

UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

ESTIMATION ADAPTATIVE DU COEFFICIENT DE RÉSISTANCE AU
ROULEMENT POUR VÉHICULES AUTONOMES PAR MOINDRES CARRÉS
RÉCURSIFS (RLS)

MÉMOIRE PRÉSENTÉ
COMME EXIGENCE PARTIELLE DE LA MAÎTRISE EN GÉNIE ÉLECTRIQUE

PAR
DYLANE ULRICH RONALD FEZZE KOUMOE

MAI 2026

Université du Québec à Trois-Rivières

Service de la bibliothèque

Avertissement

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

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

UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

Maîtrise en génie électrique (M.Sc)

Direction de recherche :

Alben Cardenas

Directeur de recherche

Jury d'évaluation

Tahar Tafticht,

Université du Québec en Abitibi-Témiscamingue

Évaluateur externe

Mamadou Lamine Doumbia

Université du Québec à Trois-Rivières

Évaluateur

Alben Cardenas

Université du Québec à Trois-Rivières

Directeur de recherche

Résumé

L'optimisation de l'interaction roue-sol constitue un enjeu majeur pour les véhicules autonomes, en particulier dans les secteurs agricole et industriel, où la stabilité du déplacement et l'efficacité énergétique représentent des critères déterminants. Ce mémoire s'inscrit dans cette perspective en proposant une approche d'estimation du coefficient de résistance au roulement μ_r , afin d'améliorer la modélisation et les performances dynamiques des véhicules à roues.

Une revue critique des principales méthodes d'estimation, notamment les moindres carrés récurrents (RLS), le filtre de Kalman et les réseaux neuronaux, a conduit à retenir l'algorithme RLS comme approche principale. Ce choix s'explique par sa simplicité de mise en œuvre, son faible coût de calcul et sa compatibilité avec les applications en temps réel.

La modélisation proposée intègre les effets aérodynamiques, l'influence de la pente ainsi que les perturbations dues au vent, afin de représenter de manière réaliste les conditions de fonctionnement du véhicule. L'implémentation de l'algorithme sous MATLAB/Simulink, associée à des simulations numériques réalisées sur différents cycles de conduite, met en évidence une convergence rapide ainsi qu'une précision d'estimation satisfaisante. Les résultats montrent que l'erreur relative d'estimation reste globalement inférieure à 10% pour l'ensemble des scénarios étudiés, y compris en présence de perturbations environnementales telles que la pente, la vitesse du vent et le bruit de mesure.

Cette approche contribue à l'amélioration des performances des systèmes de contrôle en permettant une meilleure adaptation aux conditions de roulement et une estimation plus fiable du coefficient μ_r . D'un point de vue applicatif, la solution retenue permet d'adapter dynamiquement le comportement des véhicules ou des robots autonomes

en fonction de la nature du terrain, notamment sur des terrains meubles, humides ou irréguliers.

Les résultats obtenus confirment la robustesse et l'efficacité de la méthode proposée et ouvrent la voie à des développements futurs fondés sur des approches hybrides combinant modélisation physique et techniques d'intelligence artificielle, afin d'améliorer encore les performances des véhicules autonomes évoluant dans des environnements non structurés.

Avant-propos

Ce sujet a été choisi en raison de plusieurs centres d'intérêt convergents, notamment la robotique mobile, les enjeux liés à l'autonomie des machines et l'importance croissante de l'efficacité énergétique dans les systèmes de mobilité autonome. Il s'inscrit dans une volonté de proposer des solutions concrètes aux problématiques de performance énergétique.

Le choix de s'intéresser à l'estimation du coefficient de résistance au roulement résulte du souhait d'approfondir l'étude d'un élément fondamental, souvent sous-estimé mais déterminant dans la dynamique des systèmes roulants autonomes. Ce coefficient influence directement la stabilité, le comportement dynamique et les performances globales des robots mobiles.

Ce travail de recherche résulte d'une démarche méthodique combinant analyse bibliographique, modélisation et validation par simulation. Il constitue une étape importante de mon parcours académique et scientifique.

Je souhaite exprimer ma sincère reconnaissance à mon directeur de recherche, le professeur Alben Cardenas, dont les conseils et l'exigence scientifique ont été déterminants dans la réalisation de ce travail. Je remercie également M. Bodian Abdoulaye, mes camarades ainsi que l'ensemble du personnel administratif de l'université pour leur disponibilité et leur soutien tout au long de ce projet. Enfin, je dédie ce travail à ma famille, dont le soutien constant, notamment durant les périodes de doute, a constitué un appui essentiel tout au long de ce parcours.

Table des matières

Résumé	iii
Avant-propos	v
Table des matières	vi
Liste des tableaux	ix
Liste des figures	x
Liste des symboles et abréviations	xiii
Chapitre 1 - Introduction	1
1.1 Contexte général	1
1.2 Problématique	2
1.3 Objectifs	3
1.4 Méthodologie	3
1.5 Organisation du mémoire	4
Chapitre 2 - L'état de l'art	6
2.1 Introduction	6
2.2 Étude des méthodes d'estimation	11
2.2.1 Algorithme des moindres carrés récursifs (RLS)	12
2.2.2 Méthode basée sur les réseaux neuronaux	19
2.2.3 Méthode basée sur le filtre de Kalman	22
2.3 Comparaison de méthodes étudiées	25

2.4	Conclusion	28
Chapitre 3 - Estimation du coefficient de résistance au roulement		29
3.1	Introduction	29
3.2	Modélisation	30
3.2.1	Modèle dynamique du véhicule	30
3.2.2	Hypothèses de modélisation	31
3.3	Méthodes d'estimation	32
3.4	Conclusion	34
Chapitre 4 - Implémentation numérique et validation par simulation		36
4.1	Introduction	36
4.2	Configuration des simulations	36
4.2.1	Paramètres du véhicule	36
4.2.2	Paramètres de l'algorithme RLS	37
4.2.3	Hypothèses de simulation et portée de la validation numérique	38
4.3	Implémentation numérique	39
4.3.1	Modèle de régression	39
4.3.2	Équations de mise à jour de l'algorithme RLS	41
4.3.3	Architecture Simulink du système d'estimation	41
4.3.4	Implémentation de l'algorithme sous MATLAB	43
4.4	Résultats de simulation et validation	45
4.4.1	Présentation des scénarios de simulation	45
4.4.2	Critères d'évaluation des performances	46
4.4.3	Cycle de conduite FTP75	47
4.4.4	Cycle de conduite EUDC	48

4.4.5	Cycle de conduite WLTC classe 3b	49
4.4.6	Cas 1 : Évaluation de l'estimateur en conditions idéales	51
4.4.7	Cas 2A : Influence de la vitesse du vent sur les performances de l'estimateur	56
4.4.8	Analyse comparative des performances de l'estimateur sous perturbation de vent	60
4.4.9	Cas 2B : Influence de la pente sur les performances de l'estimateur	62
4.4.10	Analyse comparative des performances de l'estimateur sous perturbation de pente	67
4.4.11	Cas 2C : Influence combinée de la V_{vent} et de la pente sur l'estimation de μ_r	68
4.4.12	Analyse comparative des performances sous perturbations combinées de V_{vent} et de pente	73
4.4.13	Limites de la méthode RLS	76
4.5	Conclusion	76
Chapitre 5 - Conclusion		78
5.1	Résultats principaux	78
5.2	Recommandations et perspectives	79

Liste des tableaux

Tableau 2-1 Comparaison qualitative des méthodes d'estimation de μ_r	26
Tableau 4-1 Paramètres du véhicule étudié.	37
Tableau 4-2 Plan des expériences de simulation pour l'estimation du coefficient de résistance au roulement μ_r	45
Tableau 4-3 Synthèse des performances de l'estimation de μ_r en condition idéale.	55
Tableau 4-4 Synthèse comparative des performances de l'estimation de μ_r sous perturbation de vitesse du vent.	61
Tableau 4-5 Synthèse comparative des performances de l'estimation de μ_r sous perturbation de pente variable.	67
Tableau 4-6 Performances de l'estimation de $\mu_r = 0.03$ sous perturbations combinées de la V_{vent} et de pente.	74
Tableau 4-7 Performances de l'estimation de $\mu_r = 0.018$ sous perturbations combinées de la V_{vent} et de pente.	74

Liste des figures

Figure 2.1	Schéma de la dynamique longitudinale du véhicule	7
Figure 2.2	Synthèse des principales méthodes d'estimation du coefficient de résistance au roulement.	11
Figure 2.3	Schéma simplifié d'un réseau de neurones multicouche	21
Figure 2.4	Architecture du réseau de neurones artificiels	21
Figure 3.1	Schéma de la dynamique longitudinale du véhicule modélisé	30
Figure 4.1	Architecture de simulation du modèle longitudinal du véhicule avec estimation RLS du coefficient de résistance au roulement μ_r	42
Figure 4.2	Organigramme de l'algorithme RLS pour l'estimation du coefficient de résistance au roulement μ_r	44
Figure 4.3	Comparaison de la vitesse longitudinale de référence et mesurée issues de la modélisation par équations dynamiques longitudinales sur le cycle FTP75.	48
Figure 4.4	Comparaison de la vitesse longitudinale de référence et mesurée issues de la modélisation par équations dynamiques longitudinales sur le cycle de conduite EUDC.	49
Figure 4.5	Comparaison de la vitesse longitudinale de référence et mesurée issues de la modélisation par équations dynamiques longitudinales sur le cycle de conduite WLTC 3b.	50
Figure 4.6	μ_r estimé en condition idéale sur le cycle de conduite FTP75 avec coefficients de référence $\mu_{r,\text{réf1}} = 0.03$ et $\mu_{r,\text{réf2}} = 0.018$	52

Figure 4.7	μ_r estimé en condition idéale sur le cycle de conduite EUDC avec coefficients de référence $\mu_{r,réf1} = 0.03$ et $\mu_{r,réf2} = 0.018$	53
Figure 4.8	μ_r estimé en condition idéale sur le cycle de conduite WLTC classe 3b avec coefficients de référence $\mu_{r,réf1} = 0.03$ et $\mu_{r,réf2} = 0.018$	54
Figure 4.9	Profils de vitesse de vent à différents niveaux d'intensité.	56
Figure 4.10	Coefficient μ_r estimé avec perturbation de vitesse du vent de différents niveaux sur le cycle de conduite FTP75 avec $\mu_{r,réf1} = 0.03$ et $\mu_{r,réf2} = 0.018$	57
Figure 4.11	Coefficient μ_r estimé avec perturbation de vitesse du vent de différents niveaux sur le cycle de conduite EUDC avec $\mu_{r,réf1} = 0.03$ et $\mu_{r,réf2} = 0.018$	58
Figure 4.12	Coefficient μ_r estimé avec perturbation de vitesse du vent de différents niveaux sur le cycle de conduite WLTC classe 3b avec $\mu_{r,réf1} = 0.03$ et $\mu_{r,réf2} = 0.018$	59
Figure 4.13	Profil de pente longitudinal appliqué aux cycles de conduite.	63
Figure 4.14	Coefficient μ_r estimé sous perturbation de pente pour le cycle de conduite FTP75 avec $\mu_{r,réf1} = 0.03$ et $\mu_{r,réf2} = 0.018$	64
Figure 4.15	Coefficient μ_r estimé sous perturbation de pente pour le cycle de conduite EUDC avec $\mu_{r,réf1} = 0.03$ et $\mu_{r,réf2} = 0.018$	65
Figure 4.16	Coefficient μ_r estimé sous perturbation de pente pour le cycle de conduite WLTC classe 3b avec $\mu_{r,réf1} = 0.03$ et $\mu_{r,réf2} = 0.018$	66
Figure 4.17	Estimation de μ_r sous perturbations combinées de V_{vent} et de pente pour le cycle de conduite FTP75 avec $\mu_{r,réf1} = 0.03$ et $\mu_{r,réf2} = 0.018$	69
Figure 4.18	Estimation de μ_r sous perturbations combinées de V_{vent} et de pente pour le cycle de conduite EUDC avec $\mu_{r,réf1} = 0.03$ et $\mu_{r,réf2} = 0.018$	71

Figure 4.19 Estimation de μ_r sous perturbations combinées de V_{vent} et de pente pour le cycle de conduite WLTC classe 3b avec $\mu_{r,réf1} = 0.03$ et $\mu_{r,réf2} = 0.018$	72
--	----

Liste des symboles et abréviations

Les symboles regroupent les variables du modèle dynamique du véhicule ainsi que celles utilisées dans les approches d'estimation. Dans ce mémoire, μ_r désigne le coefficient de résistance au roulement, tandis que μ représente le coefficient de frottement pneu-sol.

Liste des symboles

Symbole	Description	Unité
a	Nombre de neurones d'entrée (ANN)	—
A	Matrice d'état (Kalman)	—
A_f	Surface frontale du véhicule	m ²
C_{aero}	Coefficient de traînée aérodynamique	—
C_B	Constante de biais (régression linéaire de μ)	—
e_r	Temps de convergence	—
e_{max}	Erreur maximale	—
F_{aero}	Force de traînée aérodynamique	N
F_{pente}	Force gravitationnelle liée à la pente	N
F_{res}	Force résistante longitudinale équivalente	N
F_{roul}	Force de résistance au roulement	N
$F_{traction}$	Force longitudinale de traction	N
$F_{x,ij}$	Forces longitudinales aux roues, avec $i \in \{f, r\}$ (avant/arrière) et $j \in \{l, r\}$ (gauche/droite)	N
F_z	Force normale totale appliquée au véhicule	N
$F_{z,f}, F_{z,r}$	Forces normales aux essieux avant et arrière	N
g	Accélération gravitationnelle	m/s ²

Symbole	Description	Unité
h	Hauteur du centre de gravité	m
h_a	Hauteur du point d'application de la force aérodynamique	m
H	Matrice d'observation (Kalman)	—
k	Indice discret (échantillon)	—
$K(k)$	Gain adaptatif de l'algorithme RLS	—
L	Empattement total du véhicule ($L = L_f + L_r$)	m
L_f, L_r	Distances du centre de gravité aux essieux avant et arrière	m
m	Masse du véhicule	kg
$P(k)$	Covariance du paramètre estimé (RLS)	—
P_0	Covariance initiale	—
Q	Matrice de covariance du bruit de processus (Kalman)	—
R	Matrice de covariance du bruit de mesure (Kalman)	—
R_w	Rayon effectif de la roue	m
T_s	Pas d'échantillonnage	s
V_{vent}	Vitesse longitudinale du vent	m/s
V_r	Vitesse périphérique de la roue	m/s
V_x	Vitesse longitudinale du véhicule	m/s
V_{xref}	Vitesse longitudinale de référence	m/s
$x(k)$	Vecteur d'état du système dynamique dans le cadre du filtrage de Kalman	—
$y(k)$	Variable de sortie du modèle de régression utilisée dans l'algorithme RLS	—

Symbole	Description	Unité
γ	Facteur d'oubli de l'algorithme RLS	—
λ	Angle de pente longitudinale de la route	rad
μ	Coefficient de frottement pneu-sol (utilisé en revue de littérature)	—
μ_r	Coefficient de résistance au roulement	—
$\hat{\mu}_r$	Estimation du coefficient de résistance au roulement	—
$\mu_{r,\text{réf}}, \mu_{r,\text{réf}1}, \mu_{r,\text{réf}2}$	Valeurs de référence du coefficient de résistance au roulement	—
ρ	Masse volumique de l'air	kg/m ³
$\theta(k)$	Paramètre inconnu du modèle	—
$\hat{\theta}$	Paramètre estimé	—
$\varphi(k)$	Vecteur de régression associé au modèle linéaire	—
$\varepsilon(k)$	Erreur de prédiction du modèle RLS	—
$w(k)$	Bruit de processus (Kalman)	—
$v(k)$	Bruit de mesure (Kalman)	—
s_x	Glissement longitudinal	—
K_s	Pente de glissement	—
$\dot{V}_x$	Accélération longitudinale du véhicule	m/s ²
x_k, y_k	Signaux discrets à l'instant k	—

Liste des abréviations

La liste suivante présente les principales abréviations utilisées dans ce mémoire. Elle vise à faciliter la lecture des sections consacrées à la modélisation, à l'estimation du coefficient de résistance au roulement et aux simulations numériques.

Abréviation	Signification
ANN	Réseau de neurones artificiels
EKF	Filtre de Kalman étendu
KF	Filtre de Kalman
UKF	Filtre de Kalman Unscented
EUDC	Cycle de conduite extra-urbain
FTP75	Cycle de conduite urbain normalisé
HEV	Véhicule hybride électrique
ISO	Organisation internationale de normalisation
MSE	Erreur quadratique moyenne
PI	Correcteur proportionnel-intégral
RLS	Méthode des moindres carrés récurrents
RMSE	Racine de l'erreur quadratique moyenne
VE	Véhicule électrique

Suite à la page suivante

Abréviation	Signification
GPS	Système de positionnement global
WLTC	Cycle mondial harmonisé d’essai des véhicules légers

Chapitre 1 - Introduction

1.1 Contexte général

Depuis les premières décennies du XX^e siècle, les évolutions technologiques et les progrès sociétaux ont profondément transformé le secteur des transports. L'émergence des véhicules autonomes et des robots agricoles semi-autonomes répond aujourd'hui à des enjeux majeurs liés à l'amélioration de la productivité, à la réduction de la dépendance à la main-d'œuvre et à la limitation de l'impact environnemental des activités humaines [1–4]. Parmi les différentes architectures robotiques existantes, les robots mobiles à roues demeurent largement privilégiés en raison de leur simplicité mécanique, de leur efficacité énergétique et de leur facilité de contrôle [5,6]. En particulier, les robots de type automobile, caractérisés par une architecture à quatre roues avec essieu avant directionnel et essieu arrière moteur, présentent une bonne stabilité longitudinale et sont bien adaptés aux applications extérieures, notamment dans le domaine agricole [1, 5, 7]. Toutefois, les performances de ces systèmes restent fortement dépendantes des propriétés du contact roue–sol, ce qui souligne l'importance d'une modélisation dynamique précise ainsi que le développement d'outils d'estimation robustes [5, 7–10].

Dans ce contexte, l'interaction roue–sol joue un rôle déterminant dans la dynamique des systèmes roulants, car elle influence directement la traction, la stabilité longitudinale et la consommation énergétique du véhicule [2, 11, 12]. Parmi les paramètres caractérisant ce contact, le coefficient de résistance au roulement μ_r représente les pertes énergétiques liées aux déformations du pneumatique et du sol. Contrairement au coefficient d'adhérence μ , principalement associé aux phénomènes de traction et de freinage, μ_r affecte davantage l'efficacité énergétique et la stabilité globale des véhicules et des robots mobiles [2, 13]. Une estimation fiable de ce paramètre est essentielle pour

le développement de systèmes de contrôle avancés, tels que la stabilisation dynamique, les systèmes anti-patinage ou les stratégies de gestion énergétique, contribuant ainsi à améliorer la sécurité et les performances du véhicule dans des conditions réelles d'exploitation [14–16].

1.2 Problématique

Malgré leurs avantages opérationnels, les robots mobiles à roues restent confrontés à des limitations importantes liées aux pertes énergétiques, aux erreurs de trajectoire et aux instabilités dynamiques. Ces phénomènes résultent principalement de la complexité des interactions entre le pneumatique et le sol, lesquelles varient en fonction de la nature du terrain, des conditions environnementales et de l'état du véhicule [2, 7, 17].

À basse vitesse, caractéristique des applications agricoles, robotiques et des véhicules autonomes terrestres, la résistance au roulement constitue une source importante de pertes énergétiques. Toutefois, même à des vitesses plus élevées, son influence reste significative et doit être prise en compte pour une modélisation dynamique fidèle. Une estimation fiable de μ_r est donc essentielle afin d'améliorer les performances énergétiques, la stabilité dynamique et la précision de déplacement des systèmes de mobilité autonome.

Dans ce contexte, la question scientifique centrale de ce travail peut être formulée comme suit : *est-il possible d'estimer de manière fiable, robuste et en temps réel le coefficient de résistance au roulement μ_r à partir de grandeurs mesurables embarquées, tout en tenant compte des perturbations environnementales telles que la pente, le vent et les incertitudes de modélisation ?*

L'hypothèse principale de ce travail est qu'une méthode d'estimation récursive appliquée à un modèle dynamique longitudinal intégrant les forces résistantes ainsi que

les perturbations environnementales peut permettre une estimation stable, robuste et fiable de ce coefficient, même en présence de bruit de mesure et de conditions de fonctionnement variables.

1.3 Objectifs

L'objectif principal de ce travail est de développer une méthode d'estimation en ligne de μ_r , validée par simulation sous MATLAB/Simulink et applicable aux robots mobiles à roues et aux véhicules autonomes terrestres.

Les objectifs spécifiques sont les suivants :

1. Modéliser la dynamique longitudinale du robot en tenant compte des principales forces résistantes et des perturbations environnementales ;
2. Étudier et comparer les principales méthodes d'estimation existantes afin de sélectionner une approche adaptée à l'estimation en ligne du coefficient de résistance au roulement ;
3. Implémenter et valider la méthode retenue par simulation numérique, avec une perspective de validation expérimentale future.

1.4 Méthodologie

La méthodologie adoptée dans ce travail repose sur les étapes suivantes :

1. Analyse bibliographique approfondie des travaux existants relatifs à l'estimation du contact pneu-sol et des paramètres longitudinaux ;
2. Modélisation mathématique de la dynamique longitudinale du robot, dans des conditions réalistes ;
3. Développement et implémentation d'une méthode d'estimation adaptative du

coefficient de résistance au roulement μ_r ;

4. Validation numérique sous MATLAB/Simulink à l'aide de profils de conduite standards (FTP75, EUDC, WLTC) ainsi que de scénarios perturbés (pente, vent et bruit de mesure).

Cette approche permet d'évaluer la robustesse, la convergence et la stabilité de l'estimation de μ_r dans des conditions représentatives d'un fonctionnement réel. Ce travail contribue ainsi à l'amélioration des approches d'estimation en ligne de μ_r en intégrant des perturbations environnementales et en évaluant la robustesse de la méthode dans un cadre de simulation numérique.

1.5 Organisation du mémoire

Ce mémoire est structuré comme suit :

- Chapitre 2 : Revue de la littérature.

Ce chapitre propose un aperçu des travaux antérieurs portant sur les méthodes d'estimation du coefficient de résistance au roulement. Il présente l'état des connaissances existantes, les principales contributions scientifiques ainsi que les phénomènes physiques associés tels que la friction et la traction. Les différentes approches et techniques d'estimation y sont également analysées.

- Chapitre 3 : Modélisation du système.

Ce chapitre décrit la modélisation du système dynamique ainsi que les équations fondamentales utilisées. Il présente également le choix de la méthode d'estimation retenue, son principe de fonctionnement récursif, la structure de la boucle de rétroaction ainsi que les hypothèses considérées dans sa mise en œuvre.

- Chapitre 4 : Implémentation numérique et validation par simulation.

Il s'agit ici de présenter le modèle implémenté, ses propriétés et sa structure, ainsi que la définition des différents paramètres nécessaires à la simulation. Il expose également les résultats obtenus, les performances de l'estimation du coefficient de résistance au roulement ainsi que les expériences réalisées en conditions simulées.

- Chapitre 5 : Conclusion.

Ce chapitre présente une synthèse des principaux résultats obtenus dans ce mémoire. Il met en évidence les performances de l'estimation du coefficient de résistance au roulement μ_r , discute les limites de l'étude et propose des perspectives d'amélioration ainsi que des pistes de validation expérimentale.

Chapitre 2 - L'état de l'art

2.1 Introduction

L'optimisation des interactions au contact pneu-sol constitue un levier essentiel pour améliorer l'efficacité énergétique des véhicules et renforcer leur stabilité dynamique. Dans le contexte actuel des véhicules électriques (VE) et hybrides (HEV), la réduction des pertes liées à la résistance au roulement représente un enjeu majeur pour l'augmentation de l'autonomie et l'optimisation de la gestion énergétique [16, 18–20]. De nombreux travaux de recherche se sont intéressés à l'estimation de paramètres influençant la dynamique longitudinale, tels que le coefficient de frottement pneu-route μ ou la masse du véhicule, notamment dans le cadre de stratégies de contrôle et de gestion énergétique [2, 3, 10, 16, 21, 22]. En revanche, l'estimation en ligne du coefficient de résistance au roulement μ_r demeure encore relativement peu étudiée dans la littérature. Cette difficulté provient principalement de la complexité à dissocier, à partir de mesures embarquées souvent bruitées ou indirectes, les différentes contributions aux forces résistantes à l'avancement, telles que les effets inertiels, la traînée aérodynamique, la pente de la route et les pertes associées au roulement. Une distinction est faite entre le coefficient de frottement μ , associé principalement aux phénomènes d'adhérence, de traction et de freinage, et le coefficient de résistance au roulement μ_r , qui traduit les pertes énergétiques générées lors du roulement du véhicule.

Les véhicules électriques et hybrides sont particulièrement sensibles aux pertes de transmission et aux efforts résistants à l'avancement, notamment au roulement et aux phénomènes de glissement, plus marqués à basse vitesse ou sur des sols dégradés [10, 13, 16, 23]. La formulation d'un modèle longitudinal cohérent constitue une étape essentielle pour l'analyse et l'estimation de ces phénomènes. Dans cette perspective, les sections

suivantes présentent d'abord le modèle dynamique longitudinal retenu, puis une revue critique des principales méthodes d'estimation proposées dans la littérature, notamment les moindres carrés récurrents (RLS), les filtres de Kalman (EKF/UKF) et les approches fondées sur les réseaux neuronaux artificiels. Les principes, les performances et les limites de ces approches sont analysés afin de situer clairement le choix méthodologique adopté dans ce mémoire.

Le modèle longitudinal constitue la base de l'étude, puisqu'il permet de représenter les interactions entre les forces motrices, les forces résistantes et la dynamique du mouvement. Cette dynamique est illustrée à la Figure 2.1. Ce schéma met en évidence le rôle du coefficient de résistance au roulement μ_r dans la dynamique longitudinale du véhicule [21].




Figure 2.1 Schéma de la dynamique longitudinale du véhicule, selon [21]

La dynamique longitudinale (1D) du mouvement peut s'exprimer sous la forme simplifiée [21] :

$$m \cdot \dot{V}_x = F_{\text{traction}} - F_{\text{roul}} - F_{\text{aero}} - F_{\text{pente}} \quad (2.1)$$

où :

$$F_{\text{roul}} = \mu_r \cdot m \cdot g \cdot \cos(\lambda) \quad (2.2)$$

$$F_{\text{aero}} = \frac{1}{2} \cdot \rho \cdot C_{\text{aero}} \cdot A_f \cdot V_x^2 \quad (2.3)$$

$$F_{\text{pente}} = m \cdot g \cdot \sin(\lambda) \quad (2.4)$$

- m : masse du véhicule (kg) ;
- $\dot{V}_x$: accélération longitudinale du véhicule (m/s^2) ;
- F_{traction} : force longitudinale totale transmise au sol par les roues motrices (N) ;
- F_{aero} : force aérodynamique (N) ;
- F_{roul} : force de roulement (N) ;
- F_{pente} : composante du poids selon l'inclinaison (N) ;
- μ_r : coefficient de résistance au roulement (sans unité) ;
- C_{aero} : coefficient de traînée aérodynamique du véhicule (sans unité) ;
- g : accélération gravitationnelle (m/s^2) ;
- λ : angle d'inclinaison de la route (rad) ;
- ρ : masse volumique de l'air (kg/m^3) ;
- A_f : surface frontale du véhicule (m^2).

Dans la suite, la force de résistance au roulement est également exprimée sous la forme :

$$F_{\text{roul}} = \mu_r \cdot F_z \quad (2.5)$$

où F_z désigne la force normale totale appliquée au véhicule. Dans le cas d'une route faiblement inclinée et en l'absence d'effets dynamiques verticaux, on obtient l'approximation $F_z \approx mg \cos(\lambda)$, d'où l'expression $F_{\text{roul}} \approx \mu_r mg \cos(\lambda)$ utilisée dans le

modèle longitudinal.

La force de traction totale est définie comme la somme des forces longitudinales exercées par l'ensemble des roues motrices. Dans cette étude, les effets latéraux sont négligés, de même que la dynamique verticale oscillatoire. En revanche, un transfert de charge *quasi-statique* dû aux accélérations longitudinales est conservé afin d'obtenir une estimation plus réaliste de la répartition des forces normales entre les essieux avant et arrière [13,21,24–26].

$$F_{\text{traction}} = F_{x,fl} + F_{x,fr} + F_{x,rl} + F_{x,rr} \quad (2.6)$$

où, dans les indices placés après la virgule, la première lettre (*f* ou *r*) désigne l'essieu avant ou arrière, tandis que la seconde (*l* ou *r*) indique la roue gauche (*left*) ou droite (*right*) [13,21,27].

La force normale appliquée à chaque pneu joue un rôle déterminant dans la capacité du véhicule à générer une force longitudinale maximale. Elle conditionne directement le niveau d'adhérence disponible entre le pneu et la chaussée. En effet, pour une surface de contact et un type de pneu identiques, une augmentation de la force normale permet de générer une force de traction ou de freinage plus importante. La composante principale de la force normale provient du poids du véhicule, mais elle peut également être influencée de manière significative par les effets dynamiques liés aux manœuvres longitudinales (accélérations ou freinages), qui induisent une redistribution des charges entre les essieux avant et arrière [21]. Dans le cas simplifié d'un déplacement en ligne droite sur une route plane, les forces normales appliquées aux essieux avant et arrière peuvent être déterminées à l'aide d'un modèle quasi statique du véhicule, tel que présenté

dans [21].

$$F_{z,f} = \frac{m \cdot g \cdot L_r - m \cdot \dot{V}_x \cdot h - F_{\text{aero}} \cdot h_a}{L} \quad (2.7)$$

$$F_{z,r} = \frac{m \cdot g \cdot L_f + m \cdot \dot{V}_x \cdot h + F_{\text{aero}} \cdot h_a}{L} \quad (2.8)$$

$$F_z = F_{z,f} + F_{z,r} \quad (2.9)$$

où :

- h : hauteur du centre de gravité du véhicule par rapport au sol ;
- L : empattement total du véhicule, avec $L = L_f + L_r$;
- L_f : distance entre le centre de gravité et l'essieu avant ;
- L_r : distance entre le centre de gravité et l'essieu arrière ;
- V_x : vitesse longitudinale du véhicule (en m/s) ;
- m : masse totale du véhicule (en kg) ;
- g : accélération de la pesanteur ($g \approx 9,81 \text{ m/s}^2$) ;
- C_{aero} : coefficient de traînée aérodynamique du véhicule (sans unité) ;
- h_a : hauteur du point d'application de la force aérodynamique par rapport au sol ;
- F_z : force normale totale.

En résumé, la dynamique longitudinale permet de quantifier les résistances qui s'opposent au mouvement du véhicule. Elle constitue ainsi la base théorique de la modélisation et de l'estimation du coefficient μ_r , en reliant des variables mesurables (vitesse, accélération, couple moteur) aux forces de résistance au roulement et à la puissance dissipée. Ce modèle longitudinal reste valide dans le cadre d'une analyse essentiellement rectiligne, pour des angles de dérive faibles et des transferts de charge modérés, conditions généralement

rencontrées dans les cycles de conduite étudiés.

Convention de notation (continu / discret) : Dans ce chapitre, les équations physiques sont d’abord présentées en temps continu afin de clarifier la dynamique longitudinale. Les algorithmes d’estimation étant implémentés sur des signaux échantillonnés, les formulations récursives sont ensuite exprimées en temps discret, indexées par k .

2.2 Étude des méthodes d’estimation

Dans cette section, nous proposons une revue critique des principales approches d’estimation du coefficient de résistance au roulement μ_r [2, 13, 28]. L’objectif est de mettre en évidence les principes fondamentaux, les avantages et les limites de chaque méthode.

Afin de faciliter la compréhension, un schéma récapitulatif des approches étudiées est présenté à la Figure 2.2. Il met en évidence les différentes familles de méthodes utilisées ainsi que leur champ d’application pour l’estimation de μ_r .




Figure 2.2 Synthèse des principales méthodes d’estimation du coefficient de résistance au roulement.

Dans ce mémoire, le vecteur des paramètres estimés est noté θ ; ici, il se réduit au scalaire $\theta(k) = \mu_r(k)$. L'objectif principal est l'estimation en ligne du coefficient de résistance au roulement μ_r , tandis que le coefficient de frottement μ est introduit uniquement comme paramètre connexe dans certains travaux de la littérature.

2.2.1 Algorithme des moindres carrés récursifs (RLS)

L'algorithme des moindres carrés récursifs (RLS) constitue une extension adaptative de la méthode des moindres carrés ordinaires (OLS, *Ordinary Least Squares*). Contrairement à l'approche OLS, qui nécessite un recalcul global lors de l'ajout de nouvelles données, le RLS met à jour les paramètres estimés de manière récursive à chaque nouvel échantillon, ce qui le rend particulièrement adapté aux systèmes dynamiques évoluant en temps réel [29–31]. Cette méthode vise à minimiser l'erreur entre la sortie mesurée et la sortie prédite du modèle, tout en intégrant progressivement les nouvelles informations disponibles. Grâce à cette propriété récursive, le RLS est largement utilisé pour l'identification des paramètres variant lentement dans le temps, notamment dans le domaine de la dynamique des véhicules [2]. Plusieurs travaux ont montré que la valeur du coefficient de résistance au roulement μ_r dépend fortement de la géométrie du véhicule, de sa masse, de la répartition des charges et des conditions du terrain [2, 32]. Le RLS est capable de suivre ces variations paramétriques lentes, ce qui en fait un outil particulièrement adapté à l'identification en ligne des coefficients longitudinaux pour différents types de véhicules.

En raison de sa faible complexité algorithmique et de sa capacité d'adaptation en ligne, la méthode RLS est fréquemment retenue pour l'estimation embarquée des paramètres longitudinaux, en particulier dans des environnements soumis à des perturbations et à des mesures bruitées [13, 17, 33].

Le problème peut s'écrire sous la forme du modèle linéaire suivant [13, 21, 32] :

$$y(k) = \phi^\top(k) \cdot \theta(k) + \varepsilon(k) \quad (2.10)$$

Dans cette formulation générale, $y(k)$ désigne l'observation scalaire, $\phi(k)$ le vecteur de régression, $\theta(k)$ le vecteur des paramètres à estimer et $\varepsilon(k)$ l'erreur de modélisation. Dans le cas étudié ici, un seul paramètre est estimé, soit le coefficient de résistance au roulement. Ainsi, le vecteur des paramètres se réduit au scalaire :

$$\theta(k) = \mu_r(k). \quad (2.11)$$

Formulation discrète du RLS : En pratique, l'estimation est réalisée à partir de signaux échantillonnés. L'algorithme est donc exprimé en temps discret et indexé par k . Il convient de distinguer $\varepsilon(k)$, qui représente l'erreur de modélisation dans le modèle de régression, de $e(k)$, qui correspond à l'erreur de prédiction utilisée dans la mise à jour récursive.

À chaque pas d'échantillonnage, l'erreur de prédiction est d'abord calculée selon :

$$e(k) = y(k) - \phi^\top(k) \cdot \hat{\theta}(k-1). \quad (2.12)$$

Le gain RLS est ensuite obtenu par :

$$K(k) = \frac{P(k-1) \cdot \phi(k)}{\gamma + \phi^\top(k) \cdot P(k-1) \cdot \phi(k)}. \quad (2.13)$$

L'estimation du paramètre est alors mise à jour selon :

$$\hat{\theta}(k) = \hat{\theta}(k-1) + K(k) \cdot e(k). \quad (2.14)$$

Enfin, la matrice de covariance est actualisée par :

$$P(k) = \frac{1}{\gamma} \left[P(k-1) - K(k) \cdot \phi^\top(k) \cdot P(k-1) \right]. \quad (2.15)$$

Les notations utilisées dans le modèle sont les suivantes :

- $y(k)$: observation scalaire à l'instant k ;
- $\phi(k)$: vecteur de régression ;
- $\theta(k)$: vecteur des paramètres à estimer ;
- $\hat{\theta}(k)$: estimation du vecteur des paramètres ;
- $P(k)$: matrice de covariance associée à l'estimation ;
- $\gamma \in (0, 1]$: facteur d'oubli ;
- $K(k)$: gain RLS ;
- $e(k)$: erreur de prédiction ;
- $\varepsilon(k)$: erreur de modélisation.

Dans la majorité des applications embarquées et des implémentations numériques, notamment sous MATLAB/Simulink, la formulation discrète du RLS est privilégiée en raison de sa simplicité d'implémentation et de sa compatibilité avec les systèmes échantillonnés [13, 17, 31, 34]. Dans le cadre de l'estimation de μ_r , la méthode RLS est couplée au modèle dynamique longitudinal du véhicule, qui relie les grandeurs mesurées au paramètre inconnu à estimer.

La dynamique longitudinale de base s'écrit :

$$m \cdot \dot{V}_x = F_{\text{traction}} - (F_{\text{aero}} + F_{\text{pente}} + \mu_r \cdot m \cdot g \cdot \cos(\lambda)). \quad (2.16)$$

En remplaçant la force de pente par :

$$F_{\text{pente}} = m \cdot g \cdot \sin(\lambda), \quad (2.17)$$

l'équation dynamique devient :

$$m \cdot \dot{V}_x = F_{\text{traction}} - F_{\text{aero}} - m \cdot g \cdot \sin(\lambda) - \mu_r \cdot m \cdot g \cos(\lambda). \quad (2.18)$$

En regroupant les termes connus ou mesurables du côté gauche et le terme contenant le paramètre inconnu du côté droit, on obtient :

$$F_{\text{traction}} - F_{\text{aero}} - m \cdot \dot{V}_x - m \cdot g \cdot \sin(\lambda) = \mu_r \cdot m \cdot g \cos(\lambda). \quad (2.19)$$

Cette relation peut alors être écrite sous la forme de régression scalaire :

$$y(k) = \phi(k) \cdot \mu_r(k) + \varepsilon(k). \quad (2.20)$$

Par identification avec le modèle de régression, on définit :

$$y(k) = F_{\text{traction}}(k) - F_{\text{aero}}(k) - m \cdot \dot{V}_x(k) - m \cdot g \cdot \sin(\lambda(k)), \quad (2.21)$$

et :

$$\phi(k) = m \cdot g \cdot \cos(\lambda(k)). \quad (2.22)$$

Ainsi, le coefficient μ_r n'apparaît pas dans l'expression de $y(k)$, car cette grandeur regroupe uniquement les termes connus ou mesurables. Le paramètre inconnu est isolé dans le produit $\phi(k)\mu_r(k)$, ce qui permet son estimation par l'algorithme RLS.

Les paramètres intervenant dans l'équation dynamique du véhicule sont définis comme suit :

- μ_r : coefficient de résistance au roulement, sans unité ;
- $\dot{V}_x$: accélération longitudinale du véhicule, en m/s^2 ;
- λ : angle de pente de la route, en rad ;
- g : accélération gravitationnelle, en m/s^2 .

Dans les applications pratiques, l'accélération longitudinale peut être obtenue soit directement à partir d'un capteur inertiel, soit par différenciation numérique de la vitesse mesurée. Afin de limiter l'amplification du bruit associée à cette différenciation, l'accélération utilisée dans l'estimation est généralement obtenue à partir d'un signal filtré.

Remarque sur l'identifiabilité et l'excitation : La qualité de l'estimation de μ_r dépend fortement de la richesse informative des signaux mesurés. En conduite quasi stationnaire sur route plane ($\dot{V}_x \approx 0$ et $\lambda \approx 0$), le terme régressif $\varphi(k) = m \cdot g \cdot \cos(\lambda(k))$ varie peu. Dans ce cas, l'estimation peut devenir plus sensible au bruit de mesure et aux incertitudes sur F_{traction} . Une excitation suffisante (phases d'accélération ou de décélération, variations de vitesse ou pente non nulle) améliore le conditionnement numérique du problème et favorise la convergence de l'algorithme RLS.

Remarque (paramètre connexe) : Bien que ce mémoire vise principalement l'estimation de μ_r , certaines études exploitent également le glissement longitudinal s_x afin d'estimer le coefficient de frottement μ (adhérence). Cet élément est présenté ici à titre connexe, car il intervient parfois dans des approches combinées [13, 21].

$$s_x = \begin{cases} \frac{V_r - V_x}{V_r}, & \text{accélération (patinage moteur),} \\ \frac{V_r - V_x}{V_x}, & \text{freinage (blocage de la roue).} \end{cases} \quad (2.23)$$

où :

- V_r : vitesse périphérique de la roue ;
- V_x : vitesse longitudinale du véhicule.

La définition exacte du glissement longitudinal peut varier selon les conventions adoptées dans la littérature ; la formulation retenue ici correspond à celle utilisée dans les références considérées.

Lien entre la force longitudinale et le glissement : Dans la suite, F_x désigne la force longitudinale effectivement transmise au contact pneu-sol ; lorsque l'on néglige les pertes de transmission, on peut assimiler $F_x \approx F_{\text{traction}}$. Dans un domaine de faible glissement, la force longitudinale normalisée peut être approximée comme proportionnelle au glissement longitudinal [13, 35] :

$$\mu = \frac{F_x}{F_z} \approx K_s \cdot s_x \quad (2.24)$$

où :

- F_x : force longitudinale transmise au contact pneu-sol ;
- F_z : force normale appliquée au pneu ;
- K_s : pente de glissement (slip-slope) ;
- μ : coefficient de frottement pneu-route ;
- s_x : glissement longitudinal.

Estimation de μ par régression linéaire : Une relation linéaire empirique est parfois utilisée pour approximer le coefficient de frottement en fonction de paramètres caractéristiques du glissement dans la zone quasi-linéaire du contact pneu-sol [5, 13, 36] :

$$\mu \approx A_p \cdot K_s + C_B \quad (2.25)$$

où :

- μ : coefficient de frottement pneu-sol ;
- K_s : taux de glissement longitudinal ;
- A_p : coefficient de pente de la relation linéaire entre le coefficient de frottement et le glissement ;
- C_B : constante de biais ou terme d'ajustement.

Cette relation traduit une évolution approximativement linéaire du coefficient de frottement avec la pente de glissement pour de faibles taux de glissement. La constante C_B permet notamment de compenser certains biais liés aux approximations de modélisation ou aux incertitudes expérimentales [21, 36, 37].

Revue critique (RLS) : Dans les applications liées à la dynamique des véhicules, l'algorithme RLS est largement utilisé pour l'identification en ligne de paramètres longitudinaux lentement variables, notamment lorsque l'on dispose d'une relation de régression issue du modèle dynamique longitudinal [2, 13, 21, 38]. Les formulations usuelles supposent l'accès à la vitesse longitudinale V_x , à une estimation filtrée de l'accélération $\dot{V}_x$ ainsi qu'à une force motrice reconstruite à partir du couple moteur et de la transmission.

La qualité d'estimation dépend fortement de l'excitation du système. Sur route plane et en régime quasi stationnaire, le terme $\phi(k) = m \cdot g \cdot \cos(\lambda)(k)$ varie peu, ce qui rend l'estimation plus sensible au bruit et aux incertitudes sur F_{traction} , $\dot{V}_x$ et λ [2, 13]. Le choix du facteur d'oubli γ , la qualité de filtrage de $\dot{V}_x$ et la présence de phases transitoires influencent donc directement la convergence et la précision.

2.2.2 Méthode basée sur les réseaux neuronaux

Dans le domaine de la dynamique des véhicules, les réseaux de neurones artificiels (Artificial Neural Networks – ANN) sont utilisés pour estimer des paramètres longitudinaux lorsque les relations entre les grandeurs mesurées et les forces résistantes sont fortement non linéaires [13, 39–42].

Contrairement aux approches analytiques fondées sur un modèle physique explicite, les ANN apprennent directement à partir de données expérimentales une relation non linéaire entre les variables d'entrée et le paramètre à estimer. Dans le cas de la résistance au roulement, les entrées du réseau incluent généralement :

- la vitesse longitudinale $V_x(k)$;
- l'accélération longitudinale $\dot{V}_x(k)$;
- le couple moteur $T_m(k)$;
- la force normale estimée $F_z(k)$;
- éventuellement des variables environnementales (température, état du sol).

La structure la plus couramment utilisée est un réseau multicouche (MLP – Multi-Layer Perceptron) comprenant une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie. Chaque couche réalise une transformation linéaire suivie d'une fonction d'activation non linéaire :

$$\mathbf{a}^{(i)} = \phi^{(i)} \left(\mathbf{W}^{(i)} \mathbf{a}^{(i-1)} + \mathbf{b}^{(i)} \right) \quad (2.26)$$

L'apprentissage du réseau consiste à ajuster les poids $\mathbf{W}^{(i)}$ et les biais $\mathbf{b}^{(i)}$ afin de minimiser une fonction de coût, généralement l'erreur quadratique moyenne (MSE) :

$$E_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (2.27)$$

L'estimation du coefficient de résistance au roulement est alors donnée par :

$$\hat{\mu}_r(k) = f_{nn}(V_x(k), T_m(k), F_z(k), \dot{V}_x(k)) \quad (2.28)$$

où f_{nn} représente la fonction non linéaire apprise par le réseau.

Dans plusieurs travaux, les ANN sont également employés pour estimer simultanément μ_r et d'autres paramètres comme le coefficient de traînée aérodynamique C_{aero} [41–43]. Afin de préserver la cohérence physique, les valeurs estimées de μ_r sont généralement contraintes dans un intervalle réaliste $[0, \mu_{r,\text{max}}]$.

Les approches neuronales offrent une bonne capacité de modélisation des non-linéarités et peuvent fournir une estimation précise lorsque le jeu de données d'apprentissage est riche et représentatif. Toutefois, leurs performances dépendent fortement de la qualité et de la diversité des données utilisées pour l'entraînement. Hors du domaine couvert par ces données (variation de masse, changement de pneu, conditions météorologiques différentes), la capacité de généralisation peut diminuer.

De plus, l'interprétabilité physique demeure limitée, ce qui peut compliquer leur validation dans le cadre d'applications embarquées critiques. La Figure 2.3 illustre le schéma simplifié d'un réseau de neurones multicouche utilisé pour cette tâche. La Figure 2.4 présente quant à elle la structure finale du réseau employé pour l'estimation simultanée du coefficient de résistance au roulement μ_r et de la traînée aérodynamique [22, 43–47].




Figure 2.3 Schéma simplifié d'un réseau de neurones multicouche, selon [46,47].




Figure 2.4 Architecture du réseau de neurones artificiels, selon [46,47].

Revue critique (ANN) : Les approches par réseaux neuronaux sont proposées pour estimer μ_r (parfois conjointement à d'autres paramètres comme C_{aero}) lorsque la relation entre entrées mesurées et pertes au roulement est fortement non linéaire et difficile à paramétrer explicitement [13,44,46,48–51]. Elles reposent généralement sur des entrées telles que V_x , $\dot{V}_x$, le couple moteur, et des variables décrivant la charge normale ou l'état du véhicule, et nécessitent un jeu de données d'apprentissage suffisamment riche, couvrant plusieurs conditions de route et de charge. Leur limite principale concerne la *généralisation* : hors du domaine couvert par l'apprentissage (changement de pneu, température, type de sol, masse), les performances peuvent chuter et produire des estimations peu cohérentes physiquement. De plus, l'interprétabilité reste faible et la

calibration (normalisation, choix d'architecture, régularisation) peut être coûteuse, ce qui complique l'analyse et la validation explicite du comportement du modèle, notamment dans les applications critiques embarquées où la fiabilité et la compréhension des décisions du système sont essentielles.

2.2.3 Méthode basée sur le filtre de Kalman

Le filtre de Kalman est une méthode d'estimation récursive probabiliste qui combine un modèle dynamique du système avec des mesures bruitées afin de fournir une estimation optimale des états inconnus au sens de la minimisation de la variance d'estimation [6, 52–57]. Cette approche repose sur une phase de prédiction du modèle et une phase de mise à jour utilisant les mesures disponibles.

Dans sa forme discrète linéaire, le modèle d'état s'écrit :

$$x(k+1) = A(k) \cdot x(k) + w(k) \quad (2.29)$$

$$y(k) = H(k) \cdot x(k) + v(k) \quad (2.30)$$

où $x(k)$ représente le vecteur d'état à estimer, $y(k)$ le vecteur de mesures, $w(k)$ le bruit de processus et $v(k)$ le bruit de mesure, généralement supposés gaussiens, centrés et de covariance connue.

Dans le contexte de la dynamique longitudinale du véhicule, le coefficient de résistance au roulement μ_r peut être modélisé comme un état lentement variable perturbé par un bruit de processus faible. Le vecteur d'état peut par exemple inclure :

$$x(k) = \begin{bmatrix} \mu_r(k) \\ C_{\text{aero}}(k) \end{bmatrix} \quad (2.31)$$

La relation d'observation est alors dérivée du modèle longitudinal du véhicule. En considérant les forces résistantes à l'avancement, on obtient :

$$F_{\text{res}}(k) = m \cdot g \cdot \cos(\lambda(k)) \cdot \mu_r(k) + \frac{1}{2} \rho \cdot A_f \cdot C_{\text{aero}}(k) \cdot V_x^2(k) \quad (2.32)$$

En posant $y(k) = F_{\text{res}}(k)$ et en utilisant la définition du vecteur d'état $x(k)$, cette relation peut être reformulée sous la forme générale du modèle d'observation du filtre de Kalman présenté précédemment, où la matrice d'observation $H(k)$ est définie par :

$$H(k) = \begin{bmatrix} m \cdot g \cdot \cos(\lambda(k)) & \frac{1}{2} \cdot \rho \cdot A_f \cdot V_x^2(k) \end{bmatrix} \quad (2.33)$$

La matrice d'observation $H(k)$ dépend des variables mesurées du véhicule et établit le lien entre le modèle dynamique longitudinal et la formulation du problème d'estimation dans le cadre du filtre de Kalman. Dans ce cadre, le filtre de Kalman permet de fusionner les mesures disponibles (vitesse, accélération, couple moteur ou force équivalente) avec le modèle dynamique longitudinal afin d'estimer en ligne le coefficient μ_r [55, 56], malgré la présence de bruit et d'incertitudes de modélisation.

Revue critique (Kalman/EKF/UKF) : Les filtres de Kalman sont fréquemment employés pour l'estimation en ligne de μ_r , notamment en raison de leur capacité à filtrer le bruit de mesure et à suivre des variations progressives du coefficient de résistance au

roulement [2,6,52,53,58]. Toutefois, leurs performances dépendent fortement de la qualité du modèle longitudinal ainsi que du réglage des matrices de covariance Q et R . Un mauvais ajustement peut conduire à une estimation trop bruitée ou trop lente.

Lorsque les non-linéarités deviennent importantes (glissement, variations des pertes de transmission ou conditions de route changeantes), l'utilisation d'extensions non linéaires telles que l'EKF ou l'UKF est généralement nécessaire, ce qui augmente la complexité algorithmique et le coût de calcul embarqué.

Positionnement dans ce mémoire : Au regard des éléments présentés dans cette revue, l'objectif de ce travail est d'obtenir une estimation *en ligne* du coefficient de résistance au roulement μ_r , avec un coût de calcul compatible avec une implémentation embarquée et une interprétation physique explicite.

Dans ce contexte, la méthode des moindres carrés récursifs (RLS) est retenue comme approche principale pour l'estimation du coefficient de résistance au roulement. Au regard des compromis identifiés entre robustesse, interprétabilité physique et coût de calcul, cette méthode apparaît particulièrement adaptée à une identification embarquée du coefficient μ_r . Les approches basées sur le filtre de Kalman (et ses extensions EKF/UKF), ainsi que les réseaux neuronaux artificiels (ANN), sont retenues comme méthodes de comparaison, notamment en termes de robustesse au bruit, de gestion des non-linéarités et de capacité de généralisation.

La section suivante présente une synthèse de ces approches afin de mettre en évidence les compromis entre performance, complexité et interprétabilité dans l'estimation du coefficient μ_r .

2.3 Comparaison de méthodes étudiées

La comparaison des méthodes d'estimation considérées dans ce travail repose sur deux critères principaux : la performance (précision et robustesse face au bruit et aux perturbations) et la complexité algorithmique (coût de calcul, réglage et contraintes d'implémentation). Les études rapportées dans la littérature montrent que les méthodes récursives, telles que le RLS, peuvent présenter un biais et une variance dépendant du niveau de bruit, des conditions d'excitation et du réglage de l'algorithme [6, 13, 21]. À l'inverse, les filtres de Kalman offrent généralement une variance plus faible grâce au filtrage probabiliste, tandis que les approches ANN peuvent être très précises lorsque les données d'apprentissage sont riches et représentatives [2, 59–63].

Ces éléments motivent l'utilisation d'une synthèse comparative, présentée ci-après, afin de situer clairement les compromis entre robustesse, complexité et interprétabilité pour l'estimation de μ_r .

Afin de comparer les méthodes d'estimation étudiées, une analyse qualitative des performances et de la complexité d'implémentation est présentée dans le Tableau 2-1. Les avantages correspondent principalement à la précision, la robustesse et la capacité d'adaptation, tandis que les inconvénients reflètent les limites liées au bruit, à la complexité de modélisation ou au coût de calcul.

Tableau 2-1 Comparaison qualitative des méthodes d'estimation de μ_r .

Méthode	Avantages (performance)	Inconvénients (limites / complexité)
Moindres Carrés Récursifs (RLS)	Mise à jour rapide et estimation en ligne simple. Faible coût de calcul compatible avec une implémentation embarquée. Interprétation physique directe du paramètre estimé.	Sensible au bruit et aux erreurs d'accélération. Forte dépendance à l'excitation du système. Choix du facteur d'oubli critique pour la stabilité.
Filtre de Kalman (KF/EKF/UKF)	Bon filtrage du bruit. Cadre probabiliste rigoureux. Bonne précision si le modèle et les covariances sont bien réglés.	Réglage sensible des covariances Q et R. Dépend fortement du modèle d'état. EKF/UKF requis pour les non-linéarités (complexité accrue).
Réseaux Neuronaux (ANN)	Bonne précision avec des données riches. Modélisation des non-linéarités complexes. Adaptation à différents régimes de conduite.	Besoin important de données d'entraînement. Interprétabilité limitée (boîte noire). Risque de mauvaise généralisation.

Comparaison analytique des approches : Le RLS est une méthode légère et facilement interprétable, particulièrement adaptée aux applications embarquées lorsque les signaux présentent une excitation suffisante. Les filtres de Kalman (KF, EKF ou UKF) offrent une meilleure robustesse face au bruit de mesure et aux incertitudes de modélisation. Toutefois, leur mise en œuvre nécessite un réglage plus délicat des matrices de covariance et implique généralement un coût de calcul plus élevé. Les réseaux de neurones artificiels (ANN) peuvent fournir une estimation très précise lorsque des données d'apprentissage riches et représentatives sont disponibles. Néanmoins, leur capacité de généralisation reste limitée en dehors du domaine d'apprentissage et leur faible interprétabilité peut restreindre leur utilisation dans des applications embarquées critiques.

Synthèse et positionnement scientifique : La littérature propose des approches récursives (RLS), probabilistes (Kalman/EKF/UKF) et basées sur l'apprentissage (ANN) pour l'estimation des paramètres longitudinaux des véhicules. Toutefois, l'estimation en ligne de μ_r demeure relativement moins explorée, en particulier dans des conditions réalistes intégrant simultanément des perturbations environnementales, du bruit de mesure et des contraintes de calcul embarqué.

De nombreux travaux reposent encore sur des hypothèses simplificatrices ou des scénarios expérimentaux contrôlés, ce qui limite la généralisation des méthodes proposées à des conditions réelles d'exploitation, notamment dans les applications robotiques à basse vitesse. Par ailleurs, certaines approches avancées nécessitent un réglage délicat ou des jeux de données d'apprentissage conséquents, ce qui peut compliquer leur déploiement opérationnel.

Ainsi, l'estimation robuste, peu coûteuse en calcul et physiquement interprétable de μ_r , en présence de perturbations dynamiques et sous des contraintes embarquées

de temps réel, demeure un enjeu scientifique et technologique toujours ouvert. Cette problématique motive l'étude proposée dans ce mémoire.

2.4 Conclusion

Ce chapitre a présenté une revue des principales approches d'estimation des paramètres longitudinaux des véhicules, incluant les méthodes récursives, probabilistes et fondées sur l'apprentissage. L'analyse comparative a mis en évidence les compromis entre précision, robustesse au bruit, complexité algorithmique et interprétabilité physique des différentes méthodes d'estimation.

Ces éléments fournissent le cadre théorique nécessaire à la modélisation du système étudié ainsi qu'à la mise en œuvre de la méthode d'estimation développée dans ce mémoire, lesquelles seront présentées dans les chapitres suivants.

Chapitre 3 - Estimation du coefficient de résistance au roulement

3.1 Introduction

L'objectif principal de ce chapitre n'est plus de rappeler le rôle physique de μ_r , mais de formuler son estimation à partir du modèle longitudinal retenu [2, 13, 40, 64]. Contrairement à d'autres paramètres de la dynamique du véhicule, ce coefficient est rarement mesuré directement en conditions réelles, en raison de la complexité des dispositifs expérimentaux requis. Les méthodes classiques d'identification reposent généralement sur des essais normalisés de type *coast-down*, des mesures sur bancs à rouleaux ou des protocoles ISO. Ces approches nécessitent l'utilisation de capteurs de force spécifiques ainsi que des conditions d'essai contrôlées. De plus, la séparation des différentes forces résistantes (aérodynamique, gravitationnelle et de roulement) reste délicate en conduite réelle, ce qui complique l'obtention d'une estimation précise et fiable en temps réel.

Dans la littérature, le coefficient de résistance au roulement est généralement soit supposé constant, soit estimé hors ligne à partir d'essais normalisés. Toutefois, ces approches ne permettent pas de prendre en compte les variations liées à l'état de la chaussée, aux conditions climatiques ou au cycle de conduite. Dans ce contexte, l'estimation en ligne de ce coefficient apparaît comme une alternative pertinente pour améliorer la précision des modèles dynamiques et renforcer la robustesse des stratégies de contrôle embarquées.

Dans ce travail, la méthode retenue est appliquée au modèle longitudinal du véhicule afin de formuler une loi d'estimation réursive du coefficient de résistance au roulement μ_r . Cette approche permet d'obtenir une estimation adaptative et stable en combinant des grandeurs disponibles (vitesse, accélération, couple moteur) avec un

modèle dynamique longitudinal du véhicule [2, 65–67].

3.2 Modélisation

3.2.1 Modèle dynamique du véhicule

La dynamique du véhicule désigne l'étude du comportement d'un véhicule en mouvement sous l'effet des forces et des moments qui agissent sur lui [21, 40]. La dynamique longitudinale, en particulier, s'intéresse aux déplacements du véhicule selon l'axe avant–arrière, en tenant compte des forces générées par la traction ou le freinage aux roues. La Figure 3.1 illustre le modèle de dynamique longitudinale du véhicule en tenant compte de l'inclinaison de la route. Ce modèle permet d'analyser l'accélération, la décélération ainsi que la stabilité du véhicule lors de son déplacement [2, 8, 40, 68].




Figure 3.1 Schéma de la dynamique longitudinale du véhicule modélisé, selon [21]

La Figure 3.1 illustre les principales forces intervenant dans la dynamique longitudinale du véhicule. Celle-ci repose sur l'équilibre entre la force de traction et les différentes forces résistantes à l'avancement.

Le modèle dynamique correspondant, ainsi que l'expression détaillée des forces de résistance au roulement, de traînée aérodynamique et de pente, ont été présentés précédemment dans l'équation (2.1) et les relations associées. Ces expressions sont reprises dans la suite afin de formuler le problème d'estimation de μ_r .

La vitesse du vent V_{vent} est définie positive lorsqu'elle s'oppose au mouvement du véhicule (vent de face), ce qui augmente la traînée aérodynamique. Dans ce cas, la force aérodynamique peut s'écrire :

$$F_{aero} = \frac{1}{2} \cdot \rho \cdot C_{aero} \cdot A_f \cdot (V_x + V_{vent})^2 \quad (3.1)$$

La force de traction $F_{traction}$ est obtenue soit à partir du couple moteur transmis aux roues et du rayon effectif du pneumatique, soit directement à partir du modèle MATLAB/Simulink utilisé pour les simulations. Le présent chapitre se concentre sur l'estimation du coefficient de résistance au roulement μ_r à partir du modèle dynamique longitudinal du véhicule, sans intégrer de modèle de pneumatique détaillé dans la boucle d'estimation.

3.2.2 Hypothèses de modélisation

Afin de rendre le problème d'estimation compatible avec une implémentation en temps réel, plusieurs hypothèses de modélisation sont retenues :

- $F_{traction}$ est supposée estimable à partir du couple moteur et du rayon de roue, ou issue du modèle Simulink ;
- la masse du véhicule m est supposée connue et constante ;
- les forces aérodynamiques sont modélisées par une loi quadratique classique ;

- les paramètres aérodynamiques et géométriques du véhicule sont supposés connus et constants ;
- le coefficient μ_r varie lentement par rapport à la dynamique longitudinale du véhicule ;
- l'accélération longitudinale $\dot{V}_x$ est issue du modèle de simulation (ou d'une mesure inertielle filtrée), afin d'éviter l'amplification du bruit liée à une dérivation numérique de V_x ;
- une excitation suffisante du système (phases d'accélération ou de freinage et variations des efforts résistants) est supposée, de manière à assurer l'identifiabilité du paramètre μ_r avec l'algorithme RLS. Comme discuté au chapitre précédent, la qualité de l'estimation dépend fortement de cette excitation, qui améliore le conditionnement du problème régressif.

Ces hypothèses sont couramment adoptées dans la littérature afin de limiter la dimension du problème d'estimation et de garantir une implémentation robuste en temps réel, tout en conservant une précision suffisante pour l'analyse des performances longitudinales [13, 21, 69].

3.3 Méthodes d'estimation

Contrairement à la méthode proposée par [13], la masse du véhicule est supposée connue et constante dans ce travail. Cette hypothèse permet de réduire la dimension du vecteur de paramètres à estimer et de se concentrer uniquement sur l'estimation en ligne de μ_r . Le coefficient de résistance au roulement est estimé à partir du modèle longitudinal du véhicule à l'aide de grandeurs mesurables telles que la vitesse, l'accélération, le couple moteur et l'angle de pente. L'algorithme des moindres carrés récursifs (RLS) met à jour la valeur estimée de μ_r à chaque instant en minimisant l'erreur entre le modèle dynamique

et les mesures disponibles.

La formulation mathématique du problème d'estimation peut être exprimée sous une forme régressive compatible avec l'algorithme RLS, déjà introduit dans la section 2.2.1. Dans ce cadre, l'observation $y(k)$ et le terme régressif $\phi(k)$ sont obtenus à partir du modèle dynamique longitudinal du véhicule. Plus précisément, l'observation correspond à la force résultante après soustraction des forces résistantes autres que la résistance au roulement, tandis que le terme régressif est directement lié à la composante normale du poids du véhicule.

Dans le cas étudié, on obtient ainsi :

$$y(k) = F_{\text{traction}}(k) - F_{\text{aero}}(k) - m \cdot \dot{V}_x(k) - m \cdot g \cdot \sin(\lambda(k)) \quad (3.2)$$

$$\phi(k) = m \cdot g \cdot \cos(\lambda(k)) \quad (3.3)$$

de sorte que la relation régressive s'écrit sous la forme :

$$y(k) = \phi(k) \cdot \mu_r(k) + \varepsilon(k) \quad (3.4)$$

où $\varepsilon(k)$ regroupe les erreurs de modélisation, les incertitudes paramétriques et les perturbations non modélisées.

Dans le cas présent, le vecteur de paramètres se réduit au scalaire μ_r , ce qui conduit à une forme régressive scalaire. Les équations de mise à jour récursive de l'algorithme RLS sont celles présentées précédemment à la section 2.2.1 et sont utilisées ici pour estimer en ligne μ_r à partir des signaux mesurés du véhicule. Cette approche permet une mise à jour rapide de l'estimation du coefficient μ_r à chaque instant d'échantillonnage et présente

une robustesse satisfaisante face au bruit de mesure dans le cadre des hypothèses retenues. Dans les simulations, le facteur d'oubli est choisi proche de 1 ($\gamma \approx 0.99$) afin de privilégier la stabilité de l'estimation tout en conservant une capacité de suivi des variations lentes de μ_r .

L'estimation initiale est fixée à une valeur nominale $\hat{\mu}_r(0)$, tandis que la covariance initiale $P(0)$ est choisie élevée afin de refléter une incertitude initiale importante et de favoriser une convergence rapide de l'estimateur. Une valeur de γ trop faible accroît la sensibilité au bruit, tandis qu'une valeur trop proche de 1 ralentit la capacité d'adaptation de l'estimateur. Le choix retenu constitue ainsi un compromis entre rapidité de convergence et robustesse de l'estimation.

3.4 Conclusion

Dans ce chapitre, une approche d'estimation en ligne du coefficient de résistance au roulement μ_r , fondée sur la méthode des moindres carrés récurrents (RLS), a été présentée. Cette méthode se distingue par sa simplicité d'implémentation, son faible coût de calcul et sa capacité à suivre des variations lentes du paramètre estimé. L'intégration du RLS au modèle dynamique longitudinal du véhicule permet ainsi d'obtenir une estimation adaptative de μ_r à partir de grandeurs accessibles, telles que la vitesse, l'accélération, le couple moteur et l'angle de pente.

Toutefois, la qualité de l'estimation dépend fortement de la validité des hypothèses de modélisation, de la qualité des mesures disponibles ainsi que des perturbations environnementales. En particulier, les effets du vent, les variations de pente ou les incertitudes associées aux forces résistantes peuvent influencer la précision et la stabilité de l'estimateur.

Le chapitre suivant est consacré à l'implémentation et à la validation par simulation de l'algorithme proposé. Une analyse progressive est menée en considérant d'abord un scénario idéal sans perturbations, puis l'introduction de perturbations aérodynamiques liées au vent, l'effet des variations de pente longitudinale et enfin leur combinaison. Cette étude est réalisée sur plusieurs cycles de conduite représentatifs (FTP75, EUDC et WLTC classe 3b) afin d'évaluer la robustesse, la stabilité et la capacité de convergence de l'estimateur dans des conditions proches de la conduite réelle.

Chapitre 4 - Implémentation numérique et validation par simulation

4.1 Introduction

L'implémentation et la validation de l'algorithme d'estimation du coefficient de résistance au roulement μ_r constituent une étape essentielle pour évaluer la pertinence, la robustesse et les performances de l'approche proposée. À la suite de la modélisation du système dynamique longitudinal et de la formulation de l'estimation par moindres carrés récursifs (RLS), présentées au chapitre précédent, ce chapitre décrit l'implémentation numérique de la méthode ainsi que l'analyse des résultats obtenus à partir des simulations réalisées sous MATLAB/Simulink.

L'objectif principal est d'évaluer :

- la précision de l'estimation ;
- la rapidité de convergence ;
- la robustesse face aux perturbations environnementales (V_{vent} et pente) ;
- la stabilité de l'estimateur dans des conditions dynamiques variées.

Les performances de l'estimateur sont analysées à l'aide de plusieurs indicateurs, notamment la vitesse de convergence, la sensibilité aux perturbations environnementales (V_{vent} et pente) et la fidélité du suivi de la valeur de référence simulée, considérée comme vérité terrain dans le cadre de cette validation numérique [2, 7, 13, 70].

4.2 Configuration des simulations

4.2.1 Paramètres du véhicule

Afin d'assurer la cohérence et la représentativité des simulations réalisées, les paramètres physiques du véhicule ont été sélectionnés à partir de données expérimentales et de références bibliographiques. Le Tableau 4-1 synthétise l'ensemble des paramètres

utilisés dans le modèle dynamique longitudinal ainsi que les coefficients de résistance au roulement adoptés comme références pour l'analyse des performances de l'estimateur.

Tableau 4-1 Paramètres du véhicule étudié.

Paramètre	Unité	Valeur
Masse du véhicule m	kg	1547
Accélération gravitationnelle g	m/s ²	9.81
Masse volumique de l'air ρ	kg/m ³	1.2
Coefficient de traînée aérodynamique C_{aero}	–	0.375
Surface frontale A_f	m ²	2.2
Rayon effectif du pneu R_w (P205/70R15)	m	0.334
Angle de pente λ	rad	0
Coefficient de résistance au roulement (réf. 1) $\mu_{r,réf1}$	–	0.03
Coefficient de résistance au roulement (réf. 2) $\mu_{r,réf2}$	–	0.018

Les paramètres physiques du véhicule utilisés dans cette étude sont principalement issus de l'article de référence [2]. La surface frontale A_f est estimée à partir des dimensions géométriques du véhicule, conformément aux pratiques courantes de la littérature, tandis que le rayon effectif de la roue est calculé à partir des dimensions du pneumatique P205/70R_W15. Cette approximation est couramment adoptée dans les modèles longitudinaux simplifiés lorsque les données constructeurs détaillées ne sont pas disponibles.

4.2.2 Paramètres de l'algorithme RLS

L'algorithme des moindres carrés récurrents (RLS) est utilisé pour estimer de manière adaptative le coefficient μ_r à partir des grandeurs issues du modèle dynamique longitudinal.

Les paramètres retenus pour les simulations sont les suivants :

- Facteur d'oubli : $\gamma = 0.99$;

- Covariance initiale : $P(0) = P_0 = 10$;
- Valeur initiale : $\hat{\mu}_r(0) = \mu_{r,0}$.

Le choix des paramètres (γ, P_0) est réalisé en cohérence avec l'analyse présentée au Chapitre 3.3, de manière à assurer un compromis entre rapidité de convergence et stabilité de l'estimation. La valeur $\gamma = 0.99$ permet notamment un suivi satisfaisant des variations lentes du coefficient μ_r , tandis que $P_0 = 10$ favorise une convergence rapide lors de la phase initiale.

Reproductibilité et changement de palier : Afin d'assurer la reproductibilité des résultats, le pas d'échantillonnage est fixé à $T_s = 0.01$ s pour l'ensemble des simulations, et les paramètres RLS (γ, P_0) sont conservés identiques dans tous les scénarios.

Le coefficient de référence $\mu_{r,\text{réf}}(k)$ est imposé sous forme de paliers (passage de $\mu_{r,\text{réf}1} = 0.03$ à $\mu_{r,\text{réf}2} = 0.018$). L'estimateur n'est volontairement pas réinitialisé lors de ce changement afin d'évaluer sa capacité d'adaptation et sa robustesse face à une variation brusque du paramètre.

4.2.3 Hypothèses de simulation et portée de la validation numérique

La validation de l'approche proposée est réalisée dans un environnement de simulation maîtrisé sous MATLAB/Simulink. Les grandeurs utilisées pour l'estimation, notamment la vitesse longitudinale V_x , l'accélération longitudinale $\dot{V}_x$ et la force de traction F_{traction} , proviennent directement du modèle dynamique du véhicule. L'accélération $\dot{V}_x$ est extraite du modèle afin d'éviter l'amplification du bruit liée à une dérivation numérique de la vitesse ; en conditions réelles, elle pourrait être obtenue à partir d'un accéléromètre ou d'un signal filtré.

La vitesse du vent V_{vent} et la pente longitudinale λ sont considérées comme des

grandeurs connues dans cette étude et sont imposées au modèle à partir de profils réels prétraités et interpolés. En particulier, la pente n'est pas estimée par l'algorithme RLS ; elle intervient comme une entrée externe connue dans le modèle dynamique longitudinal. Cette hypothèse permet de calculer les termes de régression $y(k)$ et $\phi(k)$ nécessaires à l'estimation du coefficient de résistance au roulement μ_r .

Aucun bruit de mesure explicite n'a été introduit à ce stade afin d'isoler les performances intrinsèques de l'algorithme RLS et d'évaluer sa capacité de convergence dans des conditions idéalisées. Le coefficient μ_r est supposé constant ou lentement variable sur les fenêtres d'analyse considérées.

Enfin, cette étude constitue principalement une validation numérique de l'approche proposée. Une validation expérimentale future devra intégrer les effets du bruit de mesure, des biais capteurs, des délais d'acquisition ainsi que des incertitudes paramétriques afin d'évaluer pleinement la robustesse de l'approche en conditions réelles.

4.3 Implémentation numérique

4.3.1 Modèle de régression

Le modèle de régression utilisé pour l'estimation du coefficient de résistance au roulement μ_r a été établi au Chapitre 3 à partir du modèle dynamique longitudinal du véhicule. Dans ce cadre, la relation de régression utilisée par l'algorithme des moindres carrés récurrents (RLS) s'écrit sous la forme :

$$y(k) = \phi(k) \cdot \mu_r(k) + \varepsilon(k) \quad (4.1)$$

où $\varepsilon(k)$ regroupe les erreurs de modélisation, les incertitudes paramétriques ainsi

que les perturbations non modélisées.

Les expressions détaillées des termes $y(k)$ et $\phi(k)$ ont été présentées au Chapitre 3. Dans cette phase d'implémentation numérique, ces grandeurs sont directement calculées à partir des signaux issus du modèle longitudinal simulé sous MATLAB/Simulink. L'estimation fournie par l'algorithme RLS est notée $\hat{\mu}_r(k)$, tandis que $\mu_{r,\text{réf}}(k)$ désigne la valeur de référence utilisée pour l'évaluation des performances.

Cette formulation permet l'identification récursive du coefficient μ_r à partir des signaux mesurés, tout en assurant une compatibilité directe avec l'algorithme RLS implémenté.

Nature des signaux utilisés : Les grandeurs nécessaires à l'estimation, notamment $V_x(k)$, $\dot{V}_x(k)$ et $F_{\text{traction}}(k)$, proviennent du modèle longitudinal simulé sous MATLAB/Simulink. Les perturbations environnementales, telles que la vitesse du vent $V_{\text{vent}}(k)$ et la pente $\lambda(k)$, sont issues de profils réels prétraités et adaptés au pas d'échantillonnage T_s .

Aucun bruit de mesure explicite n'est considéré à ce stade afin d'évaluer les performances intrinsèques de l'algorithme.

Portée de la validation : Les résultats présentés constituent une validation *numérique* dans un environnement maîtrisé. Cette approche permet d'analyser la convergence, la stabilité et la sensibilité de l'estimateur face aux perturbations.

Une validation *expérimentale* devra ultérieurement intégrer les effets liés au bruit de mesure, aux biais capteurs, aux délais et aux incertitudes paramétriques.

4.3.2 Équations de mise à jour de l'algorithme RLS

Les équations de mise à jour de l'algorithme des moindres carrés récurrents (RLS) ont été présentées à la section 2.2.1. Elles sont utilisées ici dans leur forme scalaire pour l'estimation en ligne du coefficient de résistance au roulement μ_r .

Dans l'implémentation pratique, l'algorithme est initialisé à l'instant $k = 0$ avec une estimation initiale $\hat{\mu}_r(0)$ et une covariance $P(0)$ choisie élevée afin de refléter l'incertitude initiale sur le paramètre.

À chaque instant d'échantillonnage $k \geq 1$, l'estimation $\hat{\mu}_r(k)$ est mise à jour de manière récursive à partir de l'estimation précédente $\hat{\mu}_r(k-1)$, en fonction de l'erreur de prédiction et du gain d'adaptation. Le gain dépend de la covariance précédente et du terme régressif, ce qui permet d'ajuster dynamiquement la correction apportée à l'estimation.

La première estimation exploitable $\hat{\mu}_r(1)$ est obtenue après la première itération, à partir des conditions initiales. Le mécanisme de rétroaction repose ainsi sur l'utilisation systématique de l'estimation précédente pour calculer la suivante.

Cette structure récursive permet une adaptation continue du paramètre en temps réel, tout en assurant un compromis entre rapidité de convergence et robustesse face aux perturbations et aux incertitudes de modélisation.

4.3.3 Architecture Simulink du système d'estimation

La Figure 4.1 présente l'architecture Simulink développée pour la simulation du système d'estimation du coefficient de résistance au roulement μ_r . Cette architecture intègre la modélisation dynamique du véhicule, la génération de la commande de traction ainsi que l'algorithme d'estimation basé sur les moindres carrés récurrents (RLS). Elle met

en évidence l'organisation globale du système et les interactions entre ses différents blocs fonctionnels.




Figure 4.1 Architecture de simulation du modèle longitudinal du véhicule avec estimation RLS du coefficient de résistance au roulement μ_r .

Comme illustré à la Figure 4.1, le profil de conduite génère une vitesse de référence suivie à l'aide d'un contrôleur PI. Le modèle longitudinal fournit les grandeurs nécessaires (V_x , $\dot{V}_x$, $F_{traction}$) à l'estimation de μ_r par RLS. L'estimation $\hat{\mu}_r$ est ensuite comparée à $\mu_{r,ref}$ pour évaluer les performances.

Le contrôleur PI intervient uniquement dans la boucle de suivi de vitesse afin de générer la force de traction nécessaire pour reproduire le profil de conduite imposé. Son rôle consiste à réduire l'erreur entre la vitesse de référence et la vitesse réelle du véhicule. Ainsi, il ne participe pas directement à l'estimation du coefficient de résistance au roulement μ_r , laquelle est assurée exclusivement par l'algorithme RLS à partir du modèle dynamique longitudinal et des grandeurs mesurées.

Cependant, l'action du contrôleur PI influence indirectement la qualité de l'estimation en contribuant à l'excitation dynamique du système. Les variations de vitesse et d'accélération générées durant le cycle de conduite fournissent des données suffisamment riches pour assurer une bonne observabilité du paramètre estimé et favoriser la convergence de l'algorithme RLS.

Les simulations numériques sont réalisées sous MATLAB/Simulink avec un pas d'échantillonnage fixé à $T_s = 0.01$ s, permettant de représenter correctement la dynamique du véhicule tout en assurant une exécution numérique stable et compatible avec une implantation en temps réel.

4.3.4 Implémentation de l'algorithme sous MATLAB

La Figure 4.2 illustre l'implémentation de l'algorithme RLS utilisé pour l'estimation du coefficient de résistance au roulement μ_r à partir des signaux issus du modèle Simulink, notamment la vitesse longitudinale V_x , son accélération $\dot{V}_x$ et la force de traction F_{traction} .

Cet organigramme met en évidence la structure récursive de l'algorithme ainsi que l'enchaînement des différentes étapes de calcul réalisées à chaque instant d'échantillonnage.

L'implémentation repose sur deux étapes principales :

- **Initialisation** : définition des paramètres de l'algorithme, notamment le facteur d'oubli γ , la covariance initiale P_0 , la valeur initiale de l'estimation $\mu_r(0)$ et le pas d'échantillonnage T_s .
- **Mise à jour récursive** : calcul de l'erreur d'estimation, du gain K_k , puis mise à jour de l'estimation $\mu_{r,k}$ et de la covariance P_k selon les équations du RLS.




Figure 4.2 Organigramme de l'algorithme RLS pour l'estimation du coefficient de résistance au roulement μ_r .

4.4 Résultats de simulation et validation

4.4.1 Présentation des scénarios de simulation

Cette étude est réalisée sur plusieurs cycles de conduite représentatifs (FTP75, EUDC et WLTC classe 3b) afin d'évaluer la robustesse, la stabilité et la capacité de convergence de l'estimateur dans des conditions proches de la conduite réelle.

Afin de faciliter la lecture et de synthétiser les différentes configurations de simulation étudiées, le Tableau 4-2 présente le plan global des expériences réalisées.

Tableau 4-2 Plan des expériences de simulation pour l'estimation du coefficient de résistance au roulement μ_r .

Expérience	V_{vent}	Pente	Références μ_r	Cycles
Expérience 1 : Conditions idéales	Nul	Nulle	0.03 / 0.018	FTP75, EUDC, WLTC 3b
Expérience 2A : Perturbation V_{vent}	Faible / Moyen / Fort	Nulle	0.03 / 0.018	FTP75, EUDC, WLTC 3b
Expérience 2B : Perturbation pente	Nul	Variable (profil réel)	0.03 / 0.018	FTP75, EUDC, WLTC 3b
Expérience 2C : V_{vent} + pente	Faible / Moyen / Fort	Variable (profil réel)	0.03 / 0.018	FTP75, EUDC, WLTC 3b

Afin de valider les performances de l'estimation du coefficient de résistance au roulement μ_r , trois cycles de conduite ont été considérés :

- Cycle de conduite FTP75 : cycle urbain américain caractérisé par des phases d'arrêts fréquents et des variations rapides de vitesse ;
- Cycle de conduite EUDC : cycle européen comportant des phases de vitesse stabilisée et des accélérations plus douces ;
- Cycle de conduite WLTC classe 3b : cycle plus représentatif des conditions réelles, combinant des phases urbaines, périurbaines et autoroutières.

Cette diversité permet d'évaluer la robustesse de l'estimateur dans des régimes de

conduite contrastés. Pour chaque cycle, les comparaisons portent sur le suivi de vitesse longitudinale V_x et sur la capacité de l'estimateur à suivre les valeurs de référence de μ_r .

4.4.2 Critères d'évaluation des performances

Afin de quantifier objectivement les performances de l'estimateur RLS, plusieurs indicateurs sont utilisés :

- **Temps de convergence** : temps nécessaire pour que l'estimation converge durablement vers la valeur de référence du coefficient de résistance au roulement. Dans cette étude, le temps de convergence correspond au premier instant à partir duquel l'erreur relative absolue demeure inférieure à 5% pendant une durée minimale de 2 s :

$$e_r(k) = \left| \frac{\hat{\mu}_r(k) - \mu_{r,\text{ref}}(k)}{\mu_{r,\text{ref}}(k)} \right| \leq 5\%.$$

- **Erreur maximale** : plus grande valeur absolue de l'écart entre l'estimation et la valeur de référence observée sur l'ensemble de la simulation :

$$e_{\max} = \max_{1 \leq k \leq N} |\hat{\mu}_r(k) - \mu_{r,\text{ref}}(k)|.$$

- **Erreur quadratique moyenne (RMSE)** : cet indicateur permet d'évaluer la précision globale de l'estimation sur l'ensemble du cycle de conduite :

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{k=1}^N (\hat{\mu}_r(k) - \mu_{r,\text{ref}}(k))^2}.$$

Lorsque la valeur de référence varie au cours de la simulation

(changement de palier), les calculs sont réalisés en considérant la référence instantanée $\mu_{r,\text{ref}}(k)$.

- **Stabilité de l'estimation** : la stabilité de l'estimation est quantifiée à partir de l'écart-type des fluctuations résiduelles de l'estimation autour de sa valeur moyenne après convergence :

$$\sigma_{\mu_r} = \sqrt{\frac{1}{N} \sum_{k=1}^N (\hat{\mu}_r(k) - \bar{\mu}_r)^2}.$$

où $\bar{\mu}_r$ représente la valeur moyenne estimée après convergence. Une faible valeur de σ_{μ_r} traduit une estimation stable caractérisée par de faibles oscillations résiduelles, tandis qu'une valeur élevée indique une plus grande sensibilité aux perturbations et aux variations dynamiques du cycle de conduite.

Ces indicateurs combinent des critères temporels, statistiques et dynamiques permettant d'évaluer simultanément la rapidité de convergence, la précision, la robustesse et la stabilité de l'estimation dans différentes conditions de conduite.

4.4.3 Cycle de conduite FTP75

La Figure 4.3 illustre le suivi de la vitesse longitudinale V_x sous le cycle FTP75. Les courbes de référence et simulée présentent une superposition satisfaisante sur l'ensemble du cycle. Les écarts résiduels apparaissent principalement lors des transitions rapides (accélérations/décélérations), ce qui est attendu compte tenu des variations brusques de sollicitation longitudinale. Ce résultat confirme la cohérence du modèle longitudinal et la capacité du système de commande à reproduire le profil de vitesse imposé.




Figure 4.3 Comparaison de la vitesse longitudinale de référence et mesurée issues de la modélisation par équations dynamiques longitudinales sur le cycle FTP75.

4.4.4 Cycle de conduite EUDC

Le cycle de conduite EUDC (Extra-Urban Driving Cycle) représente la phase à plus haute vitesse du cycle NEDC. Il se caractérise par des accélérations modérées et plusieurs phases à vitesse stabilisée, permettant d'évaluer le comportement du modèle dans un régime où les forces aérodynamiques et de roulement deviennent plus influentes.

La Figure 4.4 montre une superposition quasi parfaite entre la vitesse de référence et la vitesse simulée, traduisant une bonne capacité du contrôleur PI à assurer le suivi du profil imposé. Les écarts les plus visibles apparaissent principalement lors des transitions de régime et au voisinage des paliers de vitesse, où les variations des efforts de traction et de traînée aérodynamique sont plus importantes.

Malgré ces transitions, le suivi demeure stable sur l'ensemble du cycle, ce qui confirme la cohérence du modèle longitudinal et sa capacité à reproduire correctement les

conditions de conduite extra-urbaines.




Figure 4.4 Comparaison de la vitesse longitudinale de référence et mesurée issues de la modélisation par équations dynamiques longitudinales sur le cycle de conduite EUDC.

4.4.5 Cycle de conduite WLTC classe 3b

Le cycle WLTC (Worldwide Harmonized Light Vehicles Test Cycle) classe 3b constitue un scénario de conduite plus exigeant en raison de ses variations rapides de vitesse, de ses accélérations plus importantes et de ses sollicitations longitudinales plus marquées. Ce cycle permet ainsi d'évaluer le comportement du modèle dans des conditions dynamiques proches d'une conduite réelle plus agressive.

La Figure 4.5 montre une concordance globalement satisfaisante entre la vitesse de référence et la vitesse simulée. Les écarts les plus visibles apparaissent principalement durant les phases transitoires rapides, où les effets liés à la traction, aux efforts aérodynamiques et à la dynamique du véhicule deviennent plus importants.

Malgré ces variations rapides, le modèle conserve un suivi stable du profil de

vitesse imposé, ce qui confirme sa capacité à reproduire correctement les conditions dynamiques du cycle WLTC classe 3b. Ce cycle constitue ainsi un cas particulièrement pertinent pour évaluer la robustesse de l'estimation du coefficient μ_r dans des conditions de conduite plus sévères.




Figure 4.5 Comparaison de la vitesse longitudinale de référence et mesurée issues de la modélisation par équations dynamiques longitudinales sur le cycle de conduite WLTC 3b.

En conditions hivernales, la résistance au roulement augmente significativement en raison de la présence de neige et de glace [13]. Dans [13], les auteurs considèrent une valeur de référence $\mu_{r,\text{réf1}} = 0.03$ comme représentative d'une route enneigée et l'utilisent comme vérité terrain dans leurs travaux d'estimation en temps réel. Cette valeur est retenue dans cette étude pour modéliser des conditions hivernales [13]. Par ailleurs, des simulations en condition normale (asphalte sec) sont également réalisées avec $\mu_{r,\text{réf2}} = 0.018$, correspondant à une valeur mesurée pour le véhicule électrique *Nemo* et utilisée comme référence de validation [2].

4.4.6 Cas 1 : Évaluation de l'estimateur en conditions idéales

Dans un premier temps, les performances de l'estimateur RLS sont analysées dans un scénario idéal ne comportant aucune perturbation environnementale. Dans cette configuration, la vitesse du vent est considérée nulle ($V_w = 0$) et la pente de la route est fixée à zéro ($\lambda = 0$). Par conséquent, la dynamique longitudinale du véhicule est principalement gouvernée par les effets inertiels ainsi que par la résistance au roulement, tandis que les influences externes susceptibles de perturber l'estimation sont volontairement éliminées.

Cette configuration permet d'évaluer le comportement intrinsèque de l'algorithme RLS dans un environnement maîtrisé, sans influence significative des perturbations extérieures. Les variations observées sur le coefficient estimé sont ainsi principalement liées aux propriétés de convergence et d'adaptation de l'estimateur.

L'objectif principal de cette configuration de référence est de valider la cohérence globale du modèle dynamique longitudinal utilisé dans cette étude ainsi que la capacité de l'algorithme RLS à identifier correctement le coefficient de résistance au roulement μ_r . Cette étape constitue une phase essentielle avant l'introduction de scénarios plus réalistes comportant des perturbations aérodynamiques et des variations de pente. Elle permet notamment de vérifier la stabilité numérique de l'estimateur, la qualité de la convergence ainsi que la précision des valeurs estimées dans des conditions favorables.

Par ailleurs, ce cas idéal sert également de référence comparative pour l'ensemble des analyses présentées dans les sections suivantes. Les performances obtenues dans cet environnement simplifié permettront d'évaluer plus clairement l'impact des perturbations extérieures sur la qualité de l'estimation, notamment en termes de temps de convergence,

d'erreur maximale et de stabilité de la réponse estimée. Ainsi, cette première étude fournit une base méthodologique importante pour interpréter l'évolution des performances de l'algorithme lorsque les conditions de fonctionnement deviennent progressivement plus complexes et plus représentatives d'une utilisation réelle du véhicule.

1. **Cycle de conduite FTP75 :** La Figure 4.6 montre l'évolution du coefficient μ_r estimé en conditions idéales sur le cycle de conduite FTP75, afin d'évaluer la capacité de l'algorithme à converger vers les valeurs de référence.




Figure 4.6 μ_r estimé en condition idéale sur le cycle de conduite FTP75 avec coefficients de référence $\mu_{r,\text{réf1}} = 0.03$ et $\mu_{r,\text{réf2}} = 0.018$.

On observe que l'estimation du coefficient de résistance au roulement μ_r converge rapidement vers les valeurs de référence, malgré la présence de légères oscillations lors des phases transitoires du cycle FTP75. Ce

comportement s'explique par le caractère fortement transitoire de ce cycle urbain, caractérisé par les variations fréquentes de vitesse et de régimes à basse vitesse, pour lesquels la modélisation dynamique est plus sensible aux incertitudes. Ces écarts restent modérés et n'affectent pas la capacité de l'algorithme à suivre les variations du coefficient de résistance au roulement.

2. **Cycle de conduite EUDC :** La Figure 4.7 illustre le comportement de l'estimateur du coefficient de résistance au roulement μ_r en conditions idéales sur le cycle EUDC, permettant d'analyser la précision et la stabilité de l'estimation dans un régime de conduite plus régulier.




Figure 4.7 μ_r estimé en condition idéale sur le cycle de conduite EUDC avec coefficients de référence $\mu_{r,réf1} = 0.03$ et $\mu_{r,réf2} = 0.018$.

Sous le cycle EUDC, l'estimation du coefficient μ_r présente

une convergence rapide avec de faibles fluctuations en régime établi. Les oscillations observées apparaissent principalement durant les phases d'accélération et de décélération, sans dégrader la stabilité globale de l'estimation.

3. **Cycle de conduite WLTC classe 3b** : étant donné le caractère fortement dynamique du cycle WLTC classe 3b, La Figure 4.8 présente l'évolution de l'estimation du coefficient de résistance au roulement μ_r en conditions idéales dans le but d'étudier la robustesse de l'algorithme face aux variations rapides de vitesse.




Figure 4.8 μ_r estimé en condition idéale sur le cycle de conduite WLTC classe 3b avec coefficients de référence $\mu_{r,réf1} = 0.03$ et $\mu_{r,réf2} = 0.018$.

Le cycle WLTC classe 3b présente des variations rapides de vitesse et des

sollicitations longitudinales importantes. Ces caractéristiques induisent des fluctuations plus marquées dans l'estimation du coefficient μ_r , en particulier lors des phases d'accélération et de décélération rapides. Malgré ces contraintes dynamiques, l'estimation converge vers les valeurs de référence, avec des écarts principalement observés lors des phases transitoires. Les écarts observés demeurent limités, confirmant la robustesse de l'algorithme dans ce contexte fortement dynamique. Une analyse comparative des performances obtenues sur les cycles FTP75, EUDC et WLTC classe 3b en conditions idéales est présentée dans le Tableau 4-3, afin de synthétiser le comportement global de l'estimateur.

Tableau 4-3 Synthèse des performances de l'estimation de μ_r en condition idéale.

Cycle	Condition	$\hat{\mu}_r$ moyen (0.03)	$\hat{\mu}_r$ moyen (0.018)	RMSE (0.03)	RMSE (0.018)	Erreur max
WLTC 3b	Idéal	0.0294	0.0177	0.001148	0.001085	± 0.0020
EUDC	Idéal	0.0291	0.0174	0.001244	0.001213	± 0.0015
FTP75	Idéal	0.0299	0.0178	0.0006198	0.004814	± 0.0020

Cette première série de simulations en conditions idéales confirme le bon fonctionnement de l'algorithme d'estimation RLS. Les valeurs moyennes estimées coïncident étroitement avec les coefficients de référence considérés ($\mu_r = 0.03$ et 0.018), avec des erreurs quadratiques moyennes faibles pour l'ensemble des cycles étudiés. Ces résultats constituent une base de validation dans un environnement contrôlé et permettent d'évaluer de manière plus rigoureuse l'impact des perturbations environnementales, telles que la pente longitudinale ou les effets aérodynamiques.

4.4.7 Cas 2A : Influence de la vitesse du vent sur les performances de l'estimateur

Après l'analyse en conditions idéales, une deuxième série de simulations est réalisée afin d'évaluer la robustesse de l'algorithme face aux perturbations aérodynamiques induites par la vitesse du vent. En conditions réelles, le vent modifie la force de traînée aérodynamique appliquée au véhicule, ce qui influence la dynamique longitudinale et peut affecter l'estimation du coefficient de résistance au roulement.

Dans cette étude, différents profils de vitesse du vent sont introduits afin d'analyser leur influence sur la convergence, la stabilité et la précision de l'estimateur RLS.

Les profils utilisés proviennent de données météorologiques réelles fournies par Environnement Canada. Les mesures horaires de la station QC-8321 (Québec), correspondant à différents niveaux d'intensité du vent, ont été converties en m/s puis interpolées afin d'être compatibles avec le pas d'échantillonnage $T_s = 0.01$ s. La durée des profils a ensuite été ajustée à celle des cycles de conduite.




Figure 4.9 Profils de vitesse de vent à différents niveaux d'intensité.

Dans la suite, les niveaux *faible*, *moyen* et *fort* correspondent à des profils réels de vitesse du vent présentant respectivement des intensités faibles, intermédiaires et élevées. Ces profils sont ensuite appliqués au modèle dynamique longitudinal comme perturbations aérodynamiques sur les cycles FTP75, EUDC et WLTC classe 3b.

1. **Cycle de conduite FTP75** : Afin d'analyser l'influence des perturbations de la vitesse du vent sur l'estimation du coefficient de résistance au roulement, La Figure 4.10 présente l'évolution du coefficient de résistance au roulement estimé μ_r sur le cycle FTP75 pour différents niveaux de vitesse du vent.




Figure 4.10 Coefficient μ_r estimé avec perturbation de vitesse du vent de différents niveaux sur le cycle de conduite FTP75 avec $\mu_{r,ref1} = 0.03$ et $\mu_{r,ref2} = 0.018$.

Le temps de convergence reste faible malgré les perturbations liées à la

vitesse du vent. L'estimation demeure globalement stable et proche de la valeur de référence de μ_r . Des fluctuations plus marquées apparaissent durant les phases transitoires du cycle FTP75, sans toutefois dégrader significativement les performances de l'estimateur.

2. **Cycle de conduite EUDC :** La Figure 4.11 illustre l'évolution du coefficient de résistance au roulement μ_r estimé sur le cycle de conduite EUDC, pour différents niveaux de vitesse du vent.




Figure 4.11 Coefficient μ_r estimé avec perturbation de vitesse du vent de différents niveaux sur le cycle de conduite EUDC avec $\mu_{r,réf1} = 0.03$ et $\mu_{r,réf2} = 0.018$.

Dans le cas du cycle EUDC, l'estimation du coefficient μ_r présente une faible variance en régime établi. La convergence demeure rapide et les fluctuations restent limitées, même pour des vitesses de vent élevées. Ce

comportement s'explique par le profil de vitesse plus régulier du cycle EUDC, qui favorise de meilleures conditions d'identification du paramètre estimé. L'analyse est ensuite étendue au cycle WLTC classe 3b afin d'évaluer la robustesse de l'estimateur dans des conditions de conduite plus dynamiques.

3. **Cycle de conduite WLTC classe 3b :** La Figure 4.12 présente le comportement du coefficient de résistance au roulement estimé lors du cycle de conduite WLTC classe 3b pour différentes vitesses du vent.




Figure 4.12 Coefficient μ_r estimé avec perturbation de vitesse du vent de différents niveaux sur le cycle de conduite WLTC classe 3b avec $\mu_{r,\text{réf1}} = 0.03$ et $\mu_{r,\text{réf2}} = 0.018$.

Pour le cycle WLTC classe 3b, l'estimation du coefficient μ_r présente une variance plus importante en raison des fortes sollicitations dynamiques imposées par le cycle,

notamment durant les phases d'accélération et de décélération rapides. L'augmentation de la vitesse du vent accentue ces oscillations à cause de la contribution aérodynamique plus élevée dans la dynamique longitudinale du véhicule.

Malgré ces conditions plus sévères, l'estimateur conserve un comportement globalement stable et reste proche de la valeur de référence. Les fluctuations observées demeurent principalement transitoires et apparaissent lors des changements rapides de régime dynamique.

4.4.8 Analyse comparative des performances de l'estimateur sous perturbation de vent

Le Tableau 4-4 présente une synthèse comparative des performances de l'estimation du coefficient μ_r sous différentes perturbations de vitesse du vent pour les trois cycles de conduite étudiés. Les résultats sont évalués à partir de deux valeurs de référence du coefficient de résistance au roulement ($\mu_{r,\text{réf}1} = 0.03$ et $\mu_{r,\text{réf}2} = 0.018$), en considérant la valeur moyenne estimée, l'erreur maximale ainsi que le comportement global de l'estimation.

Le Tableau 4-4 présentés dans cette section permettent d'observer l'influence progressive de l'intensité du vent sur la stabilité et la précision de l'algorithme RLS. Une analyse qualitative du comportement de convergence est d'abord proposée afin de faciliter la comparaison entre les différents scénarios étudiés. Les indicateurs quantitatifs complémentaires, notamment l'erreur quadratique moyenne (RMSE), sont ensuite présentés dans le Tableau 4-5.

Tableau 4-4 Synthèse comparative des performances de l'estimation de μ_r sous perturbation de vitesse du vent.

Cycle	Vitesse du vent	μ_r moyen (0.03)	μ_r moyen (0.018)	Erreur max	Stabilité
FTP75	faible	0.0297	0.0177	± 0.0025	Stable
FTP75	moyen	0.0293	0.0173	± 0.0035	Stable
FTP75	fort	0.0290	0.0170	± 0.0045	Oscillations transitoires visibles
EUDC	faible	0.0299	0.0179	± 0.0020	Très stable
EUDC	moyen	0.0296	0.0176	± 0.0025	Stable
EUDC	fort	0.0293	0.0173	± 0.0030	Stable
WLTC 3b	faible	0.0298	0.0178	± 0.0025	Très stable
WLTC 3b	moyen	0.0294	0.0174	± 0.0035	Stable
WLTC 3b	fort	0.0290	0.0170	± 0.0045	Oscillations transitoires visibles

Interprétation physique et identification : L'influence du vent sur l'estimation du coefficient μ_r s'explique par son effet direct sur la force de traînée aérodynamique équation 3.1. Les variations de la vitesse du vent V_{vent} modifient ainsi la force résistante longitudinale, ce qui perturbe le signal de régression utilisé par l'algorithme RLS et peut affecter la précision de l'estimation.

D'un point de vue identification, l'augmentation de la vitesse du vent renforce la corrélation entre les différentes contributions résistantes, en particulier entre la traînée aérodynamique et la résistance au roulement. Cette interaction rend la séparation des effets plus délicate, ce qui explique l'augmentation progressive de l'erreur maximale et le léger ralentissement de la convergence observés lorsque la vitesse du vent augmente, notamment pour le cycle WLTC classe 3b caractérisé par une dynamique plus agressive.

Malgré cette sensibilité accrue, l'erreur maximale reste dans des plages acceptables pour l'ensemble des cycles étudiés. La stabilité de l'estimation est préservée, bien qu'une

légère augmentation de la variance soit observée avec l'intensité du vent.

Ces résultats indiquent que l'introduction du vent n'affecte pas de manière critique la stabilité globale de l'estimateur. Toutefois, pour des applications embarquées en conditions réelles, une estimation ou une modélisation appropriée de la vitesse relative de l'air, ainsi qu'un filtrage adéquat des signaux dynamiques, peuvent contribuer à limiter l'impact des perturbations aérodynamiques sur la performance de l'estimation.

4.4.9 Cas 2B : Influence de la pente sur les performances de l'estimateur

Cette section analyse l'influence des variations de pente longitudinale sur l'estimation de μ_r . La pente modifie la composante gravitationnelle appliquée au véhicule et influence ainsi la dynamique longitudinale. Afin d'évaluer la robustesse de l'estimateur dans des conditions topographiques réalistes, un profil de pente variable issu d'un parcours réel est introduit dans le modèle pour les cycles FTP75, EUDC et WLTC classe 3b.

Le profil de pente utilisé est extrait de données altimétriques mesurées à Trois-Rivières à l'aide de l'application Gaia GPS. Les données sont filtrées puis interpolées afin d'être compatibles avec le pas d'échantillonnage T_s des simulations MATLAB/Simulink.

La pente longitudinale est calculée selon :

$$\lambda = \arctan\left(\frac{\Delta h}{\Delta x}\right). \quad (4.2)$$

où Δh représente la variation d'altitude et Δx la distance horizontale parcourue entre deux points successifs.

La Figure 4.13 présente le profil de pente appliqué comme perturbation gravitationnelle aux différents cycles de conduite utilisés dans cette étude.




Figure 4.13 Profil de pente longitudinal appliqué aux cycles de conduite.

1. **Cycle de conduite FTP75 :** La Figure 4.14 illustre l'évolution du coefficient de résistance au roulement estimé durant le cycle FTP75 en présence d'une pente longitudinale appliquée au modèle dynamique du véhicule. Cette configuration permet d'évaluer les performances de l'algorithme RLS dans des conditions de conduite plus réalistes, où la composante gravitationnelle influence directement le comportement longitudinal.

Les variations observées sur le coefficient estimé apparaissent principalement durant les phases transitoires du cycle, caractérisées par des accélérations et décélérations fréquentes, ainsi qu'au niveau des changements du profil de pente. Malgré ces perturbations, l'estimation demeure globalement stable et converge rapidement vers les valeurs de référence de μ_r , avec des écarts limités autour des valeurs attendues.




Figure 4.14 Coefficient μ_r estimé sous perturbation de pente pour le cycle de conduite FTP75 avec $\mu_{r,réf1} = 0.03$ et $\mu_{r,réf2} = 0.018$.

On observe que l'erreur d'estimation reste bornée malgré les variations de la composante gravitationnelle induites par la pente. Les oscillations les plus importantes apparaissent lors des transitions rapides du profil routier et des changements brusques de vitesse, qui modifient instantanément l'équilibre des forces longitudinales.

Des excursions négatives ponctuelles de $\hat{\mu}_r$ peuvent également être observées. Bien que physiquement non admissibles, elles traduisent principalement une sensibilité transitoire du signal de régression liée à la superposition des effets inertiels et gravitationnels dans y_k . Ces variations demeurent toutefois brèves et n'entraînent aucune divergence de l'estimation.

Dans une perspective d'implantation embarquée, une contrainte physique peut être imposée à l'estimation, par exemple à l'aide d'une projection $\hat{\mu}_r \leftarrow \max(\hat{\mu}_r, 0)$ ou d'une saturation dans un intervalle plausible, afin de garantir la cohérence physique du paramètre estimé.

2. **Cycle de conduite EUDC :** La Figure 4.15 présente l'évolution du coefficient de résistance au roulement μ_r estimé au cours du cycle de conduite EUDC, sous l'influence d'une pente longitudinale.




Figure 4.15 Coefficient μ_r estimé sous perturbation de pente pour le cycle de conduite EUDC avec $\mu_{r,réf1} = 0.03$ et $\mu_{r,réf2} = 0.018$.

On observe que l'estimation du coefficient de résistance au roulement μ_r reste stable sur le cycle EUDC, avec des fluctuations de faible amplitude, ce qui s'explique par le profil de vitesse plus régulier.

3. **Cycle de conduite WLTC classe 3b** : La Figure 4.16 illustre le comportement du coefficient de résistance au roulement estimé lors du cycle de conduite WLTC classe 3b, sous l'influence d'une pente longitudinale.




Figure 4.16 Coefficient μ_r estimé sous perturbation de pente pour le cycle de conduite WLTC classe 3b avec $\mu_{r, \text{réf1}} = 0.03$ et $\mu_{r, \text{réf2}} = 0.018$.

Pour le cycle WLTC classe 3b, caractérisé par une dynamique plus agressive, l'estimation du coefficient μ_r présente des oscillations plus marquées, notamment lors des phases d'accélération et décélération rapides. Néanmoins, la convergence est maintenue malgré une augmentation des erreurs transitoires en phase dynamique, démontrant sa capacité d'adaptation face aux variations rapides de charge longitudinale induites par la pente. Il convient toutefois de préciser que des excursions négatives transitoires sont observées, avec une valeur minimale d'environ $\hat{\mu}_r \approx -0.01$ pour $\mu_{r, \text{réf1}} = 0.03$ et

$\hat{\mu}_r \approx -0.05$ pour $\mu_{r,\text{réf}2} = 0.018$. Ces valeurs, aberrantes, surviennent principalement lors des phases fortement transitoires et des variations brusques de pente. Elles demeurent ponctuelles et n'affectent pas la stabilité globale ni la capacité de suivi de l'estimateur.

4.4.10 Analyse comparative des performances de l'estimateur sous perturbation de pente

Le Tableau 4-5 résume les performances de l'algorithme RLS pour l'estimation du coefficient de résistance au roulement μ_r sous perturbation de pente pour les cycles WLTC 3b, EUDC et FTP75, en considérant deux valeurs de référence ($\mu_r = 0.03$ et $\mu_r = 0.018$).

Tableau 4-5 Synthèse comparative des performances de l'estimation de μ_r sous perturbation de pente variable.

Cycle	μ_r moyen (0.03)	μ_r moyen (0.018)	RMSE (0.03)	RMSE (0.018)	Erreur max	Stabilité
WLTC 3b	0.0290	0.0172	0.004398	0.007344	± 0.0050	Oscillations visibles
EUDC	0.0295	0.0176	0.001293	0.001297	± 0.0030	Stable
FTP75	0.0296	0.0175	0.0008309	0.002191	± 0.0040	Stable avec fluctuations modérées

Les valeurs de RMSE sont calculées sur l'ensemble de la durée du cycle pour les deux valeurs de référence considérées ($\mu_r = 0.03$ et 0.018) en présence d'une perturbation de pente longitudinale.

Interprétation physique et identification : La pente longitudinale influence directement la dynamique du véhicule à travers la force gravitationnelle $F_{\text{pente}} = mgsin(\lambda)$, qui intervient explicitement dans la formulation du modèle de régression utilisé par l'algorithme RLS. Toute variation rapide ou incertitude sur la mesure de λ se répercute ainsi sur le signal de régression y_k , ce qui peut temporairement augmenter l'erreur d'estimation.

D'un point de vue identification, cette perturbation modifie la séparation entre les différentes contributions résistantes (roulement, aérodynamique et gravitationnelle). Les cycles présentant une dynamique plus marquée, comme le WLTC classe 3b, accentuent ce phénomène en raison d'une excitation longitudinale plus importante, ce qui explique les oscillations plus visibles observées dans ce cas.

L'analyse comparative montre que la perturbation de pente induit principalement des écarts transitoires lors des phases dynamiques des cycles de conduite. Malgré cette sensibilité accrue, l'erreur maximale reste dans des plages acceptables pour l'ensemble des scénarios étudiés. L'algorithme RLS maintient une estimation globalement stable, avec des erreurs principalement transitoires lors des variations rapides de pente.

Ces résultats confirment que la pente longitudinale constitue une perturbation significative pour l'estimation de μ_r , en raison de son impact direct sur la composante gravitationnelle du modèle longitudinal. Néanmoins, la robustesse observée suggère que l'approche RLS demeure pertinente pour une estimation embarquée en conditions réelles incluant des variations topographiques, à condition de disposer d'une mesure fiable de la pente et d'un filtrage adapté des signaux dynamiques.

4.4.11 Cas 2C : Influence combinée de la V_{vent} et de la pente sur l'estimation de μ_r

Après l'analyse séparée de l'influence du vent et de la pente, cette section évalue le comportement de l'estimateur lorsque ces deux perturbations agissent simultanément. En conditions réelles, le véhicule peut être soumis à des variations aérodynamiques et topographiques qui complexifient la dynamique longitudinale.

L'objectif est d'évaluer l'impact conjoint de ces perturbations sur la précision, la stabilité et la convergence de l'estimateur RLS appliqué au coefficient μ_r .

1. **Cycle de conduite FTP75** : La Figure 4.17 présente l'évolution du coefficient de résistance au roulement estimé μ_r sur le cycle FTP75 en présence simultanée de perturbations de la vitesse du vent et de pente.




Figure 4.17 Estimation de μ_r sous perturbations combinées de V_{vent} et de pente pour le cycle de conduite FTP75 avec $\mu_{r,ref1} = 0.03$ et $\mu_{r,ref2} = 0.018$.

Les résultats montrent que l'estimation demeure globalement stable malgré la superposition des perturbations aérodynamiques et gravitationnelles. Les écarts observés restent principalement transitoires et apparaissent surtout durant les phases dynamiques du cycle FTP75, notamment lors des accélérations et décélérations rapides où la dynamique du véhicule varie fortement. Ces fluctuations s'expliquent par l'action simultanée du vent et de la pente, qui modifient conjointement les différentes composantes de force

appliquées au véhicule. Cette superposition rend le signal de régression plus sensible aux variations rapides du régime dynamique, ce qui entraîne des oscillations légèrement plus marquées sur le coefficient estimé.

Malgré ces conditions plus contraignantes, l'algorithme RLS conserve une bonne stabilité et maintient une convergence satisfaisante autour des valeurs de référence de μ_r . Après l'analyse des performances obtenues sur le cycle FTP75, l'étude est étendue au cycle de conduite EUDC afin d'évaluer le comportement de l'estimateur dans un contexte de conduite plus régulier et davantage représentatif de phases de roulage stabilisées.

2. **Cycle de conduite EUDC :** La Figure 4.18 présente l'évolution du coefficient de résistance au roulement estimé μ_r durant le cycle de conduite EUDC en présence simultanée de perturbations de vent et de pente. Cette configuration permet d'évaluer les performances de l'algorithme RLS dans des conditions de conduite plus réalistes, où les effets aérodynamiques et gravitationnels influencent conjointement la dynamique longitudinale du véhicule.

En raison des vitesses plus élevées du cycle EUDC, l'influence des forces aérodynamiques devient plus importante, ce qui complexifie l'estimation du coefficient μ_r . Malgré ces perturbations combinées, l'algorithme demeure capable de suivre correctement la valeur de référence, bien que certaines fluctuations apparaissent durant les phases transitoires. Les résultats obtenus confirment ainsi la robustesse de l'approche RLS dans des conditions de conduite extra-urbaines plus représentatives de la réalité.




Figure 4.18 Estimation de μ_r sous perturbations combinées de V_{vent} et de pente pour le cycle de conduite EUDC avec $\mu_{r,réf1} = 0.03$ et $\mu_{r,réf2} = 0.018$.

On observe à La Figure 4.18 que l'estimation du coefficient de résistance au roulement μ_r présente une stabilité accrue sur le cycle de conduite EUDC. la convergence est rapide, avec des fluctuations de faible amplitude, ce qui s'explique par le profil de vitesse plus régulier de ce cycle. Ces résultats confirment que, même en présence simultanée de perturbations aérodynamiques et topographiques, l'estimateur RLS conserve un comportement stable dans des conditions de roulage quasi stationnaires. Afin d'achever cette analyse, le cycle WLTC classe 3b est ensuite considéré.

3. **Cycle de conduite WLTC classe 3b** : La Figure 4.19 montre l'évolution du coefficient de résistance au roulement estimé μ_r sur le cycle WLTC classe 3b en conditions de perturbations simultanées de la vitesse du vent et de pente.




Figure 4.19 Estimation de μ_r sous perturbations combinées de V_{vent} et de pente pour le cycle de conduite WLTC classe 3b avec $\mu_{r,réf1} = 0.03$ et $\mu_{r,réf2} = 0.018$.

Dans le cas du cycle WLTC classe 3b, l'estimation du coefficient μ_r présente des fluctuations plus marquées, en particulier lors des phases d'accélération et de décélération rapides. La combinaison des effets aérodynamiques et gravitationnels accentue la variabilité des forces longitudinales, ce qui rend l'identification du paramètre plus sensible. Néanmoins, malgré ces conditions dynamiques sévères, l'estimateur RLS parvient à maintenir la convergence, avec une augmentation des fluctuations en régime transitoire démontrant ainsi la capacité d'adaptation de l'algorithme dans un

environnement de conduite fortement perturbé. Une excursion négative transitoire est toutefois observée, avec une valeur minimale d'environ $\hat{\mu}_r \approx -0.02$ pour $\mu_{r,\text{réf}2} = 0.018$, principalement lors des phases de transition rapides. Cette valeur négative peut être considérée comme physiquement aberrante, le coefficient de résistance au roulement étant par définition positif ; elle résulte principalement des effets transitoires du modèle et des variations rapides des forces longitudinales. Ce phénomène reste ponctuel et n'affecte pas la stabilité globale ni la capacité de suivi de l'estimateur.

Après l'analyse des résultats obtenus sur les cycles FTP75, EUDC et WLTC classe 3b, une analyse comparative globale est réalisée afin de synthétiser les performances de l'estimateur RLS en présence de perturbations combinées, comme présenté dans les Tableaux 4-6 et 4-7.

4.4.12 Analyse comparative des performances sous perturbations combinées de V_{vent} et de pente

Les Tableaux 4-6 et 4-7 présentent une synthèse comparative des performances de l'algorithme RLS pour l'estimation du coefficient de résistance au roulement μ_r en présence de perturbations combinées de vent et de pente sur les cycles de conduite WLTC classe 3b, EUDC et FTP75, en considérant deux valeurs de référence ($\mu_r = 0.03$ et $\mu_r = 0.018$). Cette analyse permet d'évaluer la précision, la stabilité et la rapidité de convergence de l'estimateur dans des conditions de fonctionnement représentatives de scénarios réels. Ces observations suggèrent que l'intégration d'une estimation conjointe des perturbations environnementales ou l'utilisation de méthodes plus avancées pourrait améliorer encore la robustesse de l'estimation en conditions réelles.

Tableau 4-6 Performances de l'estimation de $\mu_r = 0.03$ sous perturbations combinées de la V_{vent} et de pente.

Cycle	Condition	μ_r moyen	RMSE	Erreur max	Convergence	Stabilité
WLTC 3b	V_{vent} faible + pente	0.0295	0.002201	± 0.0030	Rapide	Stable
WLTC 3b	V_{vent} moyen + pente	0.0290	0.002163	± 0.0040	Modérée	Oscillations transitoires visibles
WLTC 3b	V_{vent} fort + pente	0.0285	0.002159	± 0.0060	Plus lente	Sensible aux oscillations
EUDC	V_{vent} faible + pente	0.0298	0.001725	± 0.0020	Rapide	Très stable
EUDC	V_{vent} moyen + pente	0.0294	0.002071	± 0.0030	Rapide	Stable
EUDC	V_{vent} fort + pente	0.0290	0.002209	± 0.0035	Modérée	Stable
FTP75	V_{vent} faible + pente	0.0296	0.000896	± 0.0025	Rapide	Stable
FTP75	V_{vent} moyen + pente	0.0290	0.001073	± 0.0035	Modérée	Stable
FTP75	V_{vent} fort + pente	0.0288	0.001139	± 0.0050	Plus lente	Oscillations transitoires visibles

Tableau 4-7 Performances de l'estimation de $\mu_r = 0.018$ sous perturbations combinées de la V_{vent} et de pente.

Cycle	Condition	μ_r moyen	RMSE	Erreur max	Convergence	Stabilité
WLTC 3b	V_{vent} faible + pente	0.0175	0.003451	± 0.0030	Rapide	Stable
WLTC 3b	V_{vent} moyen + pente	0.0170	0.002938	± 0.0040	Modérée	Oscillations visibles
WLTC 3b	V_{vent} fort + pente	0.0165	0.002816	± 0.0060	Plus lente	Sensible aux oscillations
EUDC	V_{vent} faible + pente	0.0178	0.003451	± 0.0020	Rapide	Très stable
EUDC	V_{vent} moyen + pente	0.0175	0.002043	± 0.0030	Rapide	Stable
EUDC	V_{vent} fort + pente	0.0172	0.002184	± 0.0035	Modérée	Stable
FTP75	V_{vent} faible + pente	0.0176	0.00691	± 0.0025	Rapide	Stable
FTP75	V_{vent} moyen + pente	0.0172	0.001041	± 0.0035	Modérée	Stable
FTP75	V_{vent} fort + pente	0.0170	0.001111	± 0.0050	Plus lente	Oscillations visibles

La qualité de l'identification du coefficient de résistance au roulement dépend fortement du niveau d'excitation persistante des signaux du système, condition nécessaire

pour garantir l'identifiabilité du paramètre estimé. Les cycles de conduite présentant des variations dynamiques marquées, telles que des accélérations, décélérations ou variations de charge longitudinale, fournissent généralement une excitation suffisante pour assurer une bonne identifiabilité du coefficient μ_r . À l'inverse, les phases de roulage quasi stationnaires réduisent l'identifiabilité du paramètre et peuvent entraîner une augmentation temporaire de la variance de l'estimation. Par ailleurs, lorsque les contributions aérodynamique et gravitationnelle deviennent dominantes, notamment à vitesse élevée ou en présence de variations significatives de pente, la séparation entre les différentes forces résistantes devient plus délicate. Cela peut se traduire par une augmentation transitoire de la variance de l'estimation du coefficient μ_r .

Interprétation physique et interaction des perturbations : La combinaison simultanée de la vitesse du vent et de la pente agit sur deux composantes distinctes du modèle longitudinal : la force aérodynamique $F_{\text{aero}} = \frac{1}{2}\rho C_{\text{aero}} A_f (V_x + V_{\text{vent}})^2$ et la composante gravitationnelle $F_{\text{pente}} = mg \sin(\lambda)$. Leur superposition accroît la variabilité des forces longitudinales et complexifie la séparation entre les contributions résistantes (roulement, aérodynamique et pente) dans le signal de régression utilisé par le RLS.

D'un point de vue identification, la présence simultanée de plusieurs perturbations augmente la corrélation entre les termes du modèle et peut dégrader le conditionnement du problème, ce qui se traduit par une augmentation de la variance de l'estimation. Cet effet est particulièrement visible pour le cycle WLTC classe 3b, dont la dynamique plus agressive amplifie les fluctuations et ralentit légèrement la convergence lorsque l'intensité du vent augmente.

Malgré cette complexité accrue, l'erreur maximale demeure contenue dans des marges acceptables pour l'ensemble des cycles et pour les deux valeurs de référence.

L'estimateur conserve une convergence stable sans divergence, confirmant la robustesse globale du RLS face à des perturbations multiples et représentatives de conditions réelles.

4.4.13 Limites de la méthode RLS

Malgré sa simplicité d'implémentation et sa capacité d'adaptation en temps réel, la méthode RLS présente certaines limites. Sa performance dépend fortement de la qualité des signaux : la présence de bruit peut engendrer des oscillations et une perte de précision. De plus, l'hypothèse d'une variation lente du paramètre estimé peut entraîner un retard de convergence lors de changements rapides des conditions de roulement.

Le réglage du facteur d'oubli et de la covariance initiale conditionne également le compromis entre rapidité d'adaptation et stabilité. Par ailleurs, l'utilisation d'un modèle longitudinal simplifié peut introduire des biais liés à des phénomènes non linéaires ou à des incertitudes de modélisation. L'absence de contrainte explicite sur μ_r peut aussi conduire à des estimations transitoires non physiques, comme observé dans certaines simulations. Dans une perspective embarquée, l'ajout d'une saturation physique (par exemple $\hat{\mu}_r \leftarrow \max(\hat{\mu}_r, 0)$) permettrait d'éviter ces valeurs aberrantes.

Malgré ces limitations, le RLS demeure une solution pertinente pour l'estimation embarquée grâce à sa faible complexité et à sa facilité d'intégration. Des approches hybrides ou probabilistes, ainsi que l'introduction de contraintes physiques, constituent des pistes d'amélioration pour renforcer la robustesse en conditions réelles.

4.5 Conclusion

Ce chapitre a permis de valider, par simulation numérique, la pertinence de l'algorithme RLS pour l'estimation en ligne du coefficient de résistance au roulement μ_r .

Les résultats obtenus montrent que :

- l'estimateur converge rapidement vers les valeurs de référence en conditions idéales ;
- la présence de vent entraîne une augmentation modérée de la dispersion de l'estimation sans compromettre la stabilité ;
- les variations de pente induisent des transitoires plus marqués, mais restent compensées efficacement ;
- la combinaison des perturbations de vent et de pente accentue la sensibilité dynamique du système sans provoquer de divergence de l'estimation.

L'analyse montre que la qualité de l'estimation dépend fortement de l'excitation du système et de la qualité des signaux utilisés. Malgré quelques excursions transitoires non physiques, l'algorithme demeure globalement stable. Ces résultats, obtenus en simulation, nécessitent toutefois une validation expérimentale afin de confirmer la robustesse de l'approche face aux incertitudes de mesure et aux effets non modélisés. Dans l'ensemble, l'algorithme RLS permet une estimation fiable du coefficient μ_r , compatible avec une application embarquée.

Chapitre 5 - Conclusion

5.1 Résultats principaux

Les résultats obtenus confirment la pertinence de l'estimation en ligne du coefficient de résistance au roulement μ_r . L'approche basée sur les moindres carrés récursifs (RLS) permet d'obtenir une estimation fiable, stable et compatible avec une implémentation en temps réel. L'algorithme présente une bonne capacité de convergence et de suivi, aussi bien en conditions idéales que dans des scénarios intégrant des perturbations réalistes telles que le vent et la pente longitudinale.

L'analyse des différents cycles de conduite met en évidence l'influence déterminante de la dynamique du profil de vitesse sur la qualité de l'estimation. Les phases dynamiques (accélération et décélération) améliorent l'identifiabilité du paramètre μ_r , tandis que les régimes quasi stationnaires peuvent dégrader la précision en raison d'un manque d'excitation du système. Ces résultats confirment l'importance des conditions d'exploitation dans les performances des méthodes d'estimation paramétrique.

Par ailleurs, l'intégration de perturbations environnementales réalistes a permis de renforcer la validité des résultats et de rapprocher l'étude des conditions réelles d'utilisation. L'estimation de μ_r s'inscrit directement dans les problématiques d'optimisation énergétique des véhicules électriques et hybrides, où la réduction des pertes de roulement constitue un enjeu majeur pour l'autonomie et l'efficacité globale.

Malgré les performances obtenues, plusieurs limites doivent être soulignées. L'estimateur RLS repose sur un modèle longitudinal supposant une connaissance parfaite de certains paramètres (masse, coefficient aérodynamique, pente de la route). En conditions réelles, ces grandeurs sont entachées d'incertitudes susceptibles de dégrader

la qualité de l'estimation.

La méthode RLS est également sensible au bruit de mesure, en particulier lorsque l'accélération longitudinale est obtenue par dérivation numérique de la vitesse. Un filtrage insuffisant peut induire des fluctuations parasites dans l'estimation de μ_r . De plus, l'algorithme nécessite une excitation persistante du système pour garantir l'identifiabilité du paramètre. En conduite quasi stationnaire sur route plane, l'estimation devient plus sensible aux perturbations et aux bruits.

Une incohérence physique a également été observée dans certains régimes transitoires, où des valeurs négatives de $\hat{\mu}_r$ apparaissent ponctuellement. Bien que sans impact sur la convergence globale, ces valeurs restent physiquement irréalistes. Une amélioration consisterait à intégrer explicitement des contraintes physiques dans le processus d'estimation (RLS contraint), afin de garantir la positivité du paramètre sans recourir à une saturation a posteriori.

Enfin, la validation réalisée dans ce mémoire repose uniquement sur des simulations numériques. Bien que représentatives, ces conditions ne permettent pas de reproduire l'ensemble des phénomènes rencontrés en situation réelle, tels que les bruits capteurs corrélés, les délais de mesure ou les variations non modélisées des paramètres.

5.2 Recommandations et perspectives

Vers une validation expérimentale

Une première perspective concerne la validation expérimentale sur véhicule réel ou plateforme robotique mobile. Cette étape permettrait d'évaluer la robustesse de l'algorithme face aux incertitudes de mesure et aux perturbations non modélisées, tout en confirmant les performances observées en simulation. Un véhicule instrumenté équipé

de capteurs inertiels et d'un système d'acquisition des données constituerait un support adapté pour cette validation.

Estimation conjointe et filtrage avancé

Une seconde perspective porte sur l'estimation conjointe de plusieurs paramètres influençant la dynamique longitudinale, tels que la masse du véhicule, la pente ou les coefficients aérodynamiques. L'intégration d'approches multi-paramétriques permettrait de réduire les biais liés aux hypothèses de paramètres constants. Par ailleurs, le couplage du RLS avec des méthodes de filtrage avancées, telles que les filtres de Kalman étendu (EKF) ou unscented (UKF), constitue une voie prometteuse pour améliorer la robustesse en présence de non-linéarités et de bruit.

Approches hybrides et intelligence artificielle

L'intégration de techniques d'intelligence artificielle, notamment les approches hybrides combinant modèles physiques et apprentissage automatique, représente également une perspective intéressante. Ces méthodes pourraient améliorer la capacité de généralisation de l'estimateur et compenser certaines limitations des modèles analytiques, en particulier dans des environnements complexes ou fortement variables.

Implémentation embarquée

Enfin, une implémentation sur cible embarquée (microcontrôleur, système temps réel ou FPGA) constituerait une étape essentielle pour valider les performances en conditions opérationnelles. Des tests en boucle fermée permettraient d'évaluer l'apport de l'estimation de μ_r pour l'adaptation des lois de commande et l'optimisation énergétique.

En définitive, ce travail démontre que l'estimation en ligne du coefficient de résistance au

roulement μ_r constitue un levier pertinent pour améliorer la modélisation et le contrôle des véhicules, tout en ouvrant la voie à des stratégies d'adaptation énergétique avancées dans des environnements réels complexes.

Références

- [1] A. Ghobadpour, G. Monsalve, A. Cardenas, and H. Mousazadeh, “Off-road electric vehicles and autonomous robots in agricultural sector: Trends, challenges, and opportunities,” *Vehicles*, vol. 4, no. 3, pp. 843–864, Sep. 2022. [Online]. Available: <https://doi.org/10.3390/vehicles4030047>
- [2] F. Andriaminahy, A. Amamou, S. Kelouwani, N. Zioui, A. Ghobadpour, and K. Agbossou, “Comparative study of vehicle aerodynamic and rolling resistance coefficients estimation methods,” in *2019 IEEE Vehicle Power and Propulsion Conference (VPPC)*, IEEE. Hanoi, Vietnam: IEEE, Oct. 2019, pp. 1–5, 14–17 October 2019. [Online]. Available: <https://doi.org/10.1109/VPPC46532.2019.8952491>
- [3] R. Manca, E. Tramacere, S. Favelli, A. Tonoli, and L. Camosi, “Impact of rolling resistance modeling on energy consumption for a low voltage battery electric vehicle,” in *2023 International Symposium on Electromobility (ISEM)*, IEEE. Monterrey, Mexico: IEEE, Oct. 2023, pp. 1–6. [Online]. Available: <https://doi.org/10.1109/ISEM59023.2023.10334888>
- [4] J. Zhao, J. Zhang, and B. Zhu, “Development and verification of the tire/road friction estimation algorithm for antilock braking system,” *Mathematical Problems in Engineering*, vol. 2014, no. 1, p. 786492, Aug. 2014. [Online]. Available: <https://doi.org/10.1155/2014/786492>
- [5] G. Klancar, D. Matko, and S. Blazic, “Mobile robot control on a reference path,” in *Proceedings of the 2005 IEEE International Symposium on Intelligent Control and Mediterranean Conference on Control and Automation*, IEEE. Limassol, Cyprus: IEEE, Jun. 2005, pp. 1343–1348, 27–29 June 2005. [Online]. Available: <https://doi.org/10.1109/MED.2005.1467211>
- [6] G. Reina, L. Ojeda, A. Milella, and J. Borenstein, “Wheel slippage and sinkage detection for planetary rovers,” *IEEE/ASME Transactions on Mechatronics*, vol. 11, no. 2, pp. 185–195, Apr. 2006. [Online]. Available: <https://doi.org/10.1109/TMECH.2006.871095>
- [7] G. Paterlini, S. Yucel, M. M. Lucking, and J. Magnuson, “Rolling resistance validation,” Minnesota Department of Transportation, St. Paul, MN, USA, Tech. Rep. MN/RC 2015-15, May 2015. [Online]. Available: <https://www.dot.state.mn.us/research/reports/2015/201515.pdf>
- [8] C. C. Ward and K. Iagnemma, “A dynamic-model-based wheel slip detector for mobile robots on outdoor terrain,” *IEEE Transactions on Robotics*, vol. 24, no. 4, pp. 821–831, Aug. 2008. [Online]. Available: <https://doi.org/10.1109/TRO.2008.924945>
- [9] M. Bersani, M. Vignati, S. Mentasti, S. Arrigoni, and F. Cheli, “Vehicle state estimation based on kalman filters,” in *2019 AEIT International Conference of Electrical and Electronic Technologies for Automotive (AEIT AUTOMOTIVE)*,

- AEIT and IEEE. Turin, Italy: IEEE, Jul. 2019, pp. 1–6, 02–04 July 2019. [Online]. Available: <https://doi.org/10.23919/EETA.2019.8804527>
- [10] J. Hu, S. Rakheja, and Y. Zhang, “Tire–road friction coefficient estimation based on designed braking pressure pulse,” *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, vol. 235, no. 7, pp. 1876–1891, Jun. 2021. [Online]. Available: <https://doi.org/10.1177/0954407020974801>
- [11] J. Wang, L. Alexander, and R. Rajamani, “Friction estimation on highway vehicles using longitudinal measurements,” *Journal of Dynamic Systems, Measurement, and Control*, vol. 126, no. 2, pp. 265–275, Aug. 2004. [Online]. Available: <https://doi.org/10.1115/1.1766028>
- [12] C. R. Birkel, M. R. Roberts, E. McTurk, P. G. Bruce, and D. A. Howey, “Degradation diagnostics for lithium-ion cells,” *Journal of Power Sources*, vol. 341, no. 1, pp. 373–386, Feb. 2017. [Online]. Available: <https://doi.org/10.1016/j.jpowsour.2016.12.011>
- [13] 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)*, IEEE. Hangzhou, China: IEEE, Oct. 2016, pp. 1–6, 17–20 October 2016. [Online]. Available: <https://doi.org/10.1109/VPPC.2016.7791630>
- [14] A. Nishio, K. Tozu, H. Yamaguchi, K. Asano, and Y. Amano, “Development of vehicle stability control system based on vehicle sideslip angle estimation,” *SAE Transactions*, vol. 110, no. 6, pp. 115–122, Mar. 2001. [Online]. Available: <https://doi.org/10.4271/2001-01-0137>
- [15] J. Dakhilallah, S. Glaser, S. Mammar, and Y. Sebsadji, “Tire-road forces estimation using extended kalman filter and sideslip angle evaluation,” in *2008 American Control Conference*, IEEE. Seattle, WA, USA: IEEE, Jun. 2008, pp. 4597–4602, 11–13 June 2008. [Online]. Available: <https://doi.org/10.1109/ACC.2008.4587220>
- [16] K. Han, Y. Hwang, E. Lee, and S. Choi, “Robust estimation of maximum tire-road friction coefficient considering road surface irregularity,” *International Journal of Automotive Technology*, vol. 17, no. 3, pp. 415–425, Jun. 2016. [Online]. Available: <https://doi.org/10.1007/s12239-016-0041-5>
- [17] R. Rajamani, N. Piyabongkarn, J. Lew, K. Yi, and G. Phanomchoeng, “Tire-road friction-coefficient estimation,” *IEEE Control Systems Magazine*, vol. 30, no. 4, pp. 54–69, Aug. 2010. [Online]. Available: <https://doi.org/10.1109/MCS.2010.937006>
- [18] A. Bhattacharjee, A. Verma, S. Mishra, and T. K. Saha, “Estimating state of charge for xev batteries using 1d convolutional neural networks and transfer learning,” *IEEE Transactions on Vehicular Technology*, vol. 70, no. 4, pp. 3123–3135, Apr. 2021. [Online]. Available: <https://doi.org/10.1109/TVT.2021.3064287>
- [19] Y.-Q. Zhao, H.-Q. Li, F. Lin, J. Wang, and X.-W. Ji, “Estimation of road friction coefficient in different road conditions based on vehicle braking dynamics,” *Chinese*

- Journal of Mechanical Engineering*, vol. 30, no. 4, pp. 982–990, Jul. 2017. [Online]. Available: <https://doi.org/10.1007/s10033-017-0146-7>
- [20] D. E. Hall and J. C. Moreland, “Fundamentals of rolling resistance,” *Rubber Chemistry and Technology*, vol. 74, no. 3, pp. 525–539, Jul. 2001. [Online]. Available: <https://doi.org/10.5254/1.3547647>
 - [21] R. Rajamani, G. Phanomchoeng, D. Piyabongkarn, and J. Y. Lew, “Algorithms for real-time estimation of individual wheel tire-road friction coefficients,” *IEEE/ASME Transactions on Mechatronics*, vol. 17, no. 6, pp. 1183–1195, Dec. 2012. [Online]. Available: <https://doi.org/10.1109/TMECH.2011.2159240>
 - [22] S. Tao, Z. Ju, L. Li, H. Zhang, and W. Pedrycz, “Tire road friction coefficient estimation for individual wheel based on two robust pmi observers and a multilayer perceptron,” *IEEE Transactions on Vehicular Technology*, vol. 73, no. 9, pp. 12 530–12 541, Sep. 2024. [Online]. Available: <https://doi.org/10.1109/TVT.2024.3398294>
 - [23] G. Erdogan, L. Alexander, and R. Rajamani, “Estimation of tire-road friction coefficient using a novel wireless piezoelectric tire sensor,” *IEEE Sensors Journal*, vol. 11, no. 2, pp. 267–279, Feb. 2011. [Online]. Available: <https://doi.org/10.1109/JSEN.2010.2053198>
 - [24] M. Batra, J. McPhee, and N. L. Azad, “Parameter identification for a longitudinal dynamics model based on road tests of an electric vehicle,” in *ASME 2016 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference*, vol. 50138, American Society of Mechanical Engineers (ASME). Charlotte, NC, USA: ASME, Aug. 2016, p. V003T01A026, 21–24 August 2016. [Online]. Available: <https://doi.org/10.1115/DETC2016-59680>
 - [25] S. Das *et al.*, “Vehicle dynamics modelling: Lateral and longitudinal,” in *2021 8th International Conference on Signal Processing and Integrated Networks (SPIN)*, IEEE. Noida, India: IEEE, Aug. 2021, pp. 407–412, 26–27 August 2021. [Online]. Available: <https://doi.org/10.1109/SPIN52536.2021.9566082>
 - [26] M. Wielitzka, A. Busch, M. Dagen, and T. Ortmaier, “Estimation in vehicle dynamics,” in *Kalman Filters: Theory for Advanced Applications*. London, UK: IntechOpen, Jan. 2018, pp. 55–78. [Online]. Available: <https://doi.org/10.5772/intechopen.69424>
 - [27] S. Hong, G. Erdogan, K. Hedrick, and F. Borrelli, “Tyre–road friction coefficient estimation based on tyre sensors and lateral tyre deflection: Modelling, simulations and experiments,” *Vehicle System Dynamics*, vol. 51, no. 5, pp. 627–647, May 2013. [Online]. Available: <https://doi.org/10.1080/00423114.2012.755168>
 - [28] O. Trigui, E. Mejri, Y. Dube, S. Kelouwani, and K. Agbossou, “Energy efficient routing estimation in electric vehicle with online rolling resistance estimation,” in *2017 IEEE Vehicle Power and Propulsion Conference (VPPC)*, IEEE. Belfort,

- France: IEEE, Dec. 2017, pp. 1–6, 11–14 December 2017. [Online]. Available: <https://doi.org/10.1109/VPPC.2017.8330912>
- [29] S. Rhode and F. Gauterin, “Online estimation of vehicle driving resistance parameters with recursive least squares and recursive total least squares,” in *2013 IEEE Intelligent Vehicles Symposium (IV)*, IEEE. Gold Coast, QLD, Australia: IEEE, Jun. 2013, pp. 269–276, 23–26 June 2013. [Online]. Available: <https://doi.org/10.1109/IVS.2013.6629481>
- [30] L. Shi, L. Shen, and B. Chen, “Complementary mean square deviation and stability analyses of the widely linear recursive least squares algorithm,” *Digital Signal Processing*, vol. 122, p. 103357, Mar. 2022. [Online]. Available: <https://doi.org/10.1016/j.dsp.2021.103357>
- [31] L. Luo, P. Guo, Y. Yu, H. He, and R. de Lamare, “Robust widely linear complex-valued combined step-size algorithm for beamforming,” in *2024 19th International Symposium on Wireless Communication Systems (ISWCS)*, IEEE. Bologna, Italy: IEEE, Sep. 2024, pp. 1–6, 17–20 September 2024. [Online]. Available: <https://doi.org/10.1109/ISWCS61526.2024.10694241>
- [32] K. Zhu, C. Yu, and Y. Wan, “Recursive least squares identification with variable-direction forgetting via oblique projection decomposition,” *IEEE/CAA Journal of Automatica Sinica*, vol. 9, no. 3, pp. 547–555, Mar. 2022. [Online]. Available: <https://doi.org/10.1109/JAS.2021.1004362>
- [33] Z. Li, P. Guo, T. Yang, K. Li, and Y. Yu, “Switching step-size based widely linear adaptive filtering algorithms,” *Circuits, Systems, and Signal Processing*, vol. 43, no. 11, pp. 7401–7421, Nov. 2024. [Online]. Available: <https://doi.org/10.1007/s00034-024-02768-0>
- [34] M. Z. A. Bhotto and A. Antoniou, “New improved recursive least-squares adaptive-filtering algorithms,” *IEEE Transactions on Circuits and Systems I: Regular Papers*, vol. 60, no. 6, pp. 1548–1558, Jun. 2013. [Online]. Available: <https://doi.org/10.1109/TCSI.2012.2227335>
- [35] Z. Bei, X. Chen, W. Zhao, and C. Wang, “A novel algorithm for tire-road friction coefficient estimation using adaptive backpropagation neural network,” *Journal of Physics: Conference Series*, vol. 2832, no. 1, p. 012018, May 2024. [Online]. Available: <https://doi.org/10.1088/1742-6596/2832/1/012018>
- [36] Y. Sun, L. Li, B. Yan, C. Yang, and G. Tang, “A hybrid algorithm combining ekf and rls in synchronous estimation of road grade and vehicle mass for a hybrid electric bus,” *Mechanical Systems and Signal Processing*, vol. 68, pp. 416–430, Feb. 2016. [Online]. Available: <https://doi.org/10.1016/j.ymssp.2015.07.011>
- [37] C. Beckers, I. Besselink, and H. Nijmeijer, “Combined rolling resistance and road grade estimation based on ev powertrain data,” *IEEE Transactions on Vehicular Technology*, vol. 72, no. 3, pp. 3201–3213, Mar. 2023. [Online]. Available: <https://doi.org/10.1109/TVT.2022.3220157>

- [38] R. Arablouei and K. I. Dogancay, "Reduced-complexity constrained recursive least-squares adaptive filtering algorithm," *IEEE Transactions on Signal Processing*, vol. 60, no. 12, pp. 6687–6692, Dec. 2012. [Online]. Available: <https://doi.org/10.1109/TSP.2012.2212899>
- [39] C. Lee, J. K. Hedrick, and K. Yi, "Real-time slip-based estimation of maximum tire-road friction coefficient," *IEEE/ASME Transactions on Mechatronics*, vol. 9, no. 2, pp. 454–458, Jun. 2004. [Online]. Available: <https://doi.org/10.1109/TMECH.2004.828622>
- [40] Q. Song, Y. Mi, and W. Lai, "A novel variable forgetting factor recursive least square algorithm to improve the anti-interference ability of battery model parameters identification," *IEEE Access*, vol. 7, pp. 61 548–61 557, May 2019. [Online]. Available: <https://doi.org/10.1109/ACCESS.2019.2903625>
- [41] Z. Zhou, Y. Wang, X. Liu, Z. Li, M. Wu, and G. Zhou, "Hybrid of neural network and physics-based estimator for vehicle longitudinal dynamics modeling using limited driving data," *IEEE Transactions on Intelligent Transportation Systems*, vol. 26, no. 10, pp. 16 735–16 746, Oct. 2025. [Online]. Available: <https://doi.org/10.1109/TITS.2025.3585346>
- [42] I. Uva, J. Santos, V. Cerezo, and S. Miller, "A machine learning approach for predictive modelling of rolling resistance of passenger cars," *International Journal of Pavement Engineering*, vol. 26, no. 1, p. 2553717, Jan. 2025. [Online]. Available: <https://doi.org/10.1080/10298436.2025.2553717>
- [43] M. Chandrasekaran and P. K. Rajesh, "Real-time mass estimation of connected commercial vehicle using artificial neural network model," *Indian Journal of Engineering and Materials Sciences (IJEMS)*, vol. 31, no. 3, pp. 358–373, Jun. 2024. [Online]. Available: <https://doi.org/10.56042/ijems.v31i3.6613>
- [44] A. M. Ribeiro, A. Moutinho, A. R. Fioravanti, and E. C. de Paiva, "Estimation of tire–road friction for road vehicles: A time delay neural network approach," *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, vol. 42, no. 1, p. 4, Jan. 2020. [Online]. Available: <https://doi.org/10.1007/s40430-019-2113-6>
- [45] K. Koysuren, A. F. Keles, and M. Cakmakci, "Online parameter estimation using physics-informed deep learning for vehicle stability algorithms," *arXiv*, vol. 2303, no. 00474, Mar. 2023. [Online]. Available: <https://doi.org/10.48550/arXiv.2303.00474>
- [46] A. Zareian, S. Azadi, and R. Kazemi, "Estimation of road friction coefficient using extended kalman filter, recursive least square, and neural network," *Proceedings of the Institution of Mechanical Engineers, Part K: Journal of Multi-Body Dynamics*, vol. 230, no. 1, pp. 52–68, Mar. 2016. [Online]. Available: <https://doi.org/10.1177/1464419315596306>
- [47] S. Asif Imran, M. Barman, S. Commuri, M. Zaman, and M. Nazari, "Artificial neural network–based intelligent compaction analyzer for real-time estimation of subgrade

- quality,” *International Journal of Geomechanics*, vol. 18, no. 6, p. 04018048, Jun. 2018. [Online]. Available: [https://doi.org/10.1061/\(ASCE\)GM.1943-5622.0001135](https://doi.org/10.1061/(ASCE)GM.1943-5622.0001135)
- [48] P. Farhadi, A. Golmohammadi, A. S. Malvajerdi, and G. Shahgholi, “Prediction of the tractor tire contact area, contact volume and rolling resistance using regression model and artificial neural network,” *Agricultural Engineering International: CIGR Journal*, vol. 21, no. 3, pp. 26–38, Sep. 2019. [Online]. Available: <https://cigrjournal.org/index.php/Ejournal/article/view/5300>
- [49] H. Lim, J. W. Lee, J. Boyack, and J. B. Choi, “Ev-pinn: A physics-informed neural network for predicting electric vehicle dynamics,” *arXiv*, vol. 2411, no. 14691, Nov. 2024. [Online]. Available: <https://doi.org/10.48550/arXiv.2411.14691>
- [50] O. Alexa, C. O. Ilie, R. Vilău, M. Marinescu, and M. Truta, “Using neural networks to modeling vehicle dynamics,” *Applied Mechanics and Materials*, vol. 659, pp. 133–138, Oct. 2014. [Online]. Available: <https://doi.org/10.4028/www.scientific.net/AMM.659.133>
- [51] L. R. Ray, “Experimental determination of tire forces and road friction,” in *Proceedings of the 1998 American Control Conference*, vol. 3, IEEE. Philadelphia, PA, USA: IEEE, Jun. 1998, pp. 1843–1847, 24–26 June 1998. [Online]. Available: <https://doi.org/10.1109/ACC.1998.707336>
- [52] S. Eicke, A. Busch, M. Wielitzka, S. Zemke, A. Trabelsi, M. Dagen, and T. Ortmaier, “Tire road friction estimation for improvements to traction control during drive off maneuvers in vehicles,” in *2016 IEEE Conference on Control Applications (CCA)*, IEEE. Buenos Aires, Argentina: IEEE, Sep. 2016, pp. 917–922, 19–22 September 2016. [Online]. Available: <https://doi.org/10.1109/CCA.2016.7587930>
- [53] Y. Liu, D. Cui, and W. Peng, “Vehicle state and parameter estimation based on improved extended kalman filter,” *Journal of Measurements in Engineering*, vol. 11, no. 4, pp. 496–508, Dec. 2023. [Online]. Available: <https://doi.org/10.21595/jme.2023.23642>
- [54] R. Zhang and E. Yao, “Electric vehicles’ energy consumption estimation with real driving condition data,” *Transportation Research Part D: Transport and Environment*, vol. 41, no. 1, pp. 177–187, Dec. 2015. [Online]. Available: <https://doi.org/10.1016/j.trd.2015.10.010>
- [55] S. Antonov, A. Fehn, and A. Kugi, “Unscented kalman filter for vehicle state estimation,” *Vehicle System Dynamics*, vol. 49, no. 9, pp. 1497–1520, Sep. 2011. [Online]. Available: <https://doi.org/10.1080/00423114.2010.518124>
- [56] S. Buggaveeti, M. Batra, J. McPhee, and N. Azad, “Longitudinal vehicle dynamics modeling and parameter estimation for plug-in hybrid electric vehicle,” *SAE International Journal of Vehicle Dynamics, Stability, and NVH*, vol. 1, no. 1, pp. 289–297, Mar. 2017. [Online]. Available: <https://doi.org/10.4271/2017-01-1574>
- [57] M. C. Best, T. J. Gordon, and P. J. Dixon, “An extended adaptive kalman filter for real-time state estimation of vehicle handling dynamics,” *Vehicle*

- System Dynamics*, vol. 34, no. 1, pp. 57–75, Jul. 2000. [Online]. Available: <https://doi.org/10.1076/vesd.34.1.57.2041>
- [58] M. Doumiati, A. Victorino, A. Charara, and D. Lechner, “Estimation of vehicle lateral tire-road forces: A comparison between extended and unscented kalman filtering,” in *2009 European Control Conference (ECC)*, IEEE. Budapest, Hungary: IEEE, Aug. 2009, pp. 4804–4809, 23–26 August 2009. [Online]. Available: <https://doi.org/10.23919/ECC.2009.7074996>
- [59] R. Nikoukhah, P. Misra, and J. J. Deyst, “Kalman filtering and parameter estimation for nonlinear systems: Application to tire-road friction estimation,” *IEEE Transactions on Control Systems Technology*, vol. 3, no. 1, pp. 123–129, Mar. 1995. [Online]. Available: <https://doi.org/10.1109/87.368065>
- [60] K. T. Lee, M. J. Dai, and C. C. Chuang, “Temperature-compensated model for lithium-ion polymer batteries with extended kalman filter state-of-charge estimation for an implantable charger,” *IEEE Transactions on Industrial Electronics*, vol. 65, no. 1, pp. 589–596, Jan. 2018. [Online]. Available: <https://doi.org/10.1109/TIE.2017.2721880>
- [61] S. Feng, X. Li, S. Zhang, Z. Jian, H. Duan, and Z. Wang, “A review: State estimation based on hybrid models of kalman filter and neural network,” *Systems Science & Control Engineering*, vol. 11, no. 1, p. 2173682, Jan. 2023. [Online]. Available: <https://doi.org/10.1080/21642583.2023.2173682>
- [62] Y. Wang, G. Yin, P. Hang, J. Zhao, Y. Lin, and C. Huang, “Fundamental estimation for tire road friction coefficient: A model-based learning framework,” *IEEE Transactions on Vehicular Technology*, vol. 74, no. 1, pp. 481–493, Jan. 2024. [Online]. Available: <https://doi.org/10.1109/TVT.2024.3474203>
- [63] F. Z. Amirhosseini, B. Ghorbani Vaghei, and H. Bolandi, “Dynamic modeling of trains for application in railway transportation automation systems,” *Transactions on Machine Intelligence*, vol. 7, no. 1, pp. 23–37, Jan. 2024. [Online]. Available: <https://doi.org/10.22063/TOMI.2024.20856>
- [64] Y. Suo, D. Lu, H. Wu, Y. Zhang, and T. Zhou, “Tire-road friction coefficient estimation of sideslip-camber combined situation,” in *2024 IEEE 99th Vehicular Technology Conference (VTC2024-Spring)*, IEEE. Singapore: IEEE, Jun. 2024, pp. 1–7, 24–27 June 2024. [Online]. Available: <https://doi.org/10.1109/VTC2024-Spring62846.2024.10683382>
- [65] T. Zhu and C. Zong, “The road friction coefficient estimation based on extended kalman filter,” in *2009 International Workshop on Intelligent Systems and Applications*, IEEE. Wuhan, China: IEEE, May 2009, pp. 1–4, 23–24 May 2009. [Online]. Available: <https://doi.org/10.1109/IWISA.2009.5073206>
- [66] C. Kamali, A. A. Pashilkar, and J. R. Raol, “Evaluation of recursive least squares algorithm for parameter estimation in aircraft real time applications,” *Aerospace Science and Technology*, vol. 15, no. 3, pp. 165–174, Apr. 2011. [Online]. Available: <https://doi.org/10.1016/j.ast.2010.07.002>

- [67] A. Madhukar, B. Shashank, and M. Anup, "Estimation of tire-road friction coefficient using a recursive least squares approach," *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, vol. 233, no. 9, pp. 2356–2368, Aug. 2019. [Online]. Available: <https://doi.org/10.1177/0954407019832467>
- [68] L. Cheng, G. Wang, W.-K. Cao, and F.-J. Zhou, "Real-time estimation of road friction coefficient for the electric vehicle," in *2012 Third World Congress on Software Engineering*, IEEE. Wuhan, China: IEEE, Nov. 2012, pp. 172–175, 06–08 November 2012. [Online]. Available: <https://doi.org/10.1109/WCSE.2012.41>
- [69] Z. El-Sayegh and M. El-Gindy, "Rolling resistance prediction of off-road tire using advanced simulation and analytical techniques," *SN Applied Sciences*, vol. 2, no. 9, p. 1620, Sep. 2020. [Online]. Available: <https://doi.org/10.1007/s42452-020-03441-8>
- [70] M. Dan and S. Oprea, "Estimation of tire friction coefficient using adaptive rls methods," *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, vol. 231, no. 10, pp. 1348–1358, Aug. 2017. [Online]. Available: <https://doi.org/10.1177/0954407016684529>