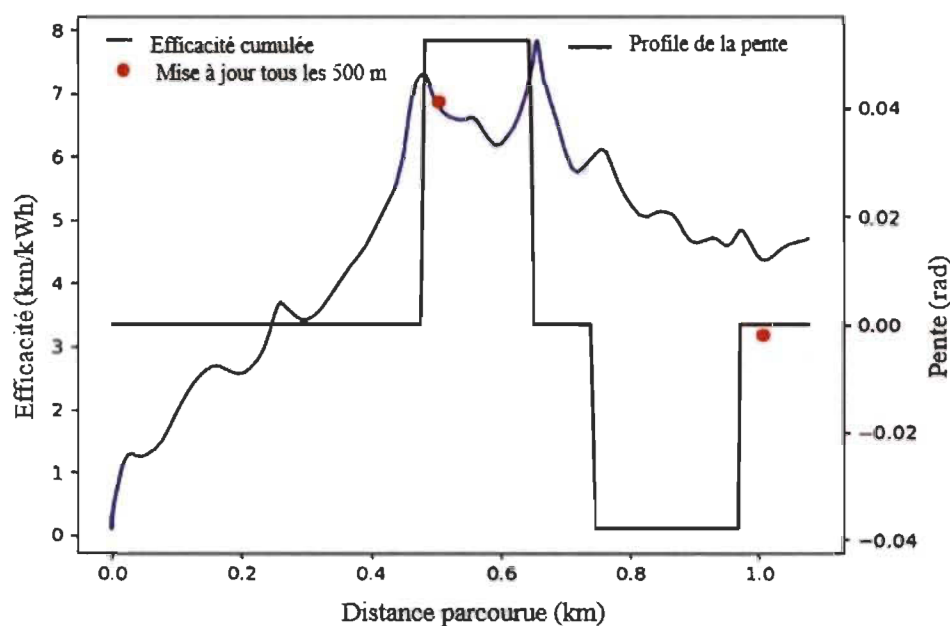


Figure 24: Efficacité de conduite pour un test de conduite dans une zone scolaire avec une présence de pente ( $V_{max} = 30 \text{ km/h}$ )

Le résultat montre que pour l'efficacité de conduite cumulée augmente progressivement pour les 500 premiers mètres et diminue pour les 500 suivants. En effet, pendant les 500 premiers mètres parcourus, le véhicule roule en descente ainsi il consomme moins d'énergie tandis que quand le véhicule roule sur les 500 derniers, il consomme plus d'énergie pour la propulsion le long de la montée entraînant une diminution de l'efficacité de conduite.

Il est assez compliqué d'estimer l'autonomie restante sans avoir recours à l'efficacité de conduite mais il est nécessaire de bien choisir les mises à jour. Pour contourner ce problème, on a utilisé le réseau NARX pour connaître l'autonomie restante et ce réseau entraîné est utilisé pour prédire l'autonomie restante du test de conduite sur autoroute.

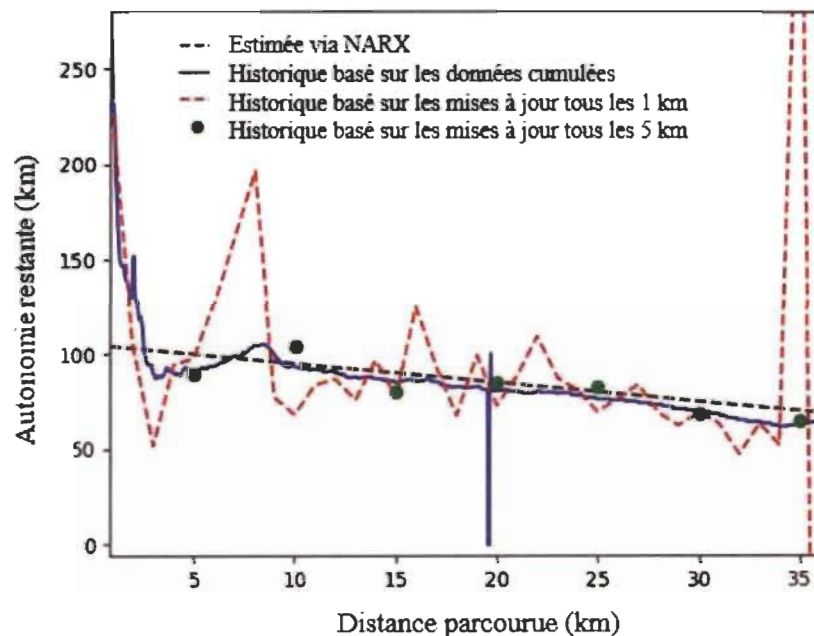


Figure 25: Estimation de l'autonomie restante via le NARX et l'historique des données de conduite



Selon la figure sur l'estimation de l'autonomie sur autoroute (figure 24), on a utilisé deux calculs de mise à jour avec le réseau NARX pour l'estimation de l'autonomie. On observe que la portée restante estimée avec le NARX est plus précise que la méthode de calcul sur l'historique traditionnelle de mise à jour. Pour les méthodes basées sur la mise à jour tous les 5 km et les données cumulées, fournissent des estimations qui suivent assez bien la tendance réelle de l'autonomie restante pour une distance parcourue supérieure à 15 km. En effet, l'efficacité de conduite est presque constante avec ces distances et ainsi l'autonomie peut être facilement calculée à partir des historiques des données le plus proche. Il convient de noter que la méthode basée sur l'historique des données de mise à jour tous les 1 km augmente l'anxiété de l'autonomie. En définitive, le réseau NARX est très robuste dans l'estimation de l'autonomie restante et constitue une alternative sérieuse aux approches des constructeurs pour estimer l'autonomie restante d'un véhicule électrique. De plus, le NARX n'a pas besoin d'aucune hypothèse sur la distance de mise à jour, ce qui le rend très utile pour l'estimation en ligne de la distance restante.

## Chapitre 6 - Discussions, conclusions et perspectives

Dans ce travail, on a élaboré des algorithmes pour les simulations afin que nous puissions avoir des résultats satisfaisants. Dans ce cas, il est nécessaire de discuter de ces résultats obtenus afin d'améliorer un peu plus le travail et de savoir si les objectifs initiaux sont atteints et que la problématique soit résolue.

En effet, l'idée est de savoir comment le véhicule utilise l'énergie qu'il a consommé permettant ainsi de savoir jusqu'où le véhicule peut rouler avec le reste d'énergie. Les chapitres I et II nous permettent d'avoir des idées et de présenter le sujet pour mettre en évidence le défi d'estimer précisément l'énergie consommée d'un véhicule électrique afin de savoir l'autonomie restante pour surmonter l'anxiété de l'autonomie et de rassurer le conducteur. Pour cela, notre objectif principal était de proposer une approche sur l'estimation de la consommation d'énergie de la famille des véhicules électriques afin que l'on puisse estimer l'autonomie de manière exacte. Pour améliorer la précision dans la prédiction de la consommation énergétique, ce projet consistait alors à inclure les valeurs des deux paramètres physiques du véhicule, qu'on a sélectionnés : les coefficients aérodynamique et résistance au roulement dans l'approche de gestion énergétique. Donc, cela nous a permis de mettre en évidence ces objectifs secondaires :

- Établir un algorithme d'estimation en ligne des coefficients aérodynamique et de la résistance au roulement au roulement du véhicule.
- Établir un modèle de prédiction afin d'avoir une bonne précision sur l'estimation de la consommation d'énergie du véhicule sur un trajet déterminé.

Le modèle longitudinal du véhicule utilisé, décrit dans le chapitre III a été simplifié afin de faire une étude sur l'impact des forces aérodynamique et résistance au roulement sur la consommation énergétique et sur l'estimation de la puissance. Durant un trajet, si une estimation non efficace de ces deux paramètres est intégrée dans l'estimation de l'autonomie, une valeur résiduelle non fiable est indiquée augmentant l'angoisse de l'autonomie et accentuer la peur du conducteur face au panne d'énergie. Cependant, en offrant une bonne estimation, précise et fiable de ces paramètres, il est plus facile pour le conducteur d'avoir plus de confiance et aussi de voyager sans angoisse de l'autonomie.

Dans notre cas, on a utilisé deux algorithmes pour l'estimation des coefficients aérodynamique et résistance au roulement dont les moindres carrés récurrents et le filtre de Kalman. L'utilisation de la puissance électrique et de la vitesse du véhicule dans ces algorithmes a permis de déterminer ces coefficients. En se basant des résultats obtenus par rapport à la convergence, le filtre de Kalman a été plus performant par rapport aux moindres carrés récurrents. L'estimation de ces paramètres nous a permis d'effectuer des analyses de la contribution de chaque force pour créer des cartes énergétiques.

D'autre part, un modèle NARX est utilisé pour l'estimation de la puissance ainsi que l'autonomie restante du véhicule. On a pu remarquer qu'en rajoutant les forces dans le modèle, on obtient plus de précision par rapport sans les forces. Cependant, on a fait quelques analyses et calculs sur l'estimation de l'autonomie restante avec des mises à jour de données permettant de prédire cette autonomie via le modèle NARX. Cela nous a permis d'avoir une bonne estimation de la puissance, l'énergie consommée ainsi que l'autonomie restante en nécessitant aucune hypothèse et nécessite que peu de données de pour entraîner ce qui le rend particulièrement utile pour les applications en ligne.

Les algorithmes élaborés dans ce projet ont été simulés en utilisant des données réelles obtenues sur le véhicule KIA SOUL EV de l'Institut de Recherche sur l'Hydrogène (IRH) connecté de son OBD 2 avec un OBD Link et le logiciel Torque pour l'acquisition des données dont la puissance électrique, la vitesse et d'autres paramètres nécessaires dans ce travail.

### **Perspectives :**

Les algorithmes élaborés dans cette étude ont été simulés à l'aide des données réelles obtenues avec le KIA Soul EV de l'IRH. Il est donc intéressant de pouvoir implémenter tous ces algorithmes pour estimer tous les paramètres qui peuvent influencer la consommation énergétique d'un véhicule électrique dans le modèle dynamique longitudinal tels que la masse, la pente, le coefficient aérodynamique ainsi que le coefficient de la résistance au roulement dans différentes conditions de conduite comme en été ou les conditions sèches et aussi pour les conditions hivernales c'est-à-dire à basse température, présence de neige et plusieurs autres facteurs (pour le cas du Canada).

D'autre part, il serait aussi intéressant d'implémenter ces algorithmes pour d'autres types de véhicule comme les voitures à moteur thermique mais surtout les véhicules lourds. Cela permettra de travailler en collaboration avec les flottes pour améliorer l'estimation de la consommation d'énergie mais aussi pour diminuer la pollution de l'environnement.

De plus, savoir comment le véhicule dépense de l'énergie est un atout. Il serait aussi très intéressant de mettre au point une stratégie pour récupérer cette énergie dépensée. Un point qui serait un plus pour l'amélioration de l'efficacité énergétique.

## Références

- [1] A. Roy, A. Lacroix, J. Watters, S. Côté et M. Grenier-Hamel, «Guide de sensibilisation à la réduction de la consommation de carburant et des émissions des gaz à effet de serre en transport,» De l'énergie pour demain, Québec, 2007.
- [2] «TRANSITION ÉNERGÉTIQUE : RÔLE DES TERRITOIRES ET DÉFIS TECHNOLOGIQUES (PANORAMA 2018),» chez *IFP Energies nouvelles*, Paris, 2018.
- [3] Utilisation de l'énergie : consommation de carburant, Ministère de l'énergie et des ressources naturelles, Québec, 2014.
- [4] U. E. Administration, «International Energy Outlook 2016 With Projections to 2040,» U.S. Department of Energy, 2016.
- [5] National Academies of Sciences, Engineering, and Medicine, «Review of the 21st Century Truck Partnership: Third Report,» National Academies Press, 2015.
- [6] K. Maalej; S. Kelouwani; Y. Dubé; K. Agbossou; N. Henao, «Long-trip optimal energy planning with online mass estimation for battery,» *Journal of Power Sources*, vol. 64, n°11, pp. 4929-4941, 2015.
- [7] K. Maalej; S. Kelouwani; Y. Dubé; K. Agbossou, «Enhanced fuelcell hybrid electric vehicle power sharing method based on fuel cost,» *Journal of Power Sources*, vol. 248, pp. 668-678, 2014.
- [8] D. Zhang; A. Ivanko; Z. Filipi, «Model-Based Estimation of Vehicle Aerodynamic Drag and Rolling Resistance,» *SAE International Journal of Commercial Vehicles*, vol. 8, pp. 433-439, 2015.

- [9] R. Andersson, «Online estimation of rolling resistance and air drag for heavy duty vehicles,» 2012.
- [10] Hamid Taghavifar; Aref Mardani; Haleh Karim-Maslak; Hashem Kalbkhani , «Artificial Neural Network estimation of wheel rolling resistance in clay loam soil,» *Applied Soft Computing*, vol. 13, n° 18, pp. 3544-3551, 2013.
- [11] K. B. Singh and S. Taheri, «Estimation of tire-road friction coefficient and its application in chassis control systems,» *Systems Science & Control Engineering*, vol. 3, pp. 39-61, 2015.
- [12] Jadranko Matuško; Ivan Petrović; Nedjeljko Peri, «Neural network based tire/road friction force estimation,» *Engineering Applications of Artificial Intelligence*, vol. 21, n° 14, p. 442-456, 2008.
- [13] Richard Barney Carlson; Henning Lohse-Busch; Jeremy Diez and Jerry Gibbs, «The Measured Impact of Vehicle Mass on Road Load Forces and Energy Consumption for a BEV, HEV and ICE Vehicle,» *SAE International Journal of Alternative Powertrains*, 2013.
- [14] A. Alagumalai, «Internal combustion engines: Progress and prospects,» *Renewable and Sustainable Energy Reviews*, vol. 38, pp. 561-571, 2014.
- [15] F. S. Richard van Basshuysen, *Internal Combustion Engine Handbook*, Warrendale, Pennsylvania: SAE International, 2016.
- [16] L. H. B. Multon, «Probleme de la motorisation d'un véhicule électrique,» *Revue 3EI*, pp. 53-64, 1995.
- [17] A. Moretti, «The new electric vehicle "Renault Kangoo",» *Electric vehicle symposium EV's 17*, 2000.
- [18] G. M. Cotter, «A study in hybrid vehicle architectures: comparing efficiency and performance,» MASSACHUSETTS INSTITUTE OF TECHNOLOGY, 2009.

- [19] L. Martellucci; M. Santoro; C. Boccaletti, «A power train with planetary gear system: Advantages and a design approach,» *Proc. of EVS*, 2001.
- [20] M. Zarkacoula, G. Zoidis et E. Tritopoulou, «Training urban bus drivers to promote smart driving: A note on a Greek eco-driving pilot program,» *Transportation Research Part D: Transport and Environment*, vol. 12, n° 16, pp. 449-451, 2007.
- [21] J. N. Barkenbus, «Eco-driving: An overlooked climate change initiative,» *Energy Policy*, vol. 38, n° 12, pp. 762-769, 2010.
- [22] M. Barth et K. Boriboonsomsin, «Energy and emissions impacts of a freeway-based dynamic eco-driving system,» *Transportation Research Part D: Transport and Environment*, vol. 14, n° 16, pp. 400-410, 2009.
- [23] M. Barth, S. Mandava, K. Boriboonsomsin et H. Xia, «Dynamic ECO-driving for arterial corridors,» chez *2011 IEEE Forum on Integrated and Sustainable Transportation Systems*, Vienna, Austria, 2011.
- [24] Y. Saboohi et H. Farzaneh, «Model for developing an eco-driving strategy of a passenger vehicle based on the least fuel consumption,» *Applied Energy*, vol. 86, n° 110, pp. 1925-1932, 2009.
- [25] «10 CONSEILS POUR ÉCO-CONDUIRE,» Ecoconso, 2020.
- [26] D. E. Hall et C. J. Moreland, «Fundamentals of Rolling Resistance,» *Rubber Chemistry and Technology*, vol. 74, n° 13, p. 525-539, 2001.
- [27] B. Coutermarsh, «Velocity effect of vehicle rolling resistance in sand,» *Journal of Terramechanics*, vol. 44, n° 14, pp. 275-291, 2007.
- [28] L. Li, F.-Y. Wang et Q. Zhou, «Integrated longitudinal and lateral tire/road friction modeling and monitoring for vehicle motion control,» *IEEE Transactions on Intelligent Transportation Systems*, vol. 7, n° 11, pp. 1-19, 2006.

- [29] A. M. A. Soliman, «Effect of Road Roughness on the Vehicle Ride Comfort and Rolling Resistance,» chez *2006 World Congress*, Detroit, Michigan, 2006.
- [30] J. Barrand et J. Bokar, «Reducing Tire Rolling Resistance to Save,» *SAE International*, vol. 1, n° 11, pp. 9-17, 2008.
- [31] H. S. Hamut, R. S. El-Emam, M. Aydin et I. Dincer, «Effects of rear spoilers on ground vehicle aerodynamic drag,» *International Journal of Numerical Methods for Heat & Fluid*, vol. 24, n° 13, pp. 627-642, 2014.
- [32] K. P. Barry, «A Review of Commercial Vehicle Aerodynamic Drag Reduction Techniques,» *Proceedings of the Institution of Mechanical Engineers, Part D: Transport Engineering*, vol. 199, n° 13, pp. 215-220, 1998.
- [33] S. Pagerit, P. Sharer et A. Rousseau, «Fuel Economy Sensitivity to Vehicle Mass for Advanced Vehicle Powertrains,» chez *Advanced Hybrid Vehicle Powertrains 2006*, Detroit, Michigan, 2006.
- [34] R. Tolouei et H. Titheridge, «Vehicle mass as a determinant of fuel consumption and secondary safety performance,» *Transportation Research Part D: Transport and Environment*, vol. 14, n° 16, pp. 385-399, 2009.
- [35] J. Sullivan, G. Lewis et G. Keoleian, «Effect of mass on multimodal fuel consumption in moving people and freight in the U.S.,» *Transportation Research Part D: Transport and Environment*, vol. 63, pp. 786-808, 2018.
- [36] S. Salisbury, «Cold Weather On-Road Testing of a 2015 Nissan Leaf,» Idaho National Laboratory, Idaho, 2016.
- [37] K. R. Kambly et T. H. Bradley, «Estimating the HVAC energy consumption of plug-in electric vehicles,» *Journal of Power Sources*, vol. 259, pp. 117-124, 2014.
- [38] T. Excel, «Caractéristiques physiques de l'eau - Masse volumique - Enthalpie spécifique - Chaleur massique et volumique - Viscosité dynamique».



- [39] K. Kikuchi et M. Suzuki, «Study of aerodynamic coefficients used to estimate critical wind speed for vehicle overturning,» *Journal of Wind Engineering and Industrial Aerodynamics*, vol. 147, pp. 1-17, 2015.
- [40] Z. Mohamed-Kassim et A. Filippone, «Fuel savings on a heavy vehicle via aerodynamic drag reduction,» *Transportation Research Part D: Transport and Environment*, vol. 15, n° 15, pp. 275-284, 2010.
- [41] C. Ahn, H. Peng et E. Tseng, «Robust estimation of road friction coefficient using lateral and longitudinal vehicle dynamics,» *Vehicle System Dynamics*, vol. 50, n° 16, pp. 961-985, 2012.
- [42] G. Bischof, E. Bratschitsch, A. Haas, A. Kaltenhauser et F. Ullrich, «On-road determination of aerodynamic drag improvements,» *SAGE Journals*, vol. 218, n° 11, pp. 1-6, 2004.
- [43] Y. Chen et J. Wang, «Adaptive Vehicle Speed Control With Input Injections for Longitudinal Motion Independent Road Frictional Condition Estimation,» *IEEE Transactions on Vehicular Technology*, vol. 60, n° 13, pp. 839 - 848, 2011.
- [44] R. Rajamani, G. Phanomchoeng, D. Piyabongkarn et J. Y. Lew, «Algorithms for Real-Time Estimation of Individual Wheel Tire-Road Friction Coefficients,» *IEEE/ASME Transactions on Mechatronics*, vol. 17, n° 16, pp. 1183 - 1195, 2012.
- [45] E. Hashemia, S. Khosravanian, A. Khajepoura, A. Kasaiezadehb, S.-K. Chenb et B. Litkouhi, «Longitudinal vehicle state estimation using nonlinear and parameter-varying observers,» *Mechatronics*, vol. 43, pp. 28-39, 2017.
- [46] J. Matuško, I. Petrović et N. Perić, «Neural network based tire/road friction force estimation,» *Engineering Applications of Artificial Intelligence*, vol. 21, n° 13, pp. 442-456, 2008.
- [47] T. Zahid, K. Xu, W. Li, C. Li et H. Li, «State of charge estimation for electric vehicle power battery using advanced machine learning algorithm under diversified drive cycles,» *Energy*, vol. 162, pp. 871-882, 2018.

- [48] X. Hu, S. E. Li et Y. Yang, «Advanced Machine Learning Approach for Lithium-Ion Battery State Estimation in Electric Vehicles,» *IEEE Transactions on Transportation Electrification*, vol. 2, n° 12, pp. 140 - 149, 2016.
- [49] C.-M. Tseng et C.-K. Chau, «Personalized Prediction of Vehicle Energy Consumption Based on Participatory Sensing,» *IEEE Transactions on Intelligent Transportation Systems*, vol. 18, n° 111, pp. 3103 - 3113, 2017.
- [50] X. Wua, D. Freeseb, A. Cabrerab et W. A. Kitch, «Electric vehicles' energy consumption measurement and estimation,» *Transportation Research Part D: Transport and Environment*, vol. 34, pp. 52-67, 2015.
- [51] C. Fioria, K. Ahna et H. A. Rakha, «Power-based electric vehicle energy consumption model: Model development and validation,» *Applied Energy*, vol. 168, pp. 257-268, 2016.
- [52] Fiche-auto, «Fonctionnement d'une voiture électrique,» 2019.
- [53] «La deuxième loi de Newton,» Québec.
- [54] H. K. Fathy, K. Dongsoo et J. L. Stein, «Online vehicle mass estimation using recursive least squares and supervisory data extraction,» chez *2008 American Control Conference*, Seattle, WA, USA, 2008.
- [55] Département de l'Énergie des États-Unis, «Tires and Passenger Vehicle Fuel Economy : Informing Consumers, Improving Performance,» National Research Council, 2006.
- [56] Département de l'Énergie des États-Unis, «Where the energy goes: Electric cars».
- [57] O. Trigui, Y. Dube, S. Kelouwani et K. Agbossou, «Comparative Estimation of Electric Vehicle Rolling Resistance Coefficient in Winter Conditions,» chez *2016 IEEE Vehicle Power and Propulsion Conference (VPPC)*, Hangzhou, China, 2016.

- [58] M. Kandidayeni, A. Macias, A. A. Amamou, L. Boulona, S. Kelouwani et H. Chaoui, «Overview and benchmark analysis of fuel cell parameters estimation for energy management purposes,» *Journal of Power Sources*, vol. 380, pp. 92-104, 2018.
- [59] E. Gelenbe, V. Koubi et F. Pekergin, «Dynamical random neural network approach to the traveling salesman problem,» chez *Proceedings of IEEE Systems Man and Cybernetics Conference - SMC*, Le Touquet, France, 2002.
- [60] A. Mellit, S. Sağlam et S. A. Kalogirou, «Artificial neural network-based model for estimating the produced power of a photovoltaic module,» *Renewable Energy*, vol. 60, pp. 71-78, 2013.
- [61] José Marie P. Menezes Jr. et Guilherme A. Barreto, «Long-term time series prediction with the NARX network: An empirical evaluation,» *Neurocomputing*, vol. 71, n° 16-18, pp. 3335-3343, 2008.
- [62] «Energie renouvelable: voiture hybride,» Futura sciences.

## **Annexe A – Fiche technique du véhicule KIA SOUL EV 2017**



### **APERÇU**

Consommation de carburant : 2.0 (Automatique ville), 2.6 (Automatique autoroute)

Moteur : 100% Électrique 81,4kW

Puissance : 109 cv @ 2730 rpm

Boîte de vitesses : Engrenage de réduction à une vitesse

Carrosserie : À hayon

Portières : 5; places : 5

### **SUSPENSION ET CONDUITE**

Barre stabilisatrice avant

Direction à assistance électrique avec direction Flex

Indicateur de basse pression des pneus : Moniteur de pression des pneus (TPMS)

Pneus : P205/60R16

Suspension arrière à barre de torsion

Suspension avant indépendante

Mode de conduite : Modes de conduite ECO et par régénération

Type de roue : Jantes en alliage de 16 pouces

### **MÉCANIQUE**

Moteur : 100% Électrique 81,4kW

Motricité : Avant

Traction asservie : Oui

Transmission : Engrenage de réduction à une vitesse

### **DIMENSIONS**

Capacité maximale de chargement : 1402 L

Dégagement-jambes arrière : 914 mm

Dégagement-jambes avant : 1040 mm

Dégagement-tête arrière : 1003 mm

Dégagement-tête avant : 1006 mm

Empattement : 2570 mm

Hauteur : 1600 mm

Largeur : 1801 mm

Longueur : 4140 mm

Poids à vide : 1492 kg

Volume du coffre : 532 L

### **COULEUR EXTÉRIEURE**

Blanc nacré

Bleu électronique

Noir onyx

### **COULEUR INTÉRIEURE**

Gris

### **SÉCURITÉ**

Ancrages et attaches pour sièges d'enfant LATCH

Assistance de démarrage en côte (HAC)

Assistance en cas de freinage d'urgence (BAS)

Caméra de recul

Ceintures de sécurité avant : rétracteurs de ceintures

Verrous de sécurité empêchant l'ouverture accidentelle des portières arrière

Freins : Disques avant / disques arrière

Freins antiblocages : Antiblocage aux 4 roues

Freins à main : Électrique

Rideaux gonflables au pavillon : Deux coussins gonflables latéraux de types rideau

Répartition électronique de force de freinage (EBD)

Sac gonflable frontal côté conducteur

Sac gonflable avant côté passager

Sacs gonflables latéraux avant

Verrouillage de sécurité pour enfants aux portes arrière

## Annexe B – Article publié

# Comparative study of vehicle aerodynamic and rolling resistance coefficients estimation methods

F. Andriamihy  
Department of mechanical engineering  
Hydrogen Research Institute  
Université du Québec à Trois-Rivières  
Trois-Rivières, Canada  
Ho.familo.andriamihy@uqtr.ca

N. Zioui  
Department of mechanical engineering  
Université du Québec à Trois-Rivières  
Trois-Rivières, Canada  
Nudjet.zioui@uqtr.ca

A. Amamou  
Department of mechanical engineering  
Hydrogen Research Institute  
Université du Québec à Trois-Rivières  
Trois-Rivières, Canada  
Ali.amamou@uqtr.ca

A. Ghobadpour  
Hydrogen Research Institute  
Université du Québec à Trois-Rivières  
Trois-Rivières, Canada  
Amin.ghobadpour@uqtr.ca

S. Kelouwani  
Department of mechanical engineering  
Hydrogen Research Institute  
Université du Québec à Trois-Rivières  
Trois-Rivières, Canada  
Souso.kelouwani@uqtr.ca

K. Agbossou  
Hydrogen Research Institute  
Université du Québec à Trois-Rivières  
Trois-Rivières, Canada  
Kodjo.agbossou@uqtr.ca

**Abstract**— The new stringent standards laid down for reducing pollution and greenhouse gas emissions in transportation sector compel the vehicle manufacturers to use different technologies to decarbonize the vehicles and reduce their energy consumption. Powertrain control optimization, especially based on instantaneous accurate information, has an important role in improving the fuel economy of vehicle. However, its successful implementation requires an accurate parameter estimation method. The main purpose of this article is to propose an accurate adaptive method for estimating the rolling resistance and aerodynamic drag, which are two important factors in powertrain optimization of a vehicle. In this regard, two online adaptive methods, namely recursive least squares (RLS) and Kalman filter (KF), are formulated for the parameters estimation of the powertrain by using the experimental data from a real driving cycle and their performances are compared with an offline trained artificial neural networks (ANN). The experimental and simulation results show that KF is more accurate than RLS in terms of predicting the road rolling resistance and aerodynamic drag and its performance is very near to the developed ANN.

**Keywords**— Aerodynamic force, online estimation, rolling resistance, recursive identification, vehicle dynamic model.

## I. INTRODUCTION

The energy consumption of conventional vehicles depends on several parameters, such as vehicle's weight, engine efficiency, and dynamic parameters like rolling resistance and vehicle aerodynamic drag [1] and the global fuel saving in such systems is thoroughly related to the power flow control between each energy source and the powertrain [2],[3]. Online estimation of vehicle parameters has been an active area of research in recent decades [4]. Due to the difference in the size of the vehicles, the form of the bodywork and the number of wheel axles, the rolling resistance and air resistance values vary from one vehicle to another [5]. However, these factors are normally assumed the same in the literature regardless of the vehicle configuration. The rolling resistance coefficient may vary depending on the type of tire and the road surface [6],[7],[8]. Moreover, vehicle mass and aerodynamic drag coefficient can significantly change when a trailer or another unpowered vehicle is attached to the car. Therefore, online parameter estimation is necessary in the formulation of powertrain control in commercial vehicles since it reduces the initial calibration effort. Furthermore, it helps the powertrain controller to quickly adapt to different vehicle configurations,

resulting in a better fuel economy. Therefore, the fuel consumption of the vehicle and the release of CO<sub>2</sub> in the atmosphere significantly depends on the resistance forces of the vehicle [9]. The driving resistance comprises rolling resistance, air drag and mass. Aerodynamic drag arises from the action of air in the opposite direction to the motion of the vehicle [10]. It is the main source of resistance and proportional to the square of the vehicle's speed. At highway conditions, over 50% of the power of a car is used to overcome air drag. For instance, when the speed of the vehicle is 50 km/h, the aerodynamic drag represents less than 50% of the total resistance while it increases to more than 80% at 130 km/h. Vehicle control systems require lateral and longitudinal conditions (velocities and forces) to control wheel spin, vehicle yaw rates, and lateral slip angles. Among these states, the estimation of longitudinal states makes a major contribution to vehicle stability and traction control [11],[12].

Accurate real-time estimation of vehicle loads, such as vehicle mass and pavement conditions, aerodynamic drag and rolling resistance, can improve safety, efficiency and performance [13]. The aerodynamic drag estimate has not been fully explored yet in the literature and requires extensive investigations. Some tests have been carried out in wind tunnels to simulate the road conditions for aerodynamic drag calculation. Since aerodynamics has become essential in automotive design, the main development tool is the large-scale wind tunnel. Unfortunately, for a realistic simulation of road conditions, the conventional large-scale wind tunnels have some limitations [14]. The ground is fixed relative to the vehicle, which allows a boundary layer to develop and the wheels of the development mule not to rotate [15]. In addition, the aerodynamic data obtained from different wind tunnels show a significant degree of dispersion. Not only there are variations in the absolute drag and the rolling resistance values, but there is also a dispersion due to the change of configuration [16]. In this regard, an independent and inexpensive method for identifying differences in aerodynamic drag resulting from various configurations should be developed. Online estimation of vehicle parameters has been an active area of research in recent years [11],[17],[18]. The model-based approach (using the longitudinal dynamic model of the vehicle and the CAN bus signals) is the preferred method for estimating parameters due to the minimal additional sensors requirements. The estimation of these parameters has been the center of attentions as they remarkably contribute to fuel consumption

[19]. The obtained information from sensors, such as GPS, accelerometer, and barometer, is usually noisy. Model-based filters are often combined with sensor measurements to improve the accuracy of the estimate.

In this work, the aerodynamic and friction coefficients are estimated simultaneously by using the experimental data acquired from a vehicle over several route conditions. To do so, three methods are employed for the aerodynamic and friction coefficients estimation. The first and the second methods are adaptive, based on the longitudinal model using recursive least squares (RLS) and Kalman filter (KF) methods while the third one uses artificial neural networks (ANN).

The rest of the document is organized as follows. The utilized methods for estimating the parameters are discussed in section II. The experimental procedure is detailed in section III. Section IV presents the obtained results of this work. Finally, the conclusion is given in section V.

## II. ESTIMATION METHODS

### A. Vehicle longitudinal dynamic model

Fig. 1 represents the resistive forces acting on the longitudinal dynamics of a vehicle. These forces are composed of vehicle traction force ( $F_x$ ), vehicle resistance forces, including the rolling resistance ( $F_{roll}$ ) and aerodynamic drag ( $F_{aero}$ ), grading resistance ( $F_{grade}$ ), and acceleration force ( $F_{acc}$ ). The dynamic equation of vehicle motion along the longitudinal direction to overcome of these forces is expressed by (1):

$$\begin{cases} F_x = F_{roll} + F_{aero} + F_{grade} + F_{acc} \\ \frac{T \eta}{v} = M g \mu \cos \theta + \frac{1}{2} \rho A C_{aero} v^2 + M g \sin \theta + M \dot{x} \end{cases} \quad (1)$$

Where  $T$  is the engine torque,  $w$  is the engine speed,  $\eta$  is the overall driveline efficiency,  $v$  is the vehicle speed,  $M$  is the vehicle mass,  $x$  is the distance,  $\dot{x}$  is the acceleration,  $g$  is the gravitational acceleration,  $\theta$  is the road grade,  $\mu$  is the rolling resistance coefficient,  $C_{aero}$  is the drag coefficient,  $\rho$  is the density of air, and  $A$  is the front surface of the vehicle.




Fig. 1. The resistive forces influencing the longitudinal dynamics of the vehicle

### B. Proposed estimation method

For the purpose of this study, three model-based approaches are used for the estimation of the aerodynamic and rolling resistance coefficients and other unknown parameters affecting the vehicle's longitudinal motion. The three methods are discussed in details in the following sections.

#### 1) RLS

RLS is an adaptive filter that recursively estimates certain parameters for minimizing a weighted linear least squares cost function. This cost function is associated with the input signals. RLS gives quality performance when operating in time-varying conditions [20].

In this approach, unknown parameter vector is updated iteratively at each time step by using the previous input and output measured data. The RLS algorithm can be formulated as follows:

$$\begin{cases} y = \phi \theta \\ y = \left[ \frac{T \eta}{v} - M \dot{x} - M g \sin \theta \right] \\ \phi = \left[ \frac{1}{2} \rho A v^2 \quad M g \cos \theta \right] \\ \theta = [C_{aero} \quad \mu]^T \end{cases} \quad (2)$$

Where  $y$  is the output signal,  $\phi$  is the input vector, and  $\theta$  is the unknown parameter vector.

#### 2) Kalman Filter

KF is perceived as an optimal estimator, which works in a two-step process to estimate the parameters of interest. This filter first estimates the current state variables and then updates them upon the receipt of the next measurement [21]. The structure of the utilized KF in this work is as follows:

$$\begin{cases} x(k) = F x(k-1) + w(k-1) \\ y(k) = H(k) x(k) + v(k) \\ y = \left[ \frac{T \eta}{v} - M \dot{x} - M g \sin \theta \right] \\ H = \left[ \frac{1}{2} \rho A v^2 \quad M g \cos \theta \right] \\ x = [C_{aero} \quad \mu]^T \end{cases} \quad (3)$$

Where  $v(k)$  is the measurement noise,  $k$  is the time step,  $F$  is the transition matrix, and  $w(k)$  is the process noise.

The identification algorithms (KF and RLS) extracts the aerodynamic drag and the rolling resistance coefficients of the vehicle longitudinal dynamic model as they receive the measured data regarding the engine torque and speed of the vehicle.

#### 3) Neural network-based method

The ANN-based model is utilized to concurrently estimate the aerodynamic and rolling resistance coefficients. The ANN model is composed of two inputs (engine torque and speed values), two outputs (aerodynamic drag and rolling resistance coefficients) and five layers of interconnected neurons. In this work, a set of experimental data are arranged in arrays to provided the ANN with the required input and output data for the training step. Once the training step is complete, the ANN is used to estimate the vehicle aerodynamic drag and rolling resistance coefficients for two different paths. It should be noted that 70% of the measured data is utilized in the training stage, 15% of the data is used for the validation and the rest is employed for testing the trained ANN.

## III. EXPERIMENTAL PROCEDURE

### A. Validation setup

#### 1) Vehicle parameters

Experimental data are acquired through using the Can-Bus-OBD module and OBDWiz software from real world driving tests. Fig. 2 shows the testing vehicle (Dodge Caliber



2012) and measurement tools. The main parameters of the vehicle are listed in Table 1 according to manufacturer catalog.

Firstly, the real world driving parameters, such as engine torque and speed, are measured. Then, the collected data are employed to estimate the aerodynamic drag and rolling resistance coefficients by using the three previously described estimation methods. Finally, the estimation methods are validated by performing a series of simulations.




Fig. 2. a) The testing vehicle and b) Can-Bus-OBD

TABLE I. PARAMETERS OF THE TESTING VEHICLE [22].

Parameter	unit	Value
Width	mm	1 747
Height	mm	1533
mass	kg	1 547
$C_{aero}$	-	0.375
$\mu$ in asphalt	-	0.018
Tire size	-	P205/70R15
$\rho$	kg/m <sup>3</sup>	1.200

## 2) Experimental tests analyses

Fig. 3 presents the vehicle speed and engine torque values during the real world short distance test.




Fig. 3. The short distance measured data profile (a) vehicle speed and (b) engine torque.

Fig. 4 shows the vehicle speed and the engine torque values during the real world long distance tests.





Fig. 4. The long distance measured data profile (a) vehicle speed and (b) engine torque.

These measured engine torque and vehicle speed values are applied to the vehicle model to estimate rolling resistance and aerodynamic drag coefficients by using the three proposed methods.

To test the robustness, each method has been applied using several real life driving cycles for the long and short distances including the highway and urban driving context.

## B. Experimental results

Fig. 5 represents the simulation results obtained from the short distance test. As it can be seen in this figure, the estimated coefficients by different approaches are converging to the real values of the aerodynamic drag coefficient ( $C_{aero} = 0.375$ ) [22] and the rolling resistance coefficient for an asphalt road ( $\mu = 0.018$ ). The value of  $\mu$  is assumed to be the true measured value of the tire rolling resistance coefficient on the asphalt). These results illustrate that the estimated coefficients by all the methods are almost within the same range. However, the estimated values by KF and ANN are more accurate than RLS.






Fig. 5. Estimated coefficients during the short distance test, a) aerodynamic drag and b) rolling resistance.

Fig. 6 shows the estimated values of aerodynamic drag and rolling resistance coefficients for the long distance test. According to this figure, the estimated coefficients of this test by the three methods are more accurate than the short test. It implies that during the long distance test, estimation errors are decreased. Furthermore, these results indicate that the estimation of rolling resistance coefficient is more accurate than the aerodynamic drag coefficient. This might be due to the variation of unknown factors such as wind during the journey. Table 2 and 3 compare the obtained error rate and mean values by different estimation methods.




Fig. 6. Estimated coefficients during long distance test, a) aerodynamic drag and b) rolling resistance.

TABLE II. ERROR RATE AND MEAN OF ESTIMATED VALUES DURING SHORT DISTANCE TESTS

Coefficients	Aerodynamic drag			Rolling resistance		
	ANN	RLS	KF	ANN	RLS	KF
RMSE	0.0065	0.0246	0.0341	$1.83 \times 10^{-6}$	0.0011	0.0011
Average value	0.3750	0.3745	0.3753	0.0180	0.0179	0.0181

TABLE III. ERROR RATE AND MEAN OF ESTIMATED VALUES DURING LONG DISTANCE TESTS

Coefficients	Aerodynamic drag			Rolling resistance		
	ANN	RLS	KF	ANN	RLS	KF
RMSE	$7.30 \times 10^{-6}$	0.018	0.0076	$1.93 \times 10^{-6}$	0.0013	$2.56 \times 10^{-6}$
Average values	0.3750	0.3758	0.3752	0.0180	0.0180	0.0180

#### IV. DISCUSSIONS

In this article, three methods for estimating the aerodynamic drag and rolling resistance coefficients are compared under two tests. In the first test (short distance test), the estimated aerodynamic drag coefficient by RLS is higher than the actual value while the rolling resistance coefficient is lower than the actual value. In addition, it can be observed that the results obtained by RLS have more fluctuations compared to the KF and ANN keeping in mind that KF shows more estimation precision than RLS. Regarding the second test (long distance test), it is clear that the RLS performance has experienced some improvements compared to the short test.

The results of the performed simulation show that the parameters vary with time but not significantly according to the three methods on each driving cycle. By linearizing the identification model, the evaluated methods can reasonably converge toward their nominal values. The accuracy of the RLS and KF estimations is strongly dependent on the torque values. However, the accuracy of the ANN highly depends on the vehicle speed and the engine torque. Since the measurements of these values are always prone to the occurrence of error, they have a significant effect on the estimation results. The comparison of the results between RLS and KF methods shows that the KF quality of estimations is better than RLS. Moreover, the convergence of the KF method is faster than the RLS. Regarding the error rate, the ANN shows a lower value than the other two methods, followed by KF.

In brief, the accuracy of the estimation depends on the measuring instruments and the configuration of the methods. In addition, RLS and KF methods are more suitable for real-time monitoring than neural network since they can easily adapt to the drifts owing the variation of the conditions.

## V. CONCLUSION

In this work, three methods, namely RLS, KF, and ANN, are used to simultaneously estimate the aerodynamic drag and rolling resistance coefficients under normal conditions. RLS and KF conduct the estimation based on the longitudinal model of the vehicle while ANN is independent of this model. The estimation results of the methods are compared with respect to the attained precision, convergence speed, and error rate. The final outcomes of this paper indicate that the estimated values of the aerodynamic drag and rolling resistance coefficients by these methods are similar to those of the nominal values. In fact, the results of the three methods show an acceptable error. However, KF, as an online estimator, has been more accurate and performed more appropriately under the normal road conditions.

Usually, manufacture gives these values for the normal operating condition (no snow, no ice, sunny days, etc.). The proposed methods can allow to estimate these parameter under different operating including winter conditions.

In addition, for electrical vehicle, those methods could be applied to estimate energy usage and also to predict the required energy to reach a destination.

## ACKNOWLEDGEMENTS

This work was supported in part FRQNT (Fonds de Recherche du Québec – Nature et technologies) in part by the Natural Science and Engineering Research Council of Canada.

## REFERENCES

- [1] E. National Academies of Sciences and Medicine, *Review of the 21st Century Truck Partnership: Third Report*, National Academies Press, 2015.
- [2] K. Maalej, S. Kelouwani, K. Agbossou, Y. Dubé, and N. Henao, "Long-trip optimal energy planning with online mass estimation for battery electric vehicles," *Journal of Power Sources*, vol. 64, no. 11, pp. 4929-4941, 2015, [1-5].
- [3] K. Maalej, S. Kelouwani, K. Agbossou, and Y. Dubé, "Enhanced fuel cell hybrid electric vehicle power sharing method based on fuel cost and mass estimation," *Journal of Power Sources*, vol. 248, pp. 668-678, 2014.
- [4] D. Zhang, A. Ivanco, and Z. Filipi, "Model-Based Estimation of Vehicle Aerodynamic Drag and Rolling Resistance," *SAE International Journal of Commercial Vehicles*, vol. 8, no. 2015-01-2776, pp. 433-439, 2015.
- [5] R. Andersson, "Online estimation of rolling resistance and air drag for heavy duty vehicles," ed, 2012.
- [6] H. Taghaviyar, A. Mardani, H. Karim Masluk, and H. Kalbkhani, "Artificial Neural Network estimation of wheel rolling resistance in clay loam soil," *Applied Soft Computing*, vol. 13, pp. 3544-3551, 8// 2013.
- [7] K. B. Singh and S. Taheri, "Estimation of tire-road friction coefficient and its application in chassis control systems," *Systems Science & Control Engineering*, vol. 3, pp. 39-61, 2015.
- [8] J. Matuško, I. Petrović, and N. Perić, "Neural network based tire/road friction force estimation," *Engineering Applications of Artificial Intelligence*, vol. 21, pp. 442-456, 4// 2008.
- [9] J. Gibbs, H. Lohs-Busch, R. Carlson, "The Measured Impact of Vehicle Mass on Road Load Forces and Energy Consumption for a BEV, HEV, and ICE Vehicle", *SAE International Journal of Alternative Powertrains*, 2013
- [10] Shu-Qing Yang et Donghong Ding, "Drag Reducing Flows in Laminar-Turbulent Transition Region", *Journal of Fluids Engineering*, 2014
- [11] A. Vahidi, A. Stefanopoulou, and H. Peng, "Recursive least squares with forgetting for online estimation of vehicle mass and road grade: theory and experiments," *Vehicle System Dynamics*, vol. 43, pp. 31-55, 2005.
- [12] Vincent Winstead et Ilya V. Kolmanovskiy, "Estimation of Road Grade and Vehicle Mass via Model Predictive Control," *Proceedings of the 2005 IEEE Conference on Control Applications*, Toronto, Canada, August 28-31, 2005
- [13] Kidambi, N., Harne, R., Fujii, Y., Pietron, G. et al., "Methods in Vehicle Mass and Road Grade Estimation", *SAE Int. J. Passeng. Cars*, en 2014
- [14] A. Vahidi, M. Druzhinina, A. Stefanopoulou, and P. Huet, "Simultaneous mass and time-varying grade estimation for heavy-duty vehicles," in *American Control Conference*, 2003. Proceedings of the 2003. , pp. 4951-4956 vol.6, 2003
- [15] Koest, H., White, R., and Metz, L., "Road Evaluation of the Aerodynamic Characteristics of Heavy Trucks", *Journal SAE Technical*, 2007
- [16] R. Zarringhalam, A. Rezaeian, W. Melek, A. Khajepour, S.-k. Chen, and N. Moshchuk, "A comparative study on identification of vehicle inertial parameters," in *2012 American Control Conference (ACC)*, , pp. 3599-3604; IEEE, 2012
- [17] H. K. Fathy, D. Kang, and J. L. Stein, "Online vehicle mass estimation using recursive least squares and supervisory data extraction," in *2008 American control conference*, 2008, pp. 1842-1848; IEEE.
- [18] R. Rajamani, G. Phanomchoeng, D. Piyabongkarn, and J. Y. Lew, "Algorithms for Real-Time Estimation of Individual Wheel Tire-Road Friction Coefficients," *Mechatronics, IEEE/ASME Transactions on*, vol. 17, pp. 1183-1195, 2012.
- [19] R. Zarringhalam, A. Rezaeian, W. Melek, A. Khajepour, S.-k. Chen, and N. Moshchuk, "A comparative study on identification of vehicle inertial parameters," in *2012 American Control Conference (ACC)*, , pp. 3599-3604; IEEE, 2012
- [20] O. Trigui, Y. Dube, S. Kelouwani, and K. Agbossou, "Comparative Estimation of Electric Vehicle Rolling Resistance Coefficient in Winter Conditions," in *2016 IEEE Vehicle Power and Propulsion Conference (VPPC)*, , pp. 1-6; IEEE, 2016
- [21] M. Kandideyeni, A. Macias, A. Amamou, L. Boulon, S. Kelouwani, and H. Chaoui, "Overview and benchmark analysis of fuel cell parameters estimation for energy management purposes," *Journal of power sources*, vol. 380, pp. 92-104, 2018.
- [22] Dodge Caliber 2012, *FICHE TECHNIQUE POUR LE CANADA*, 2012

## Annexe C – Utilisation du OBD Link et Torque Pro




Figure 26: a) module OBD Link MX, b) logiciel Torque Pro

### Étape d'installation :

1. Télécharger et installer Torque Pro sur un appareil Android
2. Télécharger les PIDS pour le KIA Soul Ev dans :  
<https://github.com/JejuSoul/OBD-PIDs-for-HKMC-EVs>
3. Après avoir téléchargé les fichiers, transférer sur l'appareil Android dans le répertoire de Torque situé généralement dans : /sdcard/.torque/extendedpids/.

Pour ajouter les PIDS dont on aura besoin comme suit :

4. Aller dans « Settings » puis sélectionner « Manage extra PIDs/Sensors »
5. Cliquer sur l'icône avec les 3 points en haut à droite après sur « Add predefined set ». On peut voir alors la liste des fichiers ajoutés précédemment.
6. Cliquer sur un fichier et répéter l'opération pour ajouter tous les fichiers voulus.

### Étape d'utilisation :

1. Cliquer sur « Real time information »
2. Aller dans Setting ou menu
3. Cliquer sur « Démarrer Log » pour commencer à enregistrer les données
4. Cliquer sur « Arrêter Log » pour arrêter l'enregistrement les données