

UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

PLANIFICATION DE MOUVEMENT ÉCO-ÉNERGÉTIQUE POUR  
VÉHICULES AUTONOMES INTÉRIEURS UTILISANT DES  
RÉSEAUX DE NEURONES PROFONDS ET MODÈLES  
CINÉTIQUES

THÈSE PRÉSENTÉE  
COMME EXIGENCE PARTIELLE DU  
DOCTORAT EN GÉNIE MÉCANIQUE

PAR  
MOHAMMAD MOHAMMADPOUR

FÉVRIER 2024

Université du Québec à Trois-Rivières

Service de la bibliothèque

Avertissement

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

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

# UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

DOCTORAT EN GÉNIE MECHANIC (PH.D.)

## Direction de recherche :

---

Prof. Sousso KELOUWANI

Directeur de recherche

---

Prof. Marc-André GAUDREAU

Codirecteur de recherche

## Jury d'évaluation :

---

Prof. Sousso KELOUWANI

Directeur de recherche

---

Prof. Marc-André GAUDREAU

Codirecteur de recherche

---

Prof. Marie HÉBERT

Président du jury

---

Prof. Sasan SATTARPANAH KARGANROUDI

Évaluateur interne

---

Prof. Jerome LE NY

Évaluateur externe

Thèse soutenue le 29 Janvier 2024

## Remerciements

Commencer mon doctorat a été une expérience qui a changé ma vie, pleine de nouvelles découvertes. Je n'aurais pas pu le faire sans le soutien solide et les bons conseils de nombreuses personnes.

Tout d'abord, je suis très reconnaissante à mon directeur de thèse, le Prof. Sousso Kelouwani. Son soutien constant, sa sagesse et ses encouragements ont été la clé de ma réussite. Sa patience et ses conseils avisés m'ont guidée tout au long de mes études et de mes recherches. Je suis également reconnaissant à mon co-superviseur, le Prof. Marc-André Gaudreau, pour les conseils utiles qu'il m'a prodigués tout au long de mes recherches et de la rédaction de ma thèse. Leur enseignement combiné a grandement enrichi mon parcours doctoral et je leur en suis éternellement reconnaissant.

Le financement du Conseil de recherches en sciences naturelles et en génie du Canada et de la Chaire de recherche industrielle Noovelia a été crucial. Il m'a permis de me concentrer pleinement sur mes recherches sans me soucier de l'argent.

Je remercie également mes collègues de l'Institut de Recherche sur l'Hydrogène (IRH). Leur amitié et l'aide qu'ils m'ont apportée de diverses manières ont amélioré l'expérience de mon doctorat.

Je remercie tout particulièrement ma merveilleuse épouse, dont l'amour et le soutien constants m'ont accompagné tout au long de ce voyage. Chaque étape a été une expérience partagée. La confiance qu'elle m'a témoignée a été la base qui m'a permis d'entamer ce voyage difficile.

Enfin, je dois beaucoup à ma famille pour son soutien spirituel sans faille. Mes parents et ma sœur ont été mon principal soutien depuis mes premières années d'études jusqu'à aujourd'hui. C'est à eux que je dois tous mes succès et c'est à eux que je dédie ce travail.

## Résumé

L'adoption croissante des concepts de l'Industrie 4.0 au Canada, particulièrement dans la province du Québec, a vu le développement d'usines intelligentes révolutionnant le paysage manufacturier. Un composant central de ces usines avancées est les Véhicules Autonomes Intérieurs (VAI), utilisés principalement pour les tâches de transport de charges. Cette thèse explore l'optimisation des VAI dans ce contexte, se concentrant spécifiquement sur leur efficacité énergétique pendant l'étape critique de navigation et l'impact des paramètres dynamiques sur leur consommation d'énergie.

La motivation derrière cette recherche réside dans la demande croissante pour les véhicules électriques, combinée aux coûts élevés associés à leurs batteries au lithium-ion. Bien que ces batteries offrent une haute densité énergétique, une faible auto-décharge et une longue durée de vie, elles sont sensibles à la Profondeur de Décharge (PdD). La PdD est un paramètre essentiel, notamment qu'une PdD plus élevée peut entraîner une réduction de la durée de vie de la batterie. Par conséquent, une optimisation de l'utilisation de l'énergie des VAI peut contribuer à la prolongation de la durée de vie de la batterie de ces véhicules électriques, réduisant ainsi les coûts d'exploitation et favorisant des pratiques durables dans les usines intelligentes.

Les approches existantes de planification de mouvement pour les VAI n'ont pas suffisamment abordé l'influence des changements dans les paramètres dynamiques causés par des charges variables et des manœuvres compliquées, qui peuvent affecter considérablement la consommation d'énergie. Par conséquent, le problème central que cette thèse traite est le développement d'une méthodologie de planification de mouvement qui reconnaît ces paramètres dynamiques et les exploite pour créer une solution éco-énergétique.

Pour combler cette lacune, cette thèse propose une approche unique qui intègre le modèle cinétique des VAI et les réseaux de neurones profonds (DNN<sup>1</sup>) afin d'optimiser la consommation d'énergie. Le modèle cinétique est utilisé pour générer des données qui forment le modèle d'apprentissage. Ensuite, le modèle résultant est intégré à l'étape de planification de mouvement des VAI. Cette approche se distingue des méthodes antérieures qui négligeaient le modèle cinétique du robot dans la recherche d'un mouvement économe en énergie. Elle intègre la dynamique cinétique du robot pour obtenir un mouvement plus efficace.

La méthode proposée a été validée expérimentalement sur deux VAI distincts, chacun est équipé d'un planificateur de mouvement différent. Les résultats ont montré une réduction substantielle de la consommation d'énergie dans les deux cas où les planificateurs de mouvement améliorés étaient utilisés. Cela a démontré que la méthode proposée était efficace dans des situations en temps réel et a souligné sa valeur pratique.

En conclusion, cette thèse contribue significativement à la recherche continue sur l'efficacité énergétique dans le contexte des usines intelligentes au sein de l'Industrie 4.0. En proposant et validant une nouvelle méthode de planification de mouvement éco-énergétique pour les VAI, elle a le potentiel de conduire à des réductions significatives des coûts d'exploitation, de promouvoir des pratiques de fabrication durables, et de contribuer à la longévité de la durée de vie des batteries dans les véhicules électriques. De plus, la méthode pose une base solide pour de nouvelles explorations et affinements dans ce domaine de recherche essentiel.

---

1. DNN est l'abréviation de "Deep Neural Networks", en anglais (réseaux de neurones profonds en français)

# Table des matières

<b>Remerciements</b>	<b>i</b>
<b>Résumé</b>	<b>ii</b>
<b>Table des matières</b>	<b>iv</b>
<b>Table des figures</b>	<b>vi</b>
<b>Chapitre 1 - Introduction</b>	<b>1</b>
1.1 Contexte général .....	1
1.2 Considérations préliminaires .....	10
1.3 Problématique de thèse .....	13
1.4 Hypothèses.....	15
1.5 Objectifs et Contributions.....	16
1.6 Méthodologie de recherche.....	19
1.7 Infrastructure de recherche .....	21
1.8 Structure de la thèse.....	22
<b>Chapitre 2 - Revue de la littérature</b>	<b>24</b>
2.1 Modèle cinétique .....	24
2.2 Identification des paramètres .....	30
2.3 Planification de mouvement .....	36
<b>Chapitre 3 - Nécessité de prendre en compte les paramètres dynamiques dans la planification du mouvement</b>	<b>43</b>
3.1 Position du centre de masse.....	43
3.2 Limites d'accélération .....	48

<b>Chapitre 4 - Modèle dynamique du VAI</b>	<b>53</b>
4.1 Équations de mouvement de l’RMAED .....	53
4.1.1 Équation de mouvement cinématique . . . . .	53
4.1.2 Équations du mouvement cinétique . . . . .	56
4.2 Équations de mouvement de CEATA .....	64
<b>Chapitre 5 - Planification de mouvement éco-énergétique</b>	<b>69</b>
5.1 Planification de mouvement éco-énergétique pour RMAED .....	71
5.2 Planification de mouvement éco-énergétique pour CEATA .....	82
<b>Chapitre 6 - Résultats des expérimentations et simulations</b>	<b>93</b>
6.1 RMAED .....	95
6.1.1 Simulations . . . . .	95
6.1.2 Expérience . . . . .	98
6.2 CEATA .....	107
6.2.1 Simulations . . . . .	107
6.2.2 Expérience . . . . .	108
6.3 Stabilité et Robustesse .....	116
<b>Chapitre 7 - Conclusions et recommandations</b>	<b>119</b>
7.1 Conclusions .....	119
7.2 Recommandations .....	120
7.3 Publications .....	124
<b>Chapitre 8 - Annexe</b>	<b>126</b>
.1 Modèle de batterie .....	126
.2 Articles de journaux publiés .....	127
.2.1 L’article 1 . . . . .	127
.2.2 L’article 2 . . . . .	147
.2.3 L’article 3 . . . . .	165



## Table des figures

1-1	Les cinq éléments principaux d'une usine intelligente. . . . .	3
1-2	Prévision de la demande d'électricité par secteur au Canada [1]. . . . .	5
1-3	Robots et véhicules autonomes dans une usine intelligente. . . . .	6
1-4	Organigramme des étapes du processus de navigation du VAI. . . . .	9
3-1	CoM <sub>g</sub> du RMAED par rapport au CoM <sub>l</sub> de la charge. . . . .	44
3-2	Le premier scénario de l'expérience (RMAED) : éviter un obstacle inattendu. . . . .	47
3-3	Le deuxième scénario de l'expérience : mouvement de rotation dans un couloir. . . . .	47
3-4	La carte du monde dans Rviz. . . . .	50
3-5	Résultats de l'expérience (première tentative) en utilisant trois limites d'accélération différentes dans le planificateur de mouvement. (a) et (b) montrent respectivement l'accélération du CEATA et la puissance des moteurs. . . . .	51
4-1	Schéma de l'RMAED. . . . .	54
4-2	Les trajectoires globales du RMAED avec le contrôleur en boucle ouverte dans les trois scénarios. . . . .	62
4-3	Couples générés pour les moteurs des roues dans les trois scénarios. . . . .	63
4-4	Diagramme de corps du CEATA. . . . .	65
5-1	Carte de flux de données avec la structure de l'EdD (RMAED). . . . .	72
5-2	L'erreur d'estimation de MLP pour les entrées des moteurs (a) et CoM (b). (RMAED). . . . .	75
5-3	La fenêtre dynamique de la méthode DWA. . . . .	76

5-4	La structure de la méthode EDWA pour l’RMAED. . . . .	78
5-5	La carte de flux de données avec la structure du EdD. . . . .	84
5-6	Résultats de la prédiction de l’accélération linéaire et angulaire par MLP. . . . .	86
5-7	Le diagramme de bloc du planificateur de mouvement éco-énergétique (ETEB). . . . .	89
6-1	Modèle RMAED conçu dans Gazebo. . . . .	96
6-2	Environnement de simulation pour le RMAED. . . . .	96
6-3	Trajectoire globale de le RMAED dans la simulation. . . . .	97
6-4	vitesse linéaire et angulaire de le RMAED dans la simulation. . . . .	98
6-5	Consommation d’énergie des moteurs gauche et droit de le RMAED dans la simulation. . . . .	99
6-6	le RMAED. . . . .	101
6-7	Environnement du test expérimental. . . . .	102
6-8	Carte de l’environnement du test expérimental sur Rviz. . . . .	102
6-9	Charges sur la plateforme de le RMAED. . . . .	103
6-10	CoM global réel ( $CoM_g$ ) sur la plateforme pour six scénarios. . . . .	104
6-11	Trajectoire globale de le RMAED lors de l’expérience (Scénario 1, première tentative). . . . .	104
6-12	Vitesse linéaires et angulaires de le RMAED lors de l’expérience (Scénario 1, première tentative). . . . .	105
6-13	Consommation d’énergie des moteurs gauche et droit de le RMAED lors de l’expérience (Scénario 1, première tentative). . . . .	105
6-14	Le CEATA simulé et l’environnement de simulation dans Gazebo. . . . .	108
6-15	(a) Le CEATA ; (b) Le CEATA avec la charge. . . . .	109
6-16	Environnement de l’expérimentation . . . . .	109
6-17	Vitesse linéaire et angulaire du CEATA lors de l’expérience (Scénario 1, première tentative). . . . .	112
6-18	Accélération linéaire et angulaire du CEATA lors de l’expérience (Scénario 1, première tentative). . . . .	112

6-19 Consommation d'énergie des moteurs de traction et de direction du CEATA  
lors de l'expérience (Scénario 1, première tentative). . . . . 113

## Liste des acronymes

<b>AA</b>	Apprentissage Automatique
<b>AP</b>	Apprentissage Profond
<b>APF</b>	Champ de potentiel artificiel en anglais "Artificial Potential Field"
<b>BIBO</b>	Entrée limitée
<b>CEA</b>	Chariots Elévateur Autonome
<b>CEATA</b>	Chariot Elévateur Autonome de Type Automobile
<b>CIA</b>	Contrôle d'Inférence Approximative
<b>CoM</b>	Centre de masse en anglais "Centre of Mass"
<b>DNN</b>	Réseau de Neurones Profond en anglais 'Deep Neural Networks'
<b>DWA</b>	Fenêtre Dynamique en anglais "Dynamic Window Approach"
<b>EKF</b>	Filtre de Kalman étendu en anglais "Extended Kalman Filter"
<b>IA</b>	Intelligence Artificielle
<b>IdO</b>	Internet des Objets
<b>IRH</b>	Institut de Recherche sur l'Hydrogène
<b>MdI</b>	Moment d'Inertie
<b>MLP</b>	Perceptron multicouche en anglais "Multi-Layer Perceptron"
<b>PdD</b>	Profondeur de Décharge
<b>RMA</b>	Robot Mobile Autonome
<b>RMAED</b>	Robot Mobile Autonome Entraînement Différentiel
<b>RMR</b>	Robot Mobile à Roues
<b>RMSE</b>	Erreur quadratique moyenne en anglais "Root-Mean-Square Error"

<b>ROS</b>	Système d'exploitation du robot en anglais "Robot Operating System"
<b>RRT</b>	Explorer rapidement un arbre aléatoire en anglais "Rapidly-exploring Random Trees"
<b>SCP</b>	Système Cyber-Physique
<b>SLAM</b>	Localisation et cartographie simultanées en anglais "Simultaneous Localization and Mapping"
<b>SMAPE</b>	Erreur de pourcentage absolue moyenne symétrique en anglais "Symmetric Mean Absolute Percentage Error"
<b>SNR</b>	Rapport signal sur bruit en anglais "Signal-to-Noise Ratios"
<b>TEB</b>	Bande élastique temporelle en anglais "Timed_Elastic_Band"
<b>UKF</b>	Filtre de kalman unscented en anglais "Unscented Kalman Filter"
<b>UQTR</b>	Université du Québec à Trois-Rivières
<b>VAI</b>	Véhicule Autonome Intérieur
<b>VGA</b>	Véhicule à Guidage Automatique

# Chapitre 1 - Introduction

Cette thèse se concentre sur la création de stratégies et d'algorithmes pour planifier le mouvement des véhicules électriques, spécifiquement dans des environnements industriels intérieurs. L'objectif principal de cette recherche est d'introduire une nouvelle méthode innovante et généralisée pour améliorer l'efficacité énergétique des algorithmes de planification de mouvement existants. Notre approche combine le modèle de mouvement du véhicule avec des réseaux de neurones profonds pour atteindre cet objectif. En conséquence, cette méthode réduit considérablement la consommation d'énergie, se traduisant par une diminution des coûts et une extension de la période opérationnelle pour ces véhicules dans les usines intelligentes.

Le chapitre suivant offre un aperçu complet du contexte de recherche. Il explique les problèmes en jeu, les objectifs que nous visons, les principales contributions de cette étude et la méthodologie de recherche que nous avons utilisée. De plus, ce chapitre décrit l'infrastructure pertinente à la recherche et se termine par les principales hypothèses soutenant notre étude. Cette section sert de feuille de route pour le parcours de recherche abordé dans la thèse.

## 1.1 Contexte général

Les usines d'aujourd'hui font face à une concurrence acharnée de la part du monde entier. Elles doivent être capables de modifier rapidement leur production pour répondre aux besoins changeants des clients. Ces exigences ne peuvent être satisfaites que par des avancées radicales dans la technologie de fabrication actuelle. La quatrième Révolution Industrielle - Industrie 4.0 est une approche prometteuse basée sur l'intégration des processus commerciaux et de fabrication, ainsi que l'intégration de tous les acteurs de la chaîne de valeur de l'entreprise (fournisseurs et clients) [2]. Industrie 4.0 est un terme utilisé pour décrire la transformation en cours dans l'industrie manufacturière grâce à l'intégration des technologies numériques.

Cette transformation représente la quatrième grande étape de la Révolution Industrielle. Le mouvement a débuté à la fin du 18<sup>e</sup> siècle avec la première étape, marquée par l'introduction de la vapeur et de la fabrication mécanique. La deuxième étape a introduit l'électricité et la production de masse, et la troisième étape a été caractérisée par l'adoption des ordinateurs et de l'automatisation. Aujourd'hui, l'Industrie 4.0, ou quatrième étape, transforme l'industrie manufacturière en permettant l'automatisation et l'optimisation des processus de production, ce qui entraîne une amélioration de l'efficacité, une réduction des coûts et une amélioration de la qualité des produits. Les usines intelligentes sont un composant essentiel de l'Industrie 4.0 [3]. Elles utilisent des technologies avancées pour créer un système de production intelligent et connecté. Les usines intelligentes se caractérisent par l'intégration de systèmes physiques et numériques, rendue possible par l'utilisation de technologies avancées. Concernant la Figure 1-1, les caractéristiques clés des usines intelligentes incluent [4] :

1. **Systèmes Cyber-Physiques (SCP) :** Les SCP sont l'épine dorsale des usines intelligentes. Ces systèmes intègrent des systèmes physiques et numériques, ce qui permet l'automatisation et l'optimisation des processus de production. Les SCP comprennent des capteurs, des actionneurs et des contrôleurs qui travaillent ensemble pour surveiller et contrôler le processus de production en temps réel.
2. **Internet des Objets (IdO) :** L'IdO fait référence à l'interconnexion des appareils et des machines via Internet. Dans les usines intelligentes, l'IdO est utilisé pour connecter les SCP, ce qui permet l'échange de données et d'informations entre différentes machines et systèmes. Cette interconnectivité améliore l'efficacité, la productivité et réduit les coûts.
3. **Analyse de Données Massives :** Les usines intelligentes génèrent une énorme quantité de données provenant de diverses sources telles que des capteurs, des machines et des systèmes. L'analyse de données massives est utilisée pour extraire des informations de ces données, ce qui aide à améliorer la prise de décision, optimiser les processus de production et prédire les besoins en maintenance.
4. **Intelligence Artificielle (IA) et Apprentissage Automatique (AA) :** L'IA et l'AA sont utilisées pour analyser les données et faire des prédictions basées sur les motifs et

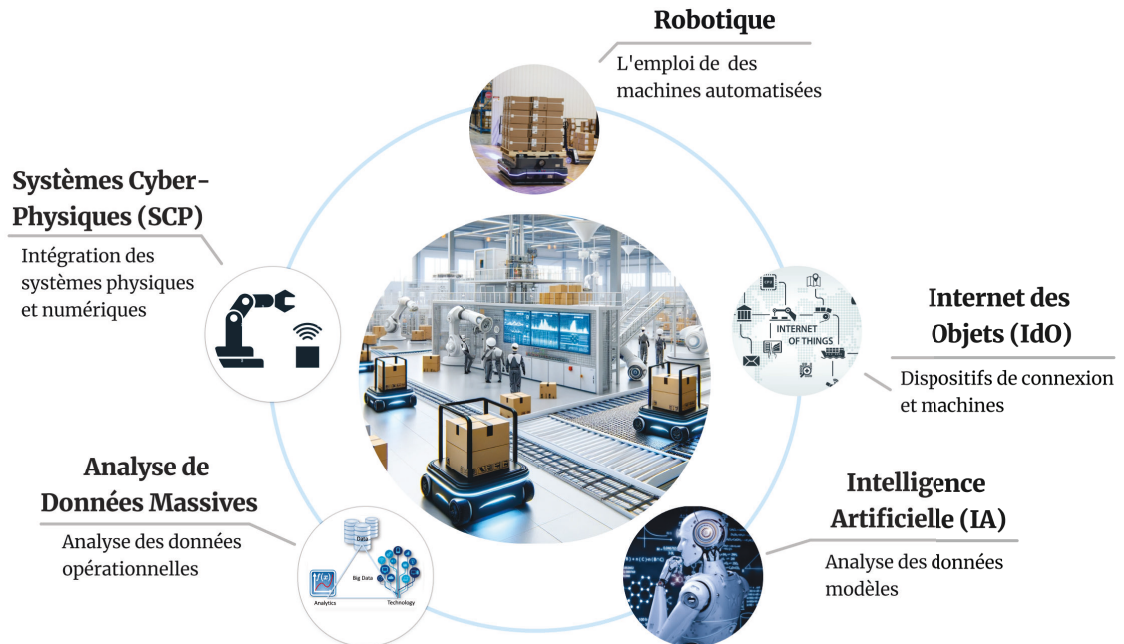


FIGURE 1-1 Les cinq éléments principaux d'une usine intelligente.

tendances dans les données. Ces technologies permettent une maintenance prédictive, un contrôle de qualité et une prise de décision autonome.

5. Robotique : La robotique joue un rôle essentiel dans les usines intelligentes. Les robots sont utilisés pour diverses tâches telles que la manutention des matériaux, l'assemblage et l'inspection. Ils peuvent travailler aux côtés des humains dans un environnement de production collaboratif, ce qui améliore la productivité, l'efficacité et la sécurité.

Les usines intelligentes offrent plusieurs avantages aux entreprises et à la société dans son ensemble [5]. Ces avantages comprennent :

- (i) Efficacité accrue : Les usines intelligentes permettent l'automatisation et l'optimisation des processus de production, améliorant ainsi l'efficacité et réduisant les coûts.
- (ii) Qualité améliorée : Des technologies telles que l'IA, l'AA et L'analyse de données massives permettent une surveillance et un contrôle en temps réel des processus de production, améliorant ainsi la qualité des produits.



- (iii) Flexibilité accrue : Les usines intelligentes permettent la personnalisation des produits et services pour répondre aux besoins de chaque client, augmentant ainsi la satisfaction de la clientèle.
- (iv) Impact environnemental réduit : Les technologies des usines intelligentes permettent l'optimisation de la consommation d'énergie et de ressources, réduisant ainsi l'impact environnemental des processus de production.
- (v) Sécurité améliorée : Des technologies telles que la robotique permettent l'automatisation des tâches dangereuses, augmentant ainsi la sécurité des travailleurs.

L'intégration des systèmes physiques et numériques dans les usines intelligentes nécessite une quantité significative d'énergie pour alimenter les différentes machines, équipements et systèmes.

Le Canada avance activement dans le développement des usines intelligentes. Un exemple notable est la récente inauguration par Deloitte Canada de The Smart Factory @ Montreal, une installation unique en son genre présentant un écosystème interconnecté de plus de 20 solutions et technologies de pointe [6]. Cette installation fait partie du réseau mondial Smart Factory de Deloitte et vise à transformer la fabrication et l'entreposage grâce à la transformation numérique. The Smart Factory @ Montreal permettra aux clients de tracer leurs propres parcours de transformation industrielle numérique et aidera à accélérer l'adoption des technologies de fabrication de pointe au Canada. De plus, un rapport de Deloitte Canada explore les transformations réussies pour aider les fabricants à démarrer, réussir et réaliser de la valeur avec leurs usines intelligentes. Alors que 86% des fabricants interrogés disent que les usines intelligentes seront le principal moteur de compétitivité dans cinq ans, seulement 5% exploitent une installation entièrement convertie. Ces actions illustrent fortement la stratégie avant-gardiste du Canada pour promouvoir l'évolution des usines intelligentes.

La Figure 1-2 présente la prévision de la demande d'électricité par secteur au Canada. D'après les résultats, l'industrie représente la plus grande part de la consommation d'énergie entre les secteurs. La consommation d'énergie dans les usines est l'une des plus grandes dépenses d'exploitation, et les coûts énergétiques peuvent avoir un impact significatif sur le résultat net d'une entreprise [7]. De plus, les processus de production dans les usines

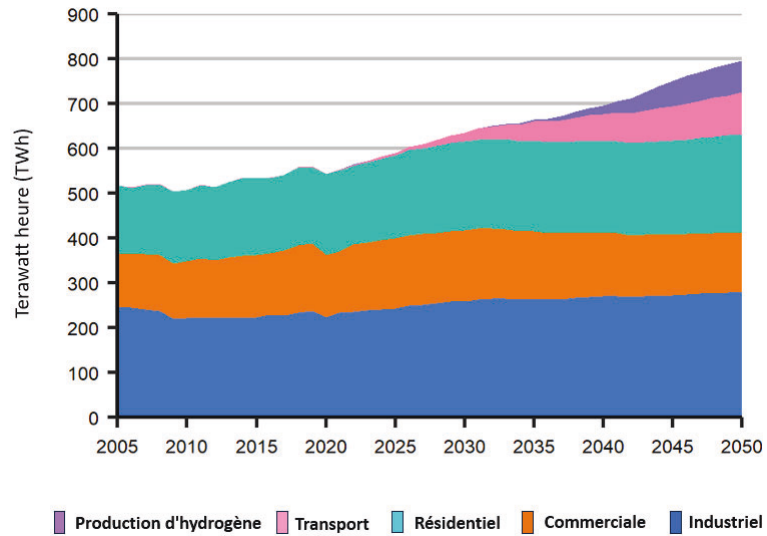


FIGURE 1-2 Prévision de la demande d'électricité par secteur au Canada [1].

intelligentes nécessitent une alimentation en énergie fiable et continue pour garantir des performances optimales. Par conséquent, l'importance de l'énergie dans les usines intelligentes ne peut être surestimée. Les processus de production dans ces usines exigent une alimentation en énergie constante et fiable. Toute perturbation de l'approvisionnement énergétique peut entraîner des temps d'arrêt et des pertes de production, ce qui peut avoir un impact significatif sur l'entreprise.

Les usines intelligentes nécessitent une quantité significative d'énergie pour alimenter les différentes machines, équipements et systèmes. Par conséquent, il est essentiel d'améliorer l'efficacité énergétique dans ces usines pour réduire la consommation d'énergie et les coûts associés. Ces usines peuvent utiliser des sources d'énergie renouvelable telles que le solaire, l'éolien et la géothermie pour alimenter leurs opérations. L'utilisation de sources d'énergie renouvelable peut réduire les coûts énergétiques et l'impact environnemental. De plus, elles peuvent également utiliser des systèmes de stockage d'énergie, tels que les batteries, pour stocker l'énergie excédentaire et l'utiliser en cas de besoin. Cela contribue à réduire les coûts énergétiques et à améliorer l'efficacité énergétique.

Concernant la Figure 1-3, l'une des technologies clés qui transforment l'industrie manufacturière est les Véhicules Autonomes Intérieurs (VAI), tels que les Véhicules Guidés



FIGURE 1-3 Robots et véhicules autonomes dans une usine intelligente.

Autonomes (VGA), les Robots Mobiles Autonomes (RMA) et les Chariots Élévateurs Autonomes (CEA) [8]. Les VGA suivent des trajectoires globales ou itinéraires prédéterminés en utilisant des systèmes de guidage tels que les lasers, les bandes magnétiques ou les systèmes de vision. Cependant, les RMA et les CEA présentent un haut niveau d'autonomie en utilisant des capteurs, des caméras et des technologies de cartographie pour percevoir leur environnement et planifier des itinéraires optimaux.

Les CEA sont plus utiles pour soulever et déplacer de lourdes charges, certains modèles étant capables de transporter jusqu'à plusieurs tonnes [9]. En revanche, les VGA et les RMA ont une capacité de charge limitée et peuvent ne pas convenir aux applications de manutention de charges lourdes. Les CEA sont généralement conçus avec un système de direction semblable à celui d'une voiture, tandis que les VGA et les RMA utilisent différents types de systèmes de conduite en fonction de leur conception et de leur application, tels que les systèmes de conduite différentielle et omnidirectionnelle.

L'utilisation des VAI dans les usines intelligentes offre plusieurs avantages, notamment :

1. Efficacité accrue : Les VAI peuvent effectuer des tâches telles que la manutention, le transport et l'assemblage sans intervention humaine. Cela se traduit par une efficacité accrue, une réduction des temps de production et une qualité améliorée.

2. Sécurité améliorée : L'utilisation des VAI réduit le risque d'accidents et de blessures dans les usines intelligentes. Les véhicules autonomes sont équipés de capteurs et de caméras qui leur permettent de détecter les obstacles et d'éviter les collisions.
3. Réduction des coûts : L'utilisation des VAI réduit les coûts de main-d'œuvre. Ils peuvent effectuer des tâches qui étaient auparavant réalisées par des humains, ce qui se traduit par une réduction des coûts de main-d'œuvre et une productivité accrue.
4. Flexibilité : Les VAI peuvent être programmés pour effectuer une large gamme de tâches, ce qui les rend idéaux pour une utilisation dans les systèmes de fabrication flexibles. Ils peuvent être facilement reprogrammés pour effectuer de nouvelles tâches, permettant ainsi aux usines intelligentes de s'adapter rapidement aux demandes changeantes du marché.

L'efficacité énergétique est une considération essentielle pour les usines intelligentes, car elle joue un rôle clé dans la réduction des coûts d'exploitation et la promotion d'une production durable [10]. Les usines intelligentes peuvent devenir plus efficaces sur le plan énergétique en utilisant des VAI. Ces véhicules offrent plusieurs avantages qui aident les usines intelligentes à atteindre leurs objectifs en matière d'économie d'énergie.

Les VAI peuvent optimiser leurs trajets et leurs opérations pour réduire la consommation d'énergie. Par exemple, ils peuvent éviter de s'écarter inutilement de la trajectoire prévue [11], réduire les temps d'inactivité [12], et optimiser leurs vitesses pour minimiser la consommation d'énergie [13]. Ils peuvent également récupérer de l'énergie grâce à des systèmes de freinage régénératif [14]. Ces systèmes de freinage régénératif capturent l'énergie cinétique générée lors du freinage et la stockent pour une utilisation ultérieure, réduisant ainsi l'énergie nécessaire pour faire fonctionner le véhicule.

De plus, ils peuvent être équipés de capteurs et de logiciels qui assurent une surveillance et une gestion en temps réel de l'utilisation de l'énergie. Cela permet une utilisation plus efficace des ressources énergétiques, comme l'arrêt des équipements inactifs et l'optimisation de l'utilisation de l'énergie pendant les heures de pointe. Ils peuvent également contribuer à réduire la consommation d'énergie en facilitant la maintenance prédictive [15]. En utilisant

l'analyse de données, les VAI peuvent prévoir quand la maintenance est nécessaire, réduisant ainsi la probabilité de défaillance des équipements et la perte d'énergie associée.

La partie principale du logiciel des VAI est le module de navigation. Conformément à la littérature, ce dernier se décompose en cinq étapes clés [16], illustrées dans le diagramme de flux de la Figure 1-4. Dès que la navigation du VAI est initiée par la perception, elle utilise divers capteurs tels que des caméras, LIDAR et des capteurs ultrasoniques pour recueillir des données essentielles sur son environnement. Cette étape de perception est conçue non seulement pour détecter et interpréter les données, mais aussi pour comprendre la pertinence et l'importance des différents éléments au sein de l'environnement. Après la perception, les données recueillies sont traitées pendant l'étape de cartographie [17]. Cette phase exploite la utilisation des algorithmes de localisation et cartographie simultanées (SLAM<sup>1</sup>) pour générer un modèle dynamique et complet de l'environnement [18]. La carte évolue continuellement à mesure que le robot se déplace, améliorant sa compréhension de l'environnement au fil du temps. L'étape suivante concerne la localisation [19]. Elle consiste à estimer la position et l'orientation du robot au sein de la carte créée précédemment. Des algorithmes tels que la Localisation Monte Carlo [20] ou les Filtres de Kalman [21] sont utilisés pour corriger la position estimée du robot en fonction des lectures des capteurs et du modèle d'environnement construit. Cette étape permet au VAI d'avoir une perception précise de sa position au sein de son environnement.

Le processus de planification de la navigation se décompose en deux parties essentielles : (i) la planification du chemin (la trajectoire globale) et (ii) la planification du mouvement (la trajectoire locale). Tout d'abord, la planification du chemin sélectionne la trajectoire globale la plus efficace entre le point de départ et la destination [22]. Cela implique généralement l'utilisation d'algorithmes tels que A\* ou l'algorithme de Dijkstra, qui prend en compte les informations cartographiques et les éventuelles limites environnementales. Ces algorithmes sont conçus pour prendre en compte les obstacles fixes afin de s'assurer que le VAI peut se déplacer en douceur sans se heurter à quoi que ce soit. La planification des mouvements est ensuite utilisée. Cette partie consiste à créer les meilleures trajectoires possibles qui adhèrent

---

1. SLAM est l'abréviation de "Simultaneous Localization and Mapping", en anglais (localisation et cartographie simultanées en français)

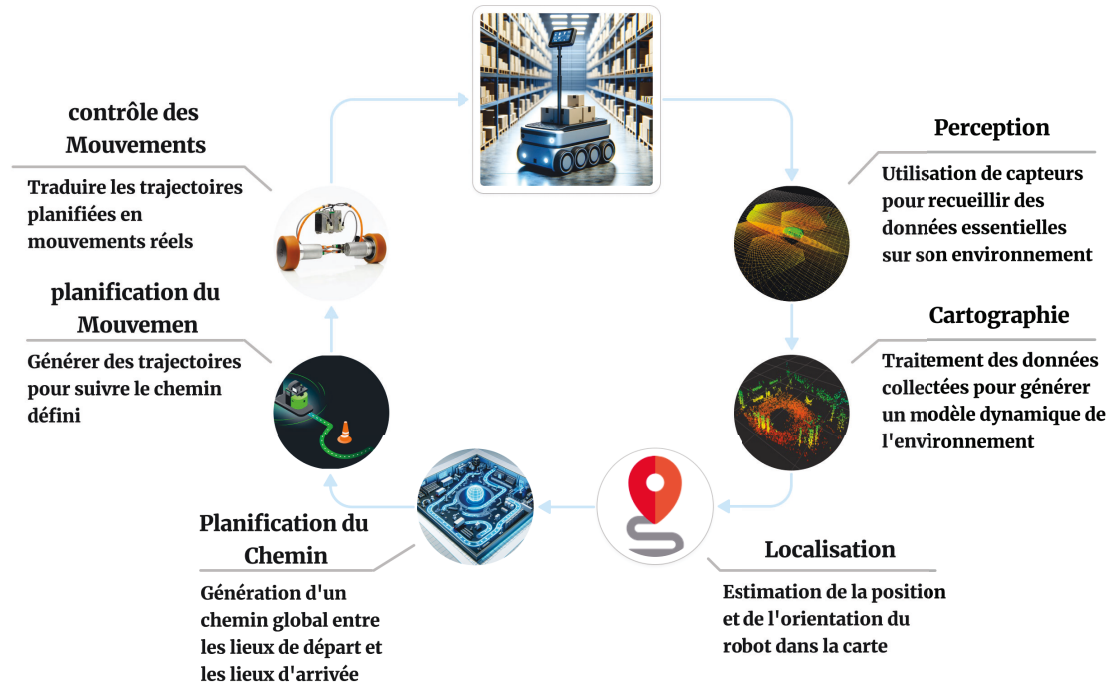


FIGURE 1-4 Organigramme des étapes du processus de navigation du VAI.

à la trajectoire globale déjà déterminée dans la phase de planification de le chemin [23]. Elle prend en compte les contraintes cinématiques du robot pour s'assurer qu'il peut suivre ces trajectoires globales. Différentes stratégies, telles que l'optimisation ou la planification basée sur l'échantillonnage, sont utilisées ici pour s'assurer que le robot se déplace de manière efficace et sûre. L'étape finale est le contrôle des mouvements. Dans cette phase, les trajectoires planifiées sont transformées en mouvements réels par les moteurs du robot [24]. Des techniques de contrôle avancées, telles que le contrôle PID ou le contrôle prédictif de modèle, sont appliquées pour gérer avec précision les forces et les rotations que les moteurs doivent appliquer. Ces étapes ne sont pas des processus ponctuels ; elles sont répétées à l'infini. Le robot rafraîchit constamment sa position, la carte, sa trajectoire prévue et ses mouvements au fur et à mesure qu'il se déplace dans l'environnement. La navigation efficace est cruciale pour les VAI, car elle leur permet de travailler en toute sécurité et avec une bonne efficacité dans différents environnements.

## 1.2 Considérations préliminaires

Les VAIs ont attiré une attention considérable en raison de leur potentiel à révolutionner le transport dans l'industrie. Cependant, l'un des principaux défis dans le développement et le déploiement de véhicules autonomes est la gestion de l'énergie et des batteries [25]. Puisque ces véhicules dépendent de batteries pour alimenter leurs moteurs et leurs systèmes de contrôle, tout problème d'énergie ou de batterie peut affecter considérablement leurs performances. Dans ce contexte, l'efficacité énergétique joue un rôle vital. La demande de véhicules électriques a augmenté ces dernières années, et cette tendance devrait se poursuivre dans les années à venir. Cependant, le coût élevé des batteries représente un obstacle majeur à l'adoption généralisée des VAIs électriques. Il est donc essentiel de trouver des solutions économiques pour améliorer l'efficacité énergétique de ces véhicules et prolonger la durée de vie de leurs batteries.

Les batteries au lithium-ion sont couramment utilisées dans les VAIs électriques en raison de leur haute densité énergétique et de leur longue durée de vie. Cependant, ces batteries sont sensibles à la Profondeur de Décharge (PdD), qui fait référence au pourcentage de la capacité de la batterie utilisée lors de chaque cycle de charge-décharge [26]. La PdD affecte la durée de vie de la batterie, et une PdD élevée peut conduire à une réduction de la durée de vie de la batterie. Par conséquent, optimiser l'efficacité énergétique de ces véhicules pendant le mouvement peut réduire la PdD et prolonger la durée de vie de la batterie.

L'efficacité énergétique peut être améliorée de plusieurs manières. L'une des méthodes est d'optimiser le système de navigation du véhicule [27]. Les systèmes de navigation jouent un rôle essentiel dans les VAIs, car ils fournissent des données en temps réel sur l'environnement du véhicule et aident ce dernier à prendre des décisions basées sur ces données. En optimisant le système de navigation, le véhicule peut prendre de meilleures décisions, entraînant une consommation d'énergie plus efficace. Par exemple, un VAI peut être programmé pour éviter les trajets avec une circulation dense ou avec des arrêts fréquents, ce qui peut entraîner une réduction significative de la consommation d'énergie [28].

Parmi les étapes de navigation des VAI, la planification du mouvement joue un rôle essentiel en déterminant les déplacements spécifiques du VAI. Cette étape génère des trajectoires locales

appropriées pour suivre la trajectoire globale créée lors de l'étape de planification. De plus, le planificateur de mouvement doit guider le VAI pour éviter les obstacles inattendus et le ramener sur la trajectoire globale définie. Ainsi, toute trajectoire non optimale peut augmenter la consommation d'énergie du VAI. Bien que les algorithmes de planification du mouvement utilisent généralement le modèle cinématique du robot pour tenir compte de ses contraintes de mouvement, ils ignorent le modèle dynamique (cinétique) du robot [29]. Étant donné que la fonction principale d'un VAI est le transport de charge, ses paramètres inertiels tels que la masse, le Moment d'Inertie (M<sub>dI</sub>) et le Centre de Masse (CoM<sup>1</sup>) varient avec chaque tâche de transport [30].

Selon les propriétés de la charge, la distribution de la masse du VAI devient asymétrique, et son CoM se déplace par rapport au CoM de la charge. Les changements du CoM affectent la capacité du VAI à accélérer et à freiner efficacement [31]. Lorsque le CoM s'éloigne des roues motrices du véhicule, la traction du VAI diminue et les moteurs doivent fournir davantage d'effort pour obtenir la même accélération ou décélération. Le CoM joue également un rôle significatif dans la capacité de virage et de direction du VAI [32]. Si la charge est distribuée de manière asymétrique, le CoM se déplacera et la maniabilité du VAI sera affectée [33].

Les problèmes liés au CoM (sur l'axe latéral) sont plus marqués chez les RMAs et VGAs par rapport aux CEAs. La plus grande surface des RMAs et VGAs permet de placer des charges de chaque côté, affectant le CoM le long de l'axe latéral. En revanche, les CEAs subissent principalement davantage de modifications du CoM le long de l'axe longitudinal en raison de leur utilisation de fourches pour soulever des palettes. C'est parce que les charges sur les palettes sont généralement réparties de manière uniforme.

L'accélération d'un VAI dépend de ses paramètres d'inertie dynamique, qui varient selon les propriétés de la charge. Une charge plus lourde signifie qu'il faut plus d'énergie pour accélérer le véhicule. Pour économiser de l'énergie, l'étape de planification du mouvement devrait limiter l'accélération en fonction des propriétés de la charge [34]. Cependant, trop de limitations peuvent également augmenter la consommation d'énergie. Cela se produit lorsque le véhicule doit maintenir une puissance de sortie élevée (dans les limites d'accélération) pendant une période prolongée pour atteindre sa vitesse de consigne, ce qui accélère la

---

1. CoM est l'abréviation de "Centre of Mass", en anglais (centre de masse en français)



décharge de la batterie. De plus, cette situation prolonge le temps de trajet du véhicule pour terminer une tâche, ce qui consomme également plus d'énergie. Cela est particulièrement pertinent dans un contexte d'entrepôt ou d'usine où VAI doit effectuer plusieurs tâches et les terminer rapidement [35].

En revanche, en fixant une limite d'accélération plus élevée lors de la phase de planification du mouvement, le VAI est capable d'exécuter les manœuvres rapidement, réduisant ainsi le temps nécessaire pour atteindre le point d'arrivée. Néanmoins, cela entraîne des changements de vitesse plus fréquents et abrupts, pouvant potentiellement entraîner une consommation d'énergie accrue en raison d'une résistance au roulement augmentée [36]. De plus, pour atteindre l'accélération et la décélération souhaitées, VAI pourrait devoir fonctionner à des régimes de couple plus élevés pendant de plus courts intervalles, mais avec une fréquence plus élevée, contribuant davantage à une augmentation de la consommation d'énergie [37].

Les limites d'accélération lors de la phase de planification du mouvement peuvent avoir des implications sur la consommation d'énergie du VAI sous un autre aspect. Les algorithmes traditionnels de planification de mouvement ne tiennent pas compte du modèle cinétique du véhicule, ce qui limite leur capacité à prendre en compte l'accélération potentielle du VAI à chaque fréquence de contrôle. Par conséquent, ils peuvent générer des trajectoires qui ne sont pas dynamiquement réalisables pour le véhicule [38]. Cela peut entraîner l'immobilisation du VAI dans des manœuvres complexes et l'oscillation entre différentes trajectoires jusqu'à ce qu'une solution physiquement viable soit trouvée par le planificateur de mouvement ou qu'un opérateur réinitialise la pile de navigation.

Une telle oscillation prolonge le temps d'achèvement de la mission et consomme une énergie excessive car le VAI ajuste constamment sa vitesse et sa direction. La complexité du système dynamique dans les Chariots Élévateurs Autonomes de Type Automobile (CEATA) présente davantage de défis comparativement aux VGAs et RMAs. En raison de la combinaison des mouvements translationnels et rotationnels dans les CEATA, prédire le mouvement du véhicule dans divers scénarios devient plus difficile pour les algorithmes de planification de mouvement [39]. Par exemple, le rayon de braquage d'un système de type automobile dépend à la fois de la vitesse linéaire et de l'angle de direction, tandis que les entraînements différentiels ou omnidirectionnels permettent un contrôle indépendant du rayon de braquage,

indépendamment de la vitesse linéaire du véhicule.

### 1.3 Problématique de thèse

S'appuyant sur les discussions des sections précédentes, plusieurs défis émergent dans le contexte de l'Industrie 4.0 et des VAIs :

#### 1. Problèmes énergétiques avec les VAI :

- Problèmes liés aux batteries Lithium-Ion des VAI [40] :
  - Sensibilité à la Profondeur de Décharge (PdD) : Une PdD élevée peut réduire considérablement la durée de vie de la batterie.
  - Coût Initial élevé : Les batteries Lithium-Ion, bien qu'efficaces, sont associées à un coût initial plus élevé.
- Limitation des sources d'énergie pour la charge [41] :
  - Dépendance à l'énergie électrique : Tous les robots et systèmes automatisés dépendent fortement de l'énergie électrique.
  - Demande énergétique fluctuante : Les cycles opérationnels variés entraînent une demande énergétique fluctuante, posant des défis pour le stockage de l'énergie.

#### 2. Changements dans les paramètres d'inertie des VAI :

- Impact des charges sur les paramètres d'inertie dynamique des VAI [42] :
  - Impact négatif sur le mouvement des VAI : Les changements dans les paramètres d'inertie dus aux variations de charge peuvent affecter la stabilité et la manœuvrabilité du véhicule.
- Défis dans l'identification en temps réel [43] :
  - En raison de la dynamique complexe et non linéaire des VAI, l'identification des paramètres d'inertie en temps réel présente des défis significatifs.

#### 3. Négligence du modèle cinétique dans les planificateurs de mouvement [25] :

- Incapacité à considérer les paramètres dynamiques :
  - Les méthodes traditionnelles de planification de mouvement des VAI utilisent principalement des modèles cinématiques, ne tenant pas compte des paramètres dynamiques.
- Échec à identifier un mouvement écoénergétique et réalisable :
  - Se fier uniquement au modèle cinématique peut conduire à des trajectoires sous-optimales, ne parvenant pas à identifier le mouvement le plus écoénergétique et réalisable pour les VAI.

Ces problèmes de recherche soulignent les complexités et les défis dans l'optimisation de la performance et de l'efficacité des Véhicules Autonomes Intelligents. En abordant ces questions, nous visons à contribuer à l'avancement de la technologie des VAI et à améliorer leurs capacités dans diverses applications.

Cette étude examine comment les paramètres dynamiques affectent les VAIs, qui peuvent varier selon le type du VAI. Pour mieux comprendre cela, nous nous concentrons sur deux études de cas différentes. Nous parlerons des paramètres dynamiques spécifiques que nous avons trouvés pour chaque véhicule et expliquerons pourquoi ils sont importants pour cette étude de cas :

- **RMAED** : La grande plateforme d'un RMAED lui permet de transporter des charges de différentes tailles et formes. Cependant, selon la position de la charge sur la plateforme, CoM de l'ensemble du système peut se déplacer. Les charges placées loin du centre géométrique du RMAED peuvent entraîner des déplacements significatifs du CoM, affectant le comportement dynamique du véhicule. Lorsque les charges sont placées de manière asymétrique ou vers les bords de la plateforme, il y a un risque plus élevé de modifier la stabilité du RMAED. La capacité du RMAED à manœuvrer efficacement est également influencée par la façon dont les charges sont réparties sur la plateforme. Une répartition inégale des charges peut entraîner une traction inégale sur les roues, affectant la direction et le freinage. Cela peut rendre le RMAED moins réactif aux commandes de contrôle, réduisant sa capacité à naviguer dans des espaces restreints ou à éviter efficacement les obstacles.

- **CEATA** : La stabilité dynamique d'un CEATA est cruciale lors de l'exécution de manœuvres complexes, surtout à des vitesses plus élevées ou lors du transport de charges. Les limites d'accélération limitent le taux auquel le chariot élévateur peut changer sa vitesse, impactant sa capacité à s'adapter rapidement aux changements dans l'environnement ou aux exigences opérationnelles. Des changements soudains dans l'accélération peuvent conduire à l'instabilité. Les CEATA, comme leurs homologues à commande manuelle, dépendent de mécanismes de direction précis pour naviguer. La relation entre l'accélération et la direction est pivotale pour déterminer le rayon de braquage et la capacité à exécuter des manœuvres nettes ou complexes. Une accélération excessive peut conduire à un sous-virage ou à un sur-virage, rendant difficile le maintien du contrôle lors de virages serrés. À l'inverse, une accélération insuffisante peut ne pas fournir suffisamment de dynamique pour certaines manœuvres, surtout lorsqu'elle opère sous charge.

#### 1.4 Hypothèses

Dans le cadre de cette étude, nous posons les hypothèses suivantes :

- Le véhicule se déplace sur le plan horizontal (2D).

Cette étude suppose que le véhicule fonctionne uniquement dans un espace plat et bidimensionnel. Cela simplifie la manière dont nous planifions son trajet et contrôlons ses mouvements, en évitant de devoir gérer des chemins en montée ou en descente ou tout changement de hauteur. Cela signifie que nous concentrons sur la manière dont le véhicule avance, recule et tourne, sans la complexité supplémentaire de monter ou descendre.

- Le véhicule est rigide et il n'y a pas de glissement entre les roues et la surface.

Nous considérons que le véhicule est une forme solide et invariable qui ne se plie ni ne se déforme, et nous supposons que ses roues adhèrent toujours au sol sans glisser. De plus, les charges sur les véhicules sont considérées comme rigides. Cela rend nos calculs plus simples car nous n'avons pas besoin de nous préoccuper de la façon dont

le véhicule pourrait se plier ou comment ses pneus pourraient glisser sur différentes surfaces. De cette manière, nous pouvons prédire avec plus de précision comment il se déplacera selon nos commandes.

- Les obstacles sont statiques (sans mouvement).

Dans notre recherche, nous traitons tous les obstacles comme s'ils ne bougeaient pas. Cela signifie que nous n'avons pas à deviner où ils seront à l'avenir, ce qui facilite la navigation autour d'eux. Cette hypothèse est utile lorsque le véhicule se déplace dans des environnements où les choses ne bougent généralement pas, ce qui nous permet de nous concentrer sur la planification d'un chemin clair sans se soucier des objets en mouvement.

- Les côtés gauche et droit de l'obstacle sont symétriques.

Nous supposons que tout obstacle que le véhicule pourrait rencontrer est identique des deux côtés. Cette simplification signifie que peu importe de quel côté le véhicule approche l'obstacle ; la situation reste la même. Cela facilite la conception du système du véhicule pour éviter les obstacles, car il peut traiter tous les obstacles comme s'ils étaient des formes simples et symétriques.

- Il n'y a aucun obstacle lors des manœuvres de stationnement.

Lorsque le véhicule se gare, nous supposons qu'il n'y a pas d'obstacles à éviter. Cela nous permet de nous concentrer sur la manière dont le véhicule se gare lui-même - comment il se déplace dans une place de stationnement - sans le défi supplémentaire d'esquiver des objets inattendus. Cette hypothèse est particulièrement utile pour tester la capacité du véhicule à se garer dans un environnement contrôlé, où nous savons que l'espace autour de la place de stationnement est dégagé.

## 1.5 Objectifs et Contributions

Compte tenu des problèmes décrits à la section 1.4 concernant les défis auxquels sont confrontés les VAI, cette recherche présente une nouvelle méthode qui comprend un cadre

étendu. Néanmoins, les spécificités de chaque composant au sein de la méthodologie sont sujettes à modification en fonction du type du VAI particulier et du problème spécifique à traiter. Par conséquent, les objectifs et contributions de ce projet sont discutés dans ce qui suit.

## 1. Développement du modèle cinétique du véhicule

Lorsqu'un VAI effectue sa tâche principale (le transport de charge), ses paramètres d'inertie dynamique subissent des modifications en fonction des propriétés de la charge qu'il transporte. Ces changements ont un impact direct sur les caractéristiques de vitesse et d'accélération du VAI. Le modèle cinétique est une représentation mathématique qui peut capturer la dynamique du VAI. Il permet l'analyse et la prédiction du mouvement du VAI en fonction de ses paramètres d'inertie dynamique, ainsi que la prise en compte des contraintes de mouvement spécifiques au VAI. Par conséquent, il devient crucial d'incorporer un modèle cinétique adapté du VAI dans les algorithmes de planification de mouvement afin de prendre en considération ces variations et de satisfaire toutes les contraintes de mouvement appliquées au VAI. De ce fait, comme premier objectif, ce travail vise à développer le modèle cinétique du VAI pour tenir compte de ces changements et contraintes de mouvement. La contribution de cet objectif est définie comme :

- Le développement d'une nouvelle représentation mathématique, le modèle cinétique du VAI, qui capture avec précision la dynamique des véhicules autonomes.
- Ce modèle prend en compte les variations des paramètres d'inertie dynamique du VAI en fonction des caractéristiques de la charge transportée, facilitant ainsi l'analyse et la prédiction des déplacements du VAI.
- En tenant compte des contraintes de mouvement spécifiques aux VAIs, le modèle cinétique offre une compréhension complète des caractéristiques de vitesse et d'accélération du VAI, améliorant la précision et l'efficacité des algorithmes de planification de mouvement.

## 2. Identification en ligne des paramètres dynamiques

Les valeurs connues des modifications discutées et des contraintes de mouvement sont utiles pour représenter avec précision le comportement du VAI et garantir une performance optimale dans des scénarios réels. En identifiant les paramètres dynamiques, l'algorithme de navigation peut générer un mouvement plus précis et fiable, prenant en compte les caractéristiques physiques réelles et la dynamique du VAI. L'utilisation de techniques d'IA pour l'identification des paramètres dynamiques du VAI peut être une option appropriée en raison de sa capacité à gérer des dynamiques complexes et non linéaires. Cette approche peut exploiter les algorithmes des réseaux de neurones profonds (DNN<sup>1</sup>) pour estimer les paramètres dynamiques du VAI à partir des données collectées, offrant une méthode efficace pour l'identification des paramètres. Par conséquent, l'objectif de cette étude est d'utiliser des techniques d'IA pour l'identification en ligne de paramètres dynamiques spécifiques des VAIs, adaptés à une application particulière. La contribution associée à cet objectif peut être résumée comme suit :

- L'utilisation de techniques d'IA pour l'identification en ligne des paramètres dynamiques spécifiques aux VAI.
- En employant l'algorithme DNN et en collectant des données en temps réel (les données provenant de capteurs et d'actionneurs), les caractéristiques physiques réelles et la dynamique du VAI peuvent être estimées avec précision.
- Cette contribution améliore la précision et la fiabilité de la représentation du comportement du VAI, permettant une génération de mouvement plus précise et fiable dans des scénarios réels.

### 3. Planification de mouvement éco-énergétique

L'identification des paramètres dynamiques joue un rôle crucial dans l'amélioration de la précision et de la fiabilité des algorithmes de planification de mouvement pour les VAI. En capturant avec précision les caractéristiques physiques réelles et la dynamique du VAI, ces paramètres permettent à l'algorithme de générer des trajectoires de mouvement plus précises et fiables. De plus, les paramètres dynamiques identifiés peuvent être exploités pour optimiser l'efficacité du mouvement du VAI, notamment en

---

1. DNN est l'abréviation de "Deep Neural Networks", en anglais (réseaux de neurones profonds en français)

considérant des contraintes telles que la consommation d'énergie et le temps d'opération. Par conséquent, ce travail vise à tirer parti de l'identification basée sur l'IA des paramètres dynamiques pour développer un algorithme de planification de mouvement éco-énergétique comme objectif principal. En intégrant ces paramètres identifiés, l'algorithme peut générer des trajectoires qui optimisent la consommation d'énergie tout en tenant compte des contraintes de temps et d'autres facteurs pertinents. En fin de compte, cette étude contribue à faire progresser le domaine des VAI en améliorant leur efficacité et leur pertinence dans les applications réelles. La contribution définie pour cet objectif est la suivante :

- L'élaboration d'un algorithme de planification de mouvement éco-énergétique pour véhicules autonomes exploitant l'identification basée sur l'IA des paramètres dynamiques.
- En intégrant les paramètres dynamiques identifiés, l'algorithme peut générer des trajectoires qui optimisent la consommation d'énergie tout en tenant compte des contraintes de temps et d'autres facteurs pertinents.
- Cette contribution permet aux VAI de naviguer efficacement, réduisant ainsi la consommation d'énergie et favorisant des solutions de manutention durables.

En résumé, les contributions de cette thèse de doctorat sont :

- (i) Développement d'un modèle cinétique VAI complet, prenant en compte les changements des paramètres d'inertie dynamique et les contraintes de mouvement.
- (ii) Utilisation des techniques d'IA pour l'identification en ligne des paramètres dynamiques, ce qui renforce la précision et la fiabilité de la modélisation des mouvements du VAI.
- (iii) Élaboration d'un algorithme de planification de mouvement éco-énergétique en exploitant l'identification basée sur l'IA des paramètres dynamiques, optimisant la consommation d'énergie et favorisant une manutention durable des charges.

## 1.6 Méthodologie de recherche

L'objectif de ce travail est de valider la méthode proposée dans deux applications différentes : un Robot Mobile Autonome à Entraînement Différentiel (RMAED) et un Chariot



Élévateur Autonome de Type Automobile (CEATA) fourni par notre partenaire industriel. Pour ce faire, la méthodologie et l'organisation suivantes sont prises en compte.

La phase initiale de ce travail est composée de deux parties essentielles. Ils sont indispensables pour atteindre la précision globale des méthodes proposées par les études antérieures : 1) Passer en revue la littérature afin de cerner l'état des connaissances actuelles relatives au sujet proposé. À cet égard, les méthodes présentées dans des travaux scientifiques récents concernant les modèles cinétiques, l'identification des paramètres et les problèmes de planification de mouvements efficaces sur le plan énergétique font l'objet d'une analyse. Par la suite, les modèles et méthodes considérés sont catégorisés en termes de précision et de pertinence dans des contextes d'exécution en temps réel, mettant en lumière les lacunes existantes dans la littérature. 2) Réaliser des simulations et des expériences pour illustrer la nécessité de prendre en compte les contraintes dynamiques dans les algorithmes de planification de mouvement pour parvenir à des méthodes éco-énergétiques. La deuxième étape de la recherche se concentre sur le développement de modèles cinétiques pour les VAIs. La méthode de modélisation Newton-Euler est utilisée pour créer le modèle cinétique pour l'RMAED, en tenant compte des changements du CoM dans un espace bidimensionnel. De plus, la méthode de modélisation Euler-Lagrange est mise en œuvre pour formuler le modèle cinétique du CEATA, tout en prenant en compte les effets induits par la présence d'une seule roue avant motorisée.

La troisième étape de la recherche concerne la tâche d'identification des paramètres dynamiques. Pour ce faire, les modèles cinétiques développés sont d'abord utilisés pour générer des ensembles de données. Les DNN sont ensuite utilisés pour former des modèles d'apprentissage à l'aide de données. La bibliothèque scikit-learn en Python [44] est utilisée pour cette tâche. Pour l'RMAED, les modèles formés visent à estimer le CoM du véhicule après placement de la charge et à prédire l'énergie requise pour les échantillons de vitesse générés par le planificateur de mouvement. De même, le modèle formé pour le CEATA se concentre sur la prédiction de l'accélération admissible du CEATA tout en considérant les contraintes énergétiques. En utilisant les modèles DNN, un outil est développé pour estimer les paramètres dynamiques inconnus. La dernière étape de ce travail consiste en la conception d'une méthode de planification de mouvement éco-énergétique, qui constitue la principale contribution de cette recherche. Les modèles DNN ont été intégrés dans des planificateurs de

mouvement afin d'identifier les paramètres dynamiques nécessaires : l'approche de fenêtre dynamique (DWA <sup>1</sup>) pour l'RMAED et la bande élastique temporelle (TEB <sup>2</sup>) pour le CEATA. Cette intégration vise à optimiser la consommation d'énergie et à améliorer l'efficacité de la planification de mouvement pour les véhicules RMAED et CEATA. Cet objectif est atteint en utilisant les paramètres dynamiques identifiés pour aider les algorithmes de planification des mouvements à générer des trajectoires plus optimales.

Gazebo est un simulateur de robot puissant utilisé par l'industrie et le monde académique qui calcule la physique, génère des données de capteurs et fournit des interfaces pratiques [45]. Il propose une nouvelle approche de la simulation avec une boîte à outils complète de bibliothèques de développement. Un simulateur bien conçu permet de tester rapidement des algorithmes, de concevoir des robots, d'effectuer des tests de régression et de former des systèmes IA à l'aide de scénarios réalistes. Le système d'exploitation pour robots (ROS <sup>3</sup>) est un cadre flexible pour écrire des logiciels pour robots [46]. C'est un ensemble d'outils, de bibliothèques et de conventions conçu pour faciliter le développement de systèmes automatisés sophistiqués et fiables, adaptés à divers types de robots.

La coopération entre ROS et Gazebo peut créer un environnement idéal pour évaluer les différentes méthodes et algorithmes. De ce fait, la phase de simulation de la méthode proposée est validée à travers l'usage de ces outils. Afin de confirmer la validité de la méthode proposée, des essais expérimentaux sur le RMAED sont réalisés au sein du laboratoire de l'Institut de Recherche sur l'Hydrogène (IRH) de l'Université du Québec à Trois-Rivières (UQTR). De plus, les tests expérimentaux du VAI de type CEATA sont réalisés dans un environnement similaire à un entrepôt. Les sols des deux endroits sont en béton peint et nivelé pour éviter les glissements. Pour tracer les résultats dans ce travail, le logiciel MATLAB [47] est utilisé.

## 1.7 Infrastructure de recherche

Toutes les ressources informatiques et électroniques pour les études de modélisation ont été fournies par l'IRH et le Département de Génie Mécanique de l'UQTR. Le VAI de type

---

1. DWA est l'abréviation de "Dynamic Window Approach", en anglais (fenêtre dynamique en français)  
 2. TEB est l'abréviation de "Timed Elastic Band", en anglais (bande élastique chronométrée en français)  
 3. ROS est l'abréviation de "Robot Operating System", en anglais (système d'exploitation du robot en français)

CEATA et l’RMAED ont été préparés par le partenaire industriel pour effectuer des tests expérimentaux. Ces tests ont été réalisés dans le laboratoire de l’IRH et dans un environnement similaire à un entrepôt préparé par le partenaire industriel.

## 1.8 Structure de la thèse

Cette thèse est présentée en 7 chapitres, le reste du document est organisé comme suit :

- **Chapitre 2 :** Ce chapitre se penche sur les études déjà publiées concernant le modèle cinétique, l’identification des paramètres et le problème de la planification du mouvement. Il offre une revue claire et approfondie des expertises existantes dans ces domaines spécifiques.
- **Chapitre 3 :** Ce chapitre explore ensuite l’importance d’utiliser des paramètres dynamiques lors de la planification des déplacements des VAIs. Cette exploration est soutenue par une série de simulations informatiques et d’expériences. Le chapitre fusionne une investigation des connaissances existantes avec des tests pratiques, préparant le terrain pour le reste de la thèse.
- **Chapitre 4 :** Ce chapitre se concentre sur la création d’équations décrivant comment les VAIs se déplacent. En alignement avec les visées du projet, qui consistent à implémenter une technique suggérée sur deux types différents du VAI, le chapitre commence par établir un modèle pour un type de véhicule connu sous le nom d’RMAED. Le chapitre procède ensuite au développement d’un modèle pour un autre type de véhicule, le CEATA, en tenant compte des limitations spécifiques et des hypothèses définies pour ce projet. À la fin de ce chapitre, deux modèles sont prêts à être utilisés dans les étapes ultérieures de la recherche.
- **Chapitre 5 :** Ce chapitre explique la méthodologie de planification des mouvements des VAI de manière plus économe en énergie. Comme le projet implique deux types de véhicules différents (RMAED et CEATA), chacun est discuté séparément, bien que la même approche de base s’applique aux deux. Le chapitre commence par détailler comment les ensembles de données nécessaires sont créés à l’aide des modèles cinétiques

générés dans le chapitre précédent. Ces ensembles de données sont ensuite utilisés pour former des modèles DNN afin d'identifier les paramètres appropriés. Une fois les modèles DNN formés, ils sont intégrés aux algorithmes de planification de mouvement. Ces algorithmes utilisent la sortie des modèles DNN - les paramètres dynamiques identifiés - pour ajuster et optimiser la planification de mouvement, améliorant ainsi l'efficacité énergétique.

- **Chapitre 6** : Ce chapitre constitue une partie essentielle de la thèse car il fournit une preuve concrète de l'efficacité des planificateurs de mouvement proposés. Les planificateurs de mouvement conçus dans le Chapitre 4 sont testés sur deux types différents du VAI (l'RMAED et le CEATA). Le chapitre examine les résultats de chaque test. L'objectif est de démontrer la performance réelle des planificateurs de mouvement et de comparer leur fonctionnement dans différentes conditions. À la fin de ce chapitre, une compréhension claire de l'application réelle des trajectoires pour un mouvement éco-énergétique est atteinte.
- **Chapitre 7** : Ce chapitre contient des conclusions et des résumés des constatations, des résultats et des discussions. Des idées de recherches futures pour développer et compléter le présent travail ont également été recommandées dans ce chapitre. Enfin, les publications extraites de cette thèse ont été listées.

## Chapitre 2 - Revue de la littérature

Ce chapitre présente l'état actuel de la littérature académique concernant les aspects du modèle cinétique, de l'identification des paramètres et du problème de planification du mouvement.

### 2.1 Modèle cinétique

Dans le contexte de l'analyse du mouvement dynamique des VAI, on peut utiliser des modèles cinématiques et cinétiques. Examinons chaque modèle plus en détail. Le modèle cinématique décrit le mouvement du VAI sans tenir compte des forces qui le font bouger [48]. Il se concentre sur la relation entre les vitesses des roues du VAI et son mouvement résultant. Ce modèle est souvent utilisé pour déterminer la vitesse du VAI en fonction des vitesses des actionneurs, ou vice versa. Il comporte deux aspects courants du modèle cinématique : (i) la cinématique directe qui, en utilisant les vitesses des actionneurs (vitesses des roues), peut déterminer la vitesse correspondante du VAI [49]. Cela aide à comprendre comment les vitesses des roues se traduisent par le mouvement global du VAI. (ii) La cinématique inverse qui peut calculer les vitesses d'actionneur nécessaires pour atteindre la vitesse désirée. Cela aide à planifier les vitesses d'actionneur nécessaires pour atteindre un objectif de mouvement spécifique.

Le modèle cinétique (dynamique) prend en compte les forces et les couples agissant sur le VAI, permettant une description plus précise de son mouvement [48]. Il fournit une compréhension complète de la manière dont les forces affectent le comportement du VAI pendant le mouvement. Le modèle dynamique considère des facteurs tels que la masse du robot, son inertie, la friction, et les forces externes résultant des interactions avec l'environnement. Il permet une analyse plus approfondie du mouvement du VAI, y compris des tâches telles que

la planification de mouvement, le contrôle, et l'analyse de stabilité. En considérant les forces et les couples, il peut simuler et prédire le comportement du robot dans des scénarios plus complexes. Ce modèle est essentiel pour des tâches nécessitant une compréhension détaillée de la dynamique du VAI, telles que l'optimisation des stratégies de contrôle ou l'analyse de la stabilité du VAI lors de diverses manœuvres.

Les modèles dynamiques peuvent être obtenus à l'aide de différentes méthodes parmi lesquelles la mécanique Lagrangienne [50]-[54] et Newton-Euler [55], [56] ont été plus utilisées dans la littérature. L'approche Newton-Euler combine la deuxième loi du mouvement de Newton avec les équations d'Euler pour le mouvement de rotation. Les équations de Newton-Euler sont obtenues en tenant compte des forces et des couples agissant sur un système et en les reliant aux accélérations et accélérations angulaires du système. Dans les équations de Newton-Euler, les forces et les couples sont généralement séparés en forces externes agissant sur le système et forces internes générées à l'intérieur du système. Les forces externes sont généralement dues aux interactions avec l'environnement, tandis que les forces internes sont liées à la distribution de la masse et à la géométrie du système. Des détails supplémentaires sur les propriétés de la technique de Newton-Euler sont fournis ci-dessous.

- **Adéquation :**

- **Systèmes multi-corps complexes :** Particulièrement bien adapté pour les robots ayant des structures mécaniques complexes où l'application directe des forces et des couples est nécessaire pour analyser le mouvement.
- **Applications en temps réel :** Efficace pour le contrôle et la simulation en temps réel des systèmes robotiques grâce à son cadre computationnel direct.

- **Avantage :**

- **Compréhension intuitive :** Fournit une interprétation physique claire des forces et des moments agissant sur chaque partie du robot.
- **Approche modulaire :** Peut être appliquée de manière modulaire, en analysant un maillon à la fois, ce qui simplifie la complexité impliquée dans la modélisation dynamique.

- **Efficacité computationnelle** : Peut être plus efficace sur le plan computationnel pour certains types de robots, en particulier ceux ayant un nombre inférieur de maillons.
- **Inconvénients** :
  - **Complexité algébrique** : Pour les robots ayant un grand nombre de maillons ou de degrés de liberté, les équations peuvent devenir algébriquement complexes et fastidieuses à résoudre.
  - **Dépendance à l'accélération linéaire et angulaire** : Nécessite le calcul des accélérations linéaires et angulaires, ce qui peut augmenter la charge computationnelle.
  - **Moins généralisable** : La méthode peut être moins généralisable à travers différents types de systèmes robotiques sans modifications significatives du modèle.

La mécanique Lagrangienne est un cadre mathématique utilisé pour décrire la dynamique d'un système en définissant une quantité appelée Lagrangien. Cette approche a été développée par Joseph-Louis Lagrange à la fin du 18ème siècle et offre une formulation alternative à la mécanique newtonienne. En mécanique Lagrangienne, le comportement d'un système est décrit en termes de coordonnées généralisées, qui sont choisies pour décrire la configuration du système. Le Lagrangien est défini comme la différence entre l'énergie cinétique et l'énergie potentielle du système. En appliquant le principe de moindre action, qui affirme que le mouvement réel d'un système minimise l'intégrale d'action, on peut déduire les équations de mouvement du système. Ces équations sont connues sous le nom d'équations d'Euler-Lagrange et décrivent comment les coordonnées généralisées et leurs dérivées évoluent au cours du temps. La mécanique Lagrangienne est particulièrement utile pour les systèmes avec contraintes, puisqu'elle permet d'incorporer des forces de contrainte [57]. Elle offre une approche plus raffinée et puissante pour analyser la dynamique des systèmes mécaniques complexes par rapport à l'approche Newtonienne traditionnelle. Le choix entre les approches Newton-Euler et Lagrangienne dépend du problème spécifique à aborder. Des informations supplémentaires sur les caractéristiques de la méthode Euler-Lagrange sont décrites comme suit :

- **Adéquation :**
  - **Systèmes avec interactions complexes :** Idéal pour les systèmes où la conservation de l'énergie et les interactions complexes entre composants sont significatives.
  - **Études analytiques :** Convient pour des études analytiques approfondies sur le mouvement, la stabilité et le contrôle des robots.
  
- **Avantages :**
  - **Généralité :** Offre une approche très générale qui peut être appliquée à une grande variété de systèmes robotiques, indépendamment de leur mécanique spécifique.
  - **Simplification des équations :** Peut mener à des équations de mouvement plus simples en présence de contraintes en les incorporant naturellement dans la formulation.
  - **Vue holistique :** Fournit une vue d'ensemble de la dynamique énergétique du système, facilitant l'analyse de l'efficacité et de l'optimisation énergétique.
  
- **Inconvénients :**
  - **Exigence de l'énergie potentielle :** Pas aussi intuitif pour les systèmes où l'énergie potentielle n'est pas clairement définie ou est difficile à quantifier.
  - **Complexité computationnelle :** Le processus d'obtention des équations du mouvement peut être intensif en calcul, surtout pour les systèmes avec de nombreux degrés de liberté.
  - **Sophistication mathématique :** Nécessite un niveau plus élevé de sophistication mathématique pour formuler et résoudre les équations, ce qui peut ne pas être évident pour tous les types d'applications robotiques.

Pour évaluer les algorithmes de mouvement et de contrôle, le modèle cinétique du robot est la première exigence. Bien que la modélisation cinématique des VAI soit bien documentée et facilement compris par les étudiants, la modélisation dynamique des VAI n'a pas été abordée de manière adéquate dans la littérature. Par conséquent, un modèle dynamique détaillé et



précis décrivant le mouvement des VAI doit être développé pour offrir un cadre général pour l'analyse de simulation et la conception de systèmes de contrôle et de mouvement basés sur des modèles. Cependant, il n'existe aucun manuel qui examine en profondeur l'approche de modélisation dynamique en tenant compte des contraintes non holonomes dans le cadre d'une procédure étape par étape pour un VAI. L'analyse est principalement disponible dans des revues, des articles de conférence et des rapports techniques. De plus, le contenu présenté varie d'un article à l'autre avec différentes variables et cadres de référence utilisés, et diverses hypothèses.

Cette étude s'efforce d'examiner l'efficacité de la méthode proposée en l'appliquant à deux applications distinctes : le RMAED et le CEATA. En ce qui concerne le RMAED, une revue des recherches antérieures montre que toutes les études existantes se sont exclusivement concentrées sur l'axe longitudinal du robot lors de la prise en compte des changements de la CoM [58]-[62]. Cependant, dans les cas où le RMAED transporte une charge, le CoM peut également subir un mouvement le long de l'axe latéral. Par conséquent, il est impératif de développer un modèle cinétique précis qui englobe toute la surface de la plate-forme de le RMAED afin de saisir les variations du CoM.

Dans le contexte des systèmes dynamiques, la tâche de planification de mouvement pour les CEATA présente plus de complexités par rapport aux RMAED. Le mouvement d'un type similaire de voiture implique une combinaison de mouvement de translation et de rotation, posant ainsi des défis pour l'algorithme de planification de mouvement pour prédire avec précision le comportement du véhicule dans diverses circonstances. Notamment, le rayon de braquage d'un système de type similaire de voiture est influencé à la fois par la vitesse linéaire du véhicule et son angle de direction, alors que dans les entraînements différentiels, le rayon de braquage peut être manipulé indépendamment de la vitesse linéaire.

Des études précédentes dans le domaine ont introduit certaines hypothèses pour simplifier le modèle cinétique des véhicules de type similaire de voiture. Par exemple, ils considèrent souvent une vitesse constante tout au long de la phase de planification [63], approximent les forces inconnues à l'aide de coefficients [64] et ignorent l'influence de la vitesse de la roue motorisée [65]. Ces simplifications sont adoptées afin de faciliter l'analyse et le calcul dans le cadre de la planification de mouvement pour les CEATA. Cependant, elles posent

des problèmes dans des scénarios réels, comme effectuer des manœuvres dans des situations compliquées.

Dans cette étude, nous cherchons à aborder les défis spécifiques associés à notre travail en développant des modèles cinétiques pour deux systèmes distincts : RMAED et CEATA. Pour ce faire, nous utilisons l'approche Newton-Euler pour formuler le modèle cinétique pour le RMAED, tandis que l'approche Euler-Lagrange est utilisée pour établir le modèle cinétique pour le CEATA. En utilisant ces approches respectives, nous pouvons capturer avec précision le comportement dynamique et les interactions au sein de chaque système, permettant une compréhension complète de leurs propriétés cinématiques. Les raisons du choix de chaque méthode pour les études de cas sont expliquées ci-dessous :

### 1. RMAED - Méthode de Newton-Euler :

- *Simplicité et application directe de la force* : Les systèmes de propulsion différentielle se caractérisent par leur conception mécanique relativement simple, où le mouvement est contrôlé par les vitesses différentielles de deux roues parallèles. La méthode de Newton-Euler est bien adaptée à de tels systèmes car elle applique directement les forces et les couples pour modéliser la dynamique du RMAED. Cette approche simplifie l'analyse de l'influence de l'application directe des forces sur les roues du RMAED.
- *Exigences de contrôle en temps réel* : Les RMAED fonctionnent souvent dans des environnements dynamiques et nécessitent un contrôle en temps réel pour naviguer efficacement. L'efficacité computationnelle de la méthode de Newton-Euler est avantageuse pour développer des algorithmes de contrôle qui répondent rapidement aux changements environnementaux et aux obstacles.
- *Analyse modulaire* : La nature modulaire de l'approche de Newton-Euler permet une analyse indépendante de chaque roue et du corps du RMAED. Cette modularité est bénéfique pour les systèmes à propulsion différentielle, où l'interaction entre les roues dicte principalement le mouvement du véhicule.

### 2. CEATA - Méthode d'Euler-Lagrange :

- *Interactions complexes et conservation de l'énergie* : Un CEATA implique des interactions plus complexes entre ses composants, tels que les mécanismes de direction et les opérations de levage, qui peuvent affecter de manière significative sa dynamique énergétique. La méthode d'Euler-Lagrange, en se concentrant sur l'énergie cinétique et potentielle totale du système, offre un cadre plus complet pour capturer ces interactions. Cette méthode assure que toutes les forces, y compris les forces non-conservatrices, sont prises en compte dans le bilan énergétique du système.
- *Incorporation des contraintes* : Les CEATA ont des contraintes liées à la direction et au mouvement, qui peuvent être élégamment incorporées dans les équations d'Euler-Lagrange. Cette méthode tient automatiquement compte des contraintes dans le système, simplifiant la modélisation de la dynamique de direction du chariot élévateur et de l'interaction entre ses roues et le sol.
- *Optimisation et analyse de la stabilité* : La méthode d'Euler-Lagrange est propice à l'étude analytique de la stabilité du système et de l'optimisation du contrôle, qui sont critiques pour les chariots élévateurs autonomes opérant dans les entrepôts et les milieux industriels. Cette méthode facilite la dérivation des équations de mouvement qui peuvent être utilisées pour optimiser la planification de la trajectoire du chariot élévateur, son efficacité énergétique et ses capacités de manipulation des charges, assurant un fonctionnement sûr et efficace.

## 2.2 Identification des paramètres

L'identification des paramètres du modèle dynamique pour les VAI est une tâche cruciale pour comprendre et caractériser leur comportement. Diverses méthodes ont été proposées pour l'identification des paramètres, qui peuvent être classées en trois groupes principaux [66]. Le premier groupe comprend les méthodes basées sur les filtres, qui utilisent des algorithmes d'estimation pour identifier les paramètres. L'idée de base derrière les méthodes fondées sur les filtres est de concevoir un filtre qui traite de manière optimale les données observées afin d'estimer les paramètres d'intérêt. Le filtre est généralement conçu sur la base de certaines

hypothèses concernant les propriétés statistiques des données et du modèle considéré. Parmi ces méthodes, le filtre de Kalman étendu (EKF<sup>1</sup>) et le filtre de Kalman unscented (UKF<sup>2</sup>) sont largement reconnus et couramment utilisés dans la littérature [67]. Ces filtres permettent estimer des paramètres essentiels tels que la masse, le moment d'inertie, et le CoM [68]-[71]. Des détails supplémentaires sur cette méthode sont fournis ci-dessous.

- **Adéquation :**

- Systèmes avec des mesures contaminées par du bruit.
- Applications où une estimation en temps réel et un contrôle adaptatif sont nécessaires.

- **Avantages :**

- *Robustesse au Bruit* : Les méthodes basées sur des filtres, comme le filtre de Kalman, sont conçues pour gérer efficacement le bruit dans les données de mesure, fournissant des estimations de paramètres précises même en présence de bruit significatif.
- *Application en Temps Réel* : Elles conviennent aux applications en temps réel grâce à leur nature récursive, permettant la mise à jour des paramètres au fur et à mesure de la disponibilité de nouvelles données.
- *Capacités Prédictives* : Les méthodes basées sur des filtres peuvent prédire les états futurs du système, ce qui est bénéfique pour le contrôle et la planification.

- **Inconvénients :**

- *Dépendance au Modèle* : Leur performance dépend fortement de la précision du modèle initial. Des modèles incorrects peuvent conduire à une mauvaise estimation des paramètres.
- *Complexité Computationnelle* : Certaines méthodes basées sur des filtres, en particulier les filtres non linéaires comme l'EKF ou le UKF, peuvent être intensives sur le plan computationnel.

---

1. EKF est l'abréviation de "Extended Kalman Filter", en anglais (filtre de kalman étendu en français)

2. UKF est l'abréviation de "Unscented Kalman Filter", en anglais (filtre de kalman unscented en français)

- *Ajustement Nécessaire* : Les filtres nécessitent souvent un ajustement minutieux de leurs paramètres (par exemple, les covariances du bruit de processus et de mesure), ce qui peut être difficile et prendre du temps.

Le deuxième groupe est constitué de méthodes basées sur les observateurs qui s'appuient sur des modèles d'observation pour estimer les paramètres [72]. Ces méthodes reposent sur le concept d'observateur, qui est un modèle mathématique qui émule le comportement de la dynamique du robot et fournit des estimations des paramètres. L'idée de base derrière les méthodes basées sur observation est de concevoir un observateur qui imite la dynamique du robot à l'aide d'un modèle connu et estime les paramètres inconnus en comparant le comportement observé du robot avec le comportement prédit par l'observateur. Parmi les exemples de ces méthodes figurent les moindres carrés récursifs [73], les observateurs linéaires et non linéaires [74], [75], et les observateurs en mode glissant [76]-[78]. Ces techniques basées sur l'observation s'appuient sur des modèles mathématiques pour estimer les paramètres inconnus du système dynamique. Plus d'informations sur cette méthode peuvent être trouvées dans la partie suivante.

**Adéquation :**

- Systèmes où la mesure directe de tous les états n'est pas possible.
- Systèmes de contrôle nécessitant une rétroaction d'état pour la stabilisation et l'amélioration des performances.

**Avantages :**

- *Estimation d'État* : Les méthodes basées sur des observateurs, comme les observateurs de Luenberger ou les Observateurs en Mode Glissant, peuvent estimer les états non mesurés du système, en plus d'identifier les paramètres, ce qui est crucial pour le contrôle par rétroaction.
- *Propriétés de Convergence* : Ces méthodes viennent souvent avec des garanties théoriques sur les propriétés de convergence sous certaines conditions, offrant une fiabilité dans l'estimation des paramètres.

- *Flexibilité* : Les observateurs peuvent être conçus pour des caractéristiques spécifiques du système, telles que la non-linéarité ou l'incertitude, améliorant leur efficacité.

**Inconvénients :**

- *Complexité de Conception* : Concevoir un observateur nécessite une compréhension approfondie de la dynamique du système et peut être complexe, en particulier pour les systèmes non linéaires.
- *Sensibilité aux Discordances du Modèle* : Les observateurs peuvent mal fonctionner si le modèle du système ne représente pas précisément la dynamique du système réel.
- *Conditions Initiales* : L'exactitude de l'identification des paramètres peut être sensible aux conditions initiales supposées pour les états de l'observateur.

Le troisième groupe englobe les approches d'estimation basées sur les données, y compris celles utilisant des réseaux de neurones, qui gagnent en popularité pour les tâches d'estimation de paramètres, en particulier dans des conditions non linéaires [79], [80]. Ces méthodes ne reposent pas sur des modèles explicites mais plutôt apprennent la relation entre les entrées (données observées) et les sorties (paramètres) à partir des données disponibles. Les réseaux de neurones, en tant qu'approximateurs de fonctions universelles, peuvent saisir des mappages non linéaires complexes entre les entrées et les sorties, les rendant adaptés aux tâches d'estimation de paramètres dans divers scénarios [81]. Des détails supplémentaires sur cette méthode sont décrits dans ce qui suit.

- **Adéquation :**

- Systèmes avec des informations de modèle limitées ou inexistantes.
- Applications où de grandes quantités de données opérationnelles sont disponibles.

- **Avantages :**

- *Indépendance du modèle* : Ces méthodes ne nécessitent pas un modèle physique détaillé du système, ce qui les rend adaptées aux systèmes complexes ou mal compris.

- *Flexibilité et adaptabilité* : Les méthodes basées sur les données peuvent s'adapter aux changements dans la dynamique du système ou aux conditions opérationnelles en apprenant à partir de nouvelles données.
- *Capacité à gérer la non-linéarité et la complexité* : Des techniques telles que les réseaux neuronaux ou les algorithmes d'apprentissage automatique peuvent modéliser efficacement et identifier les paramètres pour des systèmes hautement non linéaires et complexes.

- **Inconvénients :**

- *Exigence de données* : Des quantités significatives de données de qualité sont nécessaires pour former efficacement les modèles, ce qui peut être une limitation dans certaines applications.
- *Risque de surajustement* : Il existe un risque de surajustement du modèle aux données d'entraînement, ce qui peut entraîner une mauvaise généralisation à des données non vues.
- *Interprétabilité* : Les modèles identifiés en utilisant des techniques basées sur les données, en particulier les modèles d'apprentissage profond, peuvent manquer d'interprétabilité, rendant difficile la compréhension des principes physiques sous-jacents.

Chacune de ces méthodes d'identification de paramètres a ses avantages et ses limites. Le choix de la méthode dépend des exigences spécifiques de l'application, des données disponibles et de la précision souhaitée des estimations de paramètres. Les chercheurs choisissent souvent la méthode la plus appropriée parmi ces trois groupes en fonction des caractéristiques et de la complexité du système robotique étudié. Étant donné la nature compliquée et pas toujours évidente des modèles dynamiques pour les deux véhicules avec lesquels nous travaillons, déterminer les paramètres de navigation importants représente une tâche difficile. Ces modèles étant assez complexes, l'utilisation d'une méthode basée sur les données semble être la meilleure approche, surpassant les méthodes habituelles basées sur des filtres ou des observateurs. Les techniques pilotées par les données sont particulièrement efficaces pour gérer

les systèmes complexes et non linéaires. Elles procèdent en examinant de grandes quantités de données pour comprendre le fonctionnement interne des véhicules et la manière dont les éléments sont liés. Cela leur permet de faire des prédictions très précises concernant les éléments de navigation dont nous avons besoin, sans nécessiter de modèles mathématiques sophistiqués qui peuvent être difficiles à élaborer pour des systèmes pas toujours évidents. Opter pour une méthode pilotée par les données nous offre une manière plus flexible et intelligente de trouver les bons paramètres, même lorsque les choses se compliquent dans le monde réel où les véhicules se déplacent.

Pour les deux véhicules de notre étude, chacun dispose d'un système de navigation qui se met à jour toutes les 20 ms. Il est vraiment important de choisir une méthode capable de déterminer rapidement les bons réglages ou paramètres dans ce court laps de temps pour assurer une navigation efficace et une réponse rapide des véhicules. Certaines méthodes courantes, telles que les techniques basées sur les filtres et les observateurs, sont généralement bonnes mais prennent trop de temps pour trouver les bonnes solutions. Elles ajustent continuellement leurs estimations en fonction des nouvelles informations et des formules mathématiques. Mais si les choses changent rapidement ou si l'environnement est très chargé, ces méthodes peuvent ne pas être assez rapides pour suivre le rythme dans le délai de 20 ms. Si elles sont trop lentes, les véhicules pourraient ne pas naviguer aussi bien qu'ils le devraient, ce qui pourrait être dangereux ou entraîner d'autres problèmes.

D'autre part, les méthodes qui utilisent des données et apprennent des expériences passées, surtout celles qui utilisent l'apprentissage automatique et les réseaux de neurones, semblent être un meilleur choix pour déterminer rapidement ces paramètres. Celles-ci n'utilisent pas les ajustements progressifs lents que font les autres méthodes. Au lieu de cela, elles utilisent les informations issues des expériences passées et ce qu'elles ont appris de celles-ci pour faire des suppositions rapides sur les paramètres dès qu'elles sont nécessaires. Si ces méthodes basées sur les données ont été entraînées avec beaucoup de données de bonne qualité, elles peuvent faire des suppositions très précises presque immédiatement, certainement dans le délai de 20 ms.

Par conséquent, cette recherche utilise une approche basée sur les données comme alternative plus adaptée pour l'estimation des paramètres. En outre, au sein de cette approche,



une méthode DNN est choisie pour faciliter le processus d'estimation. Le DNN englobe une gamme de méthodologies, chacune adaptée à des applications spécifiques. Dans le contexte de cette étude, le modèle d'apprentissage profond choisi est chargé de traiter un problème d'identification en ligne à sorties multiples tout en tenant compte de la dynamique non linéaire et des perturbations. L'objectif est de développer un modèle d'apprentissage capable d'estimer avec précision les paramètres souhaités associés aux VAI, améliorant ainsi leurs performances et leur adaptabilité. Par conséquent, le perceptron multi-couche (MLP<sup>1</sup>) [82] est donc choisi pour gérer ces conditions et ces contraintes. Le MLP est un type de réseau neuronal feed-forward composé de plusieurs couches de neurones artificiels interconnectés. Il a la capacité d'apprendre des relations non linéaires entre les entrées et les sorties, le rendant bien adapté à la modélisation de systèmes complexes.

### 2.3 Planification de mouvement

Bien que la planification de trajectoire globale détermine l'itinéraire, la planification de mouvement porte sur la manière dont le VAI doit se déplacer le long de cet itinéraire. Elle est capable de prendre en compte la cinématique (comment il se déplace en fonction de ses caractéristiques physiques) et la dynamique (comment les forces affectent son mouvement) du VAI. La planification de mouvement prend également en compte les obstacles dynamiques qui peuvent bouger ou changer au cours du temps. L'objectif est de générer une séquence de commandes qui guident le robot le long du trajectoire tout en évitant les collisions et en respectant les limitations physiques du robot. Les algorithmes de planification de mouvement pour VAI peuvent être classés en plusieurs catégories en fonction de leur approche et de leur complexité. Voici certains des principaux groupes :

1. Méthodes Basées sur l'Échantillonnage [83] : Ces méthodes, telles que les arbres aléatoires à exploration rapide (RRT<sup>2</sup>) et les cartes routières probabilistes, génèrent des échantillons aléatoires dans l'espace de configuration du robot et tentent de relier ces échantillons pour former une trajectoire. Elles sont particulièrement utiles dans

---

1. MLP est l'abréviation de "Multi-Layer Perceptron", en anglais (le Perceptron multi-couche en français)

2. RRT est l'abréviation de "Rapidly-exploring Random Trees", en anglais (les arbres aléatoires à exploration rapide en français)

les espaces à haute dimension et lorsque seules des solutions approximatives sont nécessaires.

2. Méthodes Basées sur l'Optimisation [84] : Ces méthodes formulent la planification des mouvements comme un problème d'optimisation et cherchent à trouver la trajectoire optimal selon une certaine fonction de coût. Des exemples incluent les méthodes basées sur le gradient et les algorithmes évolutionnaires. L'optimisation de la trajectoire est une technique courante dans cette catégorie, qui optimise une trajectoire globale en fonction de critères tels que la longueur, la consommation d'énergie ou le temps.
3. Méthodes Basées sur la Grille [85] : Ces méthodes discrétisent l'environnement en une grille et recherchent une trajectoire globale dans cette grille. Elles sont simples et efficaces, mais peuvent ne pas convenir à des espaces de haute dimension ou continus.
4. Méthodes Basées sur la Décomposition [86] : Ces méthodes décomposent l'espace de configuration à haute dimension en espaces à plus faible dimension, ce qui simplifie le problème de planification du mouvement.
5. Méthodes Basées sur l'Apprentissage [87] : Ce sont des méthodes relativement nouvelles qui utilisent des techniques d'apprentissage automatique pour apprendre la planification du mouvement à partir de données. Elles peuvent être particulièrement efficaces dans des environnements complexes et dynamiques. Des exemples incluent l'apprentissage par renforcement et l'apprentissage par imitation.
6. Méthodes Hybrides [88] : Ces méthodes combinent deux ou plusieurs des approches ci-dessus pour exploiter leurs points forts et atténuer leurs faiblesses. Par exemple, une approche hybride courante consiste à utiliser une méthode basée sur la grille pour la planification du trajectoire globale et une méthode basée sur l'échantillonnage ou basée sur l'optimisation pour la planification du mouvement local.

Chacune de ces méthodes a ses forces et ses faiblesses, et le choix de la méthode dépend des exigences spécifiques du VAI et de son environnement opérationnel. L'objectif principal de cette recherche est de développer un schéma pour la conception et la mise en œuvre de

stratégies de planification de mouvement caractérisées par une efficacité énergétique accrue. Par conséquent, une revue des articles scientifiques pertinents concernant les préoccupations liées à l'énergie sera effectué.

Dans leurs recherches, Mei et ses collègues [89] ont exploré une stratégie éco-énergétique pour la planification de mouvements d'un dispositif robotique omnidirectionnel à trois roues. L'objectif de ce robot était d'effectuer automatiquement des opérations de nettoyage de sol dans une zone dégagée. Ils ont développé un modèle énergétique basé sur une fonction d'ajustement à six degrés dérivée de données expérimentales de vitesse, en tenant compte uniquement du modèle cinématique. Cependant, la méthode qu'ils ont proposée était spécifique à ce type de robot et n'était pas applicable à d'autres types. Ils ont suggéré que la mise en œuvre de règles d'estimation et de prédiction pourrait améliorer la capacité du robot à éviter les obstacles de manière appropriée.

Sur une note similaire, Llamazares et son équipe [90] ont proposé un cadre de Contrôle par Inférence Approximative (CIA) qui s'appuie sur un modèle de consommation d'énergie pour la planification de mouvement. Ce modèle tenait compte de défis tels que l'inertie, les changements de pente de la route, le frottement des pneus et les pertes aérodynamiques. Le cadre CIA a démontré une amélioration de l'efficacité énergétique de plus de 10% par rapport aux meilleurs résultats obtenus par les algorithmes traditionnels. Néanmoins, leur hypothèse selon laquelle le robot maintient une vitesse linéaire pourrait être irréaliste, étant donné la gamme d'actions que le robot doit effectuer dans les tâches réelles.

Dans l'étude référencée [91], la DWA a été intégrée avec une fonction de coût qui prend en compte la consommation d'énergie. Ils ont étudié un robot omnidirectionnel dans un environnement partiellement dynamique, en basant leur modèle de consommation d'énergie sur celui introduit dans [92]. Cependant, ils l'ont affiné en incorporant des facteurs d'énergie électrique, de frottement, et d'accélération. Leur approche a été encore optimisée en formulant un nouveau modèle énergétique et en définissant un nouvel objectif de coût dans le but de minimiser l'utilisation de l'énergie [93].

Dans une autre étude réalisée par Alajlan et al. [94], ils ont proposé une technique multi-capteurs pour un Robot Mobile à Roues (RMR). Ils ont utilisé des capteurs infrarouges

réfléchissants pour la détection des bords, et une combinaison de capteurs de mesure infrarouges, un capteur ultrasonique et une caméra pour la détection des obstacles, aboutissant à un cadre intégré. De plus, ils ont pris en compte des contraintes telles que la consommation d'énergie, le temps, et la distance parcourue. Le critère principal de leur fonction objective était de générer les trajectoires le plus court et le plus économe en énergie pour éviter les collisions. Au cours d'une tâche, leur méthode évalue plusieurs trajectoires potentiels et opte pour celui ayant le moindre coût.

Gupta et al. [95] se sont penchés sur le développement de modèles dynamiques pour les véhicules à roues à direction par glissement, une catégorie importante de VGAs. Ces modèles ont été vérifiés expérimentalement et utilisés pour créer un modèle de consommation d'énergie pour de tels véhicules. En utilisant un modèle d'optimisation prédictive basé sur l'échantillonnage, les auteurs ont élaboré une méthodologie permettant de générer des trajectoires éco-énergétiques. Les résultats ont révélé que même une légère augmentation de la distance de la trajectoire pouvait entraîner des économies d'énergie substantielles pour le VGA.

Varghese et Jisha [96] ont présenté une méthode efficace de planification du mouvement des RMAs, en s'appuyant sur les méthodes basées sur l'échantillonnage. Les auteurs ont discuté d'une variante RRT améliorée spécialement conçue pour les robots mobiles à entraînement différentiel. Cette variante améliorée incluait un post-traitement en boucle fermée pour générer la séquence de command du robot. Le système de planification de mouvement a été intégré à un contrôleur, utilisé de deux manières spécifiques : (i) pour minimiser les erreurs de position entre les trajectoires planifiées et réelles, et (ii) pour corriger les erreurs d'orientation. Deux types de contrôleurs, un contrôleur PI (Proportionnel-Intégral) et un contrôleur de poursuite pure, ont été utilisés pour atteindre ces objectifs.

Xidias et son équipe [97] ont décrit une approche pour concevoir un mouvement éco-énergétique pour un AV évoluant dans des environnements complexes, que ce soit dans le secteur industriel ou dans de grands entrepôts. Le véhicule devait servir plusieurs postes de travail tout en se déplaçant de manière sûre et efficace dans l'environnement. Dans l'approche proposée, le problème global a été formulé comme un problème d'optimisation avec contraintes en utilisant le concept de Bump-Surface. Ensuite, une stratégie d'optimisation multi-objectif basée sur Pareto a été adoptée, et un algorithme génétique modifié a été développé pour

déterminer la solution optimale de Pareto. L'efficacité de la méthode développée a été étudiée et discutée à travers des expériences simulées.

Zhang et ses collègues [98] ont abordé la préoccupation majeure de la consommation d'énergie dans la navigation des VGAs. Tandis que les recherches existantes se sont principalement concentrées sur les véhicules à direction par glissement ou différentielle, cette étude visait à combler les lacunes concernant les véhicules à direction Ackermann. Un modèle de coût énergétique a d'abord été établi en fonction des contraintes cinématiques du véhicule. Les primitives de mouvement sensibles à l'énergie ont ensuite été précalculées hors ligne, en utilisant ce modèle pour évaluer le coût énergétique de diverses trajectoires primaires. L'efficacité du planificateur de mouvement proposé a été validée à travers des simulations sur 150 cartes générées aléatoirement et par des tests sur des véhicules réels.

Dans des travaux plus récents sur ce sujet, Szczepanski et al. [99] ont suggéré une planification de mouvement économe en énergie basée sur les champs de potentiel artificiel (APF<sup>1</sup>) prédictif. L'algorithme introduit également une nouvelle méthode pour éviter le minimum local basée sur le placement d'obstacles virtuels appelés top quarks dans des zones critiques. En comparaison avec l'APF original, l'algorithme de planification de trajectoire proposé permet de réduire la puissance électrique utilisée de 21,4% pour un petit robot. Après un examen complet des articles de recherche sur le sujet de la planification de mouvement économe en énergie pour les RMRs, il est évident qu'aucune de ces études, de nature similaire à notre travail, n'a pris en compte l'effet des changements de dynamique sur ces robots.

Les VAIs sont principalement engagés dans des tâches de transport de charges. Ce rôle introduit inévitablement une multitude d'incertitudes qui doivent être prises en compte lors de la recherche de solutions optimales. Des facteurs tels que la variation du poids de la charge utile peuvent avoir un impact significatif sur la dynamique de ces robots, entraînant des changements dans leurs propriétés physiques, y compris les paramètres inertiels et les accélérations. En utilisant le modèle cinétique du robot, ces changements peuvent être efficacement identifiés. Par exemple, une charge utile plus lourde peut entraîner une inertie plus importante et modifier le profil d'accélération du robot. La connaissance de ces modifications dans les étapes futures

---

1. APF est l'abréviation de "Artificial Potential Field", en anglais (champ de potentiel artificiel en français)

de la trajectoire d'un robot permet au planificateur de mouvement de faire des prédictions précises de la consommation d'énergie du robot. Grâce à cette capacité prédictive, le planificateur de mouvement peut alors générer des trajectoires optimales qui prennent en compte les considérations énergétiques. En planifiant une trajectoire qui minimise la consommation d'énergie tout en accomplissant efficacement la tâche à accomplir, l'efficacité globale des opérations du robot peut être considérablement améliorée. L'accent mis sur l'adaptabilité dynamique et l'efficacité énergétique est un élément crucial pour l'avancement de la technologie VAI et ses applications potentielles.

La méthode proposée pour améliorer l'efficacité de la phase de planification de mouvement peut être appliquée en complément de divers algorithmes de planification de mouvement qui ignorent le modèle dynamique du véhicule. Cela signifie que la méthode proposée est polyvalente et peut être utilisée avec plusieurs techniques de planification de mouvement, sans se limiter à une ou deux seulement. Dans cette étude, nous avons choisi d'implémenter la méthode proposée avec deux algorithmes de planification de mouvement spécifiques : TEB [100] et DWA [101]. Ces deux algorithmes appartiennent à la famille des méthodes de planification de mouvement basées sur l'optimisation et sont reconnus pour leur capacité à calculer des plans de mouvement efficacement tout en prenant en compte les contraintes du robot et en assurant une navigation sûre dans différents environnements.

DWA est un algorithme de planification de mouvement largement adopté pour les robots mobiles à entraînement différentiel. Il prend en considération l'état actuel du robot, ses limitations cinématiques, et une fenêtre dynamique des états futurs possibles. L'algorithme évalue diverses commandes de mouvement potentielles dans cette fenêtre et attribue à chacune un score basé sur des critères tels que la proximité de l'objectif, l'évitement des collisions et la fluidité du mouvement. La commande de mouvement ayant le score le plus élevé est ensuite exécutée, permettant au robot de naviguer vers son objectif tout en évitant dynamiquement les obstacles. DWA est apprécié pour sa capacité d'adaptation et sa prise de décision en temps réel, le rendant adapté aux scénarios de navigation autonome où un robot doit atteindre efficacement sa destination tout en évitant les obstacles dans un environnement en constante évolution.

TEB, d'autre part, est un algorithme de planification de mouvement bien connu conçu pour les robots mobiles de type voiture. Il est conçu pour générer des trajectoires lisses

et sans collision, spécialement pour les véhicules avec des contraintes non holonomiques, comme les voitures. TEB prend en compte les contraintes dynamiques du robot, y compris sa vitesse maximale et son accélération, pour calculer des trajectoires réalisables. Il considère également l'aspect temporel de la planification de mouvement, optimisant à la fois le temps de voyage et un coût associé au chemin, en considérant souvent des facteurs comme la sécurité et la dynamique du véhicule. TEB est particulièrement utile lorsque des robots de type voiture doivent naviguer dans des environnements complexes, car il génère efficacement des trajectoires qui respectent les limitations physiques du robot tout en atteignant les objectifs souhaités.

## **Chapitre 3 - Nécessité de prendre en compte les paramètres dynamiques dans la planification du mouvement**

L'objectif de ce chapitre est de démontrer l'impact des paramètres dynamiques sur la performance éco-énergétique des méthodologies de planification du mouvement. Deux études de cas sont présentées dans cette recherche. Tout d'abord, nous explorons les problèmes mentionnés dans le chapitre d'introduction (Section 1.4) pour les deux études de cas. Pour ce faire, une étude de l'effet du CoM sur la consommation d'énergie du RMAED et de l'effet de l'accélération sur la consommation d'énergie du CEATA et de la faisabilité de son mouvement, a été effectué en utilisant des formules mathématiques pour plus de précision. Par la suite, nous menons des expériences en utilisant un CEATA et un RMAED fournis par le partenaire industriel, ce qui nous permet de voir pratiquement les problèmes mentionnés.

### **3.1 Position du centre de masse**

La Figure 3-1 montre la plateforme du RMAED avec le déplacement du CoM, où les indices  $i$ ,  $g$ , et  $l$  représentent respectivement inertie, global et charge. Concernant les axes latéraux et longitudinaux, on suppose que la plateforme peut être divisée en quatre zones. Lorsqu'une charge est placée sur la plateforme avec un centre de masse déterminé ( $CoM_l$ ), le  $CoM_i$  qui se trouve dans la zone B, peut se déplacer vers un nouveau point global ( $CoM_g$ ) tel que la zone A. Ainsi, le  $CoM_g$  est le nouveau CoM de la plateforme qui affecte le mouvement du RMAED. La formulation est décrite comme suit :






FIGURE 3-1  $CoM_g$  du RMAED par rapport au  $CoM_l$  de la charge.

$$r_{x_g} = (r_{x_i}m_i + r_{x_l}m_l)/m_g \quad (3.1a)$$

$$r_{y_g} = (r_{y_i}m_i + r_{y_l}m_l)/m_g \quad (3.1b)$$

Où  $r_x$  et  $r_y$  sont les distances du CoM par rapport au milieu de l'axe des roues (point  $P$ ) dans les directions  $x$  et  $y$  respectivement. De plus,  $m_g$  représente la somme de la masse du RMAED ( $m_i$ ) et de la masse de la charge ( $m_l$ ). En considérant le modèle comme un problème bidimensionnel (2D), la rotation du véhicule se produit autour de la direction  $z$  (le corps de référence). Ainsi, le moment d'inertie du RMAED autour de cette direction est :

$$I_{z_g} = I_{x_g} + I_{y_g} \quad (3.2)$$

Où  $I$  représente le moment d'inertie qui est défini autour des directions  $x$  et  $y$  par :

$$I_{x_g} = (I_{x_i} + m_i I_{x_i}^2) + (I_{x_l} + m_l I_{x_l}^2) \quad (3.3a)$$

$$I_{y_g} = (I_{y_i} + m_i I_{y_i}^2) + (I_{y_l} + m_l I_{y_l}^2) \quad (3.3b)$$

Par conséquent, les charges peuvent affecter même le moment d'inertie du véhicule.

Les mouvements rotationnels sont fréquents pour le RMAED lors de missions telles que

tourner dans les couloirs ou éviter des obstacles. Au cours d'une mission, des obstacles inattendus peuvent apparaître et croiser les trajectoires définies de RMAED, tels que des êtres humains ou d'autres véhicules. Une augmentation du nombre d'obstacles a un effet direct sur la consommation d'énergie de RMAED [94]. De plus, une réaction inadéquate pour éviter les obstacles peut augmenter la distance jusqu'à la destination et induire une perte du temps en générant des mouvements inutiles [29].

Pour montrer l'effet de la position de la charge sur la consommation d'énergie causée par l'étape de planification de mouvement, certaines expériences ont été effectuées en utilisant le RMAED du partenaire industriel. Les masses du RMAED et de la charge sont respectivement de 82 kg et 55 kg (trois conteneurs sont placés l'un sur l'autre). À cet égard, les expériences comprennent deux scénarios. Premièrement, le RMAED se déplace en ligne droite. Deuxièmement, il tourne dans un couloir. En outre, chaque scénario comporte deux tentatives par rapport à l'axe longitudinal médian du RMAED :

1. Tentative *a* : La charge est placée sur le côté droit de la plateforme ( $r_{x_l} = 0.3m$ ,  $r_{y_l} = -0.15m$ ).
2. Tentative *b* : La charge est placée sur le côté gauche de la plateforme ( $r_{x_l} = 0.3m$ ,  $r_{y_l} = +0.15m$ ).

Pour avoir une comparaison objective de la consommation d'énergie pour chaque mission, les positions du départ et d'arrivée, la trajectoire globale et la position de l'obstacle inattendu sont les mêmes pour les deux positions de charge. La consommation d'énergie d'un moteur ( $P_M$ ) peut être définie comme une fonction de la tension ( $V_M$ ) et du courant ( $i_M$ ) du moteur :

$$P_M = V_M i_M \quad (3.4)$$

Ainsi, pour mesurer la consommation d'énergie du moteur dans cette étude, l'énergie totale consommée par le moteur  $E_M$  sur la durée  $T$  peut être représentée par l'équation suivante :

$$E_M = \int_0^T P_M dt \quad (3.5)$$

La Figure 3-2 illustre la trajectoire du RMAED et la consommation d'énergie des moteurs des roues dans le premier scénario des tests expérimentaux. Le RMAED reçoit un point de destination et se dirige vers lui en ligne droite. Cependant, il y a un obstacle statique inattendu sur la trajectoire du RMAED. Ainsi, le planificateur de mouvement change la trajectoire du RMAED pour contourner l'obstacle (en tournant à gauche), puis ramène le RMAED sur la trajectoire globale défini par le planificateur de trajectoire globale (ligne droite). Lorsque la charge est du côté droit du RMAED (tentative *a*), il consomme 966.5 J d'énergie, tandis que la consommation diminue de 8.8% dans la tentative *b* au même temps.

La Figure 3-3 illustre la trajectoire globale et la consommation d'énergie de RMAED dans le deuxième scénario des tests expérimentaux. RMAED effectue un mouvement de rotation vers la gauche pour passer le couloir. La consommation d'énergie de RMAED avec une charge placée sur le côté droit de la plateforme est de 514.2 J, soit 15,2% de plus que la tentative *b*. Les résultats des expériences montrent des différences considérables en termes de consommation d'énergie entre les deux tentatives de chaque scénario dans les mêmes conditions. Ces différences peuvent être reproduites lorsque la position de la charge est modifiée sur la plateforme selon l'axe latéral médian de RMAED. Ainsi, le planificateur de mouvement peut être amélioré pour trouver des trajectoires éco-énergétiques en utilisant la position de la charge. Par exemple, RMAED pourrait passer l'obstacle ou tourner dans un couloir en utilisant différentes trajectoires ou manœuvres.

Selon les résultats de cette section et la Figure 3-1, la charge a un effet substantiel sur la dynamique du RMAED qui devrait être prise en compte dans les algorithmes de navigation. Cependant, des travaux précédents ont étudié la dynamique du RMAED en ignorant le paramètre  $r_y$  ( $r_y = 0$ ). Par conséquent, ce travail vise à développer le modèle dynamique du RMAED en considérant le déplacement du  $\text{CoM}_g$  dans les directions longitudinale ( $x$ ) et latérale ( $y$ ).

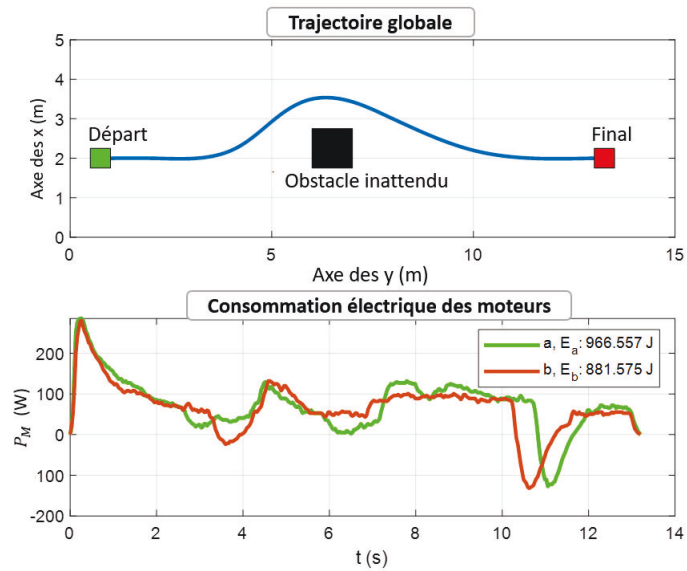


FIGURE 3-2 Le premier scénario de l'expérience (RMAED) : éviter un obstacle inattendu.

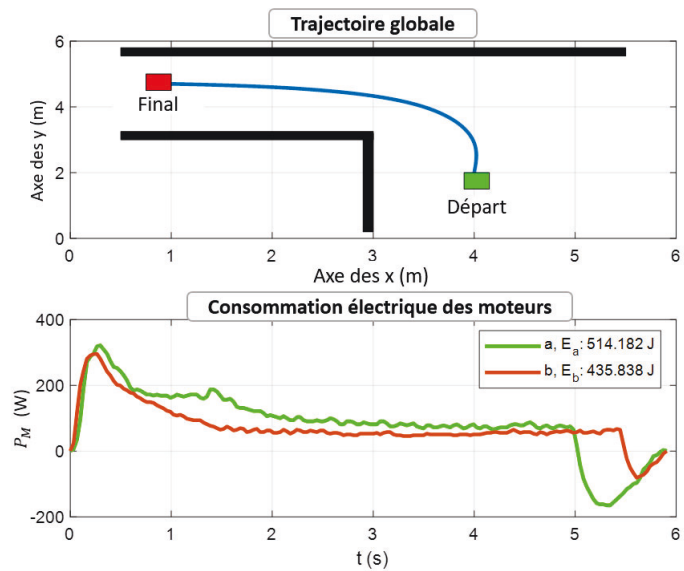


FIGURE 3-3 Le deuxième scénario de l'expérience : mouvement de rotation dans un couloir.

### 3.2 Limites d'accélération

La puissance consommée par un robot peut être modélisée en tant qu'une fonction des forces et des couples exercés par ses moteurs, qui sont à leur tour des fonctions de l'accélération du robot [102]. La relation entre ces forces (qui fournissent un couple pour faire bouger le robot) et l'accélération du robot peut être décrite par un modèle appelé modèle cinétique du robot [103]. Généralement, dans les systèmes linéaires, la consommation d'énergie est directement proportionnelle à la force appliquée et à la vitesse à laquelle le travail est effectué [104]. Ainsi,  $P_F = F \cdot v$ , qui décrit la puissance  $P_F$  en termes de force  $F$  et de vitesse  $v$  dans les systèmes linéaires. De plus, dans les systèmes rotationnels, la consommation d'énergie est directement proportionnelle au couple  $\tau$  et à la vitesse angulaire  $\omega$  [104]. Par conséquent,  $P_\tau = \tau \cdot \omega$  où  $P_\tau$  décrit la puissance en termes de couple. Ainsi, l'augmentation du couple (e.g., utiliser une machine pour soulever des charges plus lourdes) ou de la vitesse angulaire (e.g., faire fonctionner une machine à un RPM plus élevé) augmentera la puissance, et donc la consommation d'énergie [105]. Ceci est observé dans des applications comme les moteurs électriques, où faire fonctionner le moteur à des vitesses plus élevées ou sous une charge plus importante consommera plus d'énergie [106].

Les algorithmes de planification de mouvement anticipent les mouvements ultérieurs d'un robot. Nous pouvons représenter une séquence discrétisée de  $n$  configurations de robot par  $(q_k)_{k=1,2,\dots,n}$ . De même, une séquence d'intervalles de temps strictement positifs peut être symbolisée comme  $(\Delta T_k)_{k=1,2,\dots,n-1}$ , où  $\Delta T_k \in \mathbb{R}^+$ . Chaque intervalle de temps  $\Delta T_k$  correspond à la durée nécessaire pour la transition d'une configuration  $q_k$  à la suivante  $q_{k+1}$ . Par conséquent, l'accélération linéaire et angulaire du robot  $(a_k, \alpha_k)$  peut être présentée comme [107] :

$$a_k = \frac{2(v_{k+1} - v_k)}{\Delta T_k + \Delta T_{k+1}} \quad (3.6a)$$

$$\alpha_k = \frac{2(w_{k+1} - w_k)}{\Delta T_k + \Delta T_{k+1}} \quad (3.6b)$$

La faisabilité d'une trajectoire générée par le planificateur de mouvement peut être évaluée en vérifiant si l'accélération du robot satisfait les contraintes. Si l'algorithme de planification de mouvement prend en compte les limites d'accélération du robot pour les prochains échantillons

de trajectoire, il peut être décrit comme :

$$a_{\max} - |a_k| \geq 0 \quad (3.7a)$$

$$\alpha_{\max} - |\alpha_k| \geq 0 \quad (3.7b)$$

Où  $a_{\max}$  et  $\alpha_{\max}$  présentent les limites d'accélération dans le processus d'optimisation de l'algorithme de planification de mouvement. En considérant les limites d'accélération comme des valeurs constantes, certains problèmes pourraient survenir. Lorsque l'algorithme fonctionne avec des limites d'accélération élevées, il peut produire des trajectoires qui nécessitent une accélération intense. Cependant, le robot peut ne pas être en mesure d'effectuer de telles manœuvres à haute accélération. Par exemple, supposons que nous ayons fixé une accélération linéaire maximale,  $a_{\max}$ , à  $1 \text{ m/s}^2$  et une accélération angulaire maximale,  $\alpha_{\max}$ , à  $1 \text{ rad/s}^2$ . Dans ces conditions, notre algorithme de planification de mouvement est chargé de générer des trajectoires pour une manœuvre complexe comme le stationnement. Cependant, compte tenu des contraintes dynamiques du robot (qui sont intégrées dans son modèle cinétique), il est possible que certaines trajectoires nécessitent moins d'accélération, peut-être  $a_{\max} = 0.5 \text{ m/s}^2$  et  $\alpha_{\max} = 0.5 \text{ rad/s}^2$ . Si l'algorithme n'en tient pas compte, le robot peut être incapable de suivre les trajectoires générées à haute accélération. Par conséquent, le robot peut se retrouver dans une situation où il oscille de manière incontrôlée, ce qui oblige l'algorithme à régénérer des trajectoires plus appropriées. Les CEATA doivent effectuer des manœuvres de stationnement pour récupérer ou déposer des charges dans les usines et les entrepôts. De plus, cette manœuvre nécessite une planification précise à la fois de la position et de l'orientation du CEATA. Ainsi, un CEATA subit à la fois une accélération linéaire et angulaire pour effectuer cette manœuvre. De ce fait, des manœuvres de stationnement ont été prises en compte dans ce travail pour montrer l'effet des limites d'accélération sur la consommation d'énergie du CEATA et la faisabilité des manœuvres. Concernant la Figure 3-4, trois points de passage ( $w_{a-c}$ ) ont été considérés comme des emplacements de stationnement. Trois scénarios ont été réalisés permettant au CEATA (sans charge) de partir du premier point de passage ( $w_a$ ), de se rendre au deuxième point de passage ( $w_b$ ), puis de naviguer vers le troisième point de passage ( $w_c$ ). Dans le scénario 1, les limites d'accélération linéaire et angulaire dans l'algorithme de




FIGURE 3-4 La carte du monde dans Rviz.

planification de mouvement du CEATA ont été considérées à  $0.05 \text{ m/s}^2$  et  $0.05 \text{ rad/s}^2$ . Ces limites ont été modifiées à  $0.1 \text{ m/s}^2$  et  $0.1 \text{ rad/s}^2$  dans le scénario 2, et à  $1 \text{ m/s}^2$  et  $1 \text{ rad/s}^2$  dans le scénario 3.

Chaque scénario a été répété cinq fois pour tenir compte de toutes les incertitudes. Bien que plusieurs tentatives aient été menées avec des tests et des répétitions approfondis, pour une meilleure visibilité, seuls les résultats de la première tentative sont illustrés dans la figure 3-5 (le temps passé pour s'arrêter aux points de passage est ignoré). Cependant, les détails des résultats des cinq tentatives sont présentés dans le Tableau 3-1.

La Figure 3-5 illustre l'accélération linéaire et angulaire du CEATA (a) ainsi que la consommation d'énergie des moteurs de traction et de direction du CEATA (b) dans chacun des trois scénarios (première tentative). S.1, S.2, et S.3 représentent les scénarios 1 à 3. Lorsque l'accélération était limitée à  $0.05 \text{ m/s}^2$  et  $0.05 \text{ rad/s}^2$  (graphique bleu), les pics des graphiques de la consommation d'énergie des moteurs étaient la plupart du temps inférieurs aux autres. Cependant, S.1 a pris plus de temps pour terminer le scénario. De l'autre côté, lorsque l'accélération était limitée à  $1 \text{ m/s}^2$  et  $1 \text{ rad/s}^2$  (graphique pointillé jaune), le CEATA a subi une accélération plus importante. Bien que les pics de puissance des moteurs dans S.2 aient été plus importants que les autres, il a pris moins de temps que dans S.1 pour terminer le scénario. En fixant la limite d'accélération à  $0.1 \text{ m/s}^2$  et  $0.1 \text{ rad/s}^2$  dans S.2, les plages

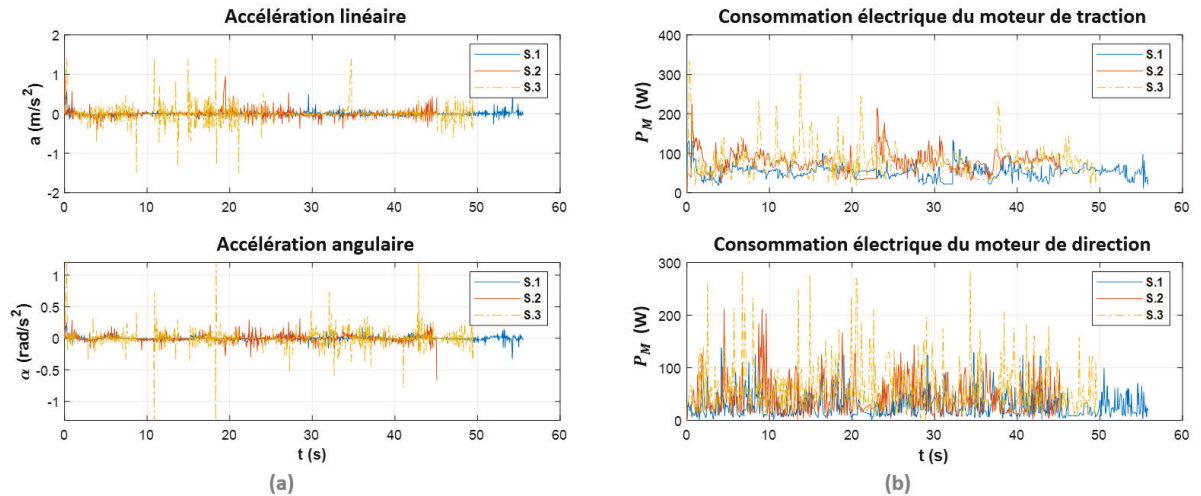


FIGURE 3-5 Résultats de l'expérience (première tentative) en utilisant trois limites d'accélération différentes dans le planificateur de mouvement. (a) et (b) montrent respectivement l'accélération du CEATA et la puissance des moteurs.

d'accélération et de consommation d'énergie du CEATA (graphiques rouges) se situent entre celles de S.1 et S.3. De plus, dans S.2, le CEATA a atteint  $w_c$  plus rapidement que dans les autres scénarios.

Le Tableau 3-1 présente les résultats de l'expérience après cinq tentatives. Le numéro de la tentative est affiché dans la première colonne. Les limites de l'accélération linéaire et angulaire dans chaque scénario sont indiquées dans les deuxième et troisième colonnes. De plus, le Temps de l'Expérience (TE), la Consommation d'Énergie du Moteur de Traction (CEMT), la Consommation d'Énergie du Moteur de Direction (CEMD) et la Consommation d'Énergie Totale des deux moteurs (CET) de l'ensemble des tentatives sont présentées. Ainsi, dans le S.1, le CEATA a terminé la mission en 386 s, ce qui est supérieur aux autres scénarios et le CET a atteint 43.94 kJ. Dans le S.3, le CEATA a atteint l'objectif final en 369 s avec un CET de 44.68 kJ. Cependant, le meilleur résultat a été obtenu dans le S.2 où le ET et le CET étaient respectivement de 351 s et de 37.22 kJ. Bien que les valeurs des limites d'accélération dans le S.3 étaient supérieures à celles du S.2, le temps de la mission du S.3 était supérieur à celui du S.2. Ceci s'est produit parce que le planificateur de mouvement a généré des trajectoires inatteignables, signifiant qu'elles impliquaient une accélération élevée, dépassant les contraintes dynamiques du véhicule. En conséquence, le véhicule n'a pas pu exécuter les manœuvres demandées, conduisant à un comportement oscillatoire alors qu'il alternait entre



TABLEAU 3-1 Résultats de l'expérience du CEATA (après cinq tentatives) en utilisant différentes limites d'accélération dans le planificateur de mouvement.

Scénario	Limite $a(m/s^2)$	Limite $\alpha(rad/s^2)$	TE (s)	CEMT (kJ)	CEMD (kJ)	CET (kJ)
1	0.05	0.05	386	26.12	17.82	43.94
2	0.1	0.1	351	22.97	14.25	37.22
3	1	1	369	25.41	19.27	44.68

différentes trajectoires jusqu'à ce que le planificateur de mouvement produise des trajectoires appropriées.

Les résultats de l'expérience ont montré que la mise en place d'une limite sur l'accélération a un effet négatif sur la consommation d'énergie, entraînant une augmentation de la durée du trajet. En revanche, des limites d'accélération élevées ont conduit à des changements de vitesse fréquents et soudains, résultant en une consommation d'énergie plus importante. De plus, l'algorithme de planification de mouvement a généré certaines trajectoires qui n'étaient pas dynamiquement réalisables pour le CEATA lors de manœuvres complexes, conduisant à une oscillation et une consommation d'énergie plus élevée. Pour résoudre ce problème, le planificateur de mouvement peut être amélioré en tenant compte du modèle cinétique du CEATA et en établissant des limites d'accélération en temps réel qui s'alignent à ses capacités dynamiques pour exécuter des manœuvres, ce qui permet d'obtenir des trajectoires économes en énergie et physiquement viables. Ceci est particulièrement crucial dans un entrepôt ou une usine, où les CEATA doivent accomplir plusieurs tâches dans un délai spécifié. Ainsi, ce travail vise à aborder ce problème en proposant une méthodologie innovante qui sera discutée dans la section suivante.

## Chapitre 4 - Modèle dynamique du VAI

Ce chapitre est consacré à la dérivation des équations de mouvement pour les VAI. Comme l'objectif de ce projet est d'appliquer la méthode proposée à deux VAI distincts, nous établissons d'abord le modèle dynamique pour un RMAED. Par la suite, en tenant compte des contraintes spécifiques du CEATA et des hypothèses de ce travail, nous dérivons le modèle dynamique pour ce type de véhicule.

### 4.1 Équations de mouvement de l'RMAED

Les équations de mouvement d'un RMAED sont détaillées ci-après.

#### 4.1.1 Équation de mouvement cinématique

Selon la Figure 4-1, il est supposé qu'une charge soit présente sur l'RMAED. Par conséquent, le centre de masse de l'RMAED (point  $G$ ) se déplace vers une nouvelle position. La position du point  $G$  est représentée par  $r_x$  et  $r_y$  qui sont les distances entre le point  $G$  et le milieu de l'axe des roues (point  $P$ ) dans les directions  $x$  et  $y$  respectivement ( $r_x = r_{xg}$  ;  $r_y = r_{yg}$ ). De plus,  $OXY$  et  $Pxy$  sont les coordonnées de référence (fixes) et les coordonnées du RMAED (mobiles), respectivement.

En définissant  $v$  comme la vitesse linéaire dans la direction  $x$  et  $\omega$  comme la vitesse angulaire du véhicule autour de la direction  $z$ , le modèle cinématique est décrit par :

$$\begin{bmatrix} \dot{X} \\ \dot{Y} \\ \dot{\theta} \end{bmatrix} = \begin{bmatrix} \cos\theta & 0 \\ \sin\theta & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} v \\ \omega \end{bmatrix} \quad (4.1)$$

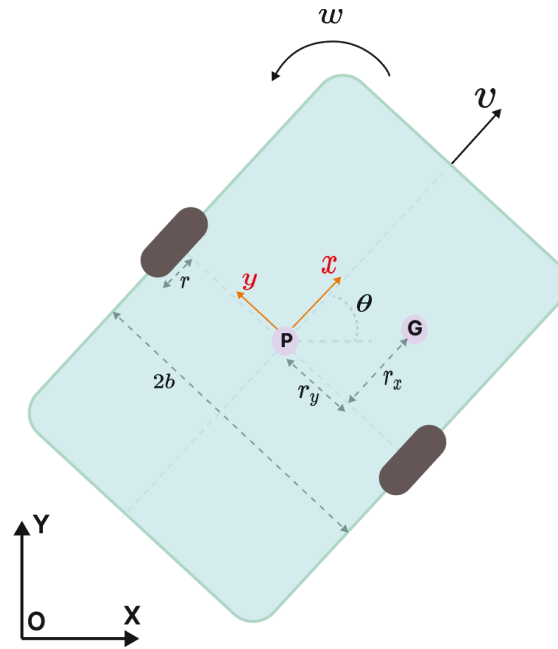


FIGURE 4-1 Schéma de l'RMAED.

En décrivant le vecteur généralisé variable  $q$ , la matrice Jacobienne  $S$ , et  $u$  :

$$q = [X, Y, \theta]^T \quad (4.2a)$$

$$S = \begin{bmatrix} \cos \theta & 0 \\ \sin \theta & 0 \\ 0 & 1 \end{bmatrix} \quad (4.2b)$$

$$u = [v, \omega]^T \quad (4.2c)$$

L'Équation (4.1) peut être décrite comme :

$$\dot{q} = Su \quad (4.3)$$

La vitesse linéaire du véhicule dans le système de coordonnées inertielles est définie :

$$\vec{v}_P = \dot{X}\hat{I} + \dot{Y}\hat{J} \quad (4.4)$$

Où  $\hat{I}$  et  $\hat{J}$  sont des vecteurs unitaires dans le système de coordonnées inertiel. De plus,  $\hat{i}$  et

$\hat{j}$  sont les vecteurs unitaires associés aux coordonnées du RMAED. En définissant les vecteurs unitaires du RMAED dans le repère inertiel :

$$\hat{j} = \cos \theta \hat{J} - \sin \theta \hat{I} \quad (4.5)$$

La projection du vecteur  $\vec{v}_P$  sur la direction  $\hat{j}$  est :

$$\vec{v}_P \cdot \hat{j} = 0 \quad (4.6)$$

En substituant les Équations (4.4) et (4.5) dans (4.6) :

$$\begin{bmatrix} \dot{X} \\ \dot{Y} \\ 0 \end{bmatrix} \cdot \begin{bmatrix} -\sin \theta \\ \cos \theta \\ 0 \end{bmatrix} = 0 \quad (4.7)$$

Ainsi, la contrainte de vitesse, qui est un type de contrainte associée aux mouvements non holonomes, est définie dans le système de coordonnées inertiel :

$$-\sin \theta \dot{X} + \cos \theta \dot{Y} = 0 \quad (4.8)$$

L'Équation (4.8) peut être réécrite sous une forme explicite :

$$A\dot{q} = 0 \quad (4.9)$$

Où  $A$  est la matrice de contrainte :

$$A = [-\sin \theta, \cos \theta, 0] \quad (4.10)$$

$$\dot{q} = [\dot{X}, \dot{Y}, \dot{\theta}]^T \quad (4.11)$$

La relation entre les vitesses angulaires des roues et les vitesses du véhicule par rapport au point  $P$  peut être décrite comme suit :

$$v = \frac{r}{2}(\dot{\phi}_r + \dot{\phi}_l) \quad (4.12a)$$

$$\omega = \frac{r}{2b}(\dot{\phi}_r - \dot{\phi}_l) \quad (4.12b)$$

Où  $\dot{\phi}_r$  et  $\dot{\phi}_l$  sont les vitesses angulaires des roues droite et gauche,  $b$  est la distance de chaque roue au point  $P$ , et  $r$  est le rayon de chaque roue. Les Équations (4.12a) et (4.12b) peuvent être écrites en fonction des vitesses angulaires des roues droite et gauche respectivement :

$$\dot{\phi}_r = \frac{1}{r}v + \frac{b}{r}\omega \quad (4.13a)$$

$$\dot{\phi}_l = \frac{1}{r}v - \frac{b}{r}\omega \quad (4.13b)$$

#### 4.1.2 Équations du mouvement cinétique

Afin de déterminer les forces généralisées agissant sur le système, il convient de recourir au principe du travail virtuel. Ceci implique de spécifier adéquatement le déplacement virtuel au sein du repère généralisé associé à la configuration du RMAED :

$$\delta\phi_r = \frac{1}{r}\delta x + \frac{b}{r}\delta\theta \quad (4.14a)$$

$$\delta\phi_l = \frac{1}{r}\delta x - \frac{b}{r}\delta\theta \quad (4.14b)$$

Le travail virtuel des forces extérieures et des moments agissant sur le véhicule peut être calculé :

$$f_x\delta x + f_y\delta y + \tau_\theta\delta\theta = \tau_r\delta\phi_r + \tau_l\delta\phi_l + \lambda\delta y \quad (4.15)$$

Où  $f_x$ ,  $f_y$  et  $\tau_\theta$  représentent les composantes des forces généralisées dans les directions  $x$  et  $y$  respectivement,  $\tau_r$  et  $\tau_l$  sont les couples des moteurs des roues droite et gauche, et  $\lambda$  est la

force de contrainte qui s'applique au système. En substituant (4.14) dans (4.15) :

$$f_x \delta x + f_y \delta y + \tau_\theta \delta \theta = \frac{1}{r} (\tau_r + \tau_l) \delta x + \frac{1}{r} (\tau_r - \tau_l) \delta \theta + \lambda \delta y \quad (4.16)$$

Ainsi, les forces généralisées peuvent être calculées à partir de (4.16) :

$$f_x = \frac{1}{r} (\tau_r + \tau_l) \quad (4.17a)$$

$$\tau_\theta = \frac{1}{r} (\tau_r - \tau_l) \quad (4.17b)$$

$$f_y = \lambda \quad (4.17c)$$

La force contrainte apparaît à cause de l'impossibilité du dérapage des roues dans la direction  $y$ . Pour définir la force contrainte dans le repère inertiel, elle peut être décrite comme suit :

$$\lambda \hat{j} = \lambda (-\sin \theta \hat{i} + \cos \theta \hat{j}) \quad (4.18)$$

L'Équation (4.18) peut être réécrite sous forme matricielle comme suit :

$$\lambda \hat{j} = \begin{bmatrix} -\sin \theta \\ \cos \theta \\ 0 \end{bmatrix} \lambda = A^T \lambda \quad (4.19)$$

De plus, il est évident que :

$$S^T A^T = 0 \quad (4.20)$$

L'Équation (4.20) montre les propriétés du Complément Orthogonal Naturel. Ainsi,  $f_x$  et  $f_y$  peuvent être définis dans les directions  $X$  et  $Y$  :

$$f_X = f_x \cos \theta - \lambda \sin \theta = \frac{1}{r} (\tau_r + \tau_l) \cos \theta - \lambda \sin \theta \quad (4.21a)$$

$$f_Y = f_x \sin \theta + \lambda \cos \theta = \frac{1}{r} (\tau_r + \tau_l) \sin \theta + \lambda \cos \theta \quad (4.21b)$$

Pour trouver les Équations de mouvement :

$$\vec{r}_P = X\hat{I} + Y\hat{J} \quad (4.22a)$$

$$\vec{r}_{G/P} = (r_x\hat{i} + r_y\hat{j}) \quad (4.22b)$$

$$\vec{r}_G = \vec{r}_P + \vec{r}_{G/P} = (X + r_x \cos \theta - r_y \sin \theta)\hat{I} + (Y + r_x \sin \theta + r_y \cos \theta)\hat{J} \quad (4.22c)$$

Où  $\vec{r}_P$  et  $\vec{r}_G$  sont les positions des points  $P$  et  $G$  dans le repère inertiel, et  $\vec{r}_{G/P}$  représente le vecteur de position du point  $G$  par rapport au point  $P$ . En utilisant l'Équation (4.22c), la vitesse linéaire  $\vec{v}_G$  et l'accélération  $\vec{a}_G$  du CoM sont définies comme suit :

$$\vec{v}_G = (\dot{X} - r_x\dot{\theta}\sin\theta - r_y\dot{\theta}\cos\theta)\hat{I} + (\dot{Y} + r_x\dot{\theta}\cos\theta - r_y\dot{\theta}\sin\theta)\hat{J} \quad (4.23a)$$

$$\begin{aligned} \vec{a}_G = & (\ddot{X} - r_x\ddot{\theta}\sin\theta - r_x\dot{\theta}^2\cos\theta - r_y\ddot{\theta}\cos\theta + r_y\dot{\theta}^2\sin\theta)\hat{I} + \\ & (\ddot{Y} + r_x\ddot{\theta}\cos\theta - r_x\dot{\theta}^2\sin\theta - r_y\ddot{\theta}\sin\theta - r_y\dot{\theta}^2\cos\theta)\hat{J} \end{aligned} \quad (4.23b)$$

Pour définir le mouvement de translation du véhicule, nous utilise la méthode de Newton :

$$\sum \vec{F} = m\vec{a}_G \quad (4.24)$$

En décomposant l'Équation (4.24) selon les composantes des directions  $X$  et  $Y$  :

$$m(a_G)_X = f_X \quad (4.25a)$$

$$m(a_G)_Y = f_Y \quad (4.25b)$$

En substituant (4.21a), (4.21b), et (4.23b) dans (4.25a) et (4.25b) :

$$m(\ddot{X} - r_x\ddot{\theta}\sin\theta - r_x\dot{\theta}^2\cos\theta - r_y\ddot{\theta}\cos\theta + r_y\dot{\theta}^2\sin\theta) = \frac{1}{r}(\tau_r + \tau_l)\cos\theta - \lambda\sin\theta \quad (4.26a)$$

$$m(\ddot{Y} + r_x\ddot{\theta}\cos\theta - r_x\dot{\theta}^2\sin\theta - r_y\ddot{\theta}\sin\theta - r_y\dot{\theta}^2\cos\theta) = \frac{1}{r}(\tau_r + \tau_l)\sin\theta + \lambda\cos\theta \quad (4.26b)$$

Pour définir le mouvement rotatif du véhicule, nous utilisons la méthode d'Euler :

$$\sum \vec{M}_P = I_G\ddot{\theta}\hat{k} + \vec{r}_{G/P} \times m\vec{a}_G \quad (4.27)$$

En substituant (4.22b) et (4.23b) dans (4.27) :

$$\begin{aligned} \sum \vec{M}_P = I_G \ddot{\theta} \hat{k} + m(r_x \hat{i} + r_y \hat{j}) \times [(\ddot{X} - r_x \ddot{\theta} \sin \theta - r_x \dot{\theta}^2 \cos \theta - r_y \ddot{\theta} \cos \theta + r_y \dot{\theta}^2 \sin \theta) \hat{I} \\ + (\ddot{Y} + r_x \ddot{\theta} \cos \theta - r_x \dot{\theta}^2 \sin \theta - r_y \ddot{\theta} \sin \theta - r_y \dot{\theta}^2 \cos \theta) \hat{J}] \end{aligned} \quad (4.28)$$

En définissant les vecteurs unitaires  $\hat{I}$  et  $\hat{J}$  dans le système de coordonnées de l'RMAED conformément à l'Équation (4.28), puis en simplifiant et réorganisant :

$$(I_G + mr_x^2 + mr_y^2) \ddot{\theta} - m(r_x \sin \theta + r_y \cos \theta) \ddot{X} + m(r_x \cos \theta - r_y \sin \theta) \ddot{Y} = br(\tau_r - \tau_l) \quad (4.29)$$

Ainsi, la forme fermée de l'équation du mouvement obtenue en utilisant la méthode Newton-Euler est :

$$M(q)\ddot{q} + C(q, \dot{q}) = B(q)\tau + A^T \lambda \quad (4.30)$$



Où :

$$M(q) = \begin{bmatrix} m & 0 & M_{13}(q) \\ 0 & m & M_{23}(q) \\ M_{31}(q) & M_{32}(q) & M_{33}(q) \end{bmatrix} \quad (4.31a)$$

$$M_{13}(q) = -m(r_x \sin \theta + r_y \cos \theta) \quad (4.31b)$$

$$M_{23}(q) = m(r_x \cos \theta - r_y \sin \theta) \quad (4.31c)$$

$$M_{31}(q) = -m(r_x \sin \theta + r_y \cos \theta) \quad (4.31d)$$

$$M_{32}(q) = m(r_x \cos \theta - r_y \sin \theta) \quad (4.31e)$$

$$M_{33}(q) = I_G + m(r_x^2 + r_y^2) \quad (4.31f)$$

$$C(q, \dot{q}) = \begin{bmatrix} -m(r_x \cos \theta - r_y \sin \theta) \dot{\theta}^2 \\ -m(r_x \sin \theta + r_y \cos \theta) \dot{\theta}^2 \\ 0 \end{bmatrix} \quad (4.31g)$$

$$B(q) = \begin{bmatrix} \cos \theta & \cos \theta \\ \sin \theta & \sin \theta \\ b & -b \end{bmatrix} \quad (4.31h)$$

$$\tau = \begin{bmatrix} \tau_r \\ \tau_l \end{bmatrix} \quad (4.31i)$$

La force de contrainte  $\lambda$  peut être supprimée dans (4.30) en utilisant (4.20). Ainsi, la matrice Jacobienne  $S$  est multipliée dans (4.30) :

$$S^T M(q) \ddot{q} + S^T C(q, \dot{q}) = S^T B(q) \tau + S^T A^T \lambda \quad (4.32)$$

Ainsi,  $\lambda$  est éliminé :

$$S^T M(q) \ddot{q} + S^T C(q, \dot{q}) = S^T B(q) \tau \quad (4.33)$$

En substituant la dérivée de (4.3) dans (4.30) et réorganisant :

$$(S^T M S) \dot{u} + (S^T M \dot{S}) u + S^T C = S^T B \tau \quad (4.34)$$

Où :

$$\dot{u} = \begin{bmatrix} \dot{v} \\ \ddot{\theta} \end{bmatrix} \quad (4.35)$$

En simplifiant et en réorganisant l'Équation (4.34), nous obtenons l'équation cinétique qui décrit le mouvement de le RMAED :

$$\begin{bmatrix} m & -mr_y \\ -mr_y & I_G + m(r_x^2 + r_y^2) \end{bmatrix} \begin{bmatrix} \dot{v} \\ \dot{w} \end{bmatrix} + \begin{bmatrix} 0 & -mr_x w \\ mr_x w & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = \frac{1}{r} \begin{bmatrix} 1 & 1 \\ b & -b \end{bmatrix} \begin{bmatrix} \tau_r \\ \tau_l \end{bmatrix} \quad (4.36)$$

Le modèle dynamique donné du RMAED présente une forte non-linéarité, principalement due à la présence de termes de couplage croisé entre les composantes de mouvement linéaire et angulaire, ainsi qu'à des termes quadratiques impliquant  $r_x^2$  et  $r_y^2$  dans la matrice de masse. Les effets de couplage croisé ( $mr_x$  et  $mr_y$ ) résultent du déplacement du centre de masse et introduisent des interactions non linéaires entre les vitesses linéaires et angulaires. De plus, les termes quadratiques ( $mr_x w$  et  $m(r_x^2 + r_y^2)$ ) créent des relations hautement non linéaires, en particulier lorsque le centre de masse est significativement déplacé par rapport au centre géométrique du RMAED. Ces complexités rendent le modèle une représentation réaliste de la dynamique du RMAED, lui permettant de capturer un comportement complexe, bien que cela vienne avec les défis associés à une forte non-linéarité.

Un contrôleur en boucle ouverte peut être utilisé pour montrer l'effet du CoM sur la dynamique du RMAED. Ainsi, nous supposons l'ajout d'une charge sur le RMAED. Cette charge provoque des changements dans la position du CoM (4.1, 4.2) selon les paramètres inertiels de la charge. Par conséquent, trois scénarios sont définis :

1. CoM sur l'axe longitudinal médian du RMAED ( $r_x = 0.1$  m,  $r_y = 0$  m)
2. CoM sur le côté gauche de l'axe longitudinal médian ( $r_x = 0.1$  m,  $r_y = 0.1$  m)
3. CoM sur le côté droit de l'axe longitudinal médian ( $r_x = 0.1$  m,  $r_y = -0.1$  m)

Les autres paramètres du RMAED en tenant compte de la charge sont  $m = 150$  kg,  $I_G = 6$  kgm<sup>2</sup>,  $b = 0.4$  m,  $r = 0.1$  m. De plus, il est supposé que les couples générés par les moteurs gauche et droit sont identiques et servent d'entrées de commande pour faciliter le mouvement

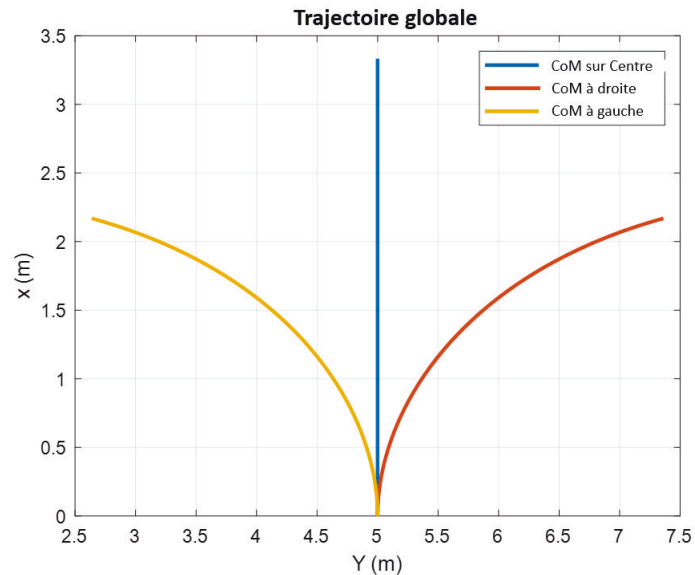


FIGURE 4-2 Les trajectoires globales du RMAED avec le contrôleur en boucle ouverte dans les trois scénarios.

en ligne droite. Afin de mettre en évidence cet effet de manière explicite, les simulations sont effectuées sans prendre en compte le bruit. Les résultats des simulations pour les trois scénarios définis préalablement sont illustrés à la Figure 4-2. Ils illustrent l'effet du CoM sur la dynamique du RMAED pour les 3 positions de la charge des moteurs des roues droite et gauche sont identiques, une trajectoire droite est attendue. Ainsi, lorsque le CoM est sur l'axe longitudinal, le RMAED se déplace en ligne droite (ligne bleue). Cependant, lorsque le CoM est sur les côtés gauche et droit (zones A et B), le RMAED a tendance à aller respectivement vers la gauche (ligne jaune) et vers la droite (ligne rouge).

Pour observer l'effet des changements du CoM sur les couples requis des moteurs des roues droite et gauche, les trois scénarios définis dans les simulations précédentes sont répétés. Ainsi, les vitesses linéaires et angulaires de référence sont considérées comme une onde et nulle respectivement pour un mouvement droit sans aucune rotation. Le contrôleur doit générer les couples appropriés pour maintenir le RMAED en ligne droite. Comme les paramètres inertiels dynamiques du RMAED sont très variables, un contrôleur adaptatif-glissant est nécessaire pour ce type de véhicule. Le contrôleur adaptatif-glissant pour véhicules à propulsion différentielle conçu par B.Mevo et al [51] est donc employé. Pour plus d'informations et de détails sur le contrôleur, consultez la référence mentionnée. La Figure 4-3 affiche les résultats des

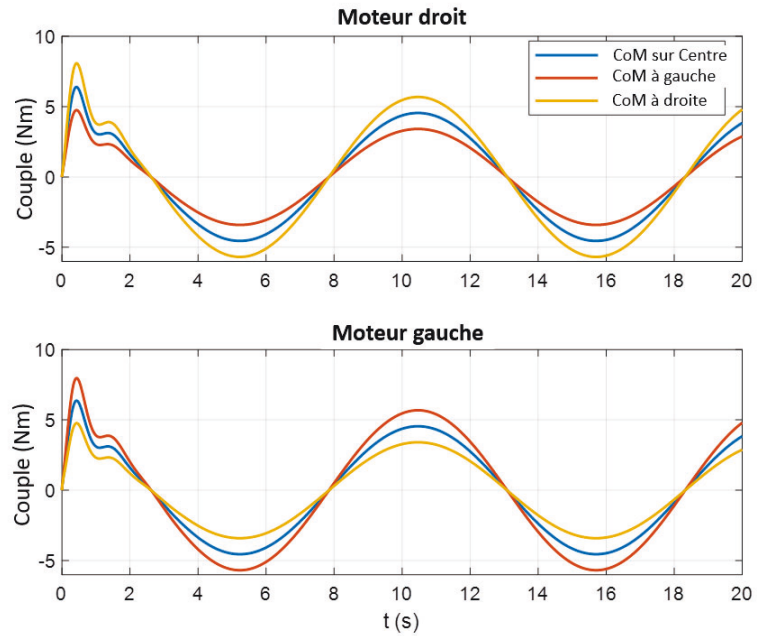


FIGURE 4-3 Couples générés pour les moteurs des roues dans les trois scénarios.

simulations. Ainsi, en considérant le CoM sur l'axe longitudinal du RMAED, les couples des moteurs gauche et droit sont identiques (graphiques bleus). Lorsque le CoM est sur le côté droit de l'axe longitudinal du RMAED, le moteur droit nécessite plus de couple pour maintenir le mouvement du RMAED en ligne droite (graphique jaune). Cependant, lorsque le CoM est sur le côté gauche, le moteur gauche consomme plus de couple (graphique rouge). Les résultats prouvent l'effet du CoM sur le mouvement du RMAED. Par conséquent, il est possible d'améliorer la manœuvre du RMAED en tenant compte du CoM.

## 4.2 Équations de mouvement de CEATA

La Figure 4-4 montre le diagramme de corps du CEATA. La roue avant (roue principale) se situe au point  $P$  et présente un angle de rotation  $\phi$ . Cette roue est à la fois motrice et directrice, équipée de deux moteurs distincts pour générer respectivement les couples de direction et de entraînement. Il y a deux roulettes pivotantes à l'arrière du CEATA et à une distance de  $L$  de la roue avant. Elles ne sont pas alimentées et leurs directions de mouvement sont uniquement le long de l'axe longitudinal du CEATA. Par conséquent, elles peuvent être considérées comme une seule roulette pivotante au centre des deux roulettes (point  $O$ ) [65]. Le CoM du CEATA est indiqué par le point  $G$  qui a une distance de  $l_1$  de la roue avant et une distance de  $l_2$  du point  $O$ . Le changement du CoM le long de l'axe latéral du CEATA est ignoré. Les systèmes de coordonnées de référence (fixe) et du CEATA sont affichés par  $OXY$  et  $Pxy$ . De plus,  $\delta$  et  $\theta$  indiquent les angles de direction et de CEATA. On suppose que le véhicule se déplace sur le plan horizontal (2D), que le véhicule est rigide et qu'il n'y a pas de glissement entre les roues et la surface. Par conséquent, le vecteur de coordonnée généralisée  $q$  est décrit comme suit :

$$q = [x, y, \theta, \delta, \phi] \quad (4.37)$$

En considérant la roue avant comme le point de référence et en définissant  $\dot{\phi}$  et  $w$  comme vitesses angulaires de la roue avant et du CEATA, le modèle cinétique du CEATA est défini comme suit [108] :

$$\dot{x} = r\dot{\phi} \cos(\delta + \theta) \quad (4.38a)$$

$$\dot{y} = r\dot{\phi} \sin(\delta + \theta) \quad (4.38b)$$

$$\dot{\theta} = r\dot{\phi} \sin(\delta)/L \quad (4.38c)$$

Où  $r$  est le rayon de la roue avant,  $\dot{x}$  et  $\dot{y}$  sont les vitesses du CEATA (point  $P$ ) et  $\dot{\theta}$  est la vitesse angulaire du CEATA ( $\dot{\theta} = w$ ).

Pour obtenir le modèle cinétique du CEATA, l'approche dynamique de Lagrange [109] est utilisée. Cette méthode dérive les équations de mouvement en tenant compte des énergies cinétique et potentielle du système donné. L'équation de Lagrange est décrite sous la forme




FIGURE 4-4 Diagramme de corps du CEATA.

suivante :

$$\frac{d}{dt} \left[ \frac{\partial L_F(\vec{q}, \dot{\vec{q}})}{\partial \dot{\vec{q}}} \right] - \frac{\partial L(\vec{q}, \dot{\vec{q}})}{\partial \vec{q}} - C^T(\vec{q}) \vec{\lambda} = \vec{U} \quad (4.39)$$

où  $L_F = T_E - V_E$  est la fonction lagrangienne,  $T_E$  et  $V_E$  sont les énergies cinétique et potentielle du système. Comme ce travail suppose que le mouvement du CEATA est sur le plan horizontal (2D), l'énergie potentielle est ignorée ( $L_F = T_E$ ). Le vecteur  $U$  représente les forces généralisées externes agissant sur le système, tandis que le vecteur  $\lambda$  désigne les multiplicateurs de Lagrange correspondant aux contraintes, exprimées par  $C$ .

Étant donné que les roulettes pivotantes (caster wheels) sont des roues non motrices, leurs énergies cinétique sont ignorées. Par conséquent, l'énergie cinétique du CEATA est décrite comme suit :

$$T_E = \frac{1}{2} [(\dot{x} + l_1 \dot{\theta} \sin(\theta))^2 + (\dot{y} - l_1 \dot{\theta} \cos(\theta))^2] + \frac{1}{2} J \dot{\theta}^2 + \frac{1}{2} m_2 [\dot{x}^2 + \dot{y}^2] + \frac{1}{2} I_h \dot{\phi}^2 + \frac{1}{2} I_v (\dot{\delta} + \dot{\theta})^2 \quad (4.40)$$

Où  $m_1$  et  $m_2$  décrivent les masses du CEATA et de la roue motrice ( $m_T = m_1 + m_2$ ). De plus,  $J$ ,  $I_h$ , et  $I_v$  sont les moments d'inertie du corps (autour de l'axe  $z$ ) et de la roue motrice (autour des axes horizontal et vertical de la roue) respectivement.

En substituant Équation 4.40 dans Équation 4.39 et en simplifiant, l'équation d'Euler-Lagrange avec les multiplicateurs de Lagrange peut être écrite sous la forme :

$$M(\vec{q})\ddot{\vec{q}} + B(\vec{q}, \dot{\vec{q}}) - C^T(\vec{q})\vec{\lambda} = \vec{U} \quad (4.41)$$

Où :

$$M(q) = \begin{bmatrix} m_T & 0 & m_1 l_1 \sin(\theta) & 0 & 0 \\ 0 & m_T & -m_1 l_1 \cos(\theta) & 0 & 0 \\ m_1 l_1 \sin(\theta) & -m_1 l_1 \cos(\theta) & m_1 l_1^2 + J + I_v & 0 & 0 \\ 0 & 0 & I_v & I_v & 0 \\ 0 & 0 & 0 & 0 & I_h \end{bmatrix} \quad (4.42a)$$

$$C = \begin{bmatrix} 1 & 0 & 0 & 0 & -r \cos(\theta + \delta) \\ 0 & 1 & 0 & 0 & -r \sin(\theta + \delta) \\ 0 & 0 & 1 & 0 & -r \sin(\theta)/L \end{bmatrix} \quad (4.42b)$$

$$B(\vec{q}, \dot{\vec{q}}) = \begin{bmatrix} m_1 l_1 \cos(\theta) \dot{\theta}^2 \\ m_1 l_1 \sin(\theta) \dot{\theta}^2 \\ 0 \\ 0 \\ 0 \end{bmatrix} \quad (4.42c)$$

$$\vec{\lambda} = \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \lambda_3 \end{bmatrix} \quad (4.42d)$$

$$\vec{U} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ u_1 \\ u_2 \end{bmatrix} \quad (4.42e)$$

Où  $u_1$  et  $u_2$  sont les entrées du modèle qui sont le couple du moteur de traction,  $\tau_t$ , et les couples du moteur de direction,  $\tau_s$ , respectivement.

Pour trouver les multiplicateurs de Lagrange, si nous supposons que :

$$C(\vec{q})\vec{\dot{q}} = 0 \quad (4.43)$$

Cela implique :

$$\frac{d}{dt} [C(\vec{q})\vec{\dot{q}}] = 0 \quad (4.44)$$

D'où nous pouvons déduire :

$$C(\vec{q})\vec{\ddot{q}} + \dot{C}(\vec{q})\vec{\dot{q}} = 0 \quad (4.45)$$

En réécrivant l'Équation 4.41 selon  $\vec{\ddot{q}}$  :

$$\vec{\ddot{q}} = M^{-1}(\vec{q})[\vec{U} - B(\vec{q}, \vec{\dot{q}}) + C^T(\vec{q})\vec{\lambda}] \quad (4.46)$$

En substituant 4.45 dans 4.46 et en simplifiant :

$$\vec{\lambda} = -[C(\vec{q})M^{-1}(\vec{q})C^T(\vec{q})]^{-1}[C(\vec{q})M^{-1}(\vec{q})(\vec{U} - B(\vec{q}, \vec{\dot{q}}) + \dot{C}(\vec{q})\vec{\dot{q}})] \quad (4.47)$$

En trouvant les multiplicateurs de Lagrange à partir de l'Équation 4.47 et en les substituant dans l'Équation 4.41, nous obtenons les équations de mouvement du CEATA. La modélisation est donc établie en considérant les énergies cinétique et en utilisant l'approche de Lagrange pour obtenir les équations de mouvement. Ces équations sont fondamentales pour comprendre et contrôler les dynamiques du CEATA.

Le modèle dynamique fourni d'un chariot élévateur est fortement non linéaire pour plusieurs raisons. Premièrement, il implique des fonctions trigonométriques telles que le sinus et le cosinus, qui sont intrinsèquement non linéaires. Ces termes trigonométriques apparaissent dans diverses équations, y compris les éléments de la matrice  $M(q)$  et les entrées de la matrice  $C$ . Ces termes introduisent des dépendances non linéaires sur l'orientation du chariot élévateur  $\theta$  et l'angle de direction  $\delta$ . De plus, les termes quadratiques, tels que  $m_1 l_1 \cos(\theta) \dot{\theta}^2$  dans la matrice  $B(q, \dot{q})$ , contribuent également à la non-linéarité. Par ailleurs, le modèle inclut des



dépendances de paramètres, tels que la masse  $m_1$ , la longueur  $l_1$  et les moments d'inertie  $I_v$  et  $I_h$ , qui peuvent varier, rendant les équations non linéaires par rapport à ces paramètres. Dans l'ensemble, la combinaison des fonctions trigonométriques, des termes quadratiques et des dépendances de paramètres rend ce modèle dynamique fortement non linéaire, capturant avec précision la complexité de la dynamique du chariot élévateur.

## Chapitre 5 - Planification de mouvement éco-énergétique

Dans ce chapitre, la méthodologie pour la planification de mouvements éco-énergétiques est expliquée. Comme cette étude implique la mise en œuvre des méthodes sur deux VAI distincts, des sections séparées sont consacrées à RMAED et CEATA. Cependant, la méthodologie reste cohérente pour les deux VAI. La première étape consiste à créer un ensemble de données (EdD) avec des entrées et des sorties connues en utilisant le modèle dynamique développé dans le Chapitre 4. Ensuite, EdD est utilisé pour entraîner un modèle DNN pour la tâche d'identification des paramètres. Étant donné la non-linéarité du modèle cinétique, une méthode DNN supervisée capable de gérer cette condition et de traiter des problèmes à sorties multiples est nécessaire.

Dans ce contexte, la méthode MLP se présente comme un choix approprié, car elle incarne une architecture de réseau neuronal artificiel feed-forward capable de répondre à tous les critères précédemment mentionnés (non-linéarité de l'EdD et identification multivariable). MLP excelle dans la gestion de problèmes non linéaires complexes et peut traiter efficacement de vastes données en entrée. De plus, elle facilite des prédictions en ligne rapides une fois correctement formé. Parmi les différents modèles MLP, le modèle de rétropropagation est le plus couramment utilisé. MLP comprend généralement au moins trois couches : une ou plusieurs couches d'entrée, une ou plusieurs couches cachées, et une couche de sortie.

Le modèle fonctionne en approximant la relation non linéaire entre l'entrée et la sortie par des ajustements internes de poids. Il suit un processus en deux étapes. Dans un premier temps, les signaux d'entrée sont transformés en couches de sortie à l'aide d'une fonction d'activation non linéaire. Par la suite, l'erreur de prédiction est rétropropagée pour affiner les poids. Ce processus itératif se poursuit jusqu'à ce que l'erreur de prédiction converge vers une valeur stable.

La transformation des données et le processus de rétropropagation sont exprimés respectivement dans les équations suivantes :

$$y_j^m(n) = f \left( \sum_{k=0}^p w_{ji}^k(n) y_i^k(n) \right) \quad (5.1)$$

$$w(n+1) = w(n) - \eta \frac{\partial E_p}{\partial w(n)} + \alpha \Delta w(n) \quad (5.2)$$

Où  $y_j^m(n)$  indique la sortie du neurone  $m$  de la couche  $j$  et  $f(x)$  est la fonction d'activation.  $p$  définit le nombre total de la couche  $i$ , et  $w_{ji}^k(n)$  est le poids de connexion du nœud  $k$  de la couche  $i$  à la itération  $n$ . De plus,  $w(n)$  définit les poids à l'itération  $n$  et  $\eta$  est le taux d'apprentissage.  $E_p$  désigne l'erreur de prédiction, et  $\alpha$  est le paramètre de momentum qui peut accélérer la convergence.

Dans la dernière étape, le modèle DNN est intégré à l'algorithme de planification de mouvement. Par conséquent, le planificateur de mouvements reçoit les sorties du modèle DNN, qui servent de paramètres dynamiques. En utilisant ces paramètres, le planificateur de mouvements ajuste et optimise dynamiquement ses propres opérations.

## 5.1 Planification de mouvement éco-énergétique pour RMAED

Pour déterminer les valeurs de CoM et les entrées des moteurs requises pour l'application de RMAED et le planificateur de mouvement sélectionné discuté ultérieurement, un EdD est généré à l'aide du modèle dynamique développé d'RMAED (Équation 4.36). La carte de flux de données dans la Figure 5-1 fournit un aperçu du processus de génération de l'EdD et de sa structure. Plusieurs scénarios sont réalisés, en considérant différents paramètres inertiels (masse, moment d'inertie, CoM) ainsi que diverses vitesses de référence pour capturer les entrées des moteurs requises dans différentes conditions. L'EdD inclut les valeurs des vitesses linéaires et angulaires ( $v, w$ ), les entrées des moteurs droit et gauche ( $\tau_r(u_1), \tau_l(u_2)$ ), et CoM ( $r_x, r_y$ ), qui sont stockées pour la création de l'EdD. Pour tenir compte du bruit présent dans les environnements industriels et considérer les incertitudes, un bruit Gaussien est ajouté lors du processus de génération de l'EdD. Le bruit Gaussien, souvent appelé bruit blanc, est un type de signal aléatoire ou d'interférence [110]. Il suit une distribution normale, qui est une distribution de probabilité symétrique et en forme de cloche. Cette distribution signifie que la plupart des points de données se regroupent autour d'une valeur centrale, typiquement zéro pour le bruit Gaussien, et deviennent moins fréquents à mesure qu'ils s'éloignent de ce point central. Une autre propriété cruciale du bruit Gaussien est sa moyenne nulle. Cela signifie que, en moyenne, le bruit n'introduit aucun biais systématique ou décalage dans le signal. Avec le temps, les écarts positifs et négatifs par rapport à zéro s'annulent mutuellement, résultant en une valeur moyenne de zéro. Le bruit Gaussien présente également une variance constante. La variance  $\sigma^2$  du bruit détermine à quel point les échantillons de bruit individuels s'écartent de la moyenne. Importamment, cette variance reste constante et ne dépend ni du temps ni du numéro de l'échantillon. Puisque cette partie utilise deux modèles d'apprentissage, deux structures l'EdD sont générées. Le premier EdD est constitué de quatre entrées ( $v, w, u_1, u_2$ ) et de deux sorties ( $r_x, r_y$ ). Inversement, le second modèle incorpore des entrées ( $v, w, r_x, r_y$ ) et des sorties ( $u_1, u_2$ ).

Le Tableau 5-1 présente les résultats de la tâche d'identification des paramètres en utilisant MLP. Le Modèle 1 se concentre sur l'estimation de  $r_{x_g}$  et  $r_{y_g}$ , tandis que le Modèle 2 estime  $u_1$  et  $u_2$ . Pour évaluer la précision de la tâche d'estimation, nous utilisons couramment l'erreur

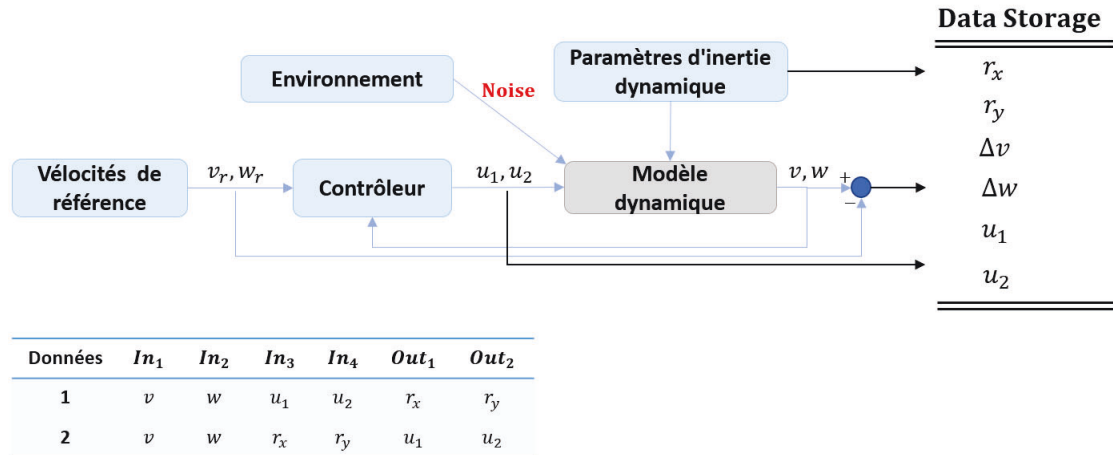


FIGURE 5-1 Carte de flux de données avec la structure de l'EdD (RMAED).

quadratique moyenne (RMSE<sup>1</sup>), comme suggéré dans la littérature [111]. Les unités de RMSE correspondent aux unités de la variable respective, c'est-à-dire mètres (m) pour la position et Newton-mètres (Nm) pour les entrées des moteurs (couples). La plage de  $r_{x_g}$  et  $r_{y_g}$  varie de -0.25 m à +0.25 m, soit un total de 0.5 m. De même, la plage de couple s'étend de -20 Nm à +20 Nm. Une autre métrique utilisée est l'erreur de pourcentage absolue moyenne symétrique (SMAPE<sup>2</sup>), qui mesure la précision en fonction de l'erreur en pourcentage [111]. Les valeurs SMAPE varient de 0% à 100% avec des pourcentages plus faibles indiquant une erreur plus faible. Le modèle MLP conçu est composé de cinq couches cachées avec des neurones [40, 30, 20, 10, 2] dans chaque couche, qui ont été déterminés comme optimaux après plusieurs itérations d'essai et d'erreur. La fonction d'activation Relu et le solveur Adam sont employés.

Lors des missions réelles, les entrées du modèle DNN sont générées par les capteurs et actionneurs de CEATA, qui introduisent intrinsèquement divers niveaux de bruit. Ainsi, pour évaluer la robustesse du modèle DNN dans différents scénarios de bruit, trois types de jeux de données sont testés. Le type 1 contient des données sans bruit, tandis que les types 2 et 3 comprennent un bruit Gaussien avec un rapport signal sur bruit (SNR<sup>3</sup>) de 70 dB et 50 dB, respectivement. Le SNR (rapport signal sur bruit) est défini comme le rapport entre la puissance du signal et la puissance du bruit. Mathématiquement, cela peut s'exprimer comme

1. RMSE est l'abréviation de "Root-Mean-Square Error", en anglais (erreur quadratique moyenne en français)  
 2. SMAPE est l'abréviation de "Symmetric Mean Absolute Percentage Error", en anglais (erreur de pourcentage absolue moyenne symétrique en français)  
 3. SNR est l'abréviation de "signal-to-noise ratios", en anglais (rapport signal sur bruit en français)

suit :

$$\text{SNR} = \frac{\text{Puissance du Signal}}{\text{Puissance du Bruit}} \quad (5.3)$$

Un SNR élevé implique que le signal (données originales) est beaucoup plus fort que le bruit (bruit gaussien). Cela signifie que la qualité des données est bonne et que le bruit a un impact minimal sur les données. Inversement, un SNR faible indique que le bruit est relativement fort par rapport au signal, ce qui peut dégrader la qualité des données et rendre plus difficile l'extraction d'informations significatives.

Dans le contexte du bruit gaussien, la "Puissance du Bruit" est liée à la variance du bruit gaussien. L'amplitude du bruit gaussien est déterminée par son écart type  $\sigma$ . Un  $\sigma$  plus petit résulte en un bruit de plus faible amplitude, tandis qu'un  $\sigma$  plus grand conduit à des données plus bruyantes. La variance du bruit gaussien  $\sigma^2$  est une mesure de l'étalement ou de la dispersion des valeurs de bruit. La relation entre le SNR et la variance du bruit gaussien est inversement proportionnelle. Un SNR plus élevé correspond à une variance plus faible (données moins bruyantes), et un SNR plus faible correspond à une variance plus élevée (données plus bruyantes).

En analysant les résultats RMSE et SMAPE présentés dans le Tableau 5-1, on peut observer que MLP réalise des prédictions satisfaisantes pour les deux variables d'accélération à travers différents types de jeux de données. Pour faciliter une compréhension claire des variations dans les résultats, celles-ci sont illustrées dans la Figure 5-2. Les erreurs d'estimation du couple et du CoM sont présentées en (a) et (b) respectivement. En (a), les lignes bleues représentent le couple du moteur gauche, tandis que les lignes vertes correspondent au couple du moteur droit. De même, en (b), les lignes bleues sont associées à  $r_x$  et les lignes vertes correspondent à  $r_y$ . À mesure que le SNR du bruit augmente du EdD 1 au EdD 3, les valeurs d'erreur augmentent progressivement. Par exemple, en (b), le RMSE de l'estimation du CoM dans la direction  $x$  est de 0,08 m pour le type de EdD 1. Lorsque le SNR du bruit augmente de 50 dB (EdD 3), le RMSE atteint 0,09 m. Le même schéma est observé dans le SMAPE de l'estimation. Les changements minimes du RMSE et du SMAPE par rapport à l'augmentation du SNR du bruit démontrent la robustesse du modèle DNN généré lorsqu'il est déployé dans des conditions réelles et non contrôlées.

TABLEAU 5-1 Propriétés et résultats de la prédiction du CoM et des entrées des moteurs en utilisant la méthode MLP.

Paramètre	Données sans bruit		Données avec bruit (SNR=70db)		Données avec bruit (SNR=50db)	
	RMSE	SMAPE(%)	RMSE	SMAPE(%)	RMSE	SMAPE(%)
<b>Modèle 1</b>						
$r_{x_g}$	0.08 m	17.7	0.083 m	18.1	0.09 m	18.9
$r_{y_g}$	0.06 m	12.9	0.067 m	13.4	0.079 m	15.3
<b>Modèle 2</b>						
$\tau_r$	0.22 Nm	9.5	0.31 Nm	11.2	0.39 Nm	12.5
$\tau_l$	0.25 Nm	9.9	0.30 Nm	11.1	0.35 Nm	12.2
<b>Méthode des réseaux neuronaux profonds</b>					MLP	
<b>Nombre de neurones dans cinq couches cachées</b>					[40,30,20,10,2]	
<b>Fonction d'activation</b>					Relu	
<b>Solveur</b>					Adam	

DWA est un algorithme de navigation largement reconnu pour la planification de mouvement, initialement proposé par Dieter Fox et al. [101]. Il fonctionne comme une méthode réactive en ligne et sa fonction de coût a subi plusieurs extensions au fil des années. Le DWA commence par considérer l'état actuel du robot et génère dynamiquement un ensemble de trajectoires possibles sur un court horizon temporel. Ces trajectoires sont créées en variant les vitesses du robot à l'intérieur d'une "fenêtre dynamique" - une gamme de vitesses admissibles qui peuvent être atteintes compte tenu de la vitesse actuelle du robot et de ses limites d'accélération. Pour déterminer les vitesses de translation ( $v$ ) et de rotation ( $w$ ) sûres et optimales, la méthode génère directement des profils de vitesse en tenant compte de la dynamique du robot et des limites des gammes de vitesse et d'accélération.

En ce qui concerne la 5-3, l'espace de recherche principal pour les vitesses appropriées est formé par l'intersection de trois principaux sous-espaces : (i) l'espace des vitesses possibles selon les contraintes cinématiques du robot,  $V_s$ , (ii) l'espace des vitesses admissibles permettant au robot de s'arrêter sans entrer en collision avec les obstacles,  $V_a$ , et (iii) l'espace des vitesses possibles compte tenu des accélérations limitées du robot,  $V_d$  :

$$V_r = V_s \cap V_a \cap V_d \quad (5.4)$$

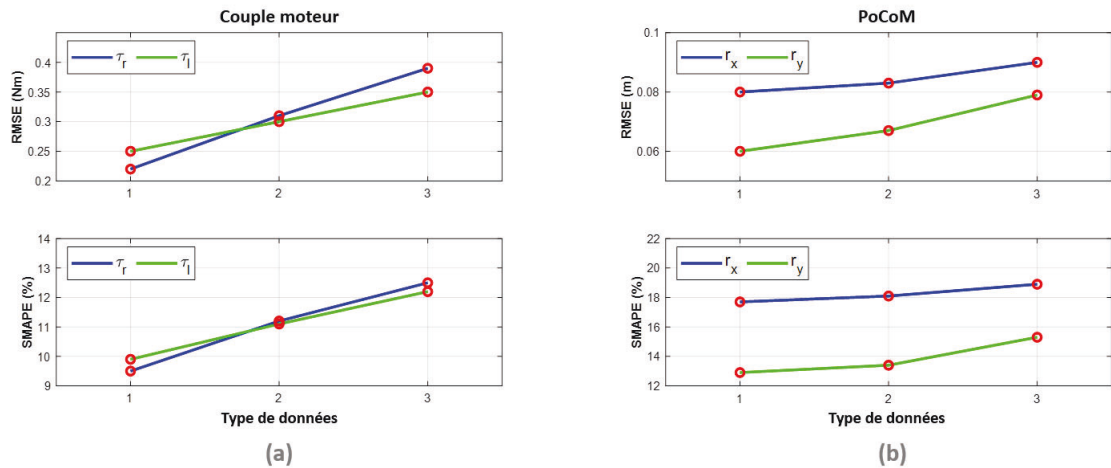


FIGURE 5-2 L'erreur d'estimation de MLP pour les entrées des moteurs (a) et CoM (b). (RMAED).

où  $V_r$  représente l'espace de recherche des vitesses optimales. Dans cette fenêtre dynamique, l'algorithme DWA génère des échantillons de paires de vitesses potentielles  $(v, w)$  et simule les trajectoires qui résulteraient de l'application de ces vitesses. Chaque trajectoire est évaluée en fonction d'une fonction de coût  $G(v, w)$ , qui intègre trois composantes critiques :

$$G(v, w) = \beta_1 \cdot h(v, w) + \beta_2 \cdot d(v, w) + \beta_3 \cdot v_F(v, w) \quad (5.5)$$

Ici,  $h$  mesure l'alignement du robot avec la direction de l'objectif,  $d$  représente la distance à l'obstacle le plus proche, et  $v_F$  désigne la vitesse avant du robot. Les poids constants ajustables  $\beta_1$ ,  $\beta_2$ , et  $\beta_3$  sont utilisés pour ajuster l'importance relative de chaque terme. Par conséquent, la méthode DWA génère de nombreuses trajectoires en ligne et sélectionne ensuite les trajectoires optimales en fonction de la fonction objective (La trajectoire avec le score le plus élevé de cette fonction objective est sélectionnée comme le chemin optimal que le robot doit suivre.). Ce processus de génération de trajectoires, d'évaluation par rapport à une fonction de coût et de sélection du chemin optimal permet au DWA de naviguer efficacement le robot dans des environnements dynamiques.

Pour établir un DWA éco-énergétique (EDWA) prenant en compte le CoM, nous proposons le modèle illustré à la Figure 5-4. Les données provenant des capteurs, représentées par la ligne pointillée verte, sont acheminées vers le module EDWA ainsi que vers d'autres processus de






FIGURE 5-3 La fenêtre dynamique de la méthode DWA.

navigation tels que la cartographie, la localisation, et la planification de trajectoire globale. La trajectoire globale formulé par l'algorithme de planification de trajectoire globale est intégré à une carte de coût locale et à la position de l'RMAED. Ces données consolidées sont ensuite transmises au module EDWA, comme indiqué par la ligne pointillée violette. Lorsque le RMAED commence à se déplacer, le Modèle DNN 1 reçoit les vitesses linéaires et angulaires de l'RMAED ( $v$ ,  $w$ ) des capteurs ainsi que les sorties des moteurs gauche et droit ( $\tau_l$ ,  $\tau_r$ , ligne pointillée rouge) pour estimer le CoM ( $r_x, r_y$ ). La relation entre les sorties des moteurs (courant( $i_M$ )) et les entrées 3 et 4 du Modèle DNN 1 (couple( $\tau$ )) est définie comme suit :

$$\tau = i_M K_\tau \quad (5.6)$$

Où  $K_\tau$  désigne la constante du couple.

Par la suite, le Modèle DNN 2 utilise le CoM estimé et les vecteurs de vitesses linéaires et angulaires ( $V$ ,  $W$ ), générés par l'espace de vitesse du EDWA, pour prédire l'énergie ( $\tau_r$ ,  $\tau_l$ ) requise pour chaque trajectoire. Finalement, cette énergie ( $E = \tau_r + \tau_l$ ) est intégrée dans la fonction de coût avec un poids ajustable ( $\kappa$ ). En conséquence, l'EDWA identifie la trajectoire optimale ( $v_c, w_c$ ) en maximisant la fonction de coût et les envoie au contrôleur de mouvement (ligne continue violette). Le contrôleur de mouvement génère ensuite des commandes moteur appropriées pour déplacer l'RMAED de manière efficiente et optimale, représenté par la ligne continue grise. Ce cycle persiste jusqu'à ce que l'RMAED atteigne sa destination locale.

L'incorporation de la contrainte d'énergie dans la fonction de coût donne la fonction suivante :

$$G(v, w) = \beta_1 \cdot h(v, w) + \beta_2 \cdot d(v, w) + \beta_3 \cdot v_F(v, w) + \frac{1}{\kappa \cdot E(\tau_r, \tau_l)} \quad (5.7)$$

Pour garantir que les vitesses optimales choisies correspondent à une trajectoire globale éco-énergétique pour l'évitement d'obstacles, les entrées du Modèle DNN 2 sont considérées comme des quantités vectorielles. Par conséquent, la fonction de coût calcule le coût des vecteurs de vitesses linéaires et angulaires, qui représentent le coût des trajectoires globales possibles, et sélectionne le vecteur optimal. Cette condition garantit la réalisation d'une trajectoire locale éco-énergétique et de la distance parcourue simultanément. Il est important de noter que les Modèles DNN 1 et 2 ne fonctionnent pas simultanément. La valeur du CoM reste constante jusqu'au début de la prochaine mission de l'RMAED, et n'est donc estimée qu'une seule fois pendant les étapes initiales du mouvement. Par la suite, elle sert d'entrée constante pour le Modèle DNN 2 jusqu'à l'apparition de la prochaine charge. Ainsi, le Modèle 2 reçoit dynamiquement des entrées en temps réel, générant des sorties à chaque étape en alignement avec la fréquence du contrôleur.

L'introduction d'un terme d'énergie exige que l'algorithme évalue chaque trajectoire potentielle non seulement en termes de sécurité, d'alignement avec la cible et de vitesse, mais aussi en termes d'efficacité énergétique. Cela signifie que le processus de génération de trajectoire inclut désormais un calcul de l'énergie requise pour chaque trajectoire, en prenant en compte des facteurs tels que l'accélération, la décélération, et toute dynamique spécifique au robot comme l'effet du CoM.

La nécessité d'estimer la consommation d'énergie pour chaque trajectoire potentielle ajoute une complexité computationnelle au DWA. L'algorithme doit maintenant effectuer des calculs supplémentaires pour estimer l'utilisation de l'énergie basée sur les vitesses du robot et possiblement d'autres facteurs (par exemple, le terrain, la charge du robot). Cela pourrait impacter la performance en temps réel de l'algorithme, nécessitant des optimisations ou des approximations pour maintenir l'efficacité.

L'impact le plus direct de l'ajout du terme d'énergie est l'amélioration de l'efficacité énergétique. En intégrant le coût énergétique de chaque trajectoire, EDWA est plus susceptible

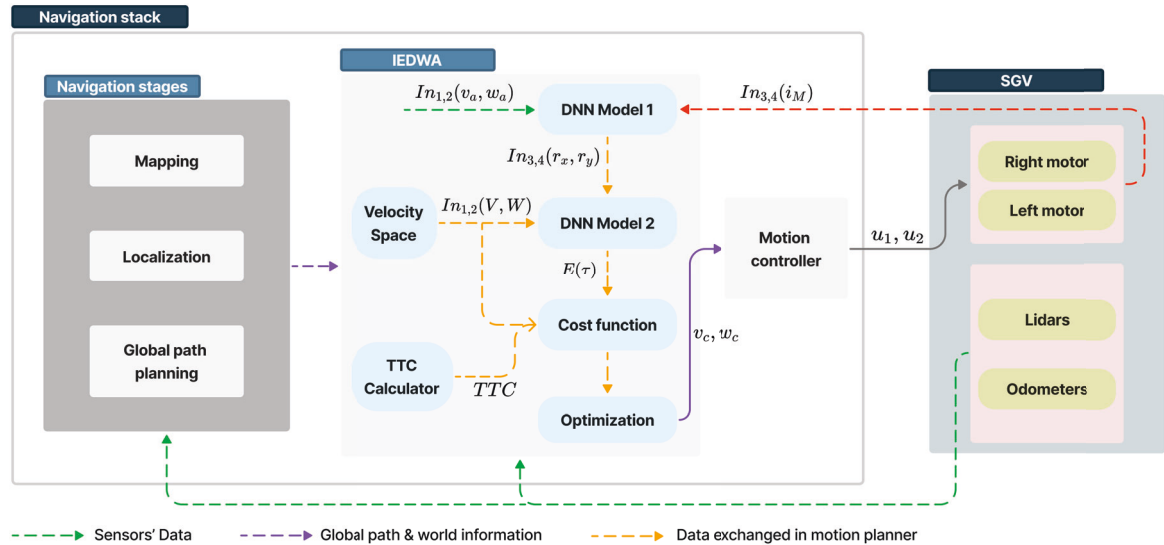


FIGURE 5-4 La structure de la méthode EDWA pour l’RMAED.

de sélectionner des chemins qui conservent l’énergie, prolongeant le temps opérationnel du robot, notamment dans les applications alimentées par batterie. Cela est particulièrement bénéfique pour les tâches de longue durée ou dans des environnements où les opportunités de recharge sont limitées.

L’inclusion du terme d’énergie peut conduire à la sélection de trajectoires plus douces et impliquant moins d’accélération et de décélération agressives. Ces trajectoires sont généralement plus économes en énergie mais pourraient aussi affecter la capacité du robot à manœuvrer rapidement dans des espaces restreints ou à réagir à des changements soudains dans l’environnement. L’équilibre entre l’efficacité énergétique et la réactivité nécessite un ajustement minutieux basé sur les exigences spécifiques de l’application.

En privilégiant l’efficacité énergétique, EDWA pourrait choisir des chemins qui sont plus longs ou prennent plus de temps à parcourir mais consomment moins d’énergie au total. Ce compromis entre la consommation d’énergie et le temps ou la distance de voyage doit être considéré, surtout dans les applications critiques en temps. Relever avec succès ces défis peut significativement améliorer les capacités et les applications des robots mobiles autonomes.

Dans le EDWA, un défi majeur se présente lorsque le véhicule rencontre des obstacles à géométrie asymétrique, comme un triangle aux côtés inégaux. Bien que EDWA évalue les trajectoires potentielles selon des critères tels que la sécurité, l’alignement avec l’objectif, la

vitesse et l'efficacité énergétique, il ne considère pas explicitement la géométrie de l'obstacle dans son processus de sélection.

Face à un obstacle, EDWA choisit une trajectoire réalisable autour de ce dernier basée sur sa fonction de coût intégrée. Cependant, ce processus n'analyse pas les propriétés géométriques de l'obstacle en détail, telles que la longueur des côtés que le véhicule pourrait contourner. Par conséquent, EDWA pourrait choisir une trajectoire qui contourne le côté le plus long de l'obstacle car elle semble plus alignée avec la direction cible du véhicule ou offre une marge de sécurité plus élevée, selon les calculs de l'algorithme. Cette décision ne garantit pas que le chemin choisi est le plus économe en énergie en termes de distance physique parcourue autour de l'obstacle.

Par exemple, considérons un scénario où le véhicule rencontre un obstacle triangulaire aux côtés de longueurs significativement différentes. EDWA pourrait sélectionner une trajectoire qui contourne le côté le plus long du triangle, entraînant potentiellement une consommation d'énergie plus élevée que si le véhicule avait contourné le côté le plus court. Ce défi met en lumière une limitation dans la prise en compte des obstacles par EDWA : l'algorithme privilégie la faisabilité immédiate et l'optimalité selon sa fonction de coût, plutôt que de réaliser une analyse complète de la géométrie de l'obstacle pour identifier le chemin de moindre résistance ou la distance la plus courte. Aborder ce problème nécessiterait l'intégration d'une analyse géométrique plus sophistiquée dans le processus de sélection de trajectoire, permettant à l'algorithme d'évaluer plus précisément les coûts énergétiques associés à la navigation autour des différents côtés d'un obstacle.

Le pseudo-code de la méthode proposée est représenté dans l'Algorithme 1. Il comprend :

- **Entrées de la Fonction** : La fonction

`EDWA_PLANNER(départ, objectif, DNN_modèle_1, DNN_modèle_2)` prend en entrée une position de départ `départ`, une position d'objectif `objectif`, et deux modèles de DNN : `DNN_modèle_1` et `DNN_modèle_2`.

- **Paramètres du Robot** : Avant de commencer la planification du trajectoire globale, les paramètres du robot, tels que la vitesse maximale/minimum, l'accélération et le rayon de braquage, sont définis.

---

**Algorithm 1** Planificateur EDWA avec DNN
 

---

```

1: fonction EDWA_PLANNER(départ, objectif, DNN_modèle_1, DNN_modèle_2)
2: Définir les paramètres du robot
3: Initialiser l'état du robot  $x = \text{départ}$ 
4: fonction CALCULER_FENETRE_DYNAMIQUE(robot)
5:   Calculer les vitesses min et max possibles du robot :  $[v_{\min}, v_{\max}]$ 
6:   Calculer les taux de lacet min et max possibles du robot :  $[\text{taux\_lacet\_min}, \text{taux\_lacet\_max}]$ 
7:   Retourner la fenêtre dynamique :  $[v_{\min}, v_{\max}, \text{taux\_lacet\_min}, \text{taux\_lacet\_max}]$ 
8: fin de la fonction
9: fonction DISCRETISER_FENETRE(fenêtre_dynamique)
10:  Créer une grille des vitesses possibles à l'intérieur de la fenêtre dynamique
11:  Chaque cellule de la grille représente une vitesse linéaire différente et un taux de lacet
12:  Retourner la grille de vitesses
13: fin de la fonction
14: fonction PREDIRE_TRAJECTOIRE(robot, v, w)
15:  Prédire la trajectoire du robot pour une période de temps donnée en avance, étant donné la vitesse (v) et le taux de lacet (w)
16:  Retourner trajectoire_prédite
17: fin de la fonction
18: fonction CALCULER_COÛT(trajectoire_prédite, objectif, E_tau)
19:  Calculer le coût de la trajectoire en considérant la proximité aux obstacles, la distance à l'objectif, la vitesse actuelle du robot et E(tau)
20:  Retourner le coût
21: fin de la fonction
22: while l'objectif n'est pas atteint do
23:   fenêtre_dynamique = CALCULER_FENETRE_DYNAMIQUE(robot)
24:   grille_vitesse = DISCRETISER_FENETRE(fenêtre_dynamique)
25:   for chaque vitesse dans grille_vitesse do
26:     v, w = vitesse
27:     r_x, r_y = DNN_modèle_1.prédire(v, w)
28:     E_tau = DNN_modèle_2.prédire(r_x, r_y, grille_vitesse_linéaire, grille_vitesse_angulaire)
29:     trajectoire_prédite = PREDIRE_TRAJECTOIRE(robot, v, w)
30:     coût = CALCULER_COÛT(trajectoire_prédite, objectif, E_tau)
31:     if coût est le minimum jusqu'à présent then
32:       vitesse_optimale = vitesse
33:     end if
34:   end for
35:   Mettre à jour l'état du robot avec la vitesse_optimale
36: end while
37: return état du robot
38: fin de la fonction

```

---

- **État du Robot** : L'état du robot  $x$  est initialisé avec la position départ.
- **Calcul de la Fenêtre Dynamique** : `CALCULER_FENETRE_DYNAMIQUE(robot)` calcule la fenêtre dynamique pour le robot, qui comprend la plage faisable des vitesses basées sur la dynamique du robot et ses contraintes.
- **Discretisation de la Fenêtre** : `DISCRETISER_FENETRE(fenêtre_dynamique)` discrétise la fenêtre dynamique en une grille de vitesses possibles.
- **Prédiction de la Trajectoire** : Pour chaque commande de vitesse potentielle de la fenêtre discrétisée, `PREDIRE_TRAJECTOIRE(robot, v, w)` prédit la trajectoire que le robot suivrait sur une durée prédéterminée.
- **Calcul du Coût** : `CALCULER_COUT(trajectoire_prédite, objectif, E_tau)` calcule le coût associé à la trajectoire prédite, en considérant la proximité des obstacles, la distance à l'objectif et une mesure supplémentaire  $E(\tau)$  obtenue à partir de `DNN_modèle_2`.
- **Prédictions DNN** : `DNN_modèle_1.prédire(v, w)` utilise `DNN_modèle_1` pour prédire  $r_x$  et  $r_y$  en fonction des vitesses du robot. De même, `DNN_modèle_2.prédire(r_x, r_y, grille_vitesse_linéaire, grille_vitesse_angulaire)` utilise `DNN_modèle_2` pour prédire  $E(\tau)$ .
- **vitesse Optimale** : Pour chaque vitesse dans la grille de vitesses, une trajectoire est prédite, le coût est calculé et si le coût est le plus bas jusqu'à maintenant, la de vitesse associée est stockée comme `vitesse_optimale`.
- **Mise à jour de l'État** : Une fois que toutes les commandes ont été évaluées, l'état du robot est mis à jour en utilisant la `vitesse_optimale` et le processus est répété jusqu'à ce que l'objectif soit atteint.

Cette approche permet l'intégration du modèle DNN avec la planification de mouvement traditionnelle, améliorant potentiellement la robustesse et l'adaptabilité du planificateur de mouvement.

## 5.2 Planification de mouvement éco-énergétique pour CEATA

Pour mieux comprendre le développement du planificateur de mouvement proposé pour le CEATA, décomposons le processus en étapes claires. Initialement, nous avons amélioré le modèle cinétique du CEATA, en nous concentrant sur l'incorporation des contraintes de mouvement nécessaires. Cette amélioration est détaillée dans la Section 4.2. À l'aide de ce modèle raffiné, nous menons un processus d'optimisation pour générer un ensemble de données précieux dans cette section. Ensuite, cet ensemble de données est utilisé pour entraîner un modèle MLP. Le but est d'identifier les limites d'accélération optimales et réalisables. Après l'entraînement, nous intégrons ce modèle MLP dans le cadre TEB, créant ainsi ETEB. Dans le système ETEB, le modèle MLP prédit activement les limites d'accélération permises et maximales à chaque étape temporelle. Ces prédictions sont utilisées pour définir les contraintes d'accélération dans le processus d'optimisation d'ETEB. Par conséquent, cela garantit que les trajectoires générées sont à la fois réalisables et adaptées à la dynamique du CEATA.

Au vu des résultats expérimentaux et de la discussion dans la Section 3.2, la consommation d'énergie du CEATA peut être affectée par les limites d'accélération et le temps passé pour terminer une mission. Ainsi, cette sous-section vise à trouver l'accélération optimale en définissant un problème d'optimisation du temps-énergie minimal. La première contrainte dans l'optimisation est le modèle cinétique du CEATA (4.40) pour s'assurer que toutes les contraintes de mouvement du CEATA sont prises en compte. La deuxième contrainte est la limitation de l'accélération d'angle de braquage [112]. Puisque le planificateur de mouvement atteint des vitesses linéaires et angulaires, cette contrainte garantit la limite acceptable de l'accélération d'angle de braquage ( $\ddot{\delta}$ ) en tenant compte du taux de direction maximal ( $\dot{\delta}_{\max}$ ) et du taux d'angle de braquage ( $\dot{\delta}_k$ ). Par conséquent, elle est décrite comme suit :

$$\ddot{\delta} \leq \frac{\dot{\delta}_{\max} - \dot{\delta}_k}{\Delta t} \quad (5.8)$$

Où l'intervalle de temps entre chaque commande est noté par  $\Delta t$ . Concernant les valeurs minimales et maximales des entrées du modèle dynamique du CEATA, la troisième contrainte est définie comme :

$$|u_i| \leq u_{i_{\max}} \quad (5.9)$$

où  $i \in [1, 2]$ .

La fonction objectif devrait être conçue pour trouver l'accélération maximale en un minimum de temps possible, ce qui conduit à l'énergie optimale (entrées des moteurs). Ainsi, un modèle mathématique non linéaire est présenté comme suit en utilisant la méthode de relaxation [113] :

$$\begin{aligned} \min_{u_1, u_2, T} \quad & \Gamma = \int_0^T (\zeta_1 + \zeta_2 u_1^2 + \zeta_3 u_2^2 + \zeta_4 [\max(a_{\max}, |a|)]^2 + \zeta_5 [\max(\alpha_{\max}, |\alpha|)]^2) dt \quad (5.10) \\ \text{s.t.} \quad & \text{Eq. ( 4.41), ( 5.8), ( 5.9)} \end{aligned}$$

Où  $\zeta_{1-5}$  sont des poids constants ajustables pour ajuster l'importance relative des différents termes dans la fonction objectif. Par conséquent,  $\zeta_1$  est considéré pour garantir l'optimisation du temps minimal,  $\zeta_2$  et  $\zeta_3$  sont des poids liés à l'énergie,  $\zeta_4$  et  $\zeta_5$  sont des poids d'accélération. De plus,  $a_{\max}$  et  $\alpha_{\max}$  sont respectivement les accélérations linéaire et angulaire maximales autorisées du CEATA. Les entrées du modèle cinétique ( $u_1(\tau_t)$ ,  $u_2(\tau_s)$ ) sont considérées comme des variables d'optimisation. En utilisant la méthode de relaxation, les contraintes d'accélération passent à la fonction objectif des contraintes d'optimisation. Ainsi, le problème d'optimisation prend en compte la contrainte d'accélération maximale tout en minimisant le temps et l'énergie.

Un EdD approprié est une partie cruciale de la méthode DNN. Pour générer le EdD, le modèle cinétique du CEATA (4.41) et la méthode d'optimisation (5.10) sont utilisés. Par conséquent, différents paramètres d'inertie ( $m_2, J, l_1, l_2$ ) et conditions initiales pour le modèle dynamique sont considérés comme les entrées du modèle cinétique. Ensuite, l'algorithme d'optimisation utilise le modèle pour trouver l'accélération linéaire et angulaire optimale (sorties du EdD) en fonction des différentes entrées. Toutes les données sont sauvegardées dans le stockage de données pour compléter le EdD. La Figure 5-5 illustre le processus de génération de données et la structure du EdD. Ainsi, le EdD avec 64520 lignes comprend huit entrées ( $In_i$ ) et deux sorties ( $Out_j$ ). Où  $i \in [1, 8]$  et  $j \in [1, 2]$ .

Dans ce problème, le MLP devrait entraîner un modèle pour apprendre la prédiction



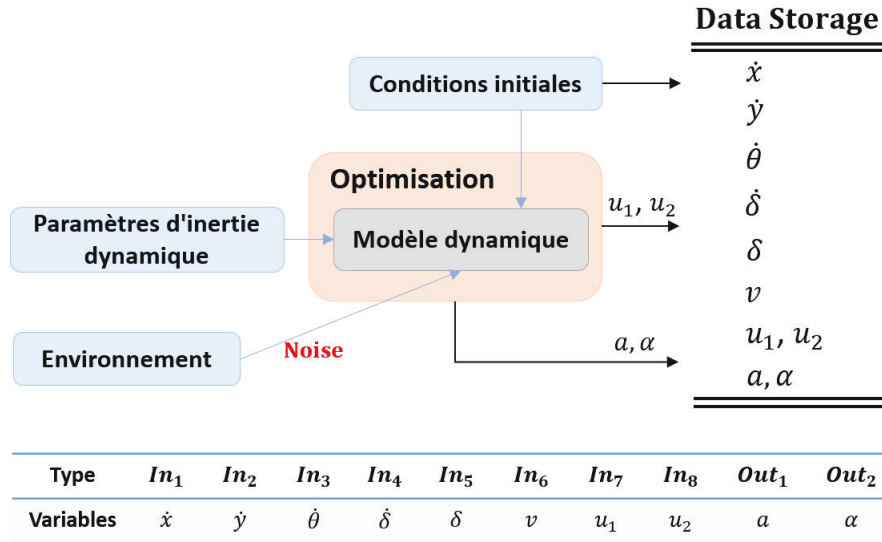


FIGURE 5-5 La carte de flux de données avec la structure du EdD.

de l'accélération linéaire et angulaire du CEATA en utilisant le EdD généré. Le Tableau 5-2 illustre les résultats du modèle formé et les propriétés des simulations. Ainsi, le MLP comprend cinq couches cachées avec des neurones [128, 64, 32, 16, 8] dans chaque couche respectivement. Les valeurs présentées sont les optimales qui ont été obtenues après un processus d'essais et d'erreurs. Relu et Adam sont utilisés comme fonction d'activation et comme solveur respectivement. RMSE et SMAPE sont sélectionnés pour afficher la précision de la tâche de prédiction. Les unités de RMSE sont  $m/s^2$  et  $rad/s^2$  pour la prédiction de l'accélération linéaire et angulaire respectivement. L'intervalle de variations de  $a$  et  $\alpha$  est de  $\pm 1 m/s^2$  et  $\pm 1 rad/s^2$ . L'intervalle SMAPE est compris entre 0 et 100% et un pourcentage plus bas signifie une erreur plus faible.

Dans les missions réelles, les entrées du modèle DNN sont générées (directement ou indirectement) par les capteurs et actionneurs de CEATA qui contiennent de nombreux bruits. Ainsi, pour démontrer la robustesse du modèle DNN face à différents niveaux de bruit, trois types de jeux de données sont considérés pour les tests. Le type 1 comprend des données sans bruit. Les types 2 et 3 contiennent un bruit Gaussien avec un SNR de 70 dB et 50 respectivement (La relation entre le bruit gaussien et le SNR est expliquée dans la Section 5.1). Concernant le RMSE et le SMAPE des résultats dans le Tableau 5-2, MLP donne des résultats acceptables pour prédire à la fois l'accélération pour différents types de jeux de données. Pour

comprendre clairement la différence entre les résultats, ceux-ci sont présentés dans la Figure 5-6. Les lignes bleues et vertes correspondent aux paramètres  $a$  et  $\alpha$ . Ainsi, les données sans bruit obtiennent le meilleur résultat. En augmentant le SNR dans les jeux de données 2 et 3, les valeurs des erreurs augmentent progressivement. Par conséquent, les prédictions de RMSE de  $a$  et  $\alpha$  sont de  $0.005 \text{ m/s}^2$  et  $0.008 \text{ rad/s}^2$  pour les données sans bruit. Cependant, cela atteint  $0.02 \text{ m/s}^2$  et  $0.04 \text{ rad/s}^2$  pour les données avec un SNR de 70 dB et  $0.06 \text{ m/s}^2$  et  $0.1 \text{ rad/s}^2$  pour les données avec un SNR de 50 dB. De plus, les prédictions du SMAPE de  $a$  et  $\alpha$  sont de 11.4% et 13.5% pour le type de données 1. Il augmente à 14.4% et 17.3% pour le type de données 2 et 22.1% et 26.7% pour le type de données 3. Les résultats globaux prouvent la performance adéquate du modèle DNN généré. Il obtient des résultats acceptables même en augmentant le taux de bruit.

TABLEAU 5-2 Propriétés et résultats de la prédiction de l'accélération linéaire et angulaire en utilisant la méthode MLP.

Paramètre	Données sans bruit		Données avec bruit (SNR=70db)		Données avec bruit (SNR=50db)	
	RMSE	SMAPE(%)	RMSE	SMAPE(%)	RMSE	SMAPE(%)
$a$	$0.005 \text{ m/s}^2$	11.4	$0.02 \text{ m/s}^2$	14.4	$0.06 \text{ m/s}^2$	22.1
$\alpha$	$0.008 \text{ rad/s}^2$	13.5	$0.04 \text{ rad/s}^2$	17.3	$0.1 \text{ rad/s}^2$	26.7

**Méthode des réseaux neuronaux profonds : MLP**  
**Nombre de neurones dans les cinq couches cachées : [128,64,32,16,8]**  
**Fonction d'activation : Relu**  
**Optimisateur : Adam**

Jusqu'à cette partie, l'accélération linéaire et angulaire optimale de CEATA a été obtenue en utilisant le DNN. En ce qui concerne l'objectif de ce travail, le modèle DNN devrait être ajouté à une méthode de planification de mouvement pour l'améliorer en tant que méthode éco-énergétique. Ainsi, le TEB (TEB spécifique pour le type de véhicule) [100], un planificateur de mouvement populaire dans la littérature, est choisi pour ce travail. Bien que le TEB utilise les contraintes cinématiques du robot, il ignore les contraintes dynamiques présentes dans le modèle cinétique. Par conséquent, il ne pourrait pas prendre en compte la faisabilité dynamique du robot et les problèmes d'énergie lors de la génération des trajectoires. Ces questions deviennent encore plus importantes lorsqu'il y a des changements consécutifs des paramètres d'inertie, comme un CEATA dont la tâche principale est de manipuler des charges.

TEB est un algorithme d'optimisation de trajectoire utilisé pour planifier et exécuter le mouvement d'un robot d'une position initiale à une position cible, tout en évitant les obstacles

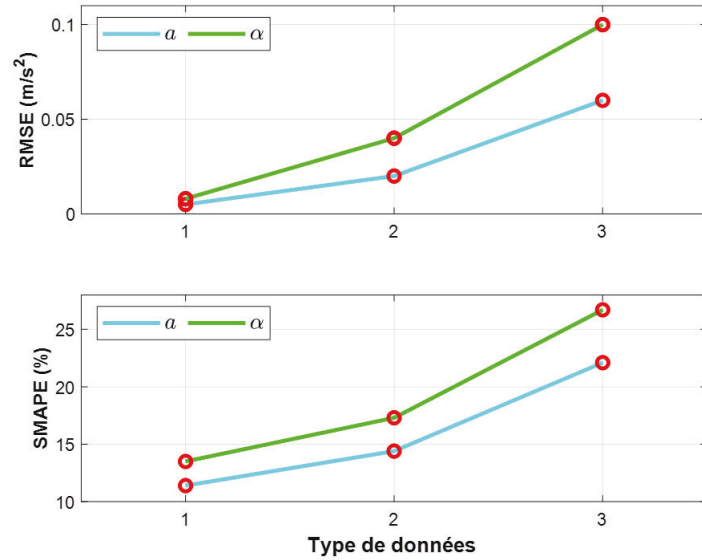


FIGURE 5-6 Résultats de la prédiction de l'accélération linéaire et angulaire par MLP.

et en respectant les contraintes du robot. TEB optimise une trajectoire représentée par une séquence de poses (c'est-à-dire, position et orientation) dans le temps. Ainsi, le problème de recherche de haute dimension de la planification du mouvement doit être résolu. La séquence des poses de CEATA dans l'espace de configuration est exprimée par :

$$Q = \{q_{jk}\}_{j=1:3; k=0\dots n-1}; \quad n \in \mathbb{N} \quad (5.11)$$

où  $n$  désigne le nombre de sommets dans chaque trajectoire.

$\Delta T$  représente l'intervalle de temps entre chaque deux poses et la collection de sommets correspondant à ces intervalles de temps est représentée comme :

$$B = \{\Delta T_k\}_{k=0\dots n-2}; \quad n \in \mathbb{N} \quad (5.12)$$

Par conséquent, la trajectoire est exprimée comme une combinaison d'une série de poses et d'intervalles de temps, qui servent de variables d'optimisation pour la solution qui suit :

$$S = \{Q, B\} \quad (5.13)$$

La fonction multi-objectif du planificateur de mouvement est exprimée comme suit :

$$\begin{aligned}
\min_S \quad & \Lambda = \sum_{k=1}^{n-1} \Delta T_k^2 \\
\text{t.q.} \quad & o_k(q_k) \geq 0 \\
& \tilde{r}_k(q_{k+1}, q_k) \geq 0 \\
& h_k(q_{k+1}, q_k) = 0 \\
& 0 \leq \Delta T_k \leq \Delta T_{\max} \\
& v_k(q_{k+1}, q_k, \leq \Delta T_k) \geq 0; \quad (k = 1, 2, \dots, n-1) \\
& acc_k(q_{k+2}, q_{k+1}, q_k, \Delta T_{k+1}, \Delta T_k) \geq 0; \quad (k = 2, 3, \dots, n-2)
\end{aligned} \tag{5.14}$$

Les contraintes comprennent leurs poids correspondants et dénotent l'évitement d'obstacle ( $o_k$ ), le rayon de braquage ( $\tilde{r}_k$ ), le mouvement de courbure ( $h_k$ ), le temps de transition ( $\Delta T_k$ ), la vitesse ( $v_k$ ) et l'accélération ( $acc_k$ ). Le problème d'optimisation est résolu par le cadre d'optimisation de graphe de g2o [114] pour obtenir un mouvement efficace.

La contrainte d'accélération comprend des contraintes d'inégalité pour l'accélération linéaire et angulaire qui sont décrites respectivement comme :

$$a_{\max} - |a_k| \geq 0 \tag{5.15a}$$

$$\alpha_{\max} - |\alpha_k| \geq 0 \tag{5.15b}$$

Où  $a_{\max}$  et  $\alpha_{\max}$  déterminent les limites d'accélération dans le processus d'optimisation. De plus,  $a_k$  et  $\alpha_k$  sont présentés comme :

$$a_k = \frac{2(v_{k+1} - v_k)}{\Delta T_k + \Delta T_{k+1}} \tag{5.16a}$$

$$\alpha_k = \frac{2(w_{k+1} - w_k)}{\Delta T_k + \Delta T_{k+1}} \tag{5.16b}$$

Lorsque nous considérons les paramètres  $a_{\max}$  et  $\alpha_{\max}$  comme des valeurs fixes, nous pourrions rencontrer les problèmes discutés dans la Sous-section 3.2. Par conséquent, pour éviter ces problèmes potentiels, il est nécessaire que l’algorithme de planification de mouvement adapte dynamiquement ces paramètres en temps réel à leurs valeurs optimales pendant la formation de la trajectoire. À cet égard, nous proposons d’intégrer un modèle DNN préétabli dans le processus d’évaluation et d’optimisation de la trajectoire. Cela nous permet de déterminer continuellement et de manière proactive les meilleures limites d’accélération pour chaque pas de temps le long de la trajectoire.

Le diagramme de blocs de la méthode proposée est illustré à la Figure 5-7. Les données du capteur (indiquées par la ligne pointillée verte) sont dirigées vers le module TEB éco-énergétique (ETEB), ainsi que vers d’autres étapes de navigation, qui incluent la cartographie, la localisation et la planification du trajectoire globale. La trajectoire globale, générée par l’algorithme de planification du trajectoire globale, est ensuite combinée avec une carte de coûts locale et la position du CEATA, et ces informations sont envoyées au module ETEB (ligne pointillée violette). Au sein du module ETEB, le composant de génération de trajectoire crée des échantillons de trajectoires globales et de vitesses possibles. Ces échantillons sont ensuite envoyés à la fois au Modèle DNN et aux composants hyper-graphe (lignes pointillées orange). Le Modèle DNN reçoit huit entrées et prédit l’accélération optimale (les entrées et sorties du Modèle DNN sont définies dans la Figure 5-5). Les six premières entrées ( $In_{1-6}$ ) sont dérivées des informations de trajectoire globale et de vitesse de chaque échantillon de trajectoire. Les deux dernières entrées ( $In_{7,8}$ ) proviennent des moteurs de traction et de direction (lignes pointillées rouges). La relation entre les sorties du moteur (courant,  $i_M$ ) et les entrées 7 et 8 du Modèle DNN (couple,  $\tau$ ) est définie par l’Équation 5.6.

Le Modèle DNN détermine dynamiquement les limites optimales de l’accélération ( $a_{\max}$ ,  $\alpha_{\max}$ ) et les transmet au composant de génération d’hypergraphe (ligne orange continue). L’hypergraphe résultant, qui comprend des sommets et des contraintes, est ensuite envoyé à l’optimiseur g2o (ligne noire continue). L’algorithme g2o traite ces informations pour trouver la trajectoire optimale, générant des valeurs de référence pour la vitesse linéaire et l’angle de direction utilisés par le contrôleur de mouvement (ligne violette continue). Le contrôleur de mouvement prépare alors les entrées moteur appropriées pour guider le CEATA de manière

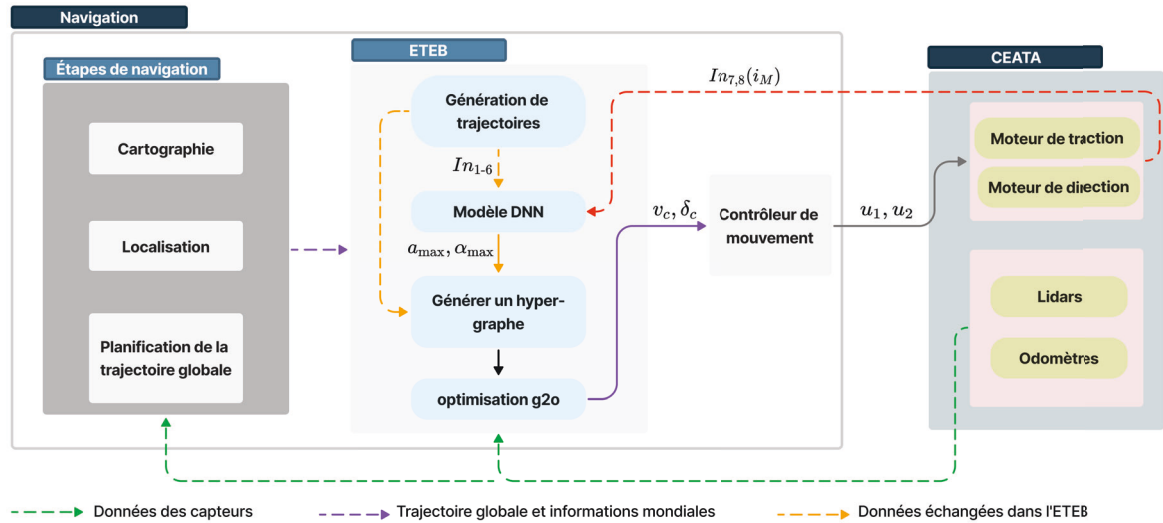


FIGURE 5-7 Le diagramme de bloc du planificateur de mouvement éco-énergétique (ETEB).

faisable et optimale (ligne grise continue). Ce processus se poursuit de manière itérative jusqu'à ce que le CEATA atteigne l'objectif local.

L'Algorithme 2 représente le pseudo-code pour l'ETEB, qui englobe :

- **Entrées de la Fonction** : La fonction `ETEB_PLANNER(start, goal, DNN_model)` prend en entrée une position de départ, une position cible, et un Modèle de DNN.
- **Initialisation des Variables** : La fonction commence par initialiser plusieurs variables. Une trajectoire globale  $P$  est établie, les vitesses  $V$  sont initialisées, les courants moteur  $i_m$  sont établis, et un intervalle de temps  $T$  entre les points est fixé à une valeur constante. De plus, un indicateur booléen `reached_goal` est initialisé à `False` pour indiquer si l'objectif a été atteint, et un compteur d'itération `iter` est initialisé à zéro.
- **Boucle Principale** : La boucle principale de l'algorithme continue jusqu'à ce que l'objectif soit atteint ou que le compteur d'itération atteigne une limite maximale (`MAX_ITERATIONS`).
- **Boucle d'Optimisation Interne** : À l'intérieur de la boucle principale, il y a une boucle interne sur `MAX_OPTIMIZATION_ITERATIONS`. Chaque itération de cette boucle interne exécute les étapes suivantes :

---

**Algorithm 2** Algorithme de ETEB
 

---

```

1: function PLANIFICATEUR_ETEB(départ, objectif, modèle_DNN)
2: Initialiser la trajectoire globale  $P$ 
3: Initialiser les vitesses  $V$ 
4: Initialiser les courants du moteur  $i_m$ 
5: Initialiser l'intervalle de temps  $T$  entre les points à une valeur constante
6: Initialiser le drapeau booléen atteint_objectif à False
7: Initialiser le compteur d'itération itération à zéro
8: while not atteint_objectif and itération < MAX_ITÉRATIONS do
9:   for each  $i$  in range(MAX_ITÉRATIONS_OPTIMISATION) do
10:     $A \leftarrow$  modèle_DNN( $P, V, i_m$ ) {Utiliser le modèle DNN pour déterminer les accélérations}
11:    coût  $\leftarrow$  CALCULER_COÛT( $P, V, A, T$ ) {Le coût inclut l'évitement d'obstacles, la fluidité, etc.}
12:    Initialiser l'optimiseur g2o
13:    Ajouter des sommets (états) à l'optimiseur g2o {Les états comprennent les positions, les vitesses et les intervalles de temps}
14:    Ajouter des arêtes (contraintes) à l'optimiseur g2o {Les contraintes comprennent les contraintes non holonomes, l'accélération, etc.}
15:    Exécuter l'optimisation g2o pour mettre à jour  $P, V$ , et  $T$  {Utiliser la méthode de Levenberg-Marquardt}
16:  end for
17:  if DISTANCE_VERS_OBJECTIF( $P[-1]$ ) < SEUIL_OBJECTIF then
18:    atteint_objectif  $\leftarrow$  True
19:  end if
20:  METTRE_À_JOUR_POSITION_ROBOT( $P[0]$ ) {Déplacer le robot le long du premier segment du trajectoire globale}
21:  Retirer le premier segment de  $P$ 
22:  Ajouter un nouveau segment à  $P$  en fonction de la position actuelle du robot et de l'objectif {Étendre la trajectoire globale vers l'objectif}
23:   $i_m \leftarrow$  OBTENIR_COURANTS_MOTEUR_ACTUELS() {Récupérer les courants du moteur actuels}
24:  itération  $\leftarrow$  itération + 1
25: end while
26: end function

```

---

- **Détermination de l'Accélération** : Le modèle DNN est utilisé pour déterminer les accélérations  $A$  étant donné la trajectoire globale actuelle  $P$ , les vitesses  $V$ , et les courants moteur  $i_m$ . Ce modèle incorpore probablement des connaissances sur la dynamique du robot.
- **Calcul du Coût** : Un coût est calculé en utilisant la fonction COMPUTE\_COST( $P$ ,

$V, A, T$ ), qui inclut probablement des facteurs tels que la distance à l'objectif, l'évitement d'obstacles, la fluidité du trajectoire globale, la consommation d'énergie, etc.

- **Configuration de l'Optimisation g2o** : L'optimiseur g2o est initialisé. g2o est un cadre général pour l'optimisation de graphes, généralement utilisé pour le SLAM (Localisation et Cartographie Simultanées) en robotique. Des sommets (représentant des états, y compris les positions, les vitesses, et les intervalles de temps) et des arêtes (représentant des contraintes, comme les contraintes non holonomes et les limites d'accélération) sont ajoutés à l'optimiseur g2o.
- **Exécution de l'Optimisation g2o** : Le processus d'optimisation g2o est ensuite exécuté, utilisant la méthode de Levenberg-Marquardt pour ajuster la trajectoire globale  $P$ , les vitesses  $V$ , et les intervalles de temps  $T$  afin de minimiser le coût calculé.
- **Vérification de l'Objectif** : Après la boucle d'optimisation interne, l'algorithme vérifie si le robot a atteint l'objectif. Si le dernier point du trajectoire globale  $P[-1]$  est à une certaine distance `GOAL_THRESHOLD` de l'objectif, il fixe `reached_goal` à `True`.
- **Mise à Jour du trajectoire globale** : Que l'objectif soit atteint ou non, le robot est déplacé le long du premier segment du trajectoire globale (`UPDATE_POSITION(P[0])`), et ce segment est ensuite retiré de  $P$ . Un nouveau segment est ajouté à  $P$  en fonction de la position actuelle du robot et de l'objectif. Cela permet au trajectoire globale d'être constamment mis à jour et étendu vers l'objectif.
- **Mise à Jour du Courant** : L'algorithme récupère les courants moteur actuels  $i_m$  en utilisant la fonction `GET_CURRENT_MOTOR_CURRENTS()`.
- **Incrémenter le Compteur d'Iterations** : Enfin, le compteur d'itération principal `iter` est augmenté de un.

Le processus se répète jusqu'à ce que l'objectif soit atteint ou que le nombre maximal d'itérations soit réalisé. Ce planificateur ETEB utilise une approche d'optimisation itérative



pour affiner continuellement sa trajectoire globale en fonction de la compréhension de la dynamique du robot et de l'environnement, dans le but de trouver les trajectoires les plus efficaces sur le plan énergétique pour atteindre l'objectif.

Le ETEB proposé pour un CEATA représente une avancée notable dans le domaine. Cependant, comme pour toutes les technologies innovantes, il est essentiel d'évaluer de manière critique les limitations potentielles et d'explorer des stratégies pour les adresser. L'intégration d'un modèle DNN pour ajuster dynamiquement les limites d'accélération ajoute une complexité computationnelle. Le fonctionnement en temps réel exige un traitement rapide, ce qui pourrait être un défi, en particulier sur du matériel avec des ressources computationnelles limitées. Par conséquent, ce travail a raffiné les algorithmes pour réduire la complexité computationnelle par la simplification et des pratiques de codage plus efficaces.

L'efficacité du modèle DNN dans la génération de limites d'accélération optimales dépend fortement de la qualité et de la diversité de l'ensemble de données d'entraînement. Si l'ensemble de données manque de représentation de certains scénarios ou dynamiques, les prédictions du modèle peuvent ne pas se généraliser bien aux conditions inédites. Ainsi, cette étude a augmenté la diversité et la qualité de l'ensemble de données d'entraînement, y compris la génération de données synthétiques, pour couvrir une gamme plus large de scénarios.

Le succès du système entier repose sur la précision du modèle cinétique du CEATA. Toute divergence entre le modèle et les dynamiques réelles du CEATA pourrait conduire à une planification de mouvement sous-optimale. Par conséquent, cette étude a intégré la modélisation de l'incertitude dans le processus de prédiction, permettant au système de tenir compte de et de s'adapter à des changements inattendus de manière plus efficace.

## **Chapitre 6 - Résultats des expérimentations et simulations**

Le Chapitre 6 intitulé "Résultats des Expérimentations et Simulations" constitue une partie essentielle de cette thèse, fournissant des preuves empiriques de l'efficacité et de l'efficacité des planificateurs de mouvement proposés. Ces planificateurs de mouvement, conçus dans le Chapitre 5, ont été implémentés sur deux VAI différents, nommés RMAED et CEATA. En examinant les résultats des expérimentations et simulations, ce chapitre vise à clarifier comment les planificateurs de mouvement proposés fonctionnent en pratique, tout en permettant une analyse comparative de leur fonctionnalité dans différentes circonstances.

Ce chapitre est structuré en deux principales sections. La première section est dédiée à l'expérimentation impliquant un RMAED avec le planificateur de mouvement EDWA. Dans le but de faciliter la compréhension de la méthode proposée, la section commence par décrire les propriétés spécifiques et les paramètres de l'expérimentation et de la simulation. Ensuite, nous décrivons en détails les résultats obtenus lors des essais. Enfin, nous présentons une analyse approfondie de ces résultats, en décortiquant leurs implications, et en évaluant la performance globale et la fiabilité de l'EDWA lorsqu'il est implémenté sur RMAED.

De même, la deuxième partie de notre étude porte sur une expérience que nous avons menée avec un CEATA en utilisant le planificateur de mouvement de l'ETEB. Nous commençons cette section en décrivant les détails de l'expérience, ce qui permettra d'expliquer les facteurs importants impliqués. Nous présentons ensuite les résultats de l'expérience, en montrant des données réelles qui illustrent le fonctionnement de l'ETEB dans la pratique. Nous terminons par un examen approfondi de ces résultats, en essayant de comprendre les points importants des résultats et en évaluant l'efficacité de l'ETEB lorsqu'il est utilisé pour le CEATA.

En séparant les résultats et l'analyse des deux planificateurs de mouvement en deux sections différentes, ce chapitre vise à fournir une compréhension claire et sans ambiguïté

de l'impact de chaque planificateur de mouvement a sur le robot correspondant. Par cette évaluation approfondit des données expérimentales, nous espérons souligner les avantages potentiels, identifier les limitations et ouvrir la voie aux améliorations futures des planificateurs de mouvement proposés.

## 6.1 RMAED

### 6.1.1 Simulations

Avant de procéder aux tests pratiques, plusieurs simulations ont été réalisées afin d'ajuster les paramètres nécessaires et de vérifier l'efficacité de l'EDWA. Ces simulations se sont appuyées sur le kit de navigation ROS pour mettre en œuvre divers outils et algorithmes de navigation. Par ailleurs, nous avons fait appel à Gazebo pour construire l'environnement simulé. Les propriétés de le RMAED dans la simulation sont représentées dans le Tableau 6-1.

La Figure 6-1 illustre le RMAED simulé dans Gazebo. De plus, la Figure 6-2 montre l'environnement de simulation. Ainsi, le RMAED commence son déplacement depuis le point de départ et marque un arrêt à cinq stations (1-5) avant d'atteindre son point d'arrivée. Les paramètres d'inertie de la charge sont modifiés à chaque station. Cependant, la géométrie de la charge conserve sa forme rectangulaire pour l'ensemble du scénario. La trajectoire globale de le RMAED, générée par le planificateur global, présente des obstacles statiques inattendus. le RMAED est tenu de suivre cette trajectoire tout en contournant ces obstacles. Deux configurations sont considérées pour le scénario : dans la première, la navigation de le RMAED repose sur le DWA général ( $\kappa = 0$ ) pour la planification du mouvement, tandis que dans la seconde, on applique la méthode EDWA ( $\kappa \neq 0$ ).

La simulation est conçue pour reproduire une mission réelle dans un entrepôt. Dans ce contexte, le RMAED navigue à travers différentes sections de l'entrepôt, chaque trajet impliquant le transport d'une nouvelle charge avec des attributs de masse et de position uniques.

TABLEAU 6-1 Caractéristiques de le RMAED.

Paramètre	Valeur
Masse ( $m_1$ )	82 kg
Moment d'inertie autour de l'axe z ( $I_z$ )	5.5 kg.m <sup>2</sup>
Distance de chaque roue au point P ( $b$ )	38 cm
Rayon de la roue ( $r$ )	0.1 m
Dimensions (longueur × largeur × hauteur)	1.65 m × 0.76 m × 0.23 m
Position du Centre de Masse (longueur, largeur) par rapport au point P	-4±1 cm, -2±1 cm




FIGURE 6-1 Modèle RMAED conçu dans Gazebo.




FIGURE 6-2 Environnement de simulation pour le RMAED.

La trajectoire globale de le RMAED est illustré à la Figure 6-3. Les cercles jaunes numérotés (1-5) marquent les points d'arrêt requis pour le RMAED, chacun correspondant à la fin d'un segment de mission (noté  $a$  à  $f$ ). La direction du mouvement de le RMAED est représentée par les flèches grises. Les rectangles verts, rouges et noirs indiquent respectivement les positions de départ, de fin et d'obstacle. L'obstacle représenté en bleu concerne spécifiquement le segment de mission  $e$ . Il convient de noter que cet obstacle particulier est absent pendant l'exécution du segment  $b$  par le RMAED.

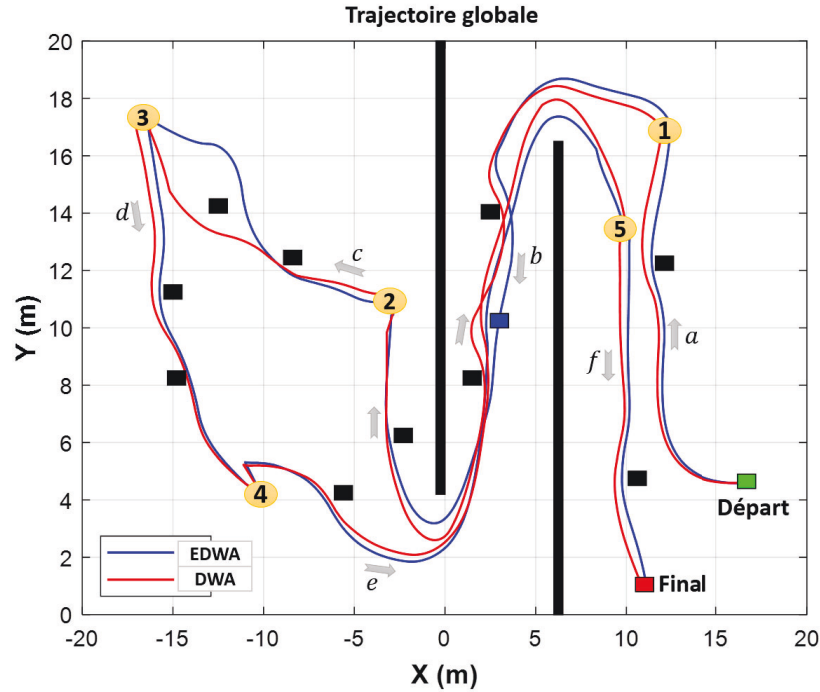


FIGURE 6-3 Trajectoire globale de le RMAED dans la simulation.

Les Figures 6-4 et 6-5 montrent respectivement la différence entre les vitesses et la différence entre les energie des moteurs lors des simulations. Afin d'offrir une comparaison plus approfondie entre le DWA général et sa version éco-énergétique, l'intégralité des résultats est consignée dans des tableaux. Dans le Tableau 6-2, des informations complètes relatives à la simulation pour chaque section sont présentées. Ce tableau précise le point de départ, le point final et la Masse Totale (MT), qui correspond à la somme des masses de le RMAED et des charges pour chaque section. La colonne  $CoM_l$  détaille les distances du centre de masse (CoM) des charges par rapport au point P. Le centre de masse réel ( $RCoM_g$ ) est calculé en se basant sur les Équations 4.1 et 4.2. De plus, nous avons obtenu le CoM estimé ( $ECoM_g$ ) en utilisant le Modèle 1 du DNN, qui est développé dans la section 5.1.

Les résultats de la simulation sont présentés dans le Tableau 6-3, qui décrit le Temps de Simulation (TS), la Distance Parcourue (DP) et la Consommation d'Énergie de le RMAED (CE) entre deux stations pour les deux scénarios de la simulation. Les résultats de l'identification du CoM sont quantifiés à l'aide du SMAPE, qui a été enregistré à 13% pour  $r_{x_g}$  et 14.2% pour  $r_{y_g}$ . La colonne Réduction de la Consommation d'Énergie (RCE) indique le pourcentage d'énergie économisée grâce à l'utilisation de l'EDWA. Une valeur positive dans cette colonne

met en évidence les avantages de la méthode proposée par rapport au DWA standard.

Les résultats totaux sont résumés dans la ligne 'Total'. En utilisant l'EDWA, le RMAED termine le scénarios en 169.2 s, parcourant une distance de 105.1 m et consommant 9563 J d'énergie. En revanche, lors de l'utilisation du DWA standard, le RMAED dépense 10982 J d'énergie pour couvrir une distance de 109.3 m en 177.8 s. Par conséquent, la méthode proposée réduit non seulement le temps et la distance parcourus par le RMAED, mais diminue également la consommation d'énergie de 13%.

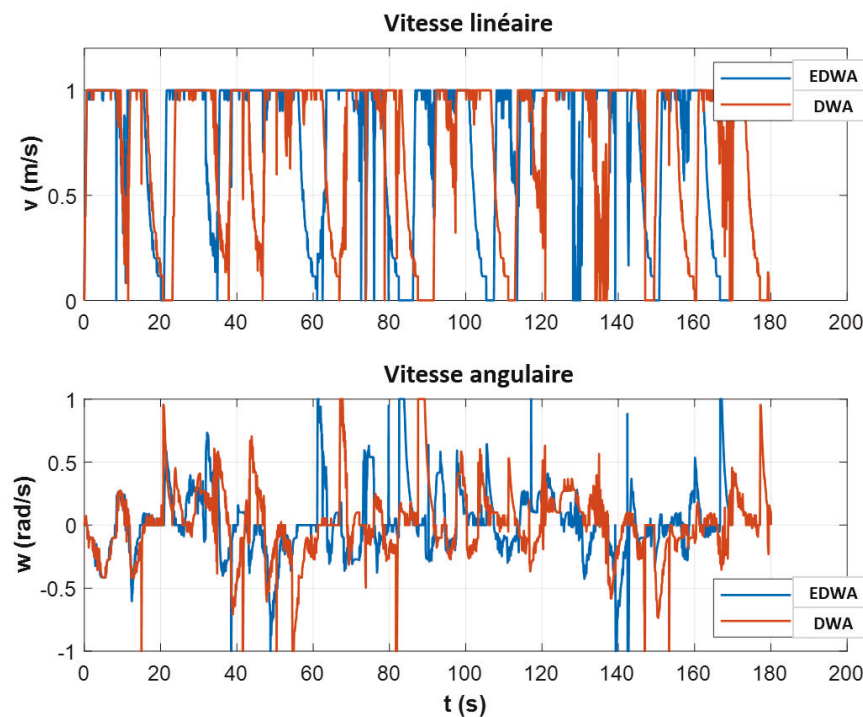


FIGURE 6-4 vitesses linéaire et angulaire de le RMAED dans la simulation.

### 6.1.2 Expérience

Pour valider empiriquement le EDWA proposé, une série de tests a été réalisée en utilisant un RMAED industriel. Les caractéristiques de le RMAED réel utilisé dans l'expérience sont similaires à celles de le RMAED simulé (voir Tableau 6-1). Pour les expériences, cinq conteneurs de stockage ont été employés comme charges. Ces essais ont eu lieu au laboratoire IRH de l'UQTR. Le revêtement du sol du laboratoire est en béton peint, nivelé afin de prévenir tout glissement.

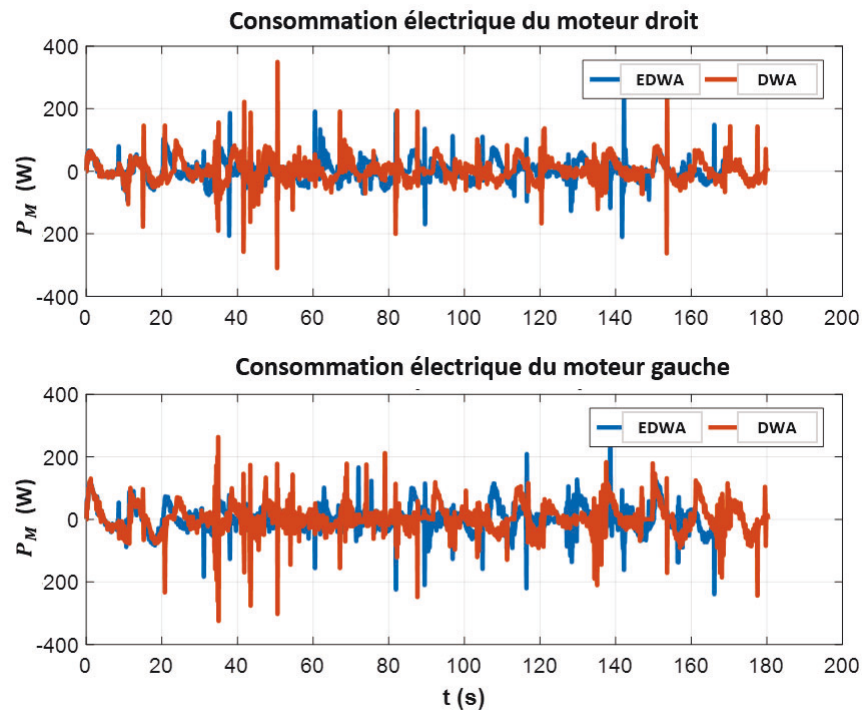


FIGURE 6-5 Consommation d'énergie des moteurs gauche et droit de le RMAED dans la simulation.

le RMAED, conçu par notre partenaire industriel, est équipé d'un PC Industriel fonctionnant sous Ubuntu 18.04 LTS et utilisant le kit de navigation ROS. Comme le montre la Figure 6-6, cet RMAED est doté de deux lidars pour la perception de l'environnement et de deux moteurs assurant les déplacements translationnels et rotationnels. Il est également muni de quatre roues fixes garantissant sa stabilité. le RMAED peut se déplacer librement dans un espace bidimensionnel (2D).

La disposition des tests expérimentaux et sa carte correspondante sont illustrées sur les Figures 6-7 et 6-8. Des éléments clés tels que la station, deux obstacles et les points de passage 1 et 2 sont indiqués sur la carte. Dans cette configuration, le RMAED doit naviguer à travers un réseau de couloirs et d'obstacles imprévus. Le principal objectif de ces expériences est d'examiner l'effet de la méthode proposée sur des durées de mission prolongées. Lors de chaque mission, le RMAED commence son parcours à partir de la station de départ, navigue à travers les points de passage 1 et 2, et finalement revient à son point de départ. Deux obstacles inattendus sont stratégiquement placés pour croiser la trajectoire de le RMAED à un endroit



TABLEAU 6-2 Charge et CoM dans la simulation de le RMAED.

Scénario	Point de Départ	Point de Fin	MT (kg)	CoM <sub>l</sub> (cm)		RCoM <sub>g</sub> (cm)		ECoM <sub>g</sub> (cm)	
				$r_{x_l}$	$r_{y_l}$	$r_{x_g}$	$r_{y_g}$	$r_{x_g}$	$r_{y_g}$
1	Départ	1	150	44	22	20	10	17.4	7.8
2	1	2	125	29	-15	10	-5	12.5	-3.9
3	2	3	165	-20	-20	-10	-10	-1.6	-11.1
4	3	4	133	-15.5	21	-6	-8	-5.9	-9.2
5	4	5	145	21	16	9	7	8.5	6.6
6	5	Final	115	-28	4	-8	4	-9.8	3.4

TABLEAU 6-3 Résultats de la simulation en utilisant DWA et EDWA comme planificateurs de mouvement de le RMAED.

Scénario	TS (s)		DP (m)		CE (J)		RCE(%)
	DWA	EDWA	DWA	EDWA	DWA	EDWA	
1	23.0	20.8	15.5	15.1	1521	1363	10
2	43.8	40.2	25.2	24.1	2689	2244	16
3	24.7	25.1	16.8	16.5	1310	1260	4
4	22.4	21.2	16.3	15.8	1405	1315	6
5	46.5	43.4	24.7	23.3	2770	2366	14
6	19.6	18.5	12.5	12.2	1287	1015	11
Total	177.8	169.2	109.3	105.1	10982	9563	13

SMAPE de l'estimation (%)	$r_x$	$r_y$
		13

spécifique pendant la mission. Une condition de charge maximale est mise en œuvre pour accentuer l'influence des mouvements optimaux ou sous-optimaux sur la consommation d'énergie de le RMAED. Par conséquent, chaque scénario comprend quatre ou cinq charges. Bien que le poids et la position de ces charges soient fixes au sein d'un scénario donné, ils sont néanmoins ajustés entre les différents scénarios.

Nous avons réalisé six scénarios différents en utilisant la même logique de base mais en variant la masse et la position des charges pour EDWA et pour l'approche générique. Comme précédemment illustré dans la Figure 3-1, la surface de chargement peut être segmentée en quatre zones par rapport au point  $P$  et aux axes  $x$  et  $y$ . Chacun des quatre premiers scénarios présente un placement de charge distinct au sein de ces zones. Dans le cinquième scénario, le




FIGURE 6-6 le RMAED.

TABLEAU 6-4 Caractéristiques de chaque charge.

Paramètre	Valeur
Masse	18.5 kg
Dimensions (longueur × largeur × hauteur)	30 cm × 21 cm × 18 cm
Position du Centre de Masse (Longueur, largeur)	15±0.5 cm, 10.5±0.5 cm

CoM global ( $CoM_g$ ) est situé près du point  $P$ , tandis que le sixième scénario est spécifiquement conçu pour comparer les résultats avec le deuxième scénario lorsque leurs positions de  $CoM_g$  sont identiques, mais que les hauteurs des charges diffèrent. Ainsi, ces expériences couvrent toutes les situations potentielles que le RMAED pourrait rencontrer, offrant une évaluation complète du système.

Cinq conteneurs de stockage sont utilisés comme charges sur la plateforme. La Figure 6-9 montre leur emplacement sur la plateforme, et leurs propriétés respectives sont décrites dans le Tableau 6-4. La position de ces conteneurs sur la plateforme varie selon les spécificités de chaque scénario individuel.

La Figure 6-10 illustre la position approximative du centre de masse (CoM) sur la plateforme (indiquée par les points verts) pour l'ensemble des scénarios, où les chiffres 1 à 6 correspondent au numéro de chaque scénario.



FIGURE 6-7 Environnement du test expérimental.

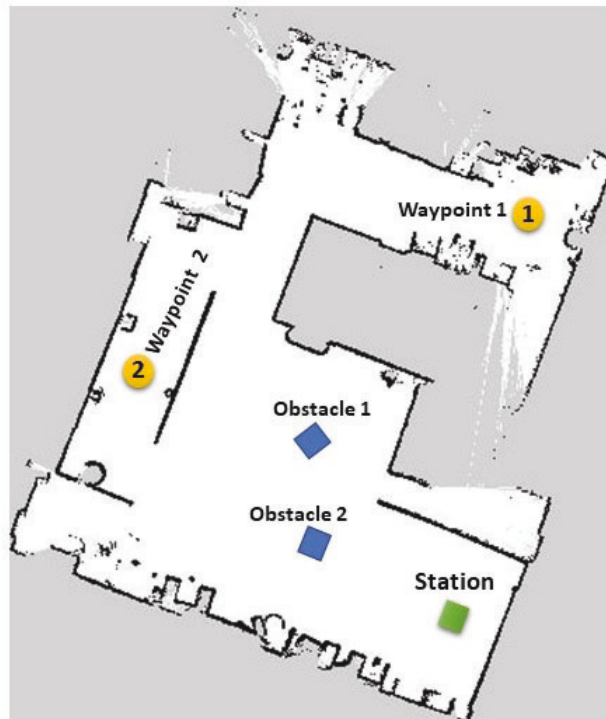


FIGURE 6-8 Carte de l'environnement du test expérimental sur Rviz.




FIGURE 6-9 Charges sur la plateforme de le RMAED.

Dans le cadre de l'évaluation des performances du RMAED au sein d'applications industrielles de longue durée, chaque scénario a été répété 28 fois consécutives, ce qui se traduit par une activité continue dépassant une heure. Cette méthode permet d'intégrer les variabilités et incertitudes inhérentes à la localisation et à la cartographie, qui peuvent rallonger la durée des missions et, par conséquent, influencer l'efficacité de la planification des trajets. En outre, l'analyse de l'efficacité énergétique sur une période excédant une heure offre un cadre comparatif plus robuste et reproduit de manière plus fidèle les conditions réelles d'une mission, contrairement à un test de courte durée.

En raison de l'ampleur de la série d'essais et de la durée des tests, seules les trajectoires de la première exécution du Scénario 1 sont dépeintes sur les Figures 6-11, avec le parcours effectué via le DWA général illustré en rouge et celui via l'EDWA en bleu. L'analyse des trajectoires globales révèle une plus grande fluidité pour celle générée par l'approche proposée (bleu) par rapport à celle du DWA général (rouge). La Figure 6-12 met en contraste les vitesses linéaires et angulaires du RMAED en appliquant la méthode proposée, alors que la Figure 6-13 illustre l'énergie consommée par les moteurs gauche et droit.

Le Tableau 6-5 détaille les informations expérimentales, y compris le Nombre de Charges (NoC) et la Masse Totale (MT) qui est la somme des masses de le RMAED et des charges dans chaque scénario. La colonne relative à  $CoM_l$  explique la distance du CoM des charges par rapport au point  $P$ . Le  $CoM_g$  réel ( $RCoM_g$ ) est calculé en utilisant les Éqs. 4.1 et 4.2. De plus, le  $CoM_g$  estimé ( $ECoM_g$ ) est obtenu en utilisant le Modèle DNN 1 généré, comme expliqué dans




FIGURE 6-10 CoM global réel ( $CoM_g$ ) sur la plateforme pour six scénarios.

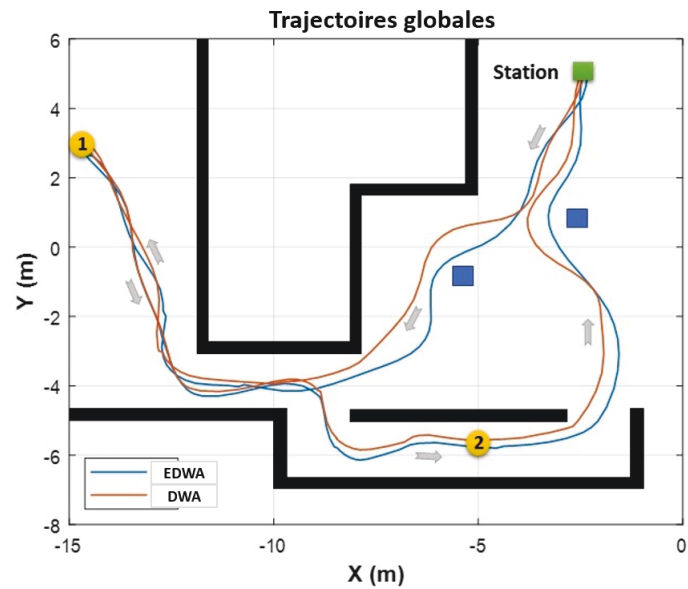


FIGURE 6-11 Trajectoire globale de le RMAED lors de l'expérience (Scénario 1, première tentative).




FIGURE 6-12 Vitesses linéaires et angulaires de le RMAED lors de l'expérience (Scénario 1, première tentative).

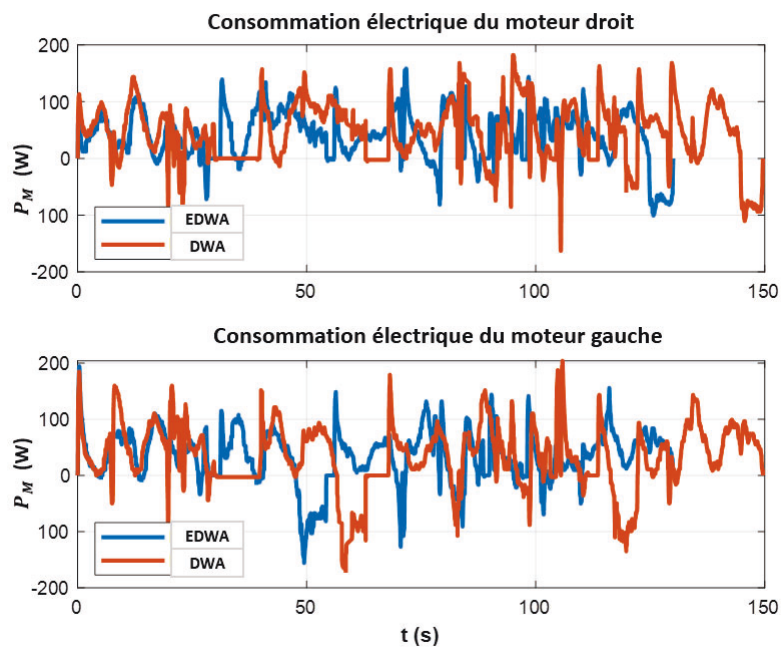


FIGURE 6-13 Consommation d'énergie des moteurs gauche et droit de le RMAED lors de l'expérience (Scénario 1, première tentative).

la Section 5.1. Le Tableau 6-6 synthétise les données issues des expériences, regroupant pour chaque scénario les 28 tentatives en termes de Temps Expérimental (TE), Distance Parcourue (DP), Profondeur de Décharge (PdD) (Le modèle de batterie est expliqué à au chapitre 8), et la Consommation d'Énergie (CE) des moteurs. L'impact de l'EDWA sur la consommation d'énergie des moteurs est quantifié par le paramètre de Réduction de Consommation d'Énergie (RCE). Bien que la plupart des résultats d'estimation soient acceptables, le Scénario 4 présente un écart avec une erreur dépassant 8 cm dans la direction x et 4 cm dans la direction y (en ce qui concerne l'analyse de la sensibilité du modèle cinétique au CoM, un critère d'acceptation de  $\pm 3$  cm est considéré pour l'estimation du CoM). Le SMAPE des estimations globales du rayon dans les directions x et y est respectivement de 26% et 23.6%. Cependant, en excluant le Scénario 4, ceux-ci deviennent 19.5% et 18.3%.

Le temps d'expérimentation de la méthode proposée, la distance parcourue par RMAED, et la consommation d'énergie des moteurs étaient inférieurs à ceux du DWA générale dans tous les scénarios à l'exception du Scénario 4. Ainsi, une estimation imprécise pourrait entraîner une inefficacité énergétique de la méthode proposée et pourrait même conduire à une consommation d'énergie plus élevée. Lors de l'utilisation du planificateur de mouvement général, le RMAED parcourt 8911 m en 446 min, consommant 1708 kJ d'énergie. En revanche, le planificateur éco-énergétique parcourt 8889 m en 424 min avec une consommation d'énergie de 1550 kJ. De plus, le PdD moyen de la batterie atteint 13.3% avec la méthode proposée, ce qui est inférieur de 9% par rapport au 14.6% de PdD de la méthode DWA générale. En conclusion, la méthode proposée a permis au RMAED d'atteindre une efficacité énergétique de 9.25% lors des expériences et de terminer les missions environ 22 min plus rapidement.

TABLEAU 6-5 Informations sur la charge et le CoM lors de l'expérience avec le RMAED.

Scénario	MT (kg)	NoC	CoM <sub>l</sub> (cm)		RCoM <sub>g</sub> (cm)		ECoM <sub>g</sub> (cm)	
			$r_{x_l}$	$r_{y_l}$	$r_{x_g}$	$r_{y_g}$	$r_{x_g}$	$r_{y_g}$
1	174.5	2	5.5	12	10.3	5.5	9.1	5.2
2	156	4	30.5	-11.5	12.5	-6.5	14.9	-6.9
3	156	4	-27	11.5	-15	4.5	-13.4	3.8
4	174.5	5	-15	-10	-9.8	-6.3	-18	-10.5
5	174.5	5	5	4	0.8	1.2	1.2	2
6	156	2	12	-11	12.6	-6.3	14.8	-7.2

TABLEAU 6-6 Résultats de l'expérience en utilisant le DWA et l'EDWA comme planificateur de mouvement du RMAED.

Scénario	TE (min)		DP (m)		PdD (%)		CE (kJ)		RCE (%)
	DWA	EDWA	DWA	EDWA	DWA	EDWA	DWA	EDWA	
1	77.77	67.8	1485	1477	15.2	12.8	299	259	13.4
2	76.4	73.3	1488	1481	14.4	13.0	275	253	8.3
3	75.9	71.3	1489	1485	14.2	12.7	321	270	11.1
4	69.7	71.2	1481	1483	14.6	14.7	271	275	-1.6
5	72.9	68.8	1482	1479	14.8	13.6	274	255	7
6	76.2	71.5	1486	1480	14.4	12.9	268	240	10.5
Total	446	424	8911	8889	14.6	13.3	1708	1550	9.25

SMAPE de l'estimation (%)	$r_x$		$r_y$	
	Avec le Scénario 4	Sans le Scénario 4	Avec le Scénario 4	Sans le Scénario 4
	26	19.5	23.6	18.3

## 6.2 CEATA

### 6.2.1 Simulations

Avant la phase d'expérimentation, de nombreuses simulations ont été réalisées pour ajuster les paramètres nécessaires et garantir l'efficacité de cette méthode. Le kit de navigation ROS a été utilisée pour implémenter les outils et les algorithmes de navigation dans les simulations. De plus, Gazebo a été utilisé pour créer l'environnement de la simulation. La Figure 6-14 montre le CEATA simulé et l'environnement de la simulation dans Gazebo. Les propriétés du



CEATA dans la simulation sont les mêmes que celles du CEATA réel lors des expérimentations (Tableau 6-7). Contrairement à la section précédente, les tests expérimentaux et de simulation de cette section ont suivi le même scénario (manœuvre de stationnement) pour le CEATA. Ainsi, seuls les résultats du test expérimental pour le CEATA sont discutés ici.




FIGURE 6-14 Le CEATA simulé et l'environnement de simulation dans Gazebo.

### 6.2.2 Expérience

Afin de valider expérimentalement la méthode proposée, plusieurs expériences ont été réalisées en utilisant le CEATA du partenaire industriel. Il est présenté sur la Figure 6-15 : (a) sans charge et (b) avec charge. De plus, ses propriétés sont présentées dans le Tableau 6-7. Le CEATA comprend deux moteurs pour la traction et la direction de la roue avant. De plus, il dispose de deux roues pivotantes fixes situées à l'arrière de la structure, qui se déplacent exclusivement dans le sens longitudinal de la structure. Additionnellement, le CEATA est équipé de capteurs pour la localisation, la cartographie et l'estimation de ses vitesses linéaires et angulaires. Il est configuré par un PC industriel avec le système d'exploitation Linux et le kit de navigation ROS. La Figure 6-16 montre l'environnement de l'expérimentation et la Figure 3-4 illustre sa cartographie avec le CEATA et les points de cheminement dans Rviz.

La manœuvre de stationnement représente un défi majeur en matière de navigation pour un CEATA, en raison de sa complexité technique. Cette opération consiste à diriger le CEATA vers un espace désigné au sein de l'entrepôt, où il stationnera et restera en attente de directives supplémentaires. Cette tâche est difficile car elle nécessite que le CEATA se positionne avec




FIGURE 6-15 (a) Le CEATA ; (b) Le CEATA avec la charge.



FIGURE 6-16 Environnement de l'expérimentation

TABLEAU 6-7 Caractéristiques du CEATA

Paramètre	Valeur
Masse ( $m_1$ )	1000 kg
Distance de la roue avant au centre des deux roues pivotantes ( $L$ )	1.7 m
Rayon de la roue avant ( $r$ )	0.15 m
Dimensions (longueur $\times$ largeur $\times$ hauteur)	2.63 m $\times$ 1.22 m $\times$ 2.75 m

précision par rapport à la position et à l'orientation de l'objectif. Sur le plan énergétique, les actions de rotation, comme celles nécessaires pour diriger ou pivoter, se révèlent souvent plus gourmandes en énergie pour le CEATA que les déplacements linéaires, comme avancer ou reculer en ligne droite. Cela est dû au fait que les mouvements de rotation exigent du CEATA qu'il dépasse une inertie plus importante et une résistance accrue lors de la rotation, nécessitant ainsi davantage d'énergie pour accomplir la même tâche. Ainsi, trois waypoints ont été stratégiquement placés afin que les rotations et la manœuvre de stationnement se succèdent de manière séquentielle.

Les scénarios expérimentaux (manœuvre de stationnement) sont les mêmes que ceux présentés dans la Sous-section 3.2. En ce qui concerne la Figure 3-4, le CEATA initie son parcours au waypoint de départ  $w_a$ , progressant ensuite vers le second  $w_b$  et le troisième  $w_c$  waypoints de manière séquentielle. Par la suite, il réalise une boucle pour revenir au point  $w_a$  et réitère ce schéma. Il est crucial de souligner que la sélection de mouvements, optimaux ou non, a un impact significatif sur la consommation énergétique du CEATA, en particulier quand il transporte des charges [29]. Pour examiner l'influence des conditions de charge sur la consommation d'énergie, une série de six scénarios distincts a été mise en place, faisant appel aux planificateurs de mouvements TEB et ETEB. Les Scénarios 1 et 5 ont été effectués à vide. En revanche, dans les Scénarios 2, 3 et 4, le CEATA portait des charges de masses respectives de 300 kg, 600 kg et 1000 kg.

Tandis que l'ETEB ajuste dynamiquement les limites d'accélération optimales à chaque intervalle de temps, le TEB repose sur des valeurs constantes pour l'ensemble des scénarios. Au terme de multiples essais, les limitations d'accélération pour le TEB ont été fixées à 0,5 m/s<sup>2</sup> pour l'accélération linéaire et à 0,5 rad/s<sup>2</sup> pour l'accélération angulaire. Pour refléter une journée d'opération typique où le CEATA est en fonctionnement pendant de longues périodes, les Scénarios 1 à 4 ont été répétés dix fois de suite, garantissant ainsi que la durée de mouvement excède les 10 minutes. Cette approche permet de tenir compte des potentielles incertitudes de localisation et de cartographie susceptibles d'allonger la durée des missions et d'influencer l'efficacité de la planification de mouvement. En contraste, le Scénario 5 a été répété cinq fois et le Scénario 6 a été exécuté trois fois. Les raisons de la diminution des répétitions pour les Scénarios 5 et 6 seront élaborées ultérieurement.

En raison de l'ampleur des tests et des multiples itérations réalisées, seule l'analyse de la première exécution du Scénario 1 est illustrée dans les Figures 6-17, 6-18, et 6-19 (y compris les durées d'arrêt aux points de cheminement 2 et 3) afin d'appréhender distinctement la différence entre TEB (représenté en bleu) et ETEB (représenté en rouge). Selon ces données, le CEATA a achevé la première tentative plus promptement avec l'ETEB par rapport au TEB. La Figure 6-17 illustre, à travers des cercles verts en pointillés, les oscillations des vitesses linéaires et angulaires du CEATA lorsque le planificateur de mouvement TEB était utilisé. Ce phénomène s'explique par le fait que le TEB a généré des trajectoires non réalisables, amenant le CEATA à s'engager dans une manœuvre difficile et à osciller entre différentes trajectoires jusqu'à ce que le TEB produise des trajectoires viables après quelques secondes.

Cependant, l'ETEB a démontré sa capacité à élaborer des trajectoires faisables, permettant ainsi au CEATA de se déplacer sans fluctuations indésirables. En optant pour une approche qui privilégie des valeurs faibles d'accélération linéaire et angulaire, l'ETEB a également la flexibilité d'augmenter ces accélérations lorsque la situation l'exige, grâce à des limites d'accélération définies en temps réel (Figure 6-18). Par conséquent, les pics de la consommation d'énergie des moteurs de traction et de direction étaient inférieurs à ceux du TEB (Figure 6-19). Bien que les limites d'accélération linéaire et angulaire aient été fixées à  $0.5 \text{ m/s}^2$  et  $0.5 \text{ rad/s}^2$  dans le TEB, elles ont été parfois dépassées ces limites. Cela s'est produit parce que la méthode d'optimisation du TEB considère les contraintes comme étant souples.

Les données recueillies à l'issue de chaque scénario sont consignées dans le Tableau 6-8. La première colonne du tableau répertorie le numéro de chaque scénario, tandis que les deuxième et troisième colonnes présentent respectivement le Nombre de Tentatives (NoT) et la présence de charge pour chaque scénario. A noter que les charges ont été omises dans les scénarios 1 et 5. La Masse de la Charge (MC) correspond aux masses des charges transportées par le CEATA. La colonne Oscillation de Vitesse (OV) indique les variations observées dans les vitesses linéaires et angulaires en utilisant les planificateurs TEB et ETEB, avec un exemple de ces oscillations visible dans la Figure 6-17. Par conséquent, un symbole de coche (✓) valide la présence d'oscillations de vitesse relevées lors de l'expérimentation, tandis qu'une marque de croix (X) signale leur absence. Le temps présente la durée de chaque scénario du début à la fin. Quant à la consommation énergétique, la colonne Consommation d'Énergie

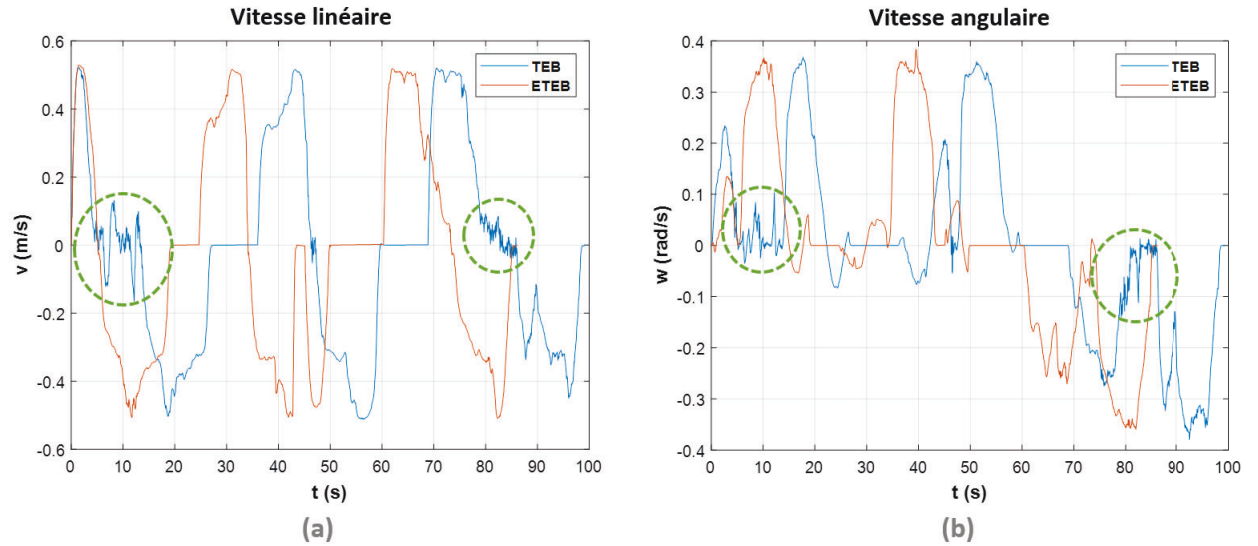


FIGURE 6-17 Vitesses linéaire et angulaire du CEATA lors de l'expérience (Scénario 1, première tentative).

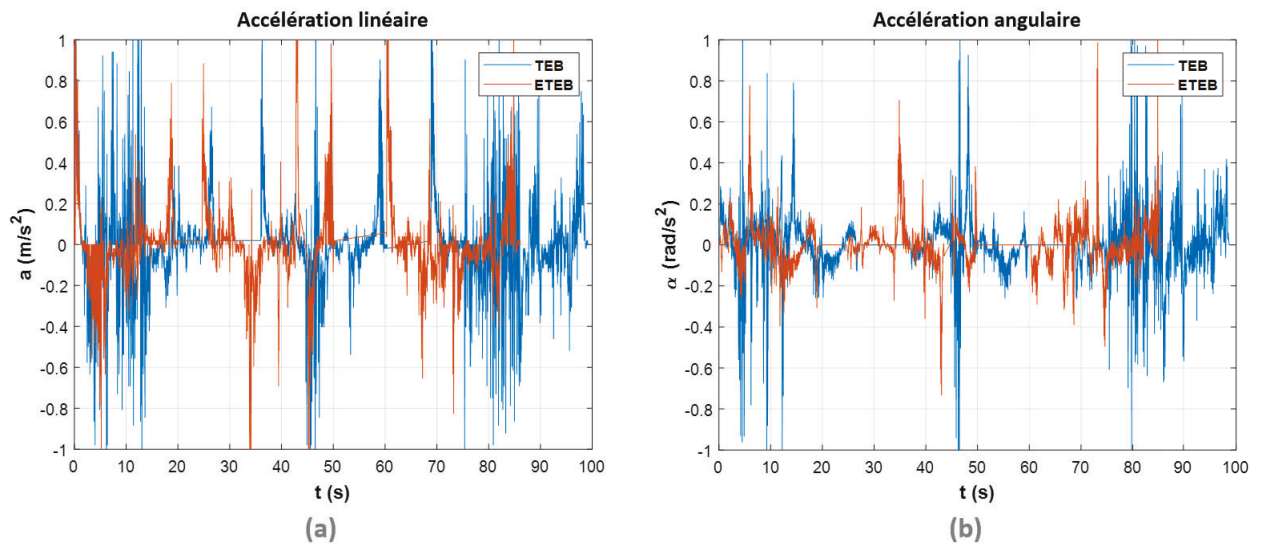


FIGURE 6-18 Accélérations linéaire et angulaire du CEATA lors de l'expérience (Scénario 1, première tentative).

(CE) représente la somme totale de l'énergie consommée par les moteurs, englobant à la fois les moteurs de traction et de direction. Le gain en efficacité énergétique réalisé grâce à l'ETEB est quantifié par le paramètre Réduction de Consommation d'Énergie (RCE). En outre, la ligne finale du tableau résume les performances cumulées du TEB et de l'ETEB, en présentant les totaux pour le Temps, la CE et la RCE.

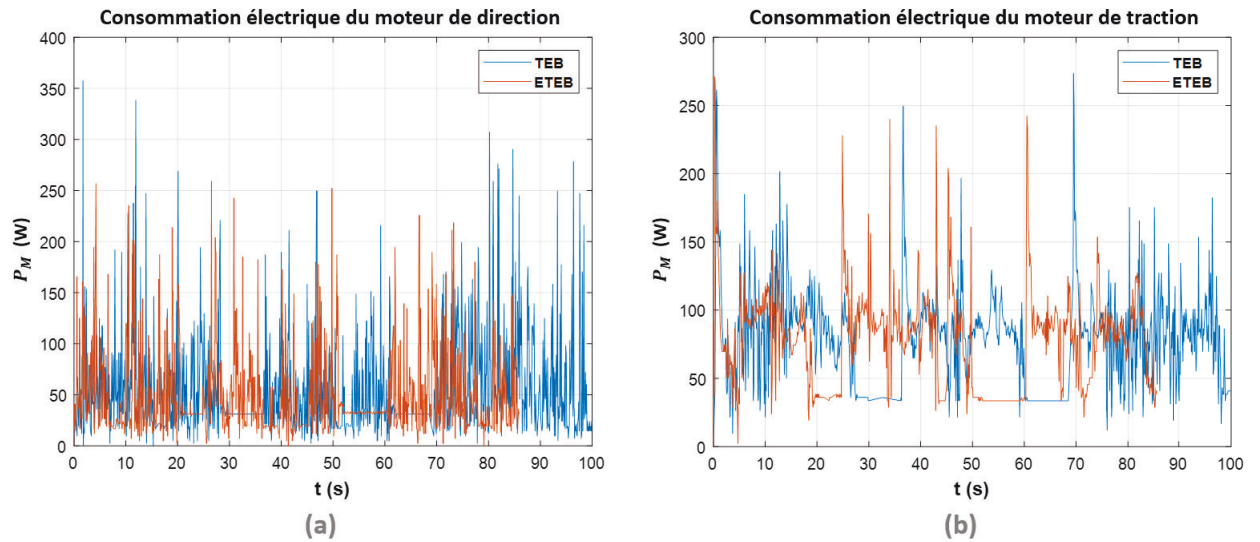


FIGURE 6-19 Consommation d'énergie des moteurs de traction et de direction du CEATA lors de l'expérience (Scénario 1, première tentative).

Selon les résultats présentés dans le Tableau 6-8, il est notable que l'utilisation de l'ETEB comme planificateur de mouvement a entraîné zéro oscillation à la fois dans les vitesses linéaires et angulaires. Au contraire, lorsque le TEB a été utilisé comme planificateur de mouvement, des oscillations ont été observées dans les Scénarios 1 à 4. Lorsque la charge a été ignorée dans le Scénario 1, le CEATA a pu terminer la mission 41 s plus tôt en utilisant l'ETEB et a réalisé une réduction de la consommation d'énergie de 10.4%. En considérant la charge dans le Scénario 2, l'efficacité de la méthode proposée a été davantage mise en évidence où le CEATA a atteint l'objectif 47 s plus tôt qu'avec le TEB et a obtenu une réduction de la consommation d'énergie de 13.8%. Il est à noter que l'efficacité s'est améliorée à mesure que les masses des charges augmentaient. Ainsi, avec l'utilisation de l'ETEB, le CEATA a terminé la mission plus rapidement (59 s plus tôt dans le Scénario 3 et 65 s plus tôt dans le Scénario 4). Par conséquent, une réduction substantielle de la consommation d'énergie a été observée (20.1% dans le Scénario 3 et 22.1% dans le Scénario 4), où les masses des charges étaient de 600 kg et 1000 kg, respectivement.

Au cours des Scénarios 1 à 4, chacun étant répété dix fois, la méthode ETEB a systématiquement enregistré des durées d'exécution comprises entre 630 et 640 secondes pour chaque scénario. Cette régularité témoigne d'une grande stabilité et efficacité dans la réalisation des scénarios, le temps d'exécution demeurant dans une marge définie à travers les différentes

TABLEAU 6-8 Résultats de l'expérience en utilisant TEB et ETEB comme algorithmes de planification de mouvement pour CEATA.

Scénario	NoT	Chargement	MC (kg)	OV		Temps (s)		CE (kJ)		RCE (%)
				TEB	ETEB	TEB	ETEB	TEB	ETEB	
1	10	✗	-	✓	✗	671	630	88.3	79.1	10.4
2	10	✓	300	✓	✗	686	639	115.8	99.8	13.8
3	10	✓	600	✓	✗	694	635	143.4	114.5	20.1
4	10	✓	1000	✓	✗	705	640	181.3	141.3	22.1
5	5	✗	-	✗	✗	334	315	43.1	39.8	7.7
6	3	✓	1000	✗	✗	214	188	47.4	41.9	11.6
Total						3304	3047	619.3	516.4	16.6

répétitions. En revanche, en utilisant la méthode TEB, l'intervalle de temps s'est allongé proportionnellement à l'accroissement de la masse de la charge. De façon plus détaillée, le temps nécessaire a fluctué entre 671 et 705 secondes, indiquant un allongement du temps d'exécution des scénarios en corrélation avec l'augmentation du poids de la charge. Ces observations soulignent la robustesse de la méthode proposée, démontrant sa capacité à s'adapter efficacement aux variations des paramètres d'inertie dynamique.

L'un des objectifs de cette étude est de comparer les résultats entre un algorithme conventionnel de planification de mouvement et son modèle amélioré lorsque la méthode typique ne produit pas de trajectoires infaisables. Dans ces conditions, nous ne devrions pas observer d'oscillation des vitesses. Cette évaluation facilite une comparaison logique entre la méthode TEB et la méthode que nous proposons, et peut confirmer que la méthode ETEB est effectivement plus optimale que l'approche standard. Nous avons donc conçu le scénario 5 pour observer cette comparaison. Ce scénario a été répété plusieurs fois en utilisant la méthode TEB jusqu'à ce que nous atteignons un maximum de cinq répétitions sans détecter d'oscillations de la vitesse. Nous avons ensuite exécuté le même scénario cinq fois en utilisant l'ETEB pour une comparaison équitable. Le facteur de charge a été ignoré dans ce scénario. Les résultats montrent que le CEATA a terminé la mission 19 s plus tôt avec l'ETEB, ce qui se traduit par une réduction de la consommation d'énergie de 7.7%.

Le Scénario 6 ressemble étroitement au Scénario 5, avec l'ajout d'une charge. Dans ce Scénario, la charge utilisée est considérée comme la valeur maximale, fixée à 1000 kg. Ce scénario a été tenté trois fois au maximum avec TEB, sans oscillations observables. Par

conséquent, pour maintenir une comparaison cohérente, le scénario a également été réalisé trois fois avec ETEB. Les résultats ont démontré que le CEATA a pu terminer la mission 26 s plus rapidement en utilisant ETEB, conduisant à une diminution de la consommation d'énergie de 11.6%. Les observations issues des Scénarios 5 et 6 indiquent une hausse de performance avec l'augmentation de la masse transportée, et ce, même en absence d'oscillations. Au cumul, le CEATA a mené à bien 48 essais (pour les Scénarios 1 à 6) en 3047 secondes, en consommant 516.4 kJ d'énergie, sans rencontrer de blocage grâce à l'ETEB. En revanche, avec l'utilisation du TEB, le CEATA a parfois été confronté à des blocages et à des oscillations, rallongeant le temps nécessaire pour atteindre le point d'arrivée à 3304 secondes et augmentant la consommation énergétique à 619.3 kJ. Par conséquent, notre méthode proposée a permis au CEATA de compléter l'ensemble de la mission 257 secondes plus rapidement, tout en parvenant à une économie d'énergie significative de 16.6 %.

Les résultats de nos expériences démontrent clairement que la méthode que nous avons proposée est efficace pour diminuer la consommation énergétique des moteurs du CEATA. En outre, l'adoption de l'ETEB a permis d'accélérer l'exécution des missions par le CEATA, ce qui représente un succès notable. Les résultats ont révélé une corrélation notable entre l'accroissement de la masse de charge et l'amélioration proportionnelle de l'efficacité. À mesure que la masse de la charge augmente, l'impact des limites d'accélération devient encore plus prononcée. La méthodologie du TEB, qui néglige les contraintes inhérentes au modèle cinétique du véhicule, a parfois abouti à des trajectoires avec des accélérations qui n'étaient pas optimales et réalisables. Ces trajectoires posaient des problèmes pratiques car elles pourraient conduire à des missions inefficaces et potentiellement infructueuses. À l'inverse, l'ETEB a adapté ses paramètres aux conditions instantanées du CEATA en intégrant des informations en temps réel sur les courants des moteurs, et a ajusté de façon dynamique les limites d'accélération à chaque intervalle de temps.

Malgré l'accroissement de la masse de la charge lors de l'expérience, la méthode ETEB a maintenu la durée de chaque scénario à l'intérieur d'une certaine plage, en contraste avec la méthode TEB. Cela démontre donc la robustesse de notre méthode proposée pour s'adapter aux changements des paramètres d'inertie du CEATA. Cette méthode assure que les accélérations ne sont pas seulement réalisables, mais également optimales en ce qui concerne la



consommation d'énergie et le temps. Dans deux scénarios de l'expérience, où il n'y avait pas d'oscillations, ETEB a surpassé TEB, donnant des résultats supérieurs. Par conséquent, l'intégration de la méthode proposée dans un algorithme de planification de mouvement permet d'obtenir des résultats plus efficace en termes d'énergie par rapport à la méthode standard, indépendamment de la présence d'oscillations. Ainsi, lorsqu'on applique la méthode proposée à n'importe quel algorithme de planification de mouvement, elle assure que les trajectoires résultantes concilient efficacité énergétique et faisabilité en termes de manœuvrabilité. La notable disparité observée dans les résultats de l'expérience met en évidence l'efficacité et la supériorité de la méthode proposée. Cela ouvre une perspective prometteuse pour les recherches futures et les améliorations dans le domaine des véhicules autonomes et de leur gestion d'énergie.

### 6.3 Stabilité et Robustesse

Dans le développement et l'évaluation des planificateurs de mouvement pour véhicules d'occasion, assurer la stabilité de ces systèmes est important. Les vérifications de stabilité sont cruciales car elles déterminent la capacité du système à maintenir ou revenir à un état ou une trajectoire souhaités en présence de perturbations ou d'incertitudes dans l'environnement [115]. Pour les VAIs, qui opèrent dans des environnements dynamiques et parfois imprévisibles, la stabilité assure la sécurité, l'efficacité et la fiabilité. Un planificateur de mouvement stable garantit que le véhicule peut gérer des obstacles inattendus, des variations de terrain et d'autres défis opérationnels sans s'écarter de son chemin prévu ou causer des conditions dangereuses.

Le critère de stabilité entrée-limitée, sortie-limitée (BIBO<sup>1</sup>) est une méthode utilisée pour évaluer la stabilité des systèmes de contrôle [116]. La stabilité BIBO se concentre sur la réponse d'un système à des entrées limitées : si chaque entrée limitée possible conduit à une sortie limitée, le système est considéré comme stable BIBO. Ce concept est particulièrement pertinent dans le contexte de la planification de mouvement, où les entrées dans le système (telles que les commandes pour changer de vitesse ou de direction) doivent résulter en mouvements contrôlés et prévisibles des véhicules. La stabilité BIBO est un outil puissant

---

1. BIBO est l'abréviation de "Bounded-Input, Bounded-Output", en anglais (entrée-limitée, sortie-limitée en français)

car elle fournit une manière simple de garantir que les réponses du système restent dans des limites sûres et opérationnelles sous toutes les conditions attendues.

Dans le contexte des planificateurs de mouvement proposés pour véhicules d'occasion, la stabilité BIBO a été employée pour garantir que les vitesses linéaires et angulaires  $(v,w)$  générées par ces planificateurs conduisent à des mouvements stables et prévisibles. En analysant la réponse du système à diverses entrées dans la plage opérationnelle attendue, il a été possible de vérifier que les vitesses générées restaient toujours dans des limites sûres, confirmant ainsi la stabilité BIBO des planificateurs de mouvement. Cette analyse a impliqué de tester les planificateurs sous différents scénarios et perturbations, garantissant que quelles que soient les entrées, les vitesses de sortie ne dépassaient pas les seuils pouvant conduire à l'instabilité ou à des conditions dangereuses. En prouvant que les planificateurs de mouvement sont stables BIBO, il a été démontré que les véhicules pouvaient suivre de manière fiable leurs chemins prévus et exécuter leurs tâches efficacement, même face à des changements environnementaux inattendus ou à des exigences opérationnelles.

Dans le développement de planificateurs de mouvement pour les VAIs, évaluer la robustesse de ces systèmes est essentiel. La robustesse, dans ce contexte, désigne la capacité des planificateurs de mouvement à fonctionner de manière fiable sous différentes conditions et perturbations, en maintenant leur intégrité opérationnelle sans échec. Cette qualité est cruciale car ces véhicules opèrent souvent dans des environnements dynamiques où ils rencontrent divers obstacles, changements de terrain et interagissent avec des humains et d'autres machines. Un planificateur de mouvement robuste assure que le véhicule peut s'adapter à ces changements, gérer des situations imprévues et continuer à opérer de manière sûre et efficace. Il garantit la constance de performance du système sur un large éventail de scénarios opérationnels, améliorant la fiabilité et la sécurité des VAIs.

Réaliser des Tests d'Opération Continue est une approche méthodologique pour évaluer la robustesse des planificateurs de mouvement proposés dans le domaine robotique [117]. Cette méthode implique de tester les planificateurs de mouvement sur de longues périodes sous diverses conditions pour observer leur performance et identifier tout échec potentiel ou comportements inattendus. Les expériences sur le long terme sont cruciales pour découvrir des problèmes qui peuvent ne pas être apparents lors de tests à court terme, comme la

dégradation graduelle de performance, l'accumulation d'erreurs, ou la réponse du système à des événements rares mais critiques. En exposant les planificateurs de mouvement à des scénarios opérationnels prolongés, il est possible d'évaluer leur endurance et fiabilité de manière complète.

Dans ce travail, la robustesse des planificateurs de mouvement proposés pour deux VAIs a été évaluée en utilisant des Tests d'Opération Continue. Ces expériences étaient conçues pour défier les planificateurs de mouvement avec une gamme de conditions opérationnelles et de perturbations potentielles sur une période étendue. L'objectif était d'observer si les planificateurs montreraient un comportement imprévu ou des modes de défaillance qui pourraient compromettre leur performance ou sécurité. Les résultats de ces expériences étaient très encourageants : aucun comportement imprévu n'a été détecté, indiquant que les planificateurs de mouvement proposés sont robustes. Ce résultat suggère que les planificateurs sont capables de gérer les complexités et incertitudes de l'opération dans le monde réel, assurant que les VAIs peuvent effectuer leurs tâches de manière fiable dans le temps. L'absence de comportement imprévu dans ces expériences à long terme renforce la confiance dans les planificateurs de mouvement proposés, marquant un pas significatif vers leur déploiement réussi dans des applications pratiques.

## **Chapitre 7 - Conclusions et recommandations**

Ce chapitre conclut l'étude en résumant les principaux résultats de ce projet de recherche par rapport aux objectifs et aux questions définies en amont ; et en discutant de la valeur et de la contribution de ces derniers. Ce chapitre présente également plusieurs recommandations pour le développement de ce travail et liste les publications réalisées dans le cadre de cette thèse.

### **7.1 Conclusions**

Le début de l'industrie 4.0 a rendu les VAIs plus importants, révélant comment ils peuvent changer la façon de transporter les charges. Cependant, le déploiement des VAIs est principalement lié à leur gestion de l'énergie et des batteries. La dépendance inhérente de ces véhicules aux moteurs et systèmes de contrôle alimentés par batterie montre l'importance de l'efficacité énergétique. De plus, l'augmentation récente de la demande des VAIs indique un changement dans les préférences de transport qui devrait persister et perturber. Malgré cela, le coût prohibitif des batteries représente un obstacle redoutable à la mise en œuvre globale des VAIs. La fonction principale d'un VAI étant le transport de charges, une augmentation du poids de la charge conduit naturellement à une consommation d'énergie accrue. De plus, les paramètres d'inertie dynamique des VAIs, qui fluctuent en fonction du placement de la charge, peuvent affecter significativement leur consommation d'énergie et leur efficacité. Le fait que l'accélération d'un VAI soit directement impactée par ces paramètres d'inertie dynamique, eux-mêmes influencés par la masse de la charge, implique que des charges plus lourdes nécessitent une entrée d'énergie proportionnellement plus élevée pour l'accélération du VAI.

Notre recherche a conduit au développement de modèles cinétiques pour les VAIs, en tenant compte des variations des paramètres d'inertie dynamique et des limitations de mouvement. En utilisant les capacités de DNN, nous avons pu identifier efficacement en ligne les paramètres dynamiques nécessaires, augmentant ainsi la précision et la fiabilité de la représentation du comportement des VAIs. De plus, nous avons proposé un algorithme de planification de mouvement éco-énergétique qui utilise l'identification basée sur DNN des paramètres dynamiques. Cet algorithme optimise la consommation d'énergie et encourage les pratiques de transport durables. Dans le cadre de notre méthodologie, nous avons utilisé le MLP comme technique DNN et nous avons examiné le raffinement du DWA et du TEB grâce à notre méthode proposée. Pour les RMAED, le modèle DNN a amélioré le DWA (EDWA), en particulier par l'identification du CoM. Pour les CEATA, nous avons affiné le TEB (ETEB) en utilisant le modèle DNN pour établir des limites optimales d'accélération permise. Ces améliorations ont entraîné d'importantes économies d'énergie : une réduction de 9,25% de la consommation d'énergie pour les RMAED utilisant l'EDWA par rapport au DWA standard, et une réduction de 16,6% pour les CEATA utilisant l'ETEB par rapport au TEB conventionnel.

Notre approche se distingue des études similaires par son intégration des contraintes dynamiques, plutôt que de se baser uniquement sur les contraintes cinématiques des robots. Cette méthodologie offre donc un cadre précieux pour le développement d'algorithmes de planification de mouvement destinés à des missions en temps réel. L'objectif ultime est d'équiper le planificateur de mouvement avec la capacité de déterminer des trajectoires éco-énergétiques en prenant en compte les paramètres dynamiques identifiés par les modèles DNN. Bien que les VAIs de notre étude n'aient fonctionné que pendant une courte période, les systèmes similaires utilisés dans l'industrie et les entrepôts sont conçus pour fonctionner beaucoup plus longtemps avec une seule charge de batterie. Ainsi, notre méthode proposée est susceptible de réduire considérablement la consommation d'énergie totale d'un VAI pendant une journée de travail moyenne.

## **7.2 Recommandations**

Cette thèse constitue une avancée innovante dans la recherche sur la planification de mouvements énergétiquement efficace pour les VAIs. Cependant, une compréhension plus

approfondie des résultats et des effets de cette thèse sur les hypothèses proposées nécessite d'aborder des scénarios allant au-delà de nos hypothèses initiales. Ceci est crucial pour la mise en œuvre pratique de l'approche de planification de mouvement suggérée.

- **Modèle cinétique tridimensionnel (3D) :** Le développement d'un modèle cinétique 3D est une suggestion intéressante pour les recherches futures. Étant donné que les VAIs sont conçus pour transporter des charges, le CoM est susceptible de se déplacer le long de l'axe  $z$  du corps du véhicule. Ce réglage peut influencer l'énergie requise et l'accélération du VAI lors d'un mouvement rotatif. Dans cette étude, le modèle dynamique utilisé était de nature 2D, limitant ainsi sa capacité à prendre en compte les modifications du CoM le long de l'axe  $z$ . Par conséquent, ce modèle 2D ne peut pas inclure pleinement la dynamique d'un VAI, en particulier lorsqu'il y a des modifications du CoM sur les trois axes du corps du véhicule. Par conséquent, le développement d'un modèle cinétique 3D pourrait offrir une représentation plus complète et précise de la dynamique d'un VAI, notamment dans des scénarios impliquant des variations du CoM sur les trois axes du corps.

- **Identification de la masse et du Mdi :**

Dans des situations où un VAI est chargé d'effectuer des mouvements rotationnels avec une charge lourde et longue, l'impact du moment d'inertie devient particulièrement notable. Bien que cette étude cherche à identifier des mouvements éco-énergétiques en tenant compte du CoM et des limites d'accélération, il est important de souligner que la masse et le moment d'inertie peuvent être utilisés pour améliorer davantage l'efficacité énergétique du mouvement une fois qu'ils ont été identifiés. Les recherches futures pourraient se concentrer sur l'intégration de ces facteurs dans les étapes de planification et d'exploitation de l'utilisation des VAIs. En procédant ainsi, il serait possible d'optimiser l'efficacité énergétique sans compromettre la capacité de transport de charge du VAI. Cela pourrait à son tour faciliter l'exécution de tâches plus complexes et prolonger la durée de fonctionnement du VAI sur une seule charge de batterie, contribuant ainsi à des opérations plus durables et rentables.

- **Géométrie des obstacles :**

Cette recherche a introduit le concept de l'EDWA pour les RMAED, qui identifie la trajectoire globale optimale pour éviter les obstacles en atteignant le vecteur optimal des trajectoires locales tout en tenant compte du CoM. Plus précisément, il détermine le meilleur côté pour contourner un obstacle (gauche ou droit) en considérant le CoM. Cette approche calcule uniquement l'énergie requise en se basant sur le côté avant de l'obstacle, en supposant que les côtés gauche et droit de l'obstacle soient identiques. Cependant, dans des scénarios réels, les obstacles peuvent avoir des géométries asymétriques, ce qui rend difficile pour le planificateur de mouvement de prévoir le côté le plus éco-énergétique pour naviguer autour de l'obstacle. Dans de telles situations, l'application des algorithmes d'IA à la vision par ordinateur, en particulier les méthodes de classification, pourrait être essentielle. Ces techniques d'IA peuvent prédire le type de géométrie de l'obstacle, aidant ainsi le planificateur de mouvement à déterminer le côté le plus éco-énergétique pour contourner les obstacles. L'intégration de la géométrie de l'obstacle dans le processus de planification de mouvement pourrait aboutir à des trajectoires plus affinées, précises et éco-énergétiques, optimisant ainsi la performance globale du VAI dans divers environnements opérationnels.

- **Obstacles imprévus lors de la manœuvre de stationnement :**

La création de l'ETEB pour les CEATA constitue une contribution majeure à cette recherche. Dans des scénarios réels, ces formes autonomes doivent exécuter des tâches complexes telles que les manœuvres de stationnement. Ces manœuvres sont souvent délicates en raison de la nécessité d'un contrôle et d'une navigation précis dans des espaces restreints. Nos tests expérimentaux ont inclus des manœuvres de stationnement pour comparer la consommation d'énergie des CEATA, fournissant des informations précieuses sur leur efficacité dans de telles circonstances. Cependant, l'apparition potentielle d'obstacles imprévisibles lors de ces manœuvres est un aspect qui introduit une couche de complexité. Ces obstacles peuvent significativement modifier la précision de la navigation, nécessitant une adaptation en temps réel et un contrôle réactif. Les obstacles imprévus lors des manœuvres de stationnement représentent un défi considérable

car ils obligent les CEATA à modifier brusquement leur trajectoire prévue. Ces modifications abruptes de trajectoire peuvent, à leur tour, entraîner d'importants changements dans les modèles de consommation d'énergie, ce qui pourrait compromettre l'efficacité énergétique globale obtenue par la méthode ETEB.

Ainsi, il est clairement nécessaire que les recherches futures se concentrent sur les performances de la méthode ETEB dans ces circonstances imprévisibles. Comprendre comment le système réagit et s'adapte à des changements environnementaux soudains est essentiel pour affiner davantage les capacités prédictives du modèle. Cela pourrait impliquer le développement d'algorithmes d'IA avancés capables d'identifier et de catégoriser efficacement les nouveaux obstacles, permettant au CEATA d'ajuster dynamiquement sa planification de mouvement en temps réel. De plus, d'autres investigations pourraient révéler des opportunités d'optimiser l'approche ETEB, peut-être en incorporant des paramètres ou des considérations supplémentaires pour gérer plus efficacement les obstacles inattendus. Cela pourrait conduire au développement de CEATA qui sont non seulement plus robustes et adaptables face aux obstacles imprévus, mais conservent également leur efficacité énergétique, même dans ces conditions difficiles.

- **Obstacles dynamiques :**

L'étude actuelle se concentre principalement sur les obstacles statiques pour évaluer l'efficacité de l'EDWA Afin d' les RMAED. Cependant, le paysage industriel, en particulier dans le contexte des usines intelligentes, peut souvent présenter des obstacles dynamiques qui sont en mouvement constant et peuvent changer de position au fil du temps. Les obstacles dynamiques introduisent un niveau de complexité et d'incertitude différent dans le fonctionnement des VAIs. Ils nécessitent des stratégies de détection, de suivi, et d'évitement en temps réel qui sont plus avancées que celles requises pour les obstacles statiques. De plus, les implications énergétiques de la manœuvre autour des obstacles dynamiques peuvent être sensiblement différentes, ce qui pourrait affecter l'efficacité énergétique globale des RMAED.

Compte tenu de ces considérations, les recherches futures devraient étendre le travail actuel en intégrant les obstacles dynamiques dans l'investigation de l'EDWA pour les



RMAED. Cela impliquerait de concevoir des scénarios expérimentaux qui émulent les conditions difficiles et en constante évolution d'une usine intelligente, et d'étudier l'impact de ces conditions sur l'efficacité énergétique de la planification de mouvement proposée. Une telle recherche ne validerait pas seulement la robustesse de l'EDWA dans des environnements plus complexes, mais pourrait également révéler des opportunités pour d'autres affinements et optimisations. En conséquence, Il pourrait en résulter des VAIs plus efficaces et plus polyvalents, qui peuvent naviguer facilement dans divers contextes industriels.

### 7.3 Publications

Les contributions et résultats de cette thèse ont été diffusés à travers les articles journaux publiés suivants.

1. Mohammadpour, M., Kelouwani, S., Gaudreau, M.-A., Zeghmi, L., Amamou, A., Bahmanabadi, H., Allani, B., & Graba, M. Optimal charging scheduling for Indoor Autonomous Vehicles : a hybrid approach using Branch-and-Bound and Deep Neural Networks ; Under review. *Expert Systems with Applications*, (2023).
2. Mohammadpour, M., Kelouwani, S., Gaudreau, M.-A., Zeghmi, L., Amamou, A., Bahmanabadi, H., Allani, B., & Graba, M. (2023). Energy-efficient motion planning of an autonomous forklift using deep neural networks and kinetic model. *Expert Systems with Applications*, 237, 121623 (2023).
3. Mohammadpour, M., Kelouwani, S., Gaudreau, M.-A., Allani, B., Zeghmi, L., Amamou, A., & Graba, M. Energy-efficient local path planning of a self-guided vehicle by considering the load position. *IEEE Access*, IF : 3.9, 10, 112669–112685 (2022).
4. Mohammadpour, M., Zeghmi, L., Kelouwani, S., Gaudreau, M.-A., Amamou, A., & Graba, M. An investigation into the energy-efficient motion of autonomous wheeled mobile robots. *Energies*, IF : 3.2, 14(12), 3517 (2021).
5. Mohammadpour, M., Kelouwani, S., Gaudreau, M.-A., Zeghmi, L., Amamou, A., Bahmanabadi, H., Allani, B., & Graba, M. Next-generation energy optimal motion

planning for Self-Guided Vehicles accounting for loads' positions : adapting to dynamic environments ; Under submission to IEEE Transactions on Industrial Electronics, (2024).

## Chapitre 8 - Annexe

### .1 Modèle de batterie

Dans cette étude, un pack de batteries au lithium d'une capacité de 40 Ah est utilisé comme unité de stockage d'énergie. L'Eq. 1a représente la tension à circuit ouvert et l'Eq. 1b représente la résistance interne.

$$U_{ocv} = nU_1 \quad (1a)$$

$$R_{bat} = nR_1 \quad (1b)$$

Où  $U_{ocv}(V)$  est la tension à circuit ouvert du pack de batteries,  $n$  est le nombre de cellules en série,  $U_1(V)$  est la tension à circuit ouvert de la cellule,  $R_{bat}(\Omega)$  est la résistance interne du pack de batteries et  $R_1(\Omega)$  est la résistance interne de la cellule unique.

Ce travail utilise le modèle RINT, qui est montré dans l'Eq.(3)

$$U_{FCHAMR} = U_{ocv} - R_{bat}I_{bat} \quad (2)$$

Par conséquent, l'expression du courant de la batterie est la suivante :

$$I_{bat} = \frac{U_{ocv} - \sqrt{U_{ocv}^2 - 4R_{bat}P_{bat}}}{2R_{bat}} \quad (3)$$

L'expression de la *Profondeur de Décharge (PdD)* de la batterie est la suivante :

$$PdD(t+1) = 1 - \left( SoC(t) - \frac{I_{bat}(T)\Delta t}{Q_{bat}} \right) \quad (4)$$

Où  $SoC(t)$ ,  $P_{bat}(W)$ ,  $\Delta T(s)$ ,  $Q_{bat}(Ah)$  sont respectivement l'état de charge de la batterie, la puissance de la batterie, l'intervalle d'échantillonnage et la capacité nominale de la batterie.

## **.2 Articles de journaux publiés**

### *.2.1 L'article 1*

Review

# An Investigation into the Energy-Efficient Motion of Autonomous Wheeled Mobile Robots

Mohammad Mohammadpour <sup>1,\*</sup>, Lotfi Zeghmi <sup>2</sup>, Souso Kelouwani <sup>1</sup>, Marc-André Gaudreau <sup>1</sup>, Ali Amamou <sup>2</sup>   
and Massinissa Graba <sup>2</sup> 

<sup>1</sup> Department of Mechanical Engineering, University of Quebec at Trois-Rivieres, Trois-Rivieres, QC G8Z 4M3, Canada; souso.kelouwani@uqtr.ca (S.K.); marc-andre.gaudreau@uqtr.ca (M.-A.G.)

<sup>2</sup> Department of Electrical and Computer Engineering, University of Quebec at Trois-Rivieres, Trois-Rivieres, QC G8Z 4M3, Canada; lotfi.zeghmi@uqtr.ca (L.Z.); ali.amamou@uqtr.ca (A.A.); massinissa.graba@uqtr.ca (M.G.)

\* Correspondence: mohammad.mohammadpour@uqtr.ca

**Abstract:** In recent years, the use of electric Autonomous Wheeled Mobile Robots (AWMRs) has dramatically increased in transport of the production chain. Generally, AWMRs must operate for several hours on a single battery charge. Since the energy density of the battery is limited, energy efficiency becomes a key element in improving material transportation performance during the manufacturing process. However, energy consumption is influenced by the navigation stages, because the type of motion necessary for the AWMR to perform during a mission is totally defined by these stages. Therefore, this paper analyzes methods of energy efficiency that have been studied recently for AWMR navigation stages. The selected publications are classified into planning and motion control categories in order to identify research gaps. Unlike other similar studies, this work focuses on these methods with respect to their implications for the energy consumption of AWMRs. In addition, by using an industrial Self-Guided Vehicle (SGV), we illustrate the direct influence of the motion planning stage on global energy consumption by means of several simulations and experiments. The results indicate that the reaction of the SGV in response to unforeseen obstacles can affect the amount of energy consumed. Hence, energy constraints must be considered when developing the motion planning of AWMRs.

**Keywords:** navigation; motion planning; dynamic; energy efficiency; autonomous wheeled mobile robots; self-guided vehicles



**Citation:** Mohammadpour, M.; Zeghmi, L.; Kelouwani, S.; Gaudreau, M.-A.; Amamou, A.; Graba, M. An Investigation into the Energy-Efficient Motion of Autonomous Wheeled Mobile Robots. *Energies* **2021**, *14*, 3517. <https://doi.org/10.3390/en14123517>

Academic Editor:  
Pedro Roncero-Sanche

Received: 22 May 2021  
Accepted: 10 June 2021  
Published: 13 June 2021

**Publisher's Note:** MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



**Copyright:** © 2021 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

## 1. Introduction

Robots are intelligent machines that sense, process, communicate, and perform multiple tasks through preprogramming. Therefore, they are replacing humans in different activities, such as human-centered intelligent robots, which cover all robot capabilities [1]. Moreover, robots are capable of operating in various environments, including in ground, air, water, and underwater surroundings [2]. Autonomous Wheeled Mobile Robots (AWMRs) are ground vehicles that make their own decisions and perform actions without operator intervention. Nowadays, the number of AWMR is significantly increasing, since they are crucial to different applications in both industry and for service providers [3]. These applications are performed in both indoor and outdoor environments and include activities such as object transportation [4] and power substation inspection [5]. In addition, they are very popular because of their ability to operate appropriately in applications with low mechanical complexity [6]. Nowadays, robotics and automation technologies are becoming more accessible, and can be helpful even in small and medium industries. Moreover, the fourth industrial revolution is aiming for autonomous production methods [7]. Therefore, usage of AWMR will increase, since they can move freely in static or dynamic environments. However, they need to operate for long periods of time on a single battery charge with

heavy payloads. Additionally, charging the battery pack requires several minutes or even hours, reducing their availability to perform missions. Recent studies on improvements to AWMR energy efficiency and consumption can be categorized in terms of whether they are related to software or hardware aspects. Although several advances have been reported regarding hardware improvements, only a few works have attempted to carry out studies on the software aspect. For instance, an AWMR can be designed to generate an energy-efficient path [8], perform more tasks in consideration of its remaining energy [9], and estimate important uncertainty parameters that can affect energy consumption [10].

Navigation is the main component of AWMR software. It is used to generate acceptable, safe, and smooth motion in accordance with a given mission. It guides the AWMR from a starting point to a goal point by following a path, avoiding obstacles, and using a multivariable cost function [11]. Carabin et al. [12] reviewed several papers related to energy optimization methods. However, they did not consider AWMRs, and only arm robots and automatic systems were discussed. Moreover, papers related to navigation techniques have been investigated comprehensively [11,13,14]. However, this article specifically surveys the latest papers considering energy as the main constraint of navigation stages and studying the effects of navigation stages on AWMRs' total energy consumption. In this work, the selected publications are classified into planning and motion control stages.

The remainder of this article is organized as follows. The second section presents a review of papers about energy efficiency and the reduction of energy consumption in the navigation stages of AWMRs. The third section describes simulations and experiments related to motion planning for Self-Guided Vehicles (SGVs). The fourth section proposes solutions for achieving energy-efficient motion. The fifth section discusses the importance of the effect of energy consumption on the obstacle avoidance problem, and this is followed by a conclusion.

## 2. Energy Efficiency in Navigation Stages: A Review

AWMRs can be classified into different categories. Depending on the motion constraints, AWMRs are divided into holonomic and nonholonomic platforms. Nonholonomic motion has some limitations with respect to moving in any direction, because the number of controller inputs is less than the dimensions of the configuration space. Sometimes, the AWMR is considered to be a particle in order to simplify the design of algorithms that are independent of the AWMR's motion constraints. With respect to the drive mode, AWMRs can be divided into differential, bicycle, tricycle, car, synchronous, omnidirectional, and tracked vehicles [2].

In most reported papers, the AWMR navigation module has five main stages, as shown in Figure 1. The process starts with perception and continues through to the motion control as the last stage for performing proper actions. However, the data flow (from sensors) can be a little different depending on the AWMR environment (indoor or outdoor) or the mission. The perception stage determines the essential information of the robot's surroundings that is necessary to perform a motion behavior. Sensors are indispensable components that allow the AWMR to perceive its environment.

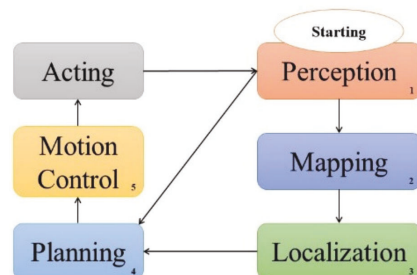


Figure 1. Flow diagram of the stages of the AWMR navigation process.

The effects of processing and sensing energy consumption were surveyed in [15]. Although this stage can influence energy consumption, it has not been studied deeply. For instance, the AWMR may not need to use all of its sensors at the same time. It can apply different sensors with in accordance with the required precision of the perception stage and switch between them at suitable times [16]. After the robot has discovered its surrounding area, the mapping stage models the environment. In other words, it integrates the information collected using the sensors into a representation. Consequently, the localization stage determines the location of the AWMR. Although both stages are vital during missions, they have a low impact on energy consumption. However, using suitable algorithms can decrease processor loads. Planning and motion control are stages that directly affect motion. Hence, they are comprehensively defined in the following sections. Moreover, the authors classify recent papers regarding energy in navigation stages into planning and motion control stages in order to identify research gaps.

### 2.1. Planning

After the AWMR's position in an environment has been located, the planning stage generates an appropriate path and motion in consideration of a variety of criteria. Based on the prior information related to the environment, the planning stage can be classified into two categories: global path planning and local path planning. Several comprehensive reviews on planning methods and algorithms have been reported [17–19].

#### 2.1.1. Global Path Planning

Global path planning generates the whole path from the start to the goal point. Environmental information such as free spaces and obstacles is contained in the map, so global planning can be performed offline. Additionally, global planning considers the geometric characteristics of static obstacles in order to plan an appropriate path [20]. The most widely reported path search methods for global planning are A\*, D\*, and artificial intelligence algorithms [17]. Designing a global path in consideration of the energy source level is important [21]. The modified Newton algorithm was used by Duleba and Sasiadek [22] for nonholonomic energy-efficient path planning. This method assumed that the robot consumed less energy by finding the shortest path from a given location to a targeted position. However, the method was not able to accurately predict the amount of energy consumed from the battery, and it is well known that a number of different parameters can lead a short path to consume excessive energy. Changes in rolling resistance and density of obstacles are among such parameters.

Exploration missions can take a long time, and thus energy efficiency is a key aspect in successfully covering a wide area. Mei et al. [23] studied an approach to minimize energy consumption during the exploration of known and unknown environments. The method used was orientation-based target selection, which means that subsequent missions were selected depending on the robot's orientation. In addition, the path from the current position of the robot to the next target was designed in order to avoid repeated target coverage. Benkrid et al. [24] proposed energy-efficient exploration with multi-robot coordination in unknown environments. This method considered three criteria when calculating each robot's motion energy consumption: (i) energy needed for traveling between two goal points, (ii) stopping, and (iii) turning at determined states. In accordance with the given constraints, each robot selected an appropriate path in order to explore the environment. Wang et al. [25] designed a path planning method that took into consideration the robot's remaining energy in order to be sure that the robot would be able to perform the mission and return to the recharging station.

Liu and Sun [26] studied an optimal path planning method for a two-wheel differentially driven robot. The method used the A\* global path planner. Furthermore, they considered a cost function in order to obtain the most energy-efficient path. Additionally, the cubic Bezier curve was used to smooth the generated path. They improved the designed method by creating an energy consumption model [27]. The Dubins method, which refers

to the shortest curve connecting two points, was used for a two-wheeled differential drive robot [28]. The study initially used the same method as Liu and Sun [29] to generate a global path. Subsequently, sharp turns were considered as waypoints. Finally, the Dubins method was used to smooth the sharp turns. Moreover, kinetic energy was used to develop the robot energy model.

Combining the A\* algorithm with an energy-related cost function, the work reported in [30] defined a heuristic function for a three-wheeled omnidirectional mobile robot. An energy consumption model was developed based on [29,31] that included kinetic energy and friction as the main energy losses. The energy criteria were based on previous robot orientation to pass the nodes towards the next goal. After a suitable path had been found, the optimal  $\eta^3$ -Spline parameters were used to create a smoother path. To decrease the travel time between waypoints, the method found the optimal velocity profile at the motion control stage by using sequential quadratic optimization. Valero et al. [32] proposed a time-efficient global path planning in known environments with static obstacles for a car-like mobile robot. The optimization problem was solved using quadratic sequential optimization techniques. Furthermore, the influence of energy consumption on the defined path was evaluated. Sathiya et al. [33] used evolutionary algorithms to generate a multi-objective optimal path for a Wheeled Mobile Robot (WMR). An elitist non-dominated sorting genetic algorithm and heterogeneous multi-objective differential evolution were applied. The algorithms helped to find trajectories with minimum traveling time and actuator effort in terms of two criteria for the global optimization functions.

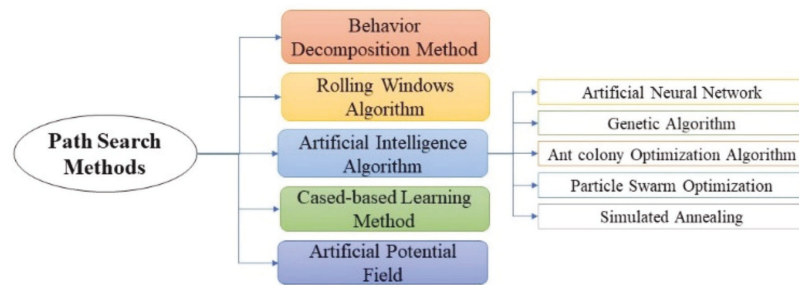
The terrain in outdoor environments severely influence robot energy consumption because of frequent inclination changes and bad soil-wheel friction. The problem of finding the optimal energy path for robots traversing steep terrains has been surveyed [34]. Some inclination angles require a lot of power, and thus the robot is not able to generate enough energy to pass the terrain. Ganganath et al. discussed energy-efficient global path planning on uneven terrains in outdoor environments. They proposed a Z\* heuristic search algorithm with an energy cost function while taking physical constraints into consideration [35]. This method generated zigzag paths in order to overcome impermissible traversal headings. In addition, they designed the Constraints Satisfying A\* (CSA\*) search algorithm to find the shortest path in consideration of the energy constraints implied by uneven terrains [36]. Energy-efficient path planning for Skid-steered Autonomous Ground Vehicles (SAGV) was surveyed by Sharma et al. [37]. SAGV wheels are fixed in a straight line relative to the body of the machine, so they do not have a steering mechanism [38]. A Sampling-Based Model Predictive Optimization (SBMPO) scheme [39] was suggested to estimate the energy requirements during the path planning process. Chuy et al. applied the energy model of the vehicle to a single surface that was dependent on the linear velocity and turning radius terms [40]. Pentzer et al. [41] developed the most recent method for addressing multiple surface types by using the kinematic model of a SAGV to estimate energy usage.

None of the above studies addressed explicit energy measurements. Furthermore, most of them did not assume the robot to possess a perfect energy model. For realistic path planning with energy constraints, a deep understanding of the correct estimation of energy consumption is mandatory. In addition, none of these studies reported the impact of energy consumption on the kino-dynamic performance of the robot.

### 2.1.2. Motion Planning

Local path planning, also called motion planning [20], generates an online trajectory. It defines trajectory segments along the path generated by the global planner. In addition, it considers the kinematic and dynamic constraints of the AWMR, as well as sudden changes in nearby areas, like obstacles. The type of robot reaction when facing an obstacle can enormously influence energy consumption. Figure 2 presents the classification of important path search methods for motion planning [17].





**Figure 2.** Path search methods in the motion planning stage.

Since static and dynamic obstacles can populate the navigation environment, the selection of an appropriate obstacle avoidance function is essential in motion planning. In addition, most global planners are unable to take into account dynamic or unforeseen obstacles during the trajectory global planning stage. Therefore, the motion planning module must determine a collision-free path in real-time. Mei et al. [42] studied an energy-efficient motion planning method for a three-wheeled omnidirectional mobile robot. The robot's task was to automatically clean the floor in an open area without obstacles. The energy model was built using a six-degree fitting function on the basis of experimental velocity data and only considering the kinematic model. The method was proposed for a specific type of robot, and could not be used for other types. Estimation and prediction rules can help robots to achieve appropriate obstacle avoidance reactions. Llamazares et al. [43] proposed an Approximate Inference Control framework (AIC) based on an energy consumption model for planning local paths. The model was based on overcoming inertia, road grade, tire friction, and aerodynamic loss. The AICO displayed an improvement in energy efficiency of more than 10% compared to the best results obtained using the classic algorithms. However, the assumption of the robot's linear speed may not be practical, because the robot must perform various actions in real missions.

In [44], the Dynamic Window Approach (DWA) was combined with a cost function based on energy consumption. An omnidirectional robot was considered in a partially dynamic environment. The energy consumption model was based on the model introduced in [29], which was improved by including electrical, frictional, and acceleration energy. The proposed method was modified by defining a new energy model and representing a new cost objective in order to reduce power consumption [45]. Alajlan et al. [46] proposed the use of a multi-sensor method for a WMR. To this end, infrared reflective sensors were applied for edge detection, and infrared measuring sensors, an ultrasonic sensor, and a camera were applied for obstacle detection, creating an integrated framework. Moreover, the constraints included energy consumption, time, and distance traveled. The generation of the shortest and most energy-efficient trajectory was the main criterion of the objective function that was used to avoid collision. During a mission, the method evaluated several possible trajectories and selected the least costly one.

This section examined recently published paper on planning that are related to energy. Table 1 provides a detailed analysis of the surveyed papers. The letters 'N' and 'Y' stand for "no" and "yes", respectively. Additionally, Table 1 describes each paper on the basis of whether static or dynamic obstacles were used, whether experiments were conducted along with simulations, whether an energy model was defined, and the type of AWMR used. Furthermore, it briefly explains the methods used. Although various methods have been developed to optimize global path planning, very few papers have used them to consider the constraint of energy efficiency. The motion planning aspect includes both kinematic and kinetic constraints. Accordingly, it has an enormous effect on energy consumption. However, there are few papers in the literature that address local path planning while taking energy consumption into consideration. In addition, an effective energy model should include proper planning that takes the energy efficiency into account. The surveyed papers have partially defined the AWMR energy model, but none has considered all of

the uncertainty parameters, or all of the geometric, kinematic, and dynamic constraints. A more precise energy model could assist with the generation of an appropriate energy efficiency path. The steps to define energy-efficient motion should result in:

1. The creation of an energy consumption model (ECM) that includes the uncertainty parameters, as well as the geometric, kinematic, and kinetic constraints, of AWMRs.
2. The definition of a cost function on the basis of the energy criteria and with respect to the ECM.
3. The execution of the path and trajectory in accordance with the defined cost function.

**Table 1.** Overview of papers on planning related to energy, with a summary of the methods used.

Paper	Static Obstacles	Dynamic Obstacles	Real-Time Experiment	Defining New Energy Model	AWMR Type	Method
[22]	N	N	N	N	Nonholonomic	Newton algorithm
[23]	Y	N	N	N	Particle	Decreasing the trajectories
[24]	Y	N	Y	Y	Nonholonomic	Using multi-robot coordination for exploration
[25]	N	N	Y	Y	Particle	Tabu-search-based
[26]	Y	N	Y	Y	Nonholonomic	Adding energy constraint to A* planner
[27]	Y	N	Y	Y	Nonholonomic	Adding energy constraint to A* planner
[28]	Y	N	Y	Y	Nonholonomic	Adding energy constraint to A* planner
[29]	Y	N	N	Y	Nonholonomic	Dubins method
[30]	Y	N	N	N	Holonomic	Integrating heuristic function to A* planner
[32]	Y	N	Y	N	Nonholonomic	Using optimization algorithm
[33]	Y	Y	N	Y	Nonholonomic	Using evolutionary algorithms
[35]	N	N	Y	N	Nonholonomic	Using zigzag-like path patterns
[36]	N	N	N	N	Particle	Integrating energy cost to A* planner
[37]	Y	N	N	Y	Nonholonomic	Using sampling-based model predictive optimization
[41]	N	N	Y	Y	Nonholonomic	Using sampling-based model predictive optimization
[42]	N	N	Y	Y	Holonomic	Using the six-degree polynomial for the energy cost function
[43]	Y	Y	Y	Y	Nonholonomic	Using approximate inference control framework
[44]	Y	Y	Y	N	Holonomic	Adding energy cost to DWA
[45]	Y	Y	Y	Y	Holonomic	Adding energy cost to DWA
[46]	Y	Y	Y	N	Nonholonomic	Multi-sensor path planning

## 2.2. Motion Control

Motion control is the last stage of the navigation process. It executes the correct velocity, acceleration, and torque required to follow the path and trajectory that were generated during the planning stage. It moves the robot in a controlled manner. The trajectory of the executed velocity and acceleration in the motors has a direct effect on energy consumption. Barili used a constant acceleration rate and limited frequent velocity changes in order to reduce power consumption [47]. However, the method assumed that

motion took place in straight lines and ignored the power consumption required by angular velocity changes. Brateman et al. [48] proposed an energy-saving method by scheduling motor speed and the processor frequency while preventing collisions. This approach was extended in [49] by generating a schedule by means of a genetic algorithm. Kim et al. [50] suggested three steps for the velocity control of efficient binary search algorithms for the WMR. The method considered the dissipation of practical energy demand in motors. They proposed optimal control theory to obtain optimal an velocity trajectory for a differential-driven WMR with a fixed total time of travel [51]. The cost function was the actual energy consumption of batteries, including motor armature resistance loss, kinetic energy, and viscous friction. However, rotational velocity was ignored, and only translational velocity changes on a straight-line path were considered. In fact, these assumptions limit the applicability of this method.

They continued their study on translational trajectory planning of three-wheeled omnidirectional mobile robots (TOMR) [52]. They surveyed both translational and rotational velocity trajectory planning for TOMR [53]. The algorithm was based on a dynamic model of the robot. The minimum energy rotational velocity trajectory was founded using Pontryagin's minimum principle. Furthermore, the minimum energy translational velocity trajectory was obtained using a novel algorithm based on the linearity condition of the state transition of TOMR. In [54], the authors proposed a method that considered a trajectory that expressed a curved-line path with the self-rotation motion of the robot. The paper developed a dynamic simulation using dynamic actuators. Tokekar et al. [55] studied a forward-only car-like robot, powered by direct current (DC) motors in a flat, obstacle-free environment. The problem of obtaining energy-efficient velocity profiles with/without limitations with respect to maximum velocity was studied for a given path. Consequently, they proposed an extended method in which the problems of achieving an energy-efficient path and velocity profiles were studied simultaneously using a discretized graph search algorithm [56].

Designing a trajectory tracking controller is challenging because of the dynamic impacts of the inertia and actuators of a mobile robot on acquiring the appropriate linear and angular velocities. In [57], a Model Predictive Control (MPC) method was used for the bicycle drive model of car-like robots. Firstly, a trajectory tracking MPC controller was designed using a nonlinear control law. Secondly, the cost function of energy consumption due to electric propulsion was used to find an energy-efficient trajectory. Wang et al. [58] designed a feedback controller to optimize predefined path tracking by considering energy efficiency for an indoor carrier robot. They developed a new dynamic model by using the dynamics of the actuator along with kinematic models of an omnidirectional robot.

The authors in [59] proposed energy-optimal path planning for tracking a moving target using a four-wheeled holonomic vehicle. The analytical simulation was performed in an environment with static obstacles, and the target possessed predictive linear motion. The artificial potential method (APF) and optimal control theory were used for path planning and energy-efficient motion, respectively. H. Kang et al. [60] discussed dynamics-based control methods in order to obtain energy-optimal trajectories between two endpoints. Their method used analytical mechanics to combine the contact kinematic between the wheels and the ground. In addition, it analyzed the robot dynamics with the assistance of the Gibbs-Apple method to create motion equations. Once the motion equations were known, two different techniques (servo constrained-based and differential flatness-based) were used to generate the input for tracking control. Serralheiro and Maruyama [61,62] obtained the optimal velocity trajectory for a nonholonomic robot by considering time efficiency as well as energy efficiency. Therefore, the method established a relation between the total energy optimization and traversal time by generating a penalty coefficient. Additionally, a convex optimization was applied instead of a nonlinear one to estimate suitable traversal time and total energy.

Table 2 provides an overview of papers on motion control related to energy. It describes each paper on the basis of experimental validation, energy model consideration, and the

algorithms used. Linear optimal control algorithms and simple controllers were mostly used for energy efficiency problems. However, none were able to address goals regarding AWMR uncertainty parameters such as mass, center of mass, and moment of inertia. This condition necessitates other control methods such as robust [63], adaptive [64], and fuzzy control [65] in order to be able to consider time-varying parameters.

**Table 2.** Overview of papers on motion control related to energy with a summary of the methods used.

Paper	Experiment	Energy Model	Method
[47]	Y	N	Clogging frequent velocity changes
[48]	Y	N	Scheduling motor speed and processor frequency
[49]	Y	N	Modifying [38] with genetic algorithms
[50]	N	Y	Three-step velocity control
[51]	Y	Y	Using optimal control theory to achieve optimal velocity trajectory
[52]	N	Y	Using optimal control theory to achieve optimal velocity trajectory
[53]	Y	Y	Combining Pontryagin's minimum principle and a novel algorithm to determine the velocity trajectory
[54]	Y	Y	Combining Pontryagin's minimum principle and a novel algorithm to determine cornering trajectory planning
[55]	Y	Y	Using dynamic programming method to obtain velocity profile
[56]	Y	Y	Using discretized graph search algorithm to find velocity profile
[57]	N	N	Using a Model Predictive Control for trajectory tracking
[58]	Y	Y	Using a Robust Feedback Controller for trajectory tracking
[59]	N	N	Using Pontryagin's minimum principle for target tracking
[60]	N	N	Using optimization algorithm based on the Ritz approximation
[62]	N	N	Convex optimization tools

### 3. Effect of Motion Planning on Energy Consumption

Among the navigation stages, motion planning is able to directly affect energy consumption, depending on the performed motion primitives. Following the global path while also avoiding unforeseen obstacles is the main task of this stage. To avoid a collision, several strategies can be employed. For instance, the robot can stop until the path is obstacle-free and then again start the movement, or it can change its path in various ways. The selection of each maneuver can change the velocity profile, the travel distance, etc. We study the obstacle avoidance problem to show the effect of the local motion planning stage on energy consumption. For this purpose, some simulations and experiments were performed using the DWA method and a manual control strategy. The goal is not to compare the two methods, but to understand and further highlight the role of motion planners in energy consumption. In the DWA approach, the platform is autonomously controlled by the machine (navigation module), while in the manual control mode, a human controls the platform motion to follow the trajectory that was generated by the global planner. In addition, a Self-Guided Vehicle (SGV) was selected to perform the simulations and experiments. Depending on the autonomy level in industrial robots, SGV is an improved model of an autonomous guided vehicle (AGV) because it has the ability to respond to changes in the mission's environment such as unforeseen obstacles [21,66].

#### 3.1. Dynamic Window Approach (DWA): An Overview

DWA is a well-known collision avoidance navigation algorithm that was proposed by Dieter Fox et al. [67]. Furthermore, DWA is an online reactive method, and its cost function has been extended several times in recent years [68,69]. To select safe and optimal translational ( $v$ ) and rotational ( $w$ ) velocities, the method directly generates their profiles by considering the dynamics of the robot and the range limitation of the velocity and acceleration. The main search space for suitable velocities is intersected by three subspaces:

the space of possible velocities in accordance with the robot kinematic constraints,  $V_s$ ; the space of admissible velocities that allows the robot to stop without colliding with an obstacle,  $V_a$ ; and the space of possible velocities in consideration of the robots limited accelerations,  $V_d$ :

$$V_r = V_s \cap V_a \cap V_d \quad (1)$$

where  $V_r$  is the search space of optimal velocities, which is selected by maximizing the following objective function:

$$G(v, w) = \alpha * h(v, w) + \beta * d(v, w) + \gamma * v_F(v, w) \quad (2)$$

where  $h$  measures the alignment of the robot with the target direction,  $d$  is the distance to the closest obstacle, and  $v_F$  is the robot's forward velocity.  $\alpha$ ,  $\beta$ , and  $\gamma$  are tunable constant weights. Hence, the DWA method generates a lot of possible online local paths and then selects the most appropriate one on the basis of the objective function. Finally, the most suitable velocity for achieving the local path is executed.

### 3.2. Energy Consumption Model

An appropriate energy model is needed to analyze the effect of obstacle avoidance on energy consumption. Therefore, the energy model proposed by Wahab et al. [31] for differential drive robots was used. Their proposed model includes five main sections, which make up the total energy consumption model of the robot. The sections are discussed in more detail in the following. The DC motor's information was obtained from its datasheet and experiments. Additionally, the superscripts  $R$  and  $L$  refer to the right and left motors.

#### 3.2.1. DC Motors

Energy consumption by DC Motors ( $E_{DC}$ ) can be defined as

$$E_{DC} = \int ((I_a^R)^2 R_a^R + (I_a^L)^2 R_a^L) dt \quad (3)$$

where  $I_a$  is the armature currents, and  $R_a$  is the armature resistance of the DC motor.

#### 3.2.2. Friction

The energy losses due to friction ( $E_F$ ) are obtained through

$$E_F = \int \mu mg((v(t) + bw(t)) + (v(t) - bw(t))) dt \quad (4)$$

where  $v$  and  $w$  are the linear and angular velocities of the robot,  $\mu$  is the coefficient of rolling friction,  $m$  is the robot mass,  $g$  is the gravity, and  $b$  is the axle length of the robot.

#### 3.2.3. Kinetic Energy

The energy losses of the robot motion ( $E_K$ ) are expressed by

$$\begin{aligned} v &= r(w^R + w^L)/2 \\ w &= r(w^R - w^L)/2b \\ E_K &= \int (\frac{1}{2} (mv(t)^2 + Iw(t)^2)) dt \end{aligned} \quad (5)$$

where  $w^R$  and  $w^L$  are rotational velocities of the DC motors,  $r$  is the wheel radius, and  $I$  is the robot's moment of inertia.

#### 3.2.4. Electronics

The energy losses of the on-board electronics ( $E_E$ ) were achieved by

$$E_E = \int (I_{elec} V_{elec}) dt \quad (6)$$

where  $I_{elec}$  and  $V_{elec}$  are the amount of current withdrawn by the electronics and their supply voltage, respectively.

### 3.2.5. Gear Friction

The energy losses of friction ( $E_G$ ) in gearhead motors can be described as follows:

$$E_G = \int \left( (P_{mech}^R - \eta_g^R P_{mech}^R) + (P_{mech}^L - \eta_g^L P_{mech}^L) \right) dt \quad (7)$$

where  $\eta_g$  is the efficiency of the gear, and  $P_{mech}$  is the motor's output mechanical power, which is obtained by the torque ( $\tau$ ):

$$\begin{aligned} P_{mech}^R &= \tau^R \omega^R \\ P_{mech}^L &= \tau^L \omega^L \end{aligned} \quad (8)$$

where the torque ( $\tau$ ) is displayed as:

$$\begin{aligned} \tau^R &= K^R I_a^R \\ \tau^L &= K^L I_a^L \end{aligned} \quad (9)$$

where  $K$  is the torque constant.

Finally, the sum of the above energy values creates the energy consumption model of the robot ( $E_{Total}$ ):

$$E_{Total} = E_{DC} + E_K + E_F + E_E + E_G \quad (10)$$

### 3.2.6. Experimental Validation of the Energy Consumption Model

To validate the energy consumption model of the SGV, the measured and simulated power profiles were compared. The measured power was obtained by multiplying the measured current and the battery voltage. The SGV started following a straight trajectory from rest and stopped after 28 s. In addition, there was a rotational trajectory in the middle of the mission. Therefore, the longitudinal and rotational speed profiles followed a trapezoidal speed profile, as shown in Figure 3. Furthermore, the power consumption was obtained by using the vehicle model and the measured power. Although there is a small difference, the obtained energy (which is the integral of the power during the entire motion) is accurate enough to demonstrate the effect of the local motion planner on the energy usage.




Figure 3. Comparison between simulated and measured power profiles.

### 3.3. Simulation

Gazebo is a powerful 3D simulator for calculating physics, generating sensor data, and providing convenient interfaces for making a specific robot. In addition, Gazebo is able to simulate a specific environment with all details. Therefore, Gazebo was used to create the 3D SGV model and the industrial environment taking into consideration the various types of dynamic and static obstacles. Figure 4 displays the SGV model in Gazebo, with properties  $m = 90$  kg,  $r = 0.1$  m and  $b = 0.8$  m, which are the same as for the real SGV used in the Experiments section. It includes two LiDARs to perceive the environment and obstacles. Moreover, three small robots were created as unexpected obstacles to cross the SGV's path. Robot Operating System (ROS) was used as the navigation stack for the simulations as well as the experiments. ROS is a software development kit that helps with the creation of robot applications such as drivers, algorithms, and node creation and destruction for various operations. Hence, the co-operation with ROS and Gazebo was used to create an ideal environment in which to perform the simulations.




Figure 4. SGV model in Gazebo.

For simplicity, the global planner was kept generating the same straight trajectory between the start position and the goal position using a simple map of the navigation environment, with no obstacles located on the trajectory. Before starting the motion, several obstacles were included in the configuration space, meaning that the local planner would have to perform obstacle avoidance maneuvers. Three scenarios were defined to include these unforeseen obstacles between the start and goal positions, as described below:

1. Three unforeseen static obstacles
2. Two unforeseen dynamic obstacles
3. Two unforeseen static obstacles and one unforeseen dynamic obstacle

The A\* method was selected as the global path planner to generate straight global trajectories between the start and target positions. Hart et al. [70] proposed the A\* algorithm in 1968. It is a heuristic function-based algorithm for appropriate global path planning. It calculates the heuristic function value at each node in the work area. Afterwards, it finds the optimal solution that possesses zero probability of collision in order to generate an optimal path [71]. The local planner receives a straight trajectory (between the start position and the goal position) from the global planner. During all simulations, the path generated by the global planner was the same. Only the motion planners (with the task of avoiding unforeseen obstacles) were different. The local motion planning was carried out using the manual control (manual obstacle avoidance) and DWA methods for all three scenarios. For the manual tests, a joystick was defined in the ROS Navigation Stack as a controller in order to follow the global path generated by A\* while avoiding unforeseen

obstacles. Moreover, a lot of simulations were performed in various scenarios with the use of different DWA parameter values in order to select appropriate tunable weights.


The values of the main parameters and the simulation results are presented in Table 3 for the three simulation scenarios. On the basis of this table, the maximum linear and angular speeds were the same for both methods. In the scenarios, the total energy consumption of manual control was less than that when using DWA algorithm. This shows that energy consumption is dependent on the motion and reaction of the SGV. In addition, these results suggest that even if the global planner generates an optimal trajectory, the way it is followed ultimately impacts energy consumption. Therefore, it is important to be aware of the potential energy requirement when performing any obstacle avoidance maneuvers.

**Table 3.** Summary of the simulation results.


Scenario Number	Local Path Planning Method	Maximum Linear Speed (m/s)	Maximum Angular Speed (rad/s)	Time (s)	Total Energy Consumption (J)	Energy Consumption Difference between DWA and Manual (%)
1	DWA	0.6	0.5	20.1	3720	−6.1 %
	Manual	0.6	0.5	18.6	3490	
2	DWA	0.6	0.5	21.4	3825	−7.5 %
	Manual	0.6	0.5	20.2	3535	
3	DWA	0.6	0.5	20.9	3880	−6.2 %
	Manual	0.6	0.5	18.9	3640	

### 3.4. Experiments

To experimentally validate the simulation conducted in the previous part, several experiments were carried out using an industrial SGV. This platform has a differential drive (Figure 5a) and consists of a Mini PC with the Ubuntu 16.04 LTS operating system and an ROS Navigation Stack. The SGV has encoders in the wheels to estimate the position and velocity, and two LiDARs to perceive environmental information. The three scenarios described in the simulation part were repeated for the experiments. Figure 5b shows the test environment with the SGV and three small AWMRs as obstacles.



(a)



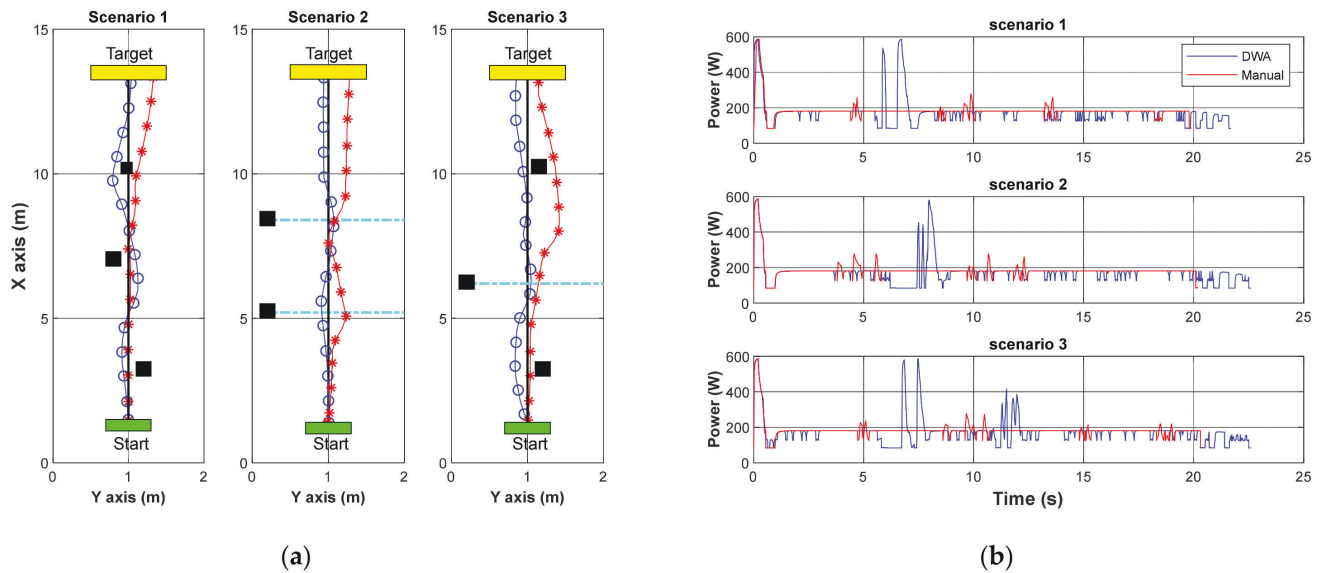
(b)

**Figure 5.** (a) The Self-Guided Vehicle (SGV); (b) the experimental environment.

Figure 6a displays the local planner trajectories for three different scenarios in the experiments. The green and yellow rectangles show the start and target points. Additionally, obstacles are indicated by the black rectangle, and the motion trajectories of dynamic obsta-



cles are illustrated by dotted (marked) lines. The straight black lines show the trajectory designed by the global planner, the red trajectory indicates manual control and the blue one is for DWA. On the basis of the power consumption profiles in Figure 6b, there are more frequent changes when using the DWA method. These changes were executed because of the sudden reaction of the SGV in response to unforeseen obstacles. Table 4 illustrates the results of both the DWA method and manual control in the real-time experiment. The maximum linear and angular speeds were the same for all scenarios. Although the time taken for each test was less than 23 s, the energy consumptions of the two methods were different. Hence, the type of SGV reaction can affect energy consumption. In addition, these results suggest that it is possible to modify the DWA planner.



**Figure 6.** (a) SGV's paths in the experiments. (Red and blue trajectories show the paths generated by manual control and DWA, respectively); (b) SGV's power consumption in the experiments.

**Table 4.** Summary of the experimental results.

Scenario Number	Local Path Planning Method	Maximum Linear Speed (m/s)	Maximum Angular Speed (rad/s)	Time (s)	Total Energy Consumption (J)	Energy Consumption Difference between DWA and Manual (%)
1	DWA	0.6	0.5	21.6	3816	−4.9%
	Manual	0.6	0.5	19.9	3636	
2	DWA	0.6	0.5	22.6	3888	−8%
	Manual	0.6	0.5	20.2	3600	
3	DWA	0.6	0.5	22.6	3960	−5.7%
	Manual	0.6	0.5	20.3	3744	

#### 4. Energy-Efficient Motion

On the basis of the results in the previous section, the motion planner method can be improved to cause the robot to consume less energy. Therefore, two solutions for addressing the problem are discussed in the following. To develop an algorithm to generate energy-efficient motion, a precise energy model is necessary. The model must include all the dynamic parameters of the robot that affect energy consumption. Then, it can be used as a constraint.

#### 4.1. Adding Energy Constraint

On the basis of (2), the DWA selects a suitable path by using the cost function. However, the function does not include the energy constraint. Therefore, the new constraint can be added. The new cost function is:

$$G(v, w) = \alpha * h(v, w) + \beta * d(v, w) + \gamma * v_F(v, w) + \sigma * E(v, w) \quad (11)$$

where  $\sigma$  is a tunable constant weight. Moreover,  $E$  is the total energy consumption of the robot, which is a function of linear and angular speeds. Therefore, when the DWA generates many executable short paths online, it can predict which one will consume less energy by using the added parameter for the cost function. The proposed method can be used in other motion planning algorithms that include cost functions.

#### 4.2. Variable Weights

The four constant weights in (11) play the main roles in DWA. They were selected on the basis of trial and error. Therefore, they are not optimal. The planning part can work in various ways depending on the aim and mission. However, Figure 7 shows in detail how the planning part operates in this work [72]. Therefore, the motion planning receives (i) navigation information from sensors, (ii) a globally designed path from the global planner, and (iii) information on the robot's surroundings, such as unforeseen obstacles, from the local cost map, which is called an online map. By collecting the information and receiving the global path, motion planning generates the appropriate linear and angular speeds to move the vehicle. Moreover, the global cost map provides the whole map of the environment, which is called an offline map. The three mentioned types of information change during the mission, and a DWA with constant weights does not consider parametric uncertainties and disturbance. Therefore, the robot is not able to carry out energy-efficient motion under all conditions. To solve this problem, the DWA's tunable weights need to adapt to changed situations. Two methods are proposed to find the optimized values of the weights in the following.

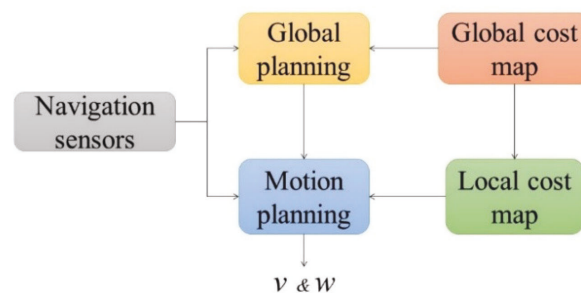


Figure 7. Flow diagram of the planning stage.

##### 4.2.1. Fuzzy Logic Control

This method needs data. Therefore, some simulations and experiments need to be performed using different weights in order to collect data. Then, a fuzzy logic (FL) controller should be designed to use the collected data and the generated energy consumption model. The controller can find appropriate online weights that will cause the robot to consume less energy.

##### 4.2.2. Reinforcement Learning

Applying a reinforcement learning (RL) algorithm in order to successfully interact with unforeseen obstacles within an environment can be helpful. The RL algorithm can be designed to use the actual behavior and the energy consumption model of the robot to

modify the weights. After some experiments, the RL algorithm will find the correct values for weights depending on the energy consumption constraints.

## 5. Discussion

The main aim of the various tests described in this paper was to show the effect of the obstacle avoidance algorithm on the energy consumption of the SGV. In fact, the platform's strategy (or choice of the path) for avoiding obstacles has a significant impact on energy usage within long-duration missions. When the SGV is driven using electric traction, careful battery management is required for two reasons:

- First, the stored energy, which is limited
- Second, the reduction in the available energy for traction due to battery degradation (as the SGV is aging)

It was observed that when the SGV faced a challenge from a dynamic obstacle, it can decrease its speed until the obstacle frees the path, or stop and then start its motion again safely. The first plan consumes less energy compared to the second one, because any start induces acceleration, which ultimately causes the platform to consume more energy (see the power profiles in Figure 6b). Moreover, some SGVs are used to transport goods in industrial environments, and they must be able to avoid unforeseen obstacles while maintaining good stability. The position of the center of mass and the geometrical distribution of the inertia matrix can also affect energy consumption. Most papers have used classic global path planning methods by adding the energy cost function to achieve a suitable trajectory. In recent years, global planning algorithms have been substantially improved. They can be used with energy cost functions to optimize the generated path. Although the motion planning stage directly affects energy consumption, the link between them has not been adequately taken into consideration. Various classic motion planning methods can be improved by adding energy criteria. More recently, they have been modified with computer vision and machine learning methods [73–75]. However, no evidence of the progress has been published so far.

## 6. Conclusions

In accordance with the growing demand for autonomous systems and technologies, AWMRs (Autonomous Wheeled Mobile Robots) have become very popular. They are often based on electric traction and use batteries as their primary energy storage. They have a lot of abilities that can improve performance in different environments. However, their limited energy storage can reduce their efficiency. The algorithms in the navigation stages have direct effects on the energy consumption of AWMRs because they are the main components designing the motions carried out in order to achieve the task. After thoroughly reviewing published papers related to navigation stages, we realized that few works have explicitly considered energy requirements, especially with respect to the local planner (motion planner) stage. To show the influence of the motion planning algorithm on energy consumption, we performed several simulations and experiments using a SGV (Self-Guided Vehicle). The analyzed scenarios illustrate that the constraint of energy consumption must be considered when designing motion planning algorithms. This constraint helps the SGV to perform tasks with high energy efficiency. In addition, the results suggest that DWA (Dynamic Windows Approach), as a popular motion planning algorithm, could be improved to use less energy in the context of the task of obstacle avoidance. Therefore, solutions for creating an energy-efficient DWA were discussed.

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

**Funding:** This research was funded by Noovelia Inc., the Natural Sciences and Engineering Research Council of Canada, grant number CRDPJ/518029-2018 and Fondation de l'UQTR" and "The APC was funded by Natural Sciences and Engineering Research Council of Canada, grant number CRDPJ/518029-2018".

**Institutional Review Board Statement:** Not applicable.

**Informed Consent Statement:** Not applicable.

**Data Availability Statement:** Not applicable.

**Acknowledgments:** Not applicable.

**Conflicts of Interest:** The authors declare no conflict of interest.

## References

1. He, W.; Li, Z.; Chen, C.P. A survey of human-centered intelligent robots: Issues and challenges. *IEEE/CAA J. Autom. Sin.* **2017**, *4*, 602–609. [\[CrossRef\]](#)
2. Klancar, G.; Zdesar, A.; Blazic, S.; Skrijanc, I. *Wheeled Mobile Robotics: From Fundamentals Towards Autonomous Systems*; Butterworth-Heinemann: Oxford, UK, 2017.
3. Sekiguchi, S.; Yorozu, A.; Kuno, K.; Okada, M.; Watanabe, Y.; Takahashi, M. Human-friendly control system design for two-wheeled service robot with optimal control approach. *Robot. Auton. Syst.* **2020**, *131*, 103562. [\[CrossRef\]](#)
4. Huzaefa, F.; Liu, Y.-C. Centralized control architecture for cooperative object transportation using multiple omnidirectional AGVs. In Proceedings of the 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Macau, China, 3–8 November 2019; IEEE: New York, NY, USA, 2019; pp. 6526–6532.
5. Lu, S.; Zhang, Y.; Su, J. Mobile robot for power substation inspection: A survey. *IEEE/CAA J. Autom. Sin.* **2017**, *4*, 830–847. [\[CrossRef\]](#)
6. Kamel, M.A.; Zhang, Y. Developments and challenges in wheeled mobile robot control. In Proceedings of the International Conference on Intelligent Unmanned Systems (ICIUS), Montreal, QC, Canada, 29 September–1 October 2014.
7. Bahrin, M.A.K.; Othman, M.F.; Azli, N.N.; Talib, M.F. Industry 4.0: A review on industrial automation and robotic. *J. Teknol.* **2016**, *78*, 137–143.
8. Mejri, E.; Kelouwani, S.; Dube, Y.; Trigui, O.; Agbossou, K. Energy efficient path planning for low speed autonomous electric vehicle. In Proceedings of the 2017 IEEE Vehicle Power and Propulsion Conference (VPPC), Belfort, France, 11–14 December 2017; IEEE: New York, NY, USA, 2017; pp. 1–6.
9. Wu, D.; Zeng, G.; Meng, L.; Zhou, W.; Li, L. Gini coefficient-based task allocation for multi-robot systems with limited energy resources. *IEEE/CAA J. Autom. Sin.* **2017**, *5*, 155–168. [\[CrossRef\]](#)
10. Andriaminahy, F.; Amamou, A.; Kelouwani, S.; Zioui, N.; Ghobadpour, A.; Agbossou, K. Comparative Study of Vehicle Aerodynamic and Rolling Resistance Coefficients Estimation Methods. In Proceedings of the 2019 IEEE Vehicle Power and Propulsion Conference (VPPC), Hanoi, Vietnam, 14–17 October 2019; IEEE: New York, NY, USA, 2019; pp. 1–5.
11. Gul, F.; Rahiman, W.; Alhady, S.S.N. A comprehensive study for robot navigation techniques. *Cogent Eng.* **2019**, *6*, 1632046. [\[CrossRef\]](#)
12. Carabin, G.; Wehrle, E.; Vidoni, R. A review on energy-saving optimization methods for robotic and automatic systems. *Robotics* **2017**, *6*, 39. [\[CrossRef\]](#)
13. Pandey, A.; Pandey, S.; Parhi, D. Mobile robot navigation and obstacle avoidance techniques: A review. *Int. Robot. Autom. J.* **2017**, *2*, 00022. [\[CrossRef\]](#)
14. McGuire, K.N.; de Croon, G.; Tuyls, K. A comparative study of bug algorithms for robot navigation. *Robot. Auton. Syst.* **2019**, *121*, 103261. [\[CrossRef\]](#)
15. Mei, Y.; Lu, Y.-H.; Hu, Y.C.; Lee, C.G. A case study of mobile robot's energy consumption and conservation techniques. In Proceedings of the ICAR'05 12th International Conference on Advanced Robotics, Seattle, WA, USA, 18–20 July 2005; IEEE: New York, NY, USA, 2005; pp. 492–497.
16. Ondruška, P.; Gurău, C.; Marchegiani, L.; Tong, C.H.; Posner, I. Scheduled perception for energy-efficient path following. In Proceedings of the 2015 IEEE International Conference on Robotics and Automation (ICRA), Seattle, WA, USA, 26–30 May 2015; IEEE: New York, NY, USA; pp. 4799–4806.
17. Zhang, H.-Y.; Lin, W.-M.; Chen, A.-X. Path planning for the mobile robot: A review. *Symmetry* **2018**, *10*, 450. [\[CrossRef\]](#)
18. Ou, L.; Liu, W.; Yan, X.; Chen, Y.; Liang, J. A Review of representation, model, algorithm and constraints for mobile robot path planning. In Proceedings of the 2018 IEEE 4th Information Technology and Mechatronics Engineering Conference (ITOEC), Chongqing, China, 14–16 December 2018; IEEE: New York, NY, USA, 2018; pp. 563–569.
19. Patle, B.; Pandey, A.; Parhi, D.; Jagadeesh, A. A review: On path planning strategies for navigation of mobile robot. *Def. Technol.* **2019**, *15*, 582–606. [\[CrossRef\]](#)
20. De Ryck, M.; Versteyhe, M.; Debrouwere, F. Automated guided vehicle systems, state-of-the-art control algorithms and techniques. *J. Manuf. Syst.* **2020**, *54*, 152–173. [\[CrossRef\]](#)

21. Graba, M.; Kelouwani, S.; Zeghmi, L.; Amamou, A.; Agbossou, K.; Mohammadpour, M. Investigating the impact of energy source level on the self-guided vehicle system performances, in the industry 4.0 context. *Sustainability* **2020**, *12*, 8541. [[CrossRef](#)]
22. Duleba, I.; Sasiadek, J.Z. Nonholonomic motion planning based on Newton algorithm with energy optimization. *IEEE Trans. Control Syst. Technol.* **2003**, *11*, 355–363. [[CrossRef](#)]
23. Mei, Y.; Lu, Y.-H.; Lee, C.G.; Hu, Y.C. Energy-efficient mobile robot exploration. In Proceedings of the 2006 IEEE International Conference on Robotics and Automation, ICRA 2006, Orlando, FL, USA, 15–19 May 2006; IEEE: New York, NY, USA, 2006; pp. 505–511.
24. Benkrid, A.; Benallegue, A.; Achour, N. Multi-robot Coordination for Energy-Efficient Exploration. *J. Control Autom. Electr. Syst.* **2019**, *30*, 911–920. [[CrossRef](#)]
25. Wang, T.; Wang, B.; Wei, H.; Cao, Y.; Wang, M.; Shao, Z. Staying-alive and energy-efficient path planning for mobile robots. In Proceedings of the 2008 American Control Conference, Seattle, WA, USA, 11–13 June 2008; IEEE: New York, NY, USA, 2008; pp. 868–873.
26. Liu, S.; Sun, D. Optimal motion planning of a mobile robot with minimum energy consumption IEEE: New York, NY, USA. In Proceedings of the 2011 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM), Budapest, Hungary, 3–7 July 2011; IEEE: New York, NY, USA, 2011; pp. 43–48.
27. Liu, S.; Sun, D. Modeling and experimental study for minimization of energy consumption of a mobile robot. In Proceedings of the 2012 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM), Kaohsiung, Taiwan, 11–14 July 2012; IEEE: New York, NY, USA, 2012; pp. 708–713.
28. Chaudhari, M.; Vachhani, L.; Banerjee, R. Towards optimal computation of energy optimal trajectory for mobile robots. *IFAC Proc. Vol.* **2014**, *47*, 82–87. [[CrossRef](#)]
29. Liu, S.; Sun, D. Minimizing energy consumption of wheeled mobile robots via optimal motion planning. *IEEE/ASME Trans. Mechatron.* **2013**, *19*, 401–411. [[CrossRef](#)]
30. Datouo, R.; Motto, F.B.; Zobo, B.E.; Melingui, A.; Bensekrane, I.; Merzouki, R. Optimal motion planning for minimizing energy consumption of wheeled mobile robots. In Proceedings of the 2017 IEEE International Conference on Robotics and Biomimetics (ROBIO), Macau, Macao, 5–8 December 2017; IEEE: New York, NY, USA, 2017; pp. 2179–2184.
31. Wahab, M.; Rios-Gutierrez, F.; el Shahat, A. *Energy Modeling of Differential Drive Robots*; IEEE: New York, NY, USA, 2015.
32. Valero, F.; Rubio, F.; Llopis-Albert, C. Assessment of the effect of energy consumption on trajectory improvement for a car-like robot. *Robotica* **2019**, *37*, 1998–2009. [[CrossRef](#)]
33. Sathiya, V.; Chinnadurai, M. Evolutionary algorithms-based multi-objective optimal mobile robot trajectory planning. *Robotica* **2019**, *37*, 1363–1382. [[CrossRef](#)]
34. Sun, Z.; Reif, J.H. On finding energy-minimizing paths on terrains. *IEEE Trans. Robot.* **2005**, *21*, 102–114.
35. Ganganath, N.; Cheng, C.-T.; Chi, K.T. A constraint-aware heuristic path planner for finding energy-efficient paths on uneven terrains. *IEEE Trans. Ind. Inform.* **2015**, *11*, 601–611. [[CrossRef](#)]
36. Ganganath, N.; Cheng, C.-T.; Fernando, T.; Iu, H.H.; Chi, K.T. Shortest path planning for energy-constrained mobile platforms navigating on uneven terrains. *IEEE Trans. Ind. Inform.* **2018**, *14*, 4264–4272. [[CrossRef](#)]
37. Sharma, A.; Gupta, N.; Collins, E.G., Jr. Energy efficient path planning for skid-steered autonomous ground vehicles. In *Unmanned Systems Technology XIII*; International Society for Optics and Photonics: Bellingham, WA, USA, 2011; Volume 8045.
38. Maclaurin, B. Comparing the steering performances of skid-and Ackermann-steered vehicles. *Proc. Inst. Mech. Eng. Part D J. Automob. Eng.* **2008**, *222*, 739–756. [[CrossRef](#)]
39. Dunlap, D.D.; Caldwell, C.V.; Collins, E.G. Nonlinear model predictive control using sampling and goal-directed optimization. In Proceedings of the 2010 IEEE International Conference on Control Applications, Yokohama, Japan, 8–10 September 2010; IEEE: New York, NY, USA, 2010; pp. 1349–1356.
40. Chuy, O.; Collins, E.G.; Yu, W.; Ordonez, C. Power modeling of a skid steered wheeled robotic ground vehicle. In Proceedings of the 2009 IEEE International Conference on Robotics and Automation, Kobe, Japan, 12–17 May 2009; IEEE: New York, NY, USA, 2009; pp. 4118–4123.
41. Pentzer, J.; Reichard, K.; Brennan, S. Energy-based path planning for skid-steer vehicles operating in areas with mixed surface types. In Proceedings of the 2016 American Control Conference (ACC), Boston, MA, USA, 6–8 July 2016; IEEE: New York, NY, USA, 2016; pp. 2110–2115.
42. Mei, Y.; Lu, Y.-H.; Hu, Y.C.; Lee, C.G. Energy-efficient motion planning for mobile robots. In Proceedings of the IEEE International Conference on Robotics and Automation, ICRA'04 2004, New Orleans, LA, USA, 26 April–1 May 2004; IEEE: New York, NY, USA, 2004; pp. 4344–4349.
43. Llamazares, A.; Ivan, V.; Molinos, E.; Ocana, M.; Vijayakumar, S. Dynamic obstacle avoidance using bayesian occupancy filter and approximate inference. *Sensors* **2013**, *13*, 2929–2944. [[CrossRef](#)] [[PubMed](#)]
44. Henkel, C.; Bubeck, A.; Xu, W. Energy efficient dynamic window approach for local path planning in mobile service robotics. *IFAC Pap.* **2016**, *49*, 32–37. [[CrossRef](#)]
45. Xie, L.; Henkel, C.; Stol, K.; Xu, W. Power-minimization and energy-reduction autonomous navigation of an omnidirectional Mecanum robot via the dynamic window approach local trajectory planning. *Int. J. Adv. Robot. Syst.* **2018**, *15*, 1729881418754563. [[CrossRef](#)]

46. Alajlan, A.; Elleithy, K.; Almasri, M.; Sobh, T. An optimal and energy efficient multi-sensor collision-free path planning algorithm for a mobile robot in dynamic environments. *Robotics* **2017**, *6*, 7. [[CrossRef](#)]
47. Barili, A.; Ceresola, M.; Parisi, C. Energy-saving motion control for an autonomous mobile robot. In Proceedings of the 1995 IEEE International Symposium on Industrial Electronics, Athens, Greece, 10–14 July 1995; IEEE: New York, NY, USA, 1995; pp. 674–676.
48. Brateman, J.; Xian, C.; Lu, Y.-H. Energy-efficient scheduling for autonomous mobile robots. In Proceedings of the 2006 IFIP International Conference on Very Large Scale Integration, Nice, France, 16–18 October 2006; IEEE: New York, NY, USA, 2006; pp. 361–366.
49. Brateman, J.; Xian, C.; Lu, Y.-H. Frequency and speed setting for energy conservation in autonomous mobile robots. In *VLSI-SoC: Research Trends in VLSI and Systems on Chip*; Springer: Berlin/Heidelberg, Germany, 2008; pp. 197–216.
50. Kim, C.H.; Kim, B.K. Energy-saving 3-step velocity control algorithm for battery-powered wheeled mobile robots. In Proceedings of the 2005 IEEE International Conference on Robotics And Automation, Barcelona, Spain, NY, USA, 18–22 April 2005; IEEE: New York, NY, USA; pp. 2375–2380.
51. Kim, C.H.; Kim, B.K. Minimum-energy translational trajectory generation for differential-driven wheeled mobile robots. *J. Intell. Robot. Syst.* **2007**, *49*, 367–383. [[CrossRef](#)]
52. Kim, H.; Kim, B.-K. Minimum-energy translational trajectory planning for battery-powered three-wheeled omni-directional mobile robots. In Proceedings of the 2008 10th International Conference on Control, Automation, Robotics and Vision, Hanoi, Vietnam, 17–20 December 2008; IEEE: New York, NY, USA; pp. 1730–1735.
53. Kim, H.; Kim, B.K. Online minimum-energy trajectory planning and control on a straight-line path for three-wheeled omnidirectional mobile robots. *IEEE Trans. Ind. Electron.* **2013**, *61*, 4771–4779. [[CrossRef](#)]
54. Kim, H.; Kim, B.K. Minimum-energy cornering trajectory planning with self-rotation for three-wheeled omni-directional mobile robots. *Int. J. Control Autom. Syst.* **2017**, *15*, 1857–1866. [[CrossRef](#)]
55. Tokekar, P.; Karnad, N.; Isler, V. Energy-optimal velocity profiles for car-like robots. In Proceedings of the 2011 IEEE International Conference on Robotics and Automation, Shanghai, China, 9–13 May 2011; IEEE: New York, NY, USA, 2011; pp. 1457–1462.
56. Tokekar, P.; Karnad, N.; Isler, V. Energy-optimal trajectory planning for car-like robots. *Auton. Robot.* **2014**, *37*, 279–300. [[CrossRef](#)]
57. Salazar, M.; Alessandretti, A.; Aguiar, A.P.; Jones, C.N. An energy efficient trajectory tracking controller for car-like vehicles using model predictive control. In Proceedings of the 2015 54th IEEE Conference on Decision and Control (CDC), Osaka, Japan, 15–18 December 2015; IEEE: New York, NY, USA, 2015; pp. 3675–3680.
58. Wang, Y.; Xiong, W.; Yang, J.; Jiang, Y.; Wang, S. A robust feedback path tracking control algorithm for an indoor carrier robot considering energy optimization. *Energies* **2019**, *12*, 2010. [[CrossRef](#)]
59. Biswas, K.; Kundu, A.S.; Kar, I. Real-time energy-optimal moving target tracking by holonomic vehicle. In Proceedings of the 2016 IEEE Annual India Conference (INDICON), Bangalore, India, 16–18 December 2016; IEEE: New York, NY, USA, 2016; pp. 1–6.
60. Kang, H.; Liu, C.; Jia, Y.-B. Inverse dynamics and energy optimal trajectories for a wheeled mobile robot. *Int. J. Mech. Sci.* **2017**, *134*, 576–588. [[CrossRef](#)]
61. Serralheiro, W.A.d.; Maruyama, N. Time-energy optimal trajectory planning over a fixed path for a wheeled mobile robot. In *ICINCO (2)*; Science and Technology Publications Lda.: Setúbal, Portugal, 2017; pp. 239–246.
62. Serralheiro, W.; Maruyama, N.; Saggin, F. Self-tuning time-energy optimization for the trajectory planning of a wheeled mobile robot. *J. Intell. Robot. Syst.* **2019**, *95*, 987–997. [[CrossRef](#)]
63. Chen, M. Robust tracking control for self-balancing mobile robots using disturbance observer. *IEEE/CAA J. Autom. Sin.* **2017**, *4*, 458–465. [[CrossRef](#)]
64. Na, J.; Herrmann, G. Online adaptive approximate optimal tracking control with simplified dual approximation structure for continuous-time unknown nonlinear systems. *IEEE/CAA J. Autom. Sin.* **2014**, *1*, 412–422.
65. Sun, P.; Yu, Z. Tracking control for a cushion robot based on fuzzy path planning with safe angular velocity. *IEEE/CAA J. Autom. Sin.* **2017**, *4*, 610–619. [[CrossRef](#)]
66. Liu, S.; Li, L.; Tang, J.; Wu, S.; Gaudiot, J.-L. Creating autonomous vehicle systems. *Synth. Lect. Comput. Sci.* **2017**, *6*, i-186. [[CrossRef](#)]
67. Fox, D.; Burgard, W.; Thrun, S. The dynamic window approach to collision avoidance. *IEEE Robot. Autom. Mag.* **1997**, *4*, 23–33. [[CrossRef](#)]
68. Li, X.; Liu, F.; Liu, J.; Liang, S. Obstacle avoidance for mobile robot based on improved dynamic window approach. *Turk. J. Electr. Eng. Comput. Sci.* **2017**, *25*, 666–676. [[CrossRef](#)]
69. Li, S.-A.; Chou, L.-H.; Chang, T.-H.; Yang, C.-H.; Chang, Y.-C. Obstacle avoidance of mobile robot based on hyperomni vision. *Sens. Mater.* **2019**, *31*, 1021–1036. [[CrossRef](#)]
70. Hart, P.E.; Nilsson, N.J.; Raphael, B. A formal basis for the heuristic determination of minimum cost paths. *IEEE Trans. Syst. Sci. Cybern.* **1968**, *4*, 100–107. [[CrossRef](#)]
71. Gurujii, A.K.; Agarwal, H.; Parsediya, D. Time-efficient A\* algorithm for robot path planning. *Procedia Technol.* **2016**, *23*, 144–149. [[CrossRef](#)]
72. Joseph, L.; Cacace, J. *Mastering ROS for Robotics Programming: Design, Build, and Simulate Complex Robots Using the Robot Operating System*; Packt Publishing Ltd.: Birmingham, UK, 2018.
73. Guo, J.; Hu, P.; Wang, R. Nonlinear coordinated steering and braking control of vision-based autonomous vehicles in emergency obstacle avoidance. *IEEE Trans. Intell. Transp. Syst.* **2016**, *17*, 3230–3240. [[CrossRef](#)]

- 
74. Taghavifar, H.; Xu, B.; Taghavifar, L.; Qin, Y. Optimal path-planning of nonholonomic terrain robots for dynamic obstacle avoidance using single-time velocity estimator and reinforcement learning approach. *IEEE Access* **2019**, *7*, 159347–159356. [[CrossRef](#)]
  75. Low, E.S.; Ong, P.; Cheah, K.C. Solving the optimal path planning of a mobile robot using improved Q-learning. *Robot. Auton. Syst.* **2019**, *115*, 143–161. [[CrossRef](#)]

.2.2 *L'article 2*



## RESEARCH ARTICLE

# Energy-Efficient Local Path Planning of a Self-Guided Vehicle by Considering the Load Position

MOHAMMAD MOHAMMADPOUR<sup>1</sup>, SOUSSO KELOUWANI<sup>1</sup>, (Senior Member, IEEE),  
MARC-ANDRÉ GAUDREAU<sup>1</sup>, BILEL ALLANI<sup>2</sup>, LOTFI ZEGHMI<sup>2</sup>,  
ALI AMAMOU<sup>2</sup>, (Member, IEEE), AND MASSINISSA GRABA<sup>2</sup>

<sup>1</sup>Department of Mechanical Engineering, University of Quebec at Trois-Rivières, Trois-Rivières, QC G8Z 4M3, Canada

<sup>2</sup>Department of Electrical and Computer Engineering, University of Quebec at Trois-Rivières, Trois-Rivières, QC G8Z 4M3, Canada

Corresponding author: Mohammad Mohammadpour (mohammad.mohammadpour@uqtr.ca)

This work was supported in part by the Industrial Research Chair Noovelia, and in part by the Natural Science and Engineering Research Council of Canada.

**ABSTRACT** The local path planning, as one of the navigation stages, plays a significant role in the energy consumption of Self-Guided Vehicles (SGV). Since SGV must operate for several hours on a single battery charge to transport loads, its energy consumption is a critical issue. Therefore, this article puts forward an approach for boosting the energy efficiency of the local path planning stage using load position. Unlike other similar works which solely use robots' kinematic and kinetic constraints to develop energy-efficient local path planners, this article considers the effect of load position on SGV's dynamic. In this regard, first, the kinetic model of the differential drive SGV is developed to consider the change of SGV's Center of Mass (CoM) affected by load properties. Second, machine learning methods are used to create two learning models for online estimation of the position of CoM (PoCoM) and prediction of required energy of sample trajectories. Hence, the generated SGV's kinetic model is used to train the learning models. Finally, estimated parameters are employed to add a new constraint to extend the cost function of the local path planner. The outcomes of the study show that the proposed planner generates smoother and shorter paths to pass obstacles and corridors than a general one. Thus, SGV's energy consumption decreases by considering the load effect.

**INDEX TERMS** Energy efficiency, local path planning, dynamic, machine learning, self-guided vehicle.

## I. INTRODUCTION

The fourth Industrial Revolution 4.0 is a promising approach based on the integration of the business and manufacturing processes, as well as the integration of all actors in the company's value chain [1]. Smart factory as a key construct of industry 4.0 aims to reach more flexible and modular production by using automation technologies which among them Self-Guided Vehicles (SGVs) take a significant role. Compared to the previous generation of Automated Guided Vehicles (AGVs) which were limited to fixed routes, SGVs can navigate dynamically and travel quickly. They are used mostly to perform repetitive heavy material delivery tasks [2].

The associate editor coordinating the review of this manuscript and approving it for publication was Jad Nasreddine<sup>1</sup>.

Hence, they are being more and more used in smart factories to increase manufacturing efficiency and keep most performance indexes as high as possible. Since most SGVs rely on batteries as only sources of energy and use electric tractions to move, their energy consumption is an essential issue to improve productivity [3], [4]. The rapidly growing demand for electric vehicles is putting huge pressure on the increase of batteries price. A possible way to contribute to reduce this pressure is to improve the electric SGV energy efficiency and the battery lifetime. It is well known that lithium-ion battery lifetime is sensitive to the depth-of-discharge (DoD) [5]. Since most electric SGVs are designed to sustain a full shift work, any improvement of energy efficiency during motion will directly reduce the DoD and contribute to augment the battery lifetime. Therefore, it is vital to amend

the energy efficiency of the whole navigation stack of these vehicles.

SGV's navigation module includes five main stages. The process starts from the perception stage by determining the essential information about the robot's surroundings. Then, the mapping stage uses the collected information to model the environment. According to generated map, the localization stage determines the vehicle's location. The fourth one is the planning stage which is divided into two categories of global path planning and local path planning to define proper paths and trajectories. Consequently, the motion control stage executes appropriate torque or current to follow the generated trajectory [6].

Because both planning and motion control stages can affect energy consumption, previous works tried to augment them. In the global path planning part, A\* method [7] as one of the famous global planners has been improved in various ways such as using an energy-related cost function [8] or optimization algorithms [9]. In the local one, energy constraints were added to cost functions [10] or multi-sensors were used to generate optimal trajectories [11]. Using optimal control theory to achieve optimal velocity trajectory [12] and adding a model predictive control for trajectory tracking [13], [14] have been famous ways in the motion control stage. However, none of the previous works considered the effect of load position on a robot's energy consumption. Since small robots do not have big loading surfaces, it seems like a good assumption to take dynamic inertial parameters as constant during missions. But for SGV, which can have a big loading surface to transport heavy loads, the inertial parameters are of interest as they will be significantly different for each given mission.

Among SGV navigation stages, local path planning has the main role to define the SGV motion. This stage generates proper trajectories to follow the created path by the global path planner stage. Moreover, the local planner must guide SGV to avoid unexpected obstacles and return it to the defined path. So, any non-optimal trajectory can raise the SGV energy consumption. Because the main task of SGV is the load transportation, its energy consumption increases with the growth of load weight. Moreover, the load effect on SGV energy consumption will intensify if SGV receives angular velocity commands to perform a rotational motion. When loads are placed on the SGV platform, its dynamic inertial parameters such as mass, the moment of inertia, and Center of Mass (CoM) are changed. According to load properties, SGV mass distribution gets asymmetric, and the position of CoM (PoCoM) moved toward the CoM of the load itself.

One important aspect that has escaped the attention of researchers in the domain of energy-efficient motion for SGVs and AGVs is the effect of load position on energy consumption during missions. Regarding this point, a proper kinetic model is required. However, in the literature, the displacement of CoM has been considered to move just in the longitudinal direction in kinetic models [15], [16]. But in reality, when there is a load on the vehicle's platform, the CoM

shifts on both longitudinal and lateral axes according to load properties. Thus, this paper has two major contributions: (i) developing the differential drive vehicle's dynamic model to consider changes of CoM in two-dimensional space. The created SGV kinetic model is employed to generate a dataset and train the machine learning (ML) models. So, the ML models help to develop a tool that estimates the required unknown dynamic parameters. (ii) Adding this tool to the local path planner algorithm to generate energy-efficient trajectories is the main contribution of this work. According to the load position on the vehicle, the first ML model finds PoCoM of loaded SGV. Then, the second ML model determines the required energy of each sample of trajectories generated by the local planner. Finally, it is added to the cost function of the local planner. Regarding the emphasis of energy on smart factories and industry 4.0, this method can be tremendously helpful.

The remainder of this paper is organized as follows. The necessity of considering load position in the local path planner is investigated in the next section. In the third section, the SGV kinetic model is developed to demonstrate the changes of PoCoM. According to the generated model, two different machine learning algorithms are employed to estimate unknown parameters and regarding results, the best one is selected in the fourth section. The fifth part describes the energy-efficient local path planner with various performed simulations and experiments to represent the efficiency of the proposed method. The sixth part discusses the results and limitations of this work and suggests some ideas for future works followed by a conclusion.

## II. NECESSITY OF CONSIDERING LOAD POSITION

### A. EFFECT OF A LOAD ON SGV'S COM

Figure 1 displays the SGV's platform with the displacement of the center of mass (CoM). Where subscripts  $i$ ,  $g$ ,  $l$  mean inertia, global, and load respectively. Regarding lateral and longitudinal axes, it is assumed that the platform can be divided into four zones. When a load is placed on the platform with the determined center of mass ( $\text{CoM}_l$ ),  $\text{CoM}_i$  that is in zone  $B$  can move to a new global point ( $\text{CoM}_g$ ) such as zone  $A$ . So,  $\text{CoM}_g$  is the new CoM of the platform that affects the SGV motion. The formulation is described as [17]:

$$r_{x_g} = \frac{r_{x_i}m_i + r_{x_l}m_l}{m_g} \quad (1)$$

$$r_{y_g} = \frac{r_{y_i}m_i + r_{y_l}m_l}{m_g} \quad (2)$$

where  $r_x$  and  $r_y$  are distances of CoM with respect to the middle of the wheels' axis (point P) in  $x$  and  $y$  directions respectively. In addition,  $m_g$  displays the sum of SGV mass ( $m_i$ ) and load mass ( $m_l$ ). By assuming the model as a two-dimensional (2D) problem, the vehicle rotation occurs around the  $z$  direction (body frame). So, the SGV's moment of inertia around this direction is:

$$I_{z_g} = I_{x_g} + I_{y_g} \quad (3)$$

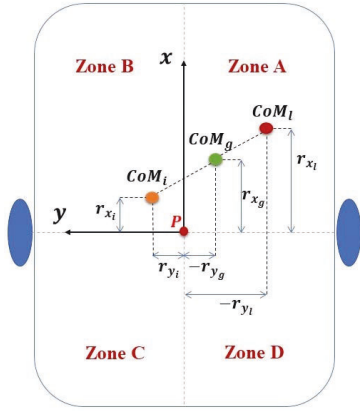


FIGURE 1. SGV's  $CoM_g$  with respect to load's  $CoM_l$ .

where  $I$  displays the moment of inertia and this parameter around  $x$  and  $y$  directions are defined as:

$$I_{x_g} = (I_{x_l} + m_l r_{x_l}^2) + (I_{x_l} + m_l I_{x_l}^2) \quad (4)$$

$$I_{y_g} = (I_{y_l} + m_l r_{y_l}^2) + (I_{y_l} + m_l I_{y_l}^2) \quad (5)$$

According to Figure 1, the load has a substantial effect on the SGV dynamic that should be considered in navigation algorithms. However, previous works have studied the SGV's dynamic by ignoring the parameter  $r_y$  ( $r_y = 0$ ). Hence, this paper intends to develop the SGV dynamic model by considering the displacement of  $CoM_g$  in both longitudinal ( $x$ ) and lateral ( $y$ ) directions.

### B. EFFECT OF CoM DISPLACEMENT ON SGV'S ENERGY CONSUMPTION

Rotational motions are frequent for SGVs during missions such as turning in corridors or avoiding obstacles. During a mission, unexpected obstacles might appear to cross the SGVs' defined paths such as humans and other vehicles. An increase in the number of obstacles has a direct effect on SGV energy consumption [11]. Moreover, a nonoptimal reaction to avoid obstacles might raise the distance to the destination and waste time by generating useless motion [18].

To show the effect of load position on energy consumption caused by the local planning stage, some experiments have been performed. The SGV and load's properties are explained in Appendix C. In this regard, experiments include two scenarios. First, SGV moves in a straight line. Second, it turns into a corridor. Moreover, each scenario has two attempts with respect to the middle longitudinal axis of SGV:

1. attempt *a*: load is placed on the right side of the platform ( $r_{x_l} = 0.3$  m,  $r_{y_l} = -0.15$  m)
2. attempt *b*: load is placed on the left side of the platform ( $r_{x_l} = 0.3$  m,  $r_{y_l} = +0.15$  m)

Three containers are on each other as load (total mass = 55.5 kg). To have an objective comparison of the energy consumption for each mission, the positions of the start and




FIGURE 2. The first scenario of the experiment, avoiding an unexpected obstacle.

goal, the global path, and the position of the unexpected obstacle are the same for the two load positions.

Figure 2 displays the SGV's path and power consumption of wheels' motors in the first scenario of experimental tests. SGV receives a goal and moves toward it in a straight line. However, there is an unexpected static obstacle to cross over the SGV path. So, the local path planner changes the SGV path to pass the obstacle (turning left) and then returns SGV on the defined path created by the global path planner (straight line). When the load is on the right side of SGV (attempt *a*), it consumes 966.5 J energy while the consumption decreases in attempt *b* by 8.8% at the same time.

Figure 3 illustrates the SGV's path and power consumption in the second scenario of the experimental tests. SGV has a rotation motion to the left to pass the corridor. The energy consumption of SGV with a load on the right side of the platform is 514.2 J which is 15.2% more than attempt *b*. The results of experiments represent considerable differences in energy consumption between two attempts of each scenario under the same conditions. The differences can be repeated when the load's position is changed on the platform according to the middle lateral axis of SGV. So, the local path planner can be improved to find energy-efficient trajectories by using the position of load. For instance, SGV could pass the obstacle or turn in a corridor by using different trajectories or maneuvers.

### III. MOTION EQUATIONS OF SGV

Motion equations of the differential drive SGV are developed in Appendix A. Although the kinematic model is like previous works, the kinetic model is developed to consider changes of CoM on both lateral and longitude axes. The kinetic model of SGV is achieved as:

$$\begin{bmatrix} m_g & -m_g r_{y_g} \\ -m_g r_{y_g} & I_{z_g} + m_g (r_{x_g}^2 + r_{y_g}^2) \end{bmatrix} \begin{bmatrix} \dot{v} \\ \dot{w} \end{bmatrix} + \begin{bmatrix} 0 & -m_g r_{x_g} w \\ m_g r_{x_g} w & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = \frac{1}{r} \begin{bmatrix} 1 & 1 \\ b & -b \end{bmatrix} \begin{bmatrix} \tau_r \\ \tau_l \end{bmatrix} \quad (6)$$




FIGURE 3. The second scenario of the experiment, turning motion in a corridor.

where  $v$  and  $w$  represent the linear and angular velocities of SGV. Also,  $b$  and  $r$  define the distance of SGV’s wheels to point  $P$ , and the radius of them respectively. Moreover,  $\tau_r$  and  $\tau_l$  are right and left wheels’ motors torques. By determining the values and signs of  $r_{y_g}$  and  $r_{x_g}$ , the new  $CoM_g$  is founded.

An open-loop controller can be used to display the effect of CoM on the SGV’s dynamic. So, it is considered that there is a load on the SGV. The load causes changes in the position of  $CoM_g$  according to the load’s inertial parameters. Therefore, three scenarios are defined:

1.  $CoM_g$  on the middle longitudinal axis of SGV ( $r_{x_g} = 0.1$  m,  $r_{y_g} = 0$  m)
2.  $CoM_g$  on the left side of the middle longitudinal axis ( $r_{x_g} = 0.1$  m,  $r_{y_g} = 0.1$  m)
3.  $CoM_g$  on the right side of the middle longitudinal axis ( $r_{x_g} = 0.1$  m,  $r_{y_g} = -0.1$  m)

Other SGV’s parameters by considering load are  $m_g = 150$  kg,  $I_{z_g} = 6$  kgm<sup>2</sup>,  $b = 0.4$  m,  $r = 0.1$  m. Moreover, left and right motors torques are considered the same as the control inputs for motion in a straight line. Noise is not considered in the simulations to demonstrate this effect clearly.

The simulations’ results of three defined scenarios are displayed in Figure 4. They illustrate the effect of CoM on the SGV dynamic for the 3 positions of the load. When torques of the right and left wheels are the same, a straight trajectory is expected. So, while the CoM is on the longitudinal axis, SGV moves along a straight line (blue line). However, when the CoM is on the left and right sides (zones A and B), SGV tends to left (yellow line) and right (red line) sides respectively.

To see the effect of changes of CoM on required torques of right and left wheels motors, three defined scenarios in the previous simulations are repeated. So, linear and angular velocities of references are considered as a wave and zero respectively for a straight motion without any rotation. The controller must generate proper torques to keep the SGV in a straight line. Because SGV’s dynamic inertial parameters are highly variable, a sliding-adaptive controller is required for this type of vehicle. So, the sliding-adaptive controller




FIGURE 4. SGV paths with the open-loop controller in three scenarios.




FIGURE 5. Generated torques for wheels motors in three scenarios.

for differential drive vehicles designed by Mevo et al. [19] is employed. To know more information and details about the controller see the mentioned reference. Figure 5 displays the results of the simulations. Hence, by considering CoM on the SGV’s longitudinal axis, torques of left and right motors are the same (blue graphs). When CoM is on the right side of the SGV’s longitudinal axis, the right motor needs more torque to keep the SGV’s motion in a straight line (yellow graph). However, when CoM is on the left side, the left motor consumes more torque (red graph). The results prove the effect of PoCoM on SGV’s motion. Hence, it is possible to improve the SGV maneuver by considering PoCoM.

#### IV. PARAMETERS ESTIMATION

According to the methodology of this work, online estimation of the PoCoM ( $r_x, r_y$ ) and torques ( $\tau_r, \tau_l$ ) are required. Hence, parameter estimation methods can be employed. They are divided into three main groups [20]. The first one is the filter-based method. The most frequently used filters in the literature are the extended Kalman filter (EKF) and unscented Kalman filter (UKF) [21], [22]. The second group is the observer-based method such as recursive least squares [23], linear and nonlinear observers, and sliding mode observers [24]. The third one is the data-driven-based estimation [25]

which uses the generated data from models or collected data from experiments to create a learning model.

Regarding SGV nonlinear dynamic model (6), there are four unknown parameters ( $I_{z_g}, m_g, r_{x_g}, r_{y_g}$ ) due to load effects. The second power of CoM's parameters ( $r_{x_g}, r_{y_g}$ ) convert them into smaller values. Moreover, they are multiplied by the mass which is a large value in this type of vehicle. So, the mentioned nonlinearity conditions represent a serious challenge for the parameter identification task. Since filter-based and observer-based groups use the model directly to estimate parameters, they cannot be proper ways to address this problem. However, the data-driven-based estimation group can be an appropriate way because of its ability to address nonlinear conditions, hence; a method from the data-driven-based estimation group will be used to estimate the unknown parameters of the loaded SGV.

### A. DATA-DRIVEN-BASED PARAMETER ESTIMATION

By using the designed SGV kinetic model, a dataset with known inputs and outputs can be generated. So, a supervised machine learning method is required. Moreover, according to the nonlinearity of the kinetic model that has been discussed, the learning model must handle this condition. Furthermore, the selected method must be able to overcome multi-output problems. In this regard, the Multi-Layer Perceptron (MLP) method can be a proper choice to cover all mentioned conditions. MLP can be applied to complex nonlinear problems and is compatible with large input data. It is able to achieve online quick predictions after fine training. To see whether there is a dependency between the data of the dataset concerning time, a time-series method is employed. Moreover, it can be helpful to obtain a comparison between the results of parameters estimation of a time-series method and MLP to select the best method for this project. Among time series methods, long short-term memory (LSTM) is the useful one that comprises MLP's advantages. A brief description of the two mentioned methods and their formulations are explained in Appendix B.

#### 1) DATASET GENERATION

Dataset is an important part of machine learning methods. Training an algorithm by a dataset is the collection of data that is fed into algorithms to create a predictive model. Regarding the aim of this work, a dataset is generated by using the developed dynamic model of SGV (6). Figure 6 illustrates the data flow map of the dataset generation process and the dataset structure. According to this diagram, various scenarios are performed with different inertial parameters (mass, moment of inertia, CoM). Moreover, various reference velocities are considered to comprehend requirement torques for different conditions. Hence, the values of linear and angular velocities ( $v, w$ ), torques of right and left motors ( $\tau_r, \tau_l$ ), PoCoM ( $r_x, r_y$ ) are saved in the data storage to create the dataset. Because of the existence of noise in an industrial environment, Gaussian noise is added to interfere in the process to consider uncertainties in the dataset. Since two learning models are used

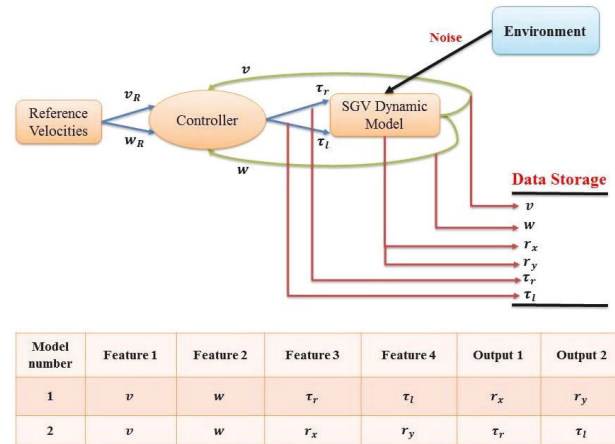


FIGURE 6. The data flow map with the dataset structure.

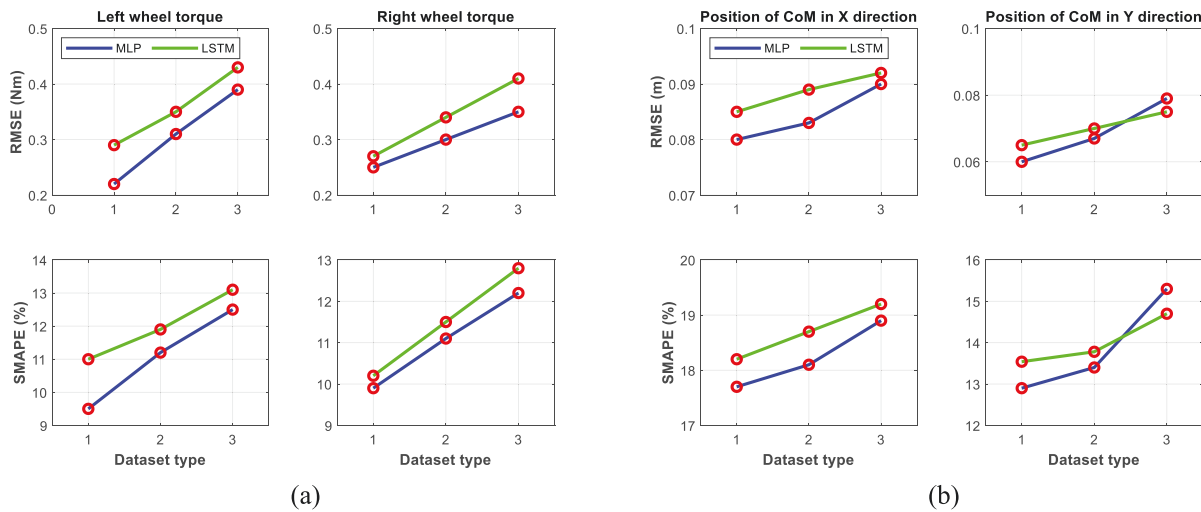
in this paper, two structures are generated. The first model includes four features  $v, w, \tau_r$  and  $\tau_l$  and two outputs  $r_x, r_y$ . However, the features of the second model are  $v, w, r_x$  and  $r_y$  and the outputs are  $\tau_r, \tau_l$ .

#### 2) SIMULATIONS AND RESULTS

The results of the parameter estimation task by using machine learning methods are displayed in Table 1. ML model 1 tries to estimate  $r_{x_g}$  and  $r_{y_g}$ ; ML model 2 estimates  $\tau_r, \tau_l$ . According to the literature, a proper way to show the accuracy of the estimation task is RMSE (Root-mean-square deviation) [26]. The unit of the RMSE is like the unit of variables. So, RMSE's units are m and Nm respectively here. The range of changes of  $r_{x_g}$  and  $r_{y_g}$  is between  $-0.25$  m to  $+0.25$  m (total is 0.5 m). Also, the range of torques changes is between  $-20$  Nm to  $+20$  Nm. Another useful method is SMAPE (symmetric mean absolute percentage error) to measure the accuracy based on the percentage error [26]. The SMAPE range is between 0 to 100% and a lower percentage means lower error. To demonstrate the robustness of ML models when dealing with different levels of noise, three conditions are considered for the dataset. Type 1 includes data with Gaussian noise. Type 2 and 3 include Gaussian noise with more than 10% and 20% Signal-to-noise ratio (SNR) respectively. The numbers of hidden layers and neurons in training are displayed. The presented values are the optimal ones that have been achieved after some trial and error process. Moreover, the names of activation functions and solvers for both methods are presented. Regarding RMSE and SMAPE of results in Table 1, both MLP and LSTM achieve acceptable results to estimate both PoCoM and torques for different dataset types. To comprehend clearly the difference between results, they are presented in Figure 7. Blue and green lines correspond to MLP and LSTM methods. By increasing the SNR of noise from dataset 1 to dataset 3, the values of errors grow gradually. For instance, in Figure 7a, RMSE of estimation of PoCoM in  $x$ -direction for dataset type 1 is 0.08 m and 0.085 m by using MLP and LSTM methods respectively.

**TABLE 1. Properties and results of parameter estimation task by MLP and LSTM methods.**

Method		MLP						LSTM					
Noise type		Data with noise	Data with noise + 10% more SNR		Data with noise + 20% more SNR		Data with noise	Data with noise + 10% more SNR		Data with noise + 20% more SNR			
Numbers of neurons in three hidden layers		[20, 40, 40]						[20, 30, 40]					
Activation function		Hyperbolic tangent						Hyperbolic tangent					
Solver		Adam						Adam					
ML Model 1	Parameter	$r_{x_g}$	$r_{y_g}$	$r_{x_g}$	$r_{y_g}$	$r_{x_g}$	$r_{y_g}$	$r_{x_g}$	$r_{y_g}$	$r_{x_g}$	$r_{y_g}$	$r_{x_g}$	$r_{y_g}$
	RMSE (m)	0.08	0.06	0.083	0.067	0.09	0.079	0.085	0.065	0.089	0.07	0.092	0.075
	SMAPE (%)	17.7	12.9	18.1	13.4	18.9	15.3	18.2	13.54	18.7	13.78	19.2	14.7
ML Model 2	Parameter	$\tau_r$	$\tau_l$	$\tau_r$	$\tau_l$	$\tau_r$	$\tau_l$	$\tau_r$	$\tau_l$	$\tau_r$	$\tau_l$	$\tau_r$	$\tau_l$
	RMSE (Nm)	0.22	0.25	0.31	0.3	0.39	0.35	0.29	0.27	0.35	0.34	0.43	0.41
	SMAPE (%)	9.5	9.9	11.2	11.1	12.5	12.2	11	10.2	11.9	11.5	13.1	12.8



**FIGURE 7. The estimation error based on the MLP and LSTM for PoCoM (a) and torques (b). (Blue and green lines indicate MLP and LSTM methods respectively).**

When the SNR of noise raises 20% (dataset type 3), RMSE reaches 0.09 m and 0.092 m for MLP and LSTM methods. Also, the same results are observed in SMAPE of estimation. The few changes of RMSE and SMAPE with respect to the increase of noise' SNR prove the robustness of generated ML models to noise when they will be deployed in real-world and uncontrolled conditions.

LSTM needs previous steps of data to predict parameters. However, MLP works with data of the current time. Although the LSTM can be used to estimate PoCoM, it is not proper for LSTM which needs previous steps of data to predict parameters. However, MLP works with data of the current time. Although the LSTM can be used to estimate PoCoM, it is not proper for torque estimation. Estimation of PoCoM is performed at the beginning of the motion once. So, there is enough time (some steps) to collect data and then predict PoCoM. But the estimation of torque must be done according to the frequency rate of the controller which is 20 ms in

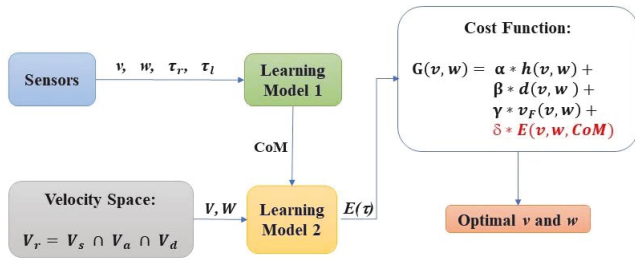
this work. Regarding these conditions, the MLP method is selected for the parameter estimation task in this article.

**V. ENERGY-EFFICIENT LOCAL PATH PLANNING**

By using the generated kinetic model and two learning models, the local path planner can be improved to achieve an energy-efficient motion. Hence, Dynamic Window Approach (DWA) as a useful local planner method is employed in this article. Then, some simulations and experiments are performed to investigate the proposed method's efficiency.

**A. DYNAMIC WINDOW APPROCH (DWA): AN OVERVIEW**

DWA is a well-known collision avoidance navigation algorithm that was proposed by Dieter Fox et al. [27]. Also, DWA is an online reactive method and its cost function has been extended several times during the last years. In order to select safe and optimal translational ( $v$ ) and rotational ( $w$ ) velocities, the method directly generates their profiles by considering the



**FIGURE 8.** The structure of the energy-efficient DWA method.

dynamic of the robot and the range limitation of the velocity and acceleration. The main search space for suitable velocities is intersected by three subspaces: (i) space of possible velocities according to the robot kinematic constraints,  $V_s$ , (ii) space of admissible velocities that allows the robot to stop without colliding with an obstacle,  $V_a$ , and (iii) space of possible velocities by considering the robot's limited accelerations,  $V_d$ :

$$V_r = V_s \cap V_a \cap V_d \quad (7)$$

where  $V_r$  is the search space of optimal velocities, which is selected by minimizing the following objective function:

$$G(v, w) = \alpha * h(v, w) + \beta * d(v, w) + \gamma * v_F(v, w) \quad (8)$$



where  $h$  measures the alignment of the robot with the target direction,  $d$  is the distance to the closest obstacle, and  $v_F$  is the robot forward velocity.  $\alpha$ ,  $\beta$ , and  $\gamma$  are tunable constant weights. Hence, the DWA method generates a lot of possible online trajectories and then selects the optimal ones according to the objective function.

### B. ENERGY-EFFICIENT DWA

To develop the energy-efficient DWA by considering PoCoM, the following model is proposed. The method's structure is displayed in Figure 8. When SGV starts moving, ML model 1 receives SGV linear and angular velocities ( $v$ ,  $w$ ), left and right motors' torques ( $\tau_l$ ,  $\tau_r$ ) to estimate PoCoM. Then ML model 2 uses PoCoM and vectors of linear and angular velocities ( $V$ ,  $W$ ) generated by the velocity space to predict the required energy of each trajectory. Finally, the energy is added to the cost function with a tunable constant weight ( $\delta$ ). Thus, DWA finds the optimal trajectory by minimizing the new cost function. By adding the energy constraint to DWA's cost function, the formulation of the new one is represented in the following formulation:

$$G(v, w) = \alpha * h(v, w) + \beta * d(v, w) + \gamma * v_F(v, w) + \delta * E(v, w, CoM) \quad (9)$$

To be sure that the selected optimal velocities are related to the energy-efficient distance traveled to pass an obstacle, the inputs of learning Model 2 are considered as vectors. So, the cost function calculates the cost of vectors of linear and angular velocities which means the cost of possible paths.



**FIGURE 9.** Gazebo environment: (a) SGV designed model, (b) simulation's world.

Then, it picks out the optimal vector. This condition can guarantee to achieve an energy-efficient trajectory and distance traveled at the same time. It is worth mentioning that learning models 1 and 2 do not work at the same time. Because the value of PoCoM is constant until the next SGV's mission, it is estimated once during the first steps of the motion. Then, it is used as a constant input of model 2 until the next load. So that, model 2 receives online inputs to generate the output in each step of the controller frequency.

### C. SIMULATION

Gazebo is a powerful 3D simulator to calculate physics, generate sensor data, and provide convenient interfaces to make a specific robot [28]. By changing the inertial parameters of a created robot in Gazebo, the robot's dynamic is affected like a real robot. In addition, it is able to simulate a specific environment with all details. So, Gazebo is a proper choice to create the 3D SGV model and the industrial environment with consideration of obstacles. Figure 9a displays the differential drive SGV model in Gazebo with inertial dynamic properties like the real one which represented in Appendix C. It includes two lidars to perceive the environment and two motors to move SGV. Moreover, CoM is displayed. The Robot Operating System (ROS) [29] has been used as the navigation stack role. ROS is a software development kit that helps the robot to create robot applications such as drivers, algorithms, and node creation and destruction for various operations. Hence, cooperation with ROS and Gazebo is used to create an ideal environment to perform simulations.

Figure 9b displays the simulation environment in Gazebo. SGV begins moving from the start point and then stops in five stations (1-5) respectively followed by the end point. The load's inertia parameters are changed in each station. However, the geometry of the load is rectangular for the whole scenario. There are some unexpected static obstacles to

**TABLE 2.** Results of simulations of SGV motion by considering load changes and effect of the energy-efficient local planner.

S	Start point	End point	Total mass (kg)	CoM <sub>l</sub> (cm)		Real CoM <sub>g</sub> (cm)		Estimated CoM <sub>g</sub> (cm)		Simulation time (s)		Distance traveled (m)		Energy consumption (J)		Energy efficiency (%)
				r <sub>x<sub>l</sub></sub>	r <sub>y<sub>l</sub></sub>	r <sub>x<sub>g</sub></sub>	r <sub>y<sub>g</sub></sub>	r <sub>x<sub>g</sub></sub>	r <sub>y<sub>g</sub></sub>	E0	E	E0	E	E0	E	
a	Start	1	150	44	22	20	10	17.4	8.7	23.0	20.8	15.5	15.1	1521	1363	10
b	1	2	125	29	-15	10	-5	12.5	-3.9	43.8	40.2	25.5	24.1	2689	2244	16
c	2	3	165	-20	-20	-10	-10	-11.6	-11.1	24.7	25.1	16.8	16.5	1310	1260	4
d	3	4	133	-15.5	21	-6	8	-5.9	9.2	22.4	21.2	16.3	15.8	1405	1315	6
e	4	5	145	21	16	9	7	8.5	6.6	46.5	43.4	24.7	23.3	2770	2366	14
f	5	End	115	-28	4	-8	4	-9.8	3.4	19.6	18.5	12.5	12.2	1287	1015	11
<b>Totally</b>										<b>177.8</b>	<b>169.2</b>	<b>109.3</b>	<b>105.1</b>	<b>10982</b>	<b>9563</b>	
														<i>r<sub>x</sub></i>	<i>r<sub>y</sub></i>	
SMAPE of estimation (%)														13	14.2	

cross over the SGV’s path. SGV must follow the global path generated by the global planner besides avoiding obstacles. The scenario is implemented in two conditions. First, SGV’s navigation uses the general DWA ( $\delta = 0$ ) as the local planner algorithm. Second, the proposed DWA method ( $\delta \neq 0$ ) is applied.

According to the direct relation between torque and current, torque is linearly proportional to current [14]:

$$\tau = Ki_M \tag{10}$$

where  $i_M$  and  $k$  denote current and torque’s constant respectively. Motors’ torques are found by the motion controller and the required currents of a motor can be obtained by using (10). The power consumption of the motor ( $P_M$ ) is defined as:


$$P_M = V_M i_M \tag{11}$$

where  $V_M$  is the voltage of the motor. So, the total energy consumption of the motor ( $E_T$ ) can be displayed as:

$$E_T = \int P_M dt \tag{12}$$

The simulation is designed to imitate a real mission in a warehouse. Hence, SGV moves between sections of a warehouse and each time it transports a new load with different mass and position. Figure 10 represents the SGV traveled path. Yellow circles with numbers 1-5 display the stations where SGV must stop, completing each section of the total mission ( $a$  to  $f$ ). The direction of SGV’s movement is illustrated by gray arrows. Green, red and black rectangles show the positions of the start, end, and obstacles respectively. The obstacle in blue is only present for section  $e$ , it is not present when the SGV is doing section  $b$ .  $E0$  implies the situation of using the general DWA ( $\delta = 0$ ) and  $E$  means when the energy-efficient DWA is applied ( $\delta \neq 0$ ).

Figures 11 displays the difference between velocities and Figure 12 represents the difference between motors’ torques in simulations. Subscripts  $R$  and  $L$  indicate right and left motors respectively. To have a better comparison between the general DWA and the energy-efficient one, the whole results are presented in Table 2. It includes six sections ( $a$ - $f$ )



**FIGURE 10.** SGV path in the simulation ( $E$  and  $E0$  are related to energy-efficient DWA and the general one respectively).

that display the simulations’ properties and results of SGV movement between two stations. Hence, the station’s number and total mass (sum of SGV’s mass and load’s mass) are presented. Moreover, the simulation time, the traveled distance, and SGV’s energy consumption between two stations for both situations of the simulation’s scenario are displayed. Loads and real global CoM (CoM<sub>l</sub>, real CoM<sub>g</sub>) are illustrated with the outputs of parameter estimation (estimated CoM<sub>l</sub>). The results are represented by SMAPE which are 13% and 14.2% for estimations of  $r_{x_g}$  and  $r_{y_g}$ . The column related to energy efficiency shows the percentage of reduction of energy consumption by using the energy-efficient local planner. So, the positive value of this column demonstrates the advantage of the proposed method than the general one. The total results are displayed in green color. Hence, SGV terminates the scenario in 169.2 s by traveling 105.1 m and consuming 9563 J energy while using the energy-efficient DWA. However, SGV consumes 10982 J energy to travel 109.3 m in 177.9 s by applying the general DWA. Hence, in addition to the reduction in time and distance traveled of SGV, the energy consumption decreases by 13% while activating the proposed method.






FIGURE 11. Linear and angular velocities of SGV in the simulation.




FIGURE 12. Power consumption of SGV's left and right motors in the simulation.

D. EXPERIMENTAL VALIDATION

In order to experimentally validate the simulations in the previous part, several experiments are carried out by using an

industrial SGV. Five storage containers are used as loads. The experimental tests are performed in the lab of the Hydrogen Research Institute (IRH) of the University of Quebec at Trois-Rivières (UQTR). The floor is painted concrete leveled to avoid slip. The properties of SGV, loads, and test environment are presented in Appendix C. Regarding the space limitation of the lab, the environment of simulations and experiments are different. However, their logics of scenarios are the same where load's mass and position are changed during missions and SGV must pass corridors and unexpected obstacles. Although simulations aim to see the output of the proposed method in a more complicated world, experiments intend to find this effect on long-time missions. SGV starts from the station, passes waypoints 1 and 2, then returns to the station. Two unexpected obstacles are considered to cross over SGV's path. The first obstacle appears when SGV departs from the station into waypoint 1 and the second one becomes visible when SGV moves from waypoint 2 to the station. The effect of optimal or nonoptimal motions on SGV's energy consumption intensifies by the maximum load. Thus, there are four or five loads in each attempt. Moreover, the loads' weight and positions are constant during each attempt. When SGV returns to the station at the end of an attempt, their weight and positions are changed for the next attempt. In total, six attempts are performed with the same scenario and different loads' mass and position for both energy-efficient DWA and the general one. As shown earlier (see Figure 1), the loading surface can be divided into 4 zones with respect to point P and x and y axes. Attempts 1 to 4 present a different load in each of the 4 zones. In attempt 5, the global CoM is considered close to point P. Also, attempt 6 is created to see the result compared to attempt 2 when their  $CoM_g$  is the same however loads' heights are different. Hence, the experiments cover all of the possible conditions that might happen for SGV. Because SGV performs long-time scenarios in the industry,

TABLE 3. Results of experimental tests of SGV motion by considering load changes and effect of the energy-efficient local planner.

At	TM (kg)	NoL	CoM <sub>l</sub> (cm)		RCoM <sub>g</sub> (cm)		ECoM <sub>g</sub> (cm)		ET (min)		DT (m)		DoD (%)		EC (KJ)		EE (%)	
			r <sub>x<sub>l</sub></sub>	r <sub>y<sub>l</sub></sub>	r <sub>x<sub>g</sub></sub>	r <sub>y<sub>g</sub></sub>	r <sub>x<sub>g</sub></sub>	r <sub>y<sub>g</sub></sub>	E0	E	E0	E	E0	E	E0	E		
1	174.5	2	5.5	12	10.3	5.5	9.1	5.2	75	67.8	1485	1477	15.2	12.8	299	259	13.4	
		3	34.5	12														
2	156	4	30.5	-11.5	12.5	-6.5	14.9	-6.9	76.4	73.3	1488	1481	14.4	13.0	275	253	8.3	
3	156	4	-27	11.5	-15	4.5	-13.4	3.8	75.9	71.3	1489	1485	14.2	12.7	321	270	11.1	
4	174.5	5	-15	-10	-9.8	-6.3	-18	-10.5	69.7	71.2	1481	1483	14.6	14.7	271	275	-1.6	
5	174.5	5	5	4	0.8	1.2	1.2	2	72.9	68.8	1482	1479	14.8	13.6	274	255	7	
6	156	2	12	-11	12.6	-6.3	14.8	-7.2	76.2	71.5	1486	1480	14.4	12.9	268	240	10.5	
		2	50	-11														
<b>Totally</b>									<b>446</b>	<b>424</b>	<b>8911</b>	<b>8889</b>	<b>14.6</b>	<b>13.3</b>	<b>1708</b>	<b>1550</b>	<b>9.25</b>	
															r <sub>x</sub>		r <sub>y</sub>	
SMAPE of estimation (%)												With scenario 4		26		23.6		
												Without scenario 4		19.5		18.3		




FIGURE 13. SGV path in the experiment (attempt 1, first iteration).

so each attempt is repeated 28 times (nonstop) here to be guaranteed more than an hour of motion. This condition helps to consider uncertainties of localization and mapping that might raise the time of missions. Hence, they can affect the efficiency of motion planning. Moreover, the percentage of the energy efficiency due to more than an hour of motion is more applicable for the comparison and is more similar to a real mission than just a few minutes scenario.

Because of long-time tests and the high number of repetitions, the results of the first iteration of scenario 1 are just displayed in Figures 13-15 where red and blue colors mean general DWA ( $E0$ ) and energy-efficient DWA ( $E$ ) respectively. Hence, SGV's path is represented in Figure 13 where the green rectangular shows the position of the station, and the blue ones are related to the positions of unexpected obstacles. In addition, two yellow circles display the positions of waypoints 1 and 2. The direction of SGV's movement is illustrated by gray arrows. According to the generated paths, the one generated by the proposed method (blue) is more smoother than the general DWA (red). When SGV passes an obstacle, the energy-efficient DWA tries to generate optimal trajectories to create a shorter distance than the obstacle to pass it. Figure 14 demonstrates linear and angular velocities of SGV which are different by using the proposed method and Figure 15 displays the power consumption of left and right motors.

Table 3 represents the details and results of experimental tests. It includes the number of loads (NoL) and the total mass (TM) which is the sum of SGV and loads mass in each attempt (At). The column related to  $CoM_l$  explains the distance of loads' CoM with respect to point  $P$ . The real  $CoM_g$  is calculated by using (1) and (2). Also, the estimated  $CoM_g$  is achieved by using the generated learning model 1 which is explained in the previous section. Moreover, the experiments' time (ET), distance traveled (DT), DoD, and motors energy consumption (EC) columns display the sum of 28 times of repetitions in each attempt. The difference between motors' energy consumption due to the two used methods are illustrated as the energy efficiency (EE).




FIGURE 14. Linear and angular velocities of SGV in the experiment (attempt 1, first iteration).




FIGURE 15. Power consumption of SGV's left and right motors in the experiment (attempt 1, first iteration).

The estimations' results are acceptable except in scenario 4 where the error is more than 8 cm in the  $x$ -direction and 4 cm in the  $y$ -direction. The SMAPE of the whole estimations of  $r_{x_g}$  and  $r_{y_g}$  are 26% and 23.6%. However, they become 19.5% and 18.3% without considering scenario 4. The simulation time, SGV distance traveled, and motors' energy consumption of proposed methods are less than the general DWA in all scenarios except scenario 4. Thus, by achieving an incorrect estimation, the proposed method cannot be energy-efficient and even makes SGV consumes more energy. SGV travels 8911 m in 446 min by consuming 1708 KJ energy while using the general local planner. However, it travels 8889 m in 424 min with 1550 KJ energy consumption and by using the energy-efficient one. Moreover, the average of the battery's DoD becomes 13.3% which is 9% less than the general DWA method with 14.6% DoD. In the end, the proposed method helps SGV to achieve 9.25% energy efficiency during experiments and finish the missions almost 22 min sooner.

VI. DISCUSSION AND FUTURE WORKS

Since energy-efficient motion is a vital subject to raise the robot's operation without charging, previous studies have

proposed different ways to improve it. However, few of them have surveyed the local planning part. The energy-efficient DWA was proposed by Xie et al. [10]. They added the robot's energy consumption model to DWA's cost function and achieved different percentages of the reduction in the energy consumption by changing the constant gains. In more recent work on this topic, Szczepanski et al. [30] suggested an energy-efficient local path planning based on predictive Artificial Potential Field (APF). Also, their method could reduce the energy consumption of a small robot. However, none of these works, as similar works to this paper, considered the effect of load on local planning to achieve an energy-efficient motion. Hence, the changes in mass, the moment of inertia, and CoM during a mission were ignored. Since the main role of SGV is load transportation, this paper proposed a method to consider the changes of dynamic inertial parameters to achieve an energy-efficient mission.

The previous section surveys the effect of the proposed method on the energy consumption of SGV. The results of simulations and experimental tests display 13% and 9.25% reduction in energy consumption. Moreover, this method helps SGV to complete the mission by consuming less time and distance traveled. However, when there is a high estimation error (experimental tests, attempt 4), this method cannot be useful and even increase energy consumption. So, the high accuracy of the parameter estimation is essential for this work. Concerning this matter, some improvements are suggested for future works. Hence, besides the parameter estimation task, a classification method can be employed to make sure that the estimated sign of  $r_x$  and  $r_y$  (positive or negative) are correct. A combination of the result of estimation and classification methods guarantees the precision of the final result. Another point that is perceived from the experimental results, is the effect of loads' height on the results. Whereas the positions of real global CoM of loads in attempts 2 and 6 are the same, their energy consumption is different. Four containers are on each other in attempt 2. However, they are divided into  $2 \times 2$  in attempt 6. The SGV completed the mission in less time and energy consumption in attempt 6, showing the fact that the height of the CoM influences the dynamic properties of the SGV. Since this work develops the SGV kinetic model in 2D, it is not able to consider changes of CoM in the  $z$ -direction. So, a 3D kinetic model might be more useful when there are changes in loads' height. When SGV performs rotational motion with a heavy and long load, the effect of the moment of inertia would appear. Although this study tries to find energy-efficient motion by considering PoCoM, the estimated moment of inertia can be employed in future works to raise the energy efficiency of motion.

An interesting topic that can be considered in future work is the geometry of obstacles. The proposed local planner in this paper finds the optimal path to avoid obstacles by achieving the optimal vector of trajectories and considering PoCoM. In other words, it finds the optimal side to pass an obstacle (left or right) by considering PoCoM. It just calculates the required energy according to the front side

of the obstacle and assumes the left and right sides of the obstacle are the same. However, sometimes the obstacle has an asymmetric geometry, and the optimal side is unknown to the local planner. In this condition, machine learning algorithms such as classification methods can be employed to predict the type of geometry and help the local planner to find an energy-efficient side to pass obstacles. This study deals with static obstacles which cross over SGV's pass. However, dynamic obstacles might appear in environments. Hence, our future work will discuss the proposed method by considering dynamic obstacles.

Although SGV performs a mission for more than an hour in this study, it must work much more time in industrial surroundings and warehouses on a single battery charge. Hence, the proposed method can decrease the total energy consumption of SGV on a workday.

## VII. CONCLUSION

The current study proposed a new methodology to make energy-efficient local path planning for SGVs' navigation. First, this work used the newton-Euler method to develop a SGV kinetic model that takes into account the position and the weight of the added load. Hence, it included displacement of CoM on both longitudinal and lateral axes. Second, the created kinetic model was employed to generate a dataset with known inputs and outputs. The dataset was used to train two learning models which estimated CoM and required torque respectively. Regarding the nonlinearity of the kinetic model and the supervised dataset, MLP and LSTM methods were tried for the parameter estimation task. However, MLP was selected as the main parameters estimator with respect to the problem's condition and results of estimation. Finally, the two trained models were added to DWA as the local path planner of SGV navigation. DWA could generate trajectories by considering CoM and the required energy of sample trajectories. The simulations and experiment results proved the energy efficiency of the proposed method in comparison with the general DWA. This method can be used as a tool for all created local path planner algorithms in real-time missions. It will help them to consider the load position on SGVs to choose energy-efficient motion during turning in corridors or avoiding obstacles.

## APPENDIX A SGV'S MOTION EQUATIONS (PROOF OF EQUATION 6)

The motion equations of differential drive SGV are achieved in the following.

### A. KINEMATIC MOTION EQUATIONS

According to Figure 16, it is assumed that there is a load on SGV. Therefore, SGV's center of mass (point  $G$ ) moves to a new position. The position of point  $G$  is illustrated by  $r_x$  and  $r_y$  which are the distance between point  $G$  to the middle of the wheels' axis (point  $P$ ) in  $x$  and  $y$  directions respectively. Moreover, OXY and Pxy are reference coordinates (fixed) and body coordinates (moving) respectively.




FIGURE 16. SGV free body diagram.

By defining  $v$  as the linear velocity in  $x$  direction and  $\omega$  as the angular velocity of the vehicle around  $z$  direction the kinematic model is described:

$$\begin{bmatrix} \dot{X} \\ \dot{Y} \\ \dot{\theta} \end{bmatrix} = \begin{bmatrix} \cos \theta & 0 \\ \sin \theta & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} v \\ \omega \end{bmatrix} \quad (1)$$

By describing the variable generalized vector  $q$ , the Jacobian matrix  $s$ , and  $u$ :

$$q = \begin{bmatrix} X \\ Y \\ \theta \end{bmatrix}; \quad S = \begin{bmatrix} \cos \theta & 0 \\ \sin \theta & 0 \\ 0 & 1 \end{bmatrix}; \quad u = \begin{bmatrix} v \\ \omega \end{bmatrix} \quad (2a, b, c)$$

Equation (1) can be described as:

$$\dot{q} = Su \quad (3)$$

The linear velocity of the vehicle in the inertial coordinate is defined:

$$\vec{v}_P = \dot{X}\hat{I} + \dot{Y}\hat{J} \quad (4)$$

where  $\hat{I}$  and  $\hat{J}$  are unit vectors of inertial coordinate. Moreover,  $\hat{i}$  and  $\hat{j}$  are unit vectors of body coordinate. By defining the unit vector of body coordinate in the inertial coordinate:

$$\hat{j} = \cos \theta \hat{J} - \sin \theta \hat{I} \quad (5)$$

Vector projection of  $\vec{v}_P$  on the direction  $\hat{j}$  is:

$$\vec{v}_P \cdot \hat{j} = 0 \quad (6)$$

By substituting (4) and (5) in (6):

$$\begin{bmatrix} \dot{X} \\ \dot{Y} \\ 0 \end{bmatrix} \cdot \begin{bmatrix} -\sin \theta \\ \cos \theta \\ 0 \end{bmatrix} = 0 \quad (7)$$

So, velocity constraint which is a type of nonholonomic motion family is defined in the inertial coordinate:

$$-\sin \theta \dot{X} + \cos \theta \dot{Y} = 0 \quad (8)$$

Equation (8) can be rewritten as a closed form:

$$A\dot{q} = 0 \quad (9)$$

where  $A$  is the constraint matrix:

$$A = [-\sin \theta \quad \cos \theta \quad 0] \quad (10)$$

$$\dot{q} = [\dot{X} \quad \dot{Y} \quad \dot{\theta}]^T \quad (11)$$

The relation between wheels' angular velocities and vehicle's velocities according to point  $P$  can be described:

$$v = \frac{r}{2}(\dot{\phi}_r + \dot{\phi}_l) \quad (12)$$

$$\omega = \frac{r}{2b}(\dot{\phi}_r - \dot{\phi}_l) \quad (13)$$

where  $\dot{\phi}_r$  and  $\dot{\phi}_l$  are angular velocities of right and left wheels,  $b$  is the distance of each wheel to point  $P$ , and  $r$  is the radius of each wheel. Equations (12) and (13) can be written according to right and left wheels' angular velocities respectively:

$$\begin{aligned} \dot{\phi}_r &= \frac{1}{r}v + \frac{b}{r}\omega \\ \dot{\phi}_l &= \frac{1}{r}v - \frac{b}{r}\omega \end{aligned} \quad (14a, b)$$

### B. KINETIC MOTION EQUATIONS

The principle of virtual work should be used to find generalized forces. So, by defining the virtual movement in the body coordinate:

$$\begin{aligned} \delta\phi_r &= \frac{1}{r}\delta x + \frac{b}{r}\delta\theta \\ \delta\phi_l &= \frac{1}{r}\delta x - \frac{b}{r}\delta\theta \end{aligned} \quad (15a, b)$$

The virtual work of external forces and moments acting on the vehicle can be calculated:

$$f_x\delta x + f_y\delta y + \tau_\theta\delta\theta = \tau_r\delta\phi_r + \tau_l\delta\phi_l + \lambda\delta y \quad (16)$$

where  $f_x, f_y$  and  $\tau_\theta$  are generalized forces,  $\tau_r$  and  $\tau_l$  are torques of right and left wheels' motors, and  $\lambda$  is the constraint force. Substituting (15) in (16):

$$f_x\delta x + f_y\delta y + \tau_\theta\delta\theta = \frac{1}{r}(\tau_r + \tau_l)\delta x + \frac{1}{r}(\tau_r - \tau_l)\delta\theta + \lambda\delta y \quad (17)$$

So, the generalized forces can be calculated from (17):

$$\begin{aligned} f_x &= \frac{1}{r}(\tau_r + \tau_l) \\ \tau_\theta &= \frac{1}{r}(\tau_r - \tau_l) \\ f_y &= \lambda \end{aligned} \quad (18a, b, c)$$

The constrained force is appeared because of the impossibility of wheels slipping in the  $y$  direction. To define the constraint force in the inertial coordinate, it can be described:

$$\lambda\hat{j} = \lambda(-\sin \theta \hat{I} + \cos \theta \hat{J}) \quad (19)$$

Equation (19) can be rewritten in the matrix form:

$$\lambda\hat{j} = \begin{bmatrix} -\sin \theta \\ \cos \theta \\ 0 \end{bmatrix} \lambda = A^T \lambda \quad (20)$$

Moreover, it is clear that:

$$S^T A^T = 0 \quad (21)$$

Equation (21) shows the properties of the Natural Orthogonal Complement. So,  $f_x$  and  $f_y$  can be defined in  $X$  and  $Y$  directions:

$$\begin{aligned} f_X &= f_x \cos \theta - \lambda \sin \theta \\ &= \frac{1}{r} (\tau_r + \tau_l) \cos \theta - \lambda \sin \theta \end{aligned} \quad (22)$$

$$\begin{aligned} f_Y &= f_x \sin \theta + \lambda \cos \theta \\ &= \frac{1}{r} (\tau_r + \tau_l) \sin \theta + \lambda \cos \theta \end{aligned} \quad (23)$$

To find the motion equations:

$$\vec{r}_P = X\hat{I} + Y\hat{J} \quad (24)$$

$$\vec{r}_{G/P} = (r_x\hat{i} + r_y\hat{j}) \quad (25)$$

$$\begin{aligned} \vec{r}_G &= \vec{r}_P + \vec{r}_{G/P} \\ &= (X + r_x \cos \theta - r_y \sin \theta)\hat{I} \\ &\quad + (Y + r_x \sin \theta + r_y \cos \theta)\hat{J} \end{aligned} \quad (26)$$

where  $\vec{r}_P$  and  $\vec{r}_G$  are the position of points  $P$  and  $G$  in the inertial coordinate, and  $\vec{r}_{G/P}$  is the position of point  $G$  related to point  $P$ . By using (26), linear velocity  $\vec{v}_G$  and acceleration  $\vec{a}_G$  of CoM are defined:

$$\begin{aligned} \vec{v}_G &= (\dot{X} - r_x\dot{\theta} \sin \theta - r_y\dot{\theta} \cos \theta)\hat{I} \\ &\quad + (\dot{Y} + r_x\dot{\theta} \cos \theta - r_y\dot{\theta} \sin \theta)\hat{J} \end{aligned} \quad (27)$$

$$\begin{aligned} \vec{a}_G &= (\ddot{X} - r_x\ddot{\theta} \sin \theta - r_x\dot{\theta}^2 \cos \theta - r_y\ddot{\theta} \cos \theta + r_y\dot{\theta}^2 \sin \theta)\hat{I} \\ &\quad + (\ddot{Y} + r_x\ddot{\theta} \cos \theta - r_x\dot{\theta}^2 \sin \theta - r_y\ddot{\theta} \sin \theta - r_y\dot{\theta}^2 \cos \theta)\hat{J} \end{aligned} \quad (28)$$

To define the translation motion of the vehicle, the Newton method is used:

$$\sum \vec{F} = m\vec{a}_G \quad (29)$$

By dividing (29) into components of  $X$  and  $Y$  directions:

$$m(a_G)_X = f_X \quad (30)$$

$$m(a_G)_Y = f_Y \quad (31)$$

By substituting (22), (23), and (28) in (30) and (31):

$$\begin{aligned} m(\ddot{X} - r_x\ddot{\theta} \sin \theta - r_x\dot{\theta}^2 \cos \theta - r_y\ddot{\theta} \cos \theta + r_y\dot{\theta}^2 \sin \theta) \\ = \frac{1}{r} (\tau_r + \tau_l) \cos \theta - \lambda \sin \theta \end{aligned} \quad (32)$$

and

$$\begin{aligned} m(\ddot{Y} + r_x\ddot{\theta} \cos \theta - r_x\dot{\theta}^2 \sin \theta - r_y\ddot{\theta} \sin \theta - r_y\dot{\theta}^2 \cos \theta) \\ = \frac{1}{r} (\tau_r + \tau_l) \sin \theta + \lambda \cos \theta \end{aligned} \quad (33)$$

To define the rotational motion of the vehicle, the Euler method is used:

$$\sum \vec{M}_P = I_G \ddot{\theta} \hat{k} + \vec{r}_{G/P} \times m\vec{a}_G \quad (34)$$

By substituting (25) and (28) in (34):

$$\begin{aligned} \sum \vec{M}_P &= I_G \ddot{\theta} \hat{k} + m(r_x\hat{i} + r_y\hat{j}) \\ &\quad \times [(\ddot{X} - r_x\ddot{\theta} \sin \theta - r_x\dot{\theta}^2 \cos \theta - r_y\ddot{\theta} \cos \theta \\ &\quad + r_y\dot{\theta}^2 \sin \theta)\hat{I} + (\ddot{Y} + r_x\ddot{\theta} \cos \theta - r_x\dot{\theta}^2 \sin \theta \\ &\quad - r_y\ddot{\theta} \sin \theta - r_y\dot{\theta}^2 \cos \theta)\hat{J}] \end{aligned} \quad (35)$$

By defining  $\hat{I}$  and  $\hat{J}$  in the body coordination in (35), then simplifying and sorting:

$$\begin{aligned} (I_G + mr_x^2 + mr_y^2)\ddot{\theta} - m(r_x \sin \theta + r_y \cos \theta)\ddot{X} \\ + m(r_x \cos \theta - r_y \sin \theta)\ddot{Y} = \frac{b}{r}(\tau_r - \tau_l) \end{aligned} \quad (36)$$

So, the closed-form of the motion equation that is obtained by using the Newton-Euler method:

$$M(q)\ddot{q} + C(q, \dot{q}) = B(q)\tau + A^T \lambda \quad (37)$$

where:

$$M(q) = \begin{bmatrix} m & 0 & M(q)_{13} \\ 0 & m & M(q)_{23} \\ M(q)_{31} & M(q)_{32} & M(q)_{33} \end{bmatrix} \quad (38a)$$

$$M(q)_{13} = -m(r_x \sin \theta + r_y \cos \theta) \quad (38b)$$

$$M(q)_{23} = m(r_x \cos \theta - r_y \sin \theta) \quad (38c)$$

$$M(q)_{31} = -m(r_x \sin \theta + r_y \cos \theta) \quad (38d)$$

$$M(q)_{32} = m(r_x \cos \theta - r_y \sin \theta) \quad (38e)$$

$$M(q)_{33} = I_G + m(r_x^2 + r_y^2) \quad (38f)$$

$$C(q, \dot{q}) = \begin{bmatrix} -m(r_x \cos \theta - r_y \sin \theta)\dot{\theta}^2 \\ -m(r_x \sin \theta + r_y \cos \theta)\dot{\theta}^2 \\ 0 \end{bmatrix} \quad (39)$$

$$B(q) = \begin{bmatrix} \cos \theta & \cos \theta \\ \sin \theta & \sin \theta \\ b & -b \end{bmatrix} \quad (40)$$

$$\tau = \begin{bmatrix} \tau_r \\ \tau_l \end{bmatrix} \quad (41)$$

The constraint force  $\lambda$  can be removed in (37) by using (21). So, the Jacobian matrix  $S$  is multiplied in (38):

$$S^T M(q)\ddot{q} + S^T C(q, \dot{q}) = S^T B(q)\tau + S^T A^T \lambda \quad (42)$$

So,  $\lambda$  is eliminated:

$$S^T M(q)\ddot{q} + S^T C(q, \dot{q}) = S^T B(q)\tau \quad (43)$$

By substituting the derivative of (2) in (37) and sorting:

$$(S^T M S)\dot{u} + (S^T M \dot{S})u + S^T C = S^T B \tau \quad (44)$$

where:

$$\dot{u} = \begin{bmatrix} \dot{\theta} \\ \dot{\theta} \end{bmatrix} \quad (45)$$

By simplifying and sorting (44), the kinetic motion equation of the differential drive SGV is achieved:

$$\begin{aligned} & \begin{bmatrix} m & -mr_y \\ -mr_y & I_G + m(r_x^2 + r_y^2) \end{bmatrix} \begin{bmatrix} \dot{v} \\ \dot{w} \end{bmatrix} \\ & + \begin{bmatrix} 0 & -mr_x w \\ mr_x w & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} \\ & = \frac{1}{r} \begin{bmatrix} 1 & 1 \\ b & -b \end{bmatrix} \begin{bmatrix} \tau_r \\ \tau_l \end{bmatrix} \end{aligned} \quad (46)$$

**APPENDIX B FORMULATIONS OF MLP AND LSTM METHODS**

The formulations of MLP and LSTM methods' equations are described in the following.

**C. MLP**

The MLP is one of the most popular feed-forward artificial neural network (ANN) architectures for supervised multi-estimation and nonlinear problems. The back-propagation (BP) model is the most used among different types of MLP models. MLP includes at least three layers: (i): input layer(s), (ii): hidden layer(s), and (iii): an output layer(s). It works by approximating the non-linear relationship between the input and the output by adjusting the weight values internally. It has two main processes. Firstly, input signals are transformed into output layers by using a nonlinear activation function. Then, the prediction error is back-propagated to tune the weights. The process continues until the prediction error converges to a stable value.

The data transformation and the back-propagation process are expressed respectively in the following equations [31].

$$y_j^m(n) = f \left( \sum_{k=0}^p w_{ji}^k(n) y_i^k(n) \right) \quad (1)$$

$$w(n+1) = w(n) - \eta \frac{\partial E_p}{\partial w(n)} + \alpha \Delta w(n) \quad (2)$$

where  $y_j^m(n)$  shows the output of the  $m$ th neuron of the  $j$ th layer and  $f(x)$  is the activation function.  $p$  defines the total number of the  $i$ th layer, and  $w_{ji}^k(n)$  is the connection weight from the  $k$ th node of  $i$ th layer at the  $n$ th iteration. Moreover,  $w(n)$  defines the weights at  $n$ th iteration and  $\eta$  is the learning rate.  $E_p$  denotes the prediction error, and  $\alpha$  is the momentum parameter that can accelerate the convergence.

**D. LSTM**

LSTM is a sort of Recurrent Neural Network (RNN) in the field of Deep Learning that has been specifically developed for the use of addressing sequential prediction problems. It includes a cell to remember values over arbitrary time intervals and three gates of forget  $f_g$ , input  $i_g$  and output  $o_g$  to regulate the flow of information into and out of the cell. To solve the problem of disappearing gradients, LSTM structure is a beneficial solution. A detailed description can be found in [32].




FIGURE 17. The Self-Guided Vehicle.

TABLE 4. SGV characteristic.

Parameter	Value
Vehicle Weight ( $m$ )	82 kg
Moment of inertia around z-direction ( $I_z$ )	5.5 kg.m <sup>2</sup>
Distance of each wheel to point $P$ ( $b$ )	38 cm
Wheel's radius	10 cm
Dimensions (length $\times$ width $\times$ height)	165 $\times$ 76 $\times$ 23 cm
Position of Center of Mass (length, width) with respect to point $P$	-4 $\pm$ 1 cm, -2 $\pm$ 1 cm

The equations of LSTM method are displayed as [33]:

$$g_c(t) = phi(W_{gx}a(t) + W_{gh}h(t-1) + b_g) \quad (3)$$

$$i_g(t) = \sigma(W_{ix}a(t) + W_{ih}h(t-1) + b_i) \quad (4)$$

$$f_g(t) = \sigma(W_{fx}a(t) + W_{fh}h(t-1) + b_f) \quad (5)$$

$$o_g(t) = \sigma(W_{ox}a(t) + W_{oh}h(t-1) + b_o) \quad (6)$$

$$s(t) = g_c(t)i_g(t) + s(t-1)f_g(t) \quad (7)$$

$$h(t) = \phi(s(t)o_g(t)) \quad (8)$$

where  $W_{gx}$ ,  $W_{ix}$ ,  $W_{fx}$  and  $W_{ox}$  indicate the correlation weight matrices;  $a(t)$  and  $h(t)$  represents the inputs and outputs of an LSTM block at time step  $t$ ; Also,  $b_g$ ,  $b_i$ ,  $b_f$ ,  $b_o$  are biases of input node, input gate, forget gate, and output gate respectively.  $\sigma$  and  $\phi$  indicate sigmoid and hyperbolic tangent nonlinear activation functions.

**APPENDIX C PROPERTIES OF SGV, LOADS AND ENVIRONMENT**

**E. SGV**

The SGV has a differential drive and is configured by a Mini PC with Ubuntu 18.04 LTS operating system and ROS Navigation Stack. According to Figure 17, SGV includes two lidars to perceive the environment and two motors to move it. Moreover, the properties of SGV are displayed in Table 4.

**F. LOADS**

Five storage containers are considered as loads on the platform. Figure 18 shows them on the platform and their



FIGURE 18. Loads on the platform.




FIGURE 19. Real global CoM ( $CoM_g$ ) on the platform for six scenarios.



FIGURE 20. The experimental test's environment.

properties are displayed in Table 5. According to the scenarios' details, their positions are different on the platform.

Figure 19 displays the position of real global CoM (approximately) on the platform (green points) for all attempts where subscripts 1 to 6 mean attempt' number. Moreover, the red

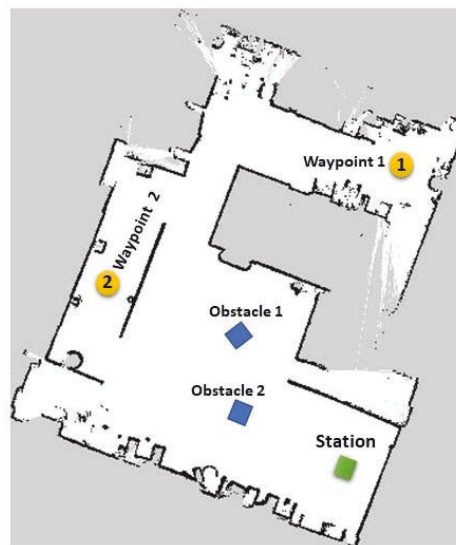


FIGURE 21. The map of experimental test's environment on rviz.

TABLE 5. Characteristics of each Load.

Parameter	Value
Weight	18.5 kg
Dimensions (length × width × height)	30 × 21 × 18 cm
Position of Center of Mass (length, width)	15±0.5 cm, 10.5±0.5 cm

and orange points show the middle of the wheels' axis ( $P$ ) and the inertial CoM ( $CoM_i$ ) respectively.

### G. ENVIRONMENT

The environment of experimental test and its map are presented in Figures 20 and 21. Positions of the station, two obstacles, and waypoints 1 and 2 are displayed on the map.

### REFERENCES

- [1] E. A. Oyekanlu, A. C. Smith, W. P. Thomas, G. Mulroy, D. Hitesh, M. Ramsey, D. J. Kuhn, J. D. Mcghinnis, S. C. Buonavita, N. A. Looper, M. Ng, A. Ng'oma, W. Liu, P. G. McBride, M. G. Shultz, C. Cerasi, and D. Sun, "A review of recent advances in automated guided vehicle technologies: Integration challenges and research areas for 5G-based smart manufacturing applications," *IEEE Access*, vol. 8, pp. 202312–202353, 2020, doi: 10.1109/ACCESS.2020.3035729.
- [2] X. Liu, G. Wang, and K. Chen, "Nonlinear model predictive tracking control with C/GMRES method for heavy-duty AGVs," *IEEE Trans. Veh. Technol.*, vol. 70, no. 12, pp. 12567–12580, Dec. 2021, doi: 10.1109/TVT.2021.3123176.
- [3] S. Riazi, K. Bengtsson, and B. Lennartson, "Energy optimization of large-scale AGV systems," *IEEE Trans. Autom. Sci. Eng.*, vol. 18, no. 2, pp. 638–649, Apr. 2021.
- [4] M. Graba, S. Kelouwani, L. Zeghmi, A. Amamou, K. Agbossou, and M. Mohammadpour, "Investigating the impact of energy source level on the self-guided vehicle system performances, in the industry 4.0 context," *Sustainability*, vol. 12, no. 20, p. 8541, Oct. 2020.
- [5] J. Peng, X. Zhou, S. Jia, Y. Jin, S. Xu, and J. Chen, "High precision strain monitoring for lithium ion batteries based on fiber Bragg grating sensors," *J. Power Sources*, vol. 433, Sep. 2019, Art. no. 226692.
- [6] B. K. Patle, A. Pandey, D. R. K. Parhi, and A. Jagadeesh, "A review: On path planning strategies for navigation of mobile robot," *Defence Technol.*, vol. 15, pp. 582–606, Aug. 2019.

- [7] P. E. Hart, N. J. Nilsson, and B. Raphael, "A formal basis for the heuristic determination of minimum cost paths," *IEEE Trans. Syst. Sci. Cybern.*, vol. SSC-4, no. 2, pp. 100–107, Jul. 1968.
- [8] M. Chaudhari, L. Vachhani, and R. Banerjee, "Towards optimal computation of energy optimal trajectory for mobile robots," *IFAC Proc. Volumes*, vol. 47, no. 1, pp. 82–87, 2014.
- [9] F. Valero, F. Rubio, and C. Llopis-Albert, "Assessment of the effect of energy consumption on trajectory improvement for a car-like robot," *Robotica*, vol. 37, no. 11, pp. 1998–2009, Nov. 2019.
- [10] L. Xie, C. Henkel, K. Stol, and W. Xu, "Power-minimization and energy-reduction autonomous navigation of an omnidirectional Mecanum robot via the dynamic window approach local trajectory planning," *Int. J. Adv. Robot. Syst.*, vol. 15, no. 1, 2018, Art. no. 1729881418754563.
- [11] A. Alajlan, K. Elleithy, M. Almasri, and T. Sobh, "An optimal and energy efficient multi-sensor collision-free path planning algorithm for a mobile robot in dynamic environments," *Robotics*, vol. 6, no. 2, p. 7, Mar. 2017.
- [12] H. Kim and B.-K. Kim, "Minimum-energy translational trajectory planning for battery-powered three-wheeled omni-directional mobile robots," in *Proc. 10th Int. Conf. Control, Autom., Robot. Vis.*, Dec. 2008, pp. 1730–1735, doi: 10.1109/ICARCV.2008.4795788.
- [13] M. Salazar, A. Alessandretti, A. P. Aguiar, and C. N. Jones, "An energy efficient trajectory tracking controller for car-like vehicles using model predictive control," in *Proc. 54th IEEE Conf. Decis. Control (CDC)*, Dec. 2015, pp. 3675–3680, doi: 10.1109/CDC.2015.7402789.
- [14] A. Parra, D. Tavernini, P. Gruber, A. Sornioti, A. Zubizarreta, and J. Perez, "On nonlinear model predictive control for energy-efficient torque-vectoring," *IEEE Trans. Veh. Technol.*, vol. 70, no. 1, pp. 173–188, Jan. 2021, doi: 10.1109/TVT.2020.3022022.
- [15] M. A. Ali and M. Mailah, "A simulation and experimental study on wheeled mobile robot path control in road roundabout environment," *Int. J. Adv. Robot. Syst.*, vol. 16, no. 2, 2019, Art. no. 1729881419834778.
- [16] M. F. Jaramillo-Morales, S. Dogru, and L. Marques, "Generation of energy optimal speed profiles for a differential drive mobile robot with payload on straight trajectories," in *Proc. IEEE Int. Symp. Saf., Secur., Rescue Robot. (SSRR)*, Nov. 2020, pp. 136–141.
- [17] J. L. Meriam, L. G. Kraige, and J. N. Bolton, *Engineering Mechanics: Dynamics*. Hoboken, NJ, USA: Wiley, 2020.
- [18] M. Mohammadpour, L. Zeghmi, S. Kelouwani, M.-A. Gaudreau, A. Amamou, and M. Graba, "An investigation into the energy-efficient motion of autonomous wheeled mobile robots," *Energies*, vol. 14, no. 12, p. 3517, Jun. 2021.
- [19] B. B. Mevo, M. R. Saad, and R. Fareh, "Adaptive sliding mode control of wheeled mobile robot with nonlinear model and uncertainties," in *Proc. IEEE Can. Conf. Electr. Comput. Eng. (CCECE)*, May 2018, pp. 1–5.
- [20] Y. Jin and Chen, "Advanced estimation techniques for vehicle system dynamic state: A survey," *Sensors*, vol. 19, no. 19, p. 4289, Oct. 2019. [Online]. Available: <https://www.mdpi.com/1424-8220/19/19/4289>
- [21] G. Reina, M. Paiano, and J.-L. Blanco-Claraco, "Vehicle parameter estimation using a model-based estimator," *Mech. Syst. Signal Process.*, vol. 87, pp. 227–241, Mar. 2017, doi: 10.1016/j.ymsp.2016.06.038.
- [22] X. Jin and G. Yin, "Estimation of lateral tire–road forces and sideslip angle for electric vehicles using interacting multiple model filter approach," *J. Franklin Inst.*, vol. 352, no. 2, pp. 686–707, Feb. 2015, doi: 10.1016/j.jfranklin.2014.05.008.
- [23] R. Rajamani, G. Phanomchoeng, D. Piyabongkarn, and J. Y. Lew, "Algorithms for real-time estimation of individual wheel tire-road friction coefficients," *IEEE/ASME Trans. Mechatronics*, vol. 17, no. 6, pp. 1183–1195, Dec. 2012, doi: 10.1109/TMECH.2011.2159240.
- [24] C. Ren, X. Li, X. Yang, and X. Ma, "Extended state observer-based sliding mode control of an omnidirectional mobile robot with friction compensation," *IEEE Trans. Ind. Electron.*, vol. 66, no. 12, pp. 9480–9489, Dec. 2019, doi: 10.1109/TIE.2019.2892678.
- [25] Y. Wei, X. Zhang, Y. Shi, L. Xia, S. Pan, J. Wu, M. Han, and X. Zhao, "A review of data-driven approaches for prediction and classification of building energy consumption," *Renew. Sustain. Energy Rev.*, vol. 82, pp. 1027–1047, Feb. 2018, doi: 10.1016/j.rser.2017.09.108.
- [26] R. J. Hyndman and A. B. Koehler, "Another look at measures of forecast accuracy," *Int. J. Forecasting*, vol. 22, no. 4, pp. 679–688, 2006.
- [27] D. Fox, W. Burgard, and S. Thrun, "The dynamic window approach to collision avoidance," *IEEE Robot. Autom. Mag.*, vol. 4, no. 1, pp. 23–33, Mar. 1997, doi: 10.1109/100.580977.
- [28] K. Takaya, T. Asai, V. Kroumov, and F. Smarandache, "Simulation environment for mobile robots testing using ROS and gazebo," in *Proc. 20th Int. Conf. Syst. Theory, Control Comput. (ICSTCC)*, Oct. 2016, pp. 96–101, doi: 10.1109/ICSTCC.2016.7790647.
- [29] Accessed: Jan. 20, 2022. [Online]. Available: <https://www.ros.org/>
- [30] R. Szczepanski, T. Tarczewski, and K. Erwinski, "Energy efficient local path planning algorithm based on predictive artificial potential field," *IEEE Access*, vol. 10, pp. 39729–39742, 2022.
- [31] H. You, Z. Ma, Y. Tang, Y. Wang, J. Yan, M. Ni, K. Cen, and Q. Huang, "Comparison of ANN (MLP), ANFIS, SVM, and RF models for the online classification of heating value of burning municipal solid waste in circulating fluidized bed incinerators," *Waste Manage.*, vol. 68, pp. 186–197, Oct. 2017, doi: 10.1016/j.wasman.2017.03.044.
- [32] Z. C. Lipton, J. Berkowitz, and C. Elkan, "A critical review of recurrent neural networks for sequence learning," 2015, *arXiv:1506.00019*.
- [33] C. Zheng, S. Wang, Y. Liu, C. Liu, W. Xie, C. Fang, and S. Liu, "A novel equivalent model of active distribution networks based on LSTM," *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 30, no. 9, pp. 2611–2624, Sep. 2019, doi: 10.1109/TNNLS.2018.2885219.



**MOHAMMAD MOHAMMADPOUR** received the B.S. degree in mechanical engineering and the master's degree in aerospace engineering from the Amirkabir University of Technology, Tehran, Iran, in 2011 and 2014, respectively. He is currently pursuing the Ph.D. degree with the Department of Mechanical Engineering, University of Quebec at Trois-Rivières (UQTR), Trois-Rivières, QC, Canada. His research interests include mobile robotics, motion planning, machine learning, dynamic, and control.




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





**MARC-ANDRÉ GAUDREAU** received the Ph.D. degree in industrial acoustics from the École de Technologie Supérieure (ÉTS), Montréal, QC, Canada, in 2016. He has been a Professor with the Department of Mechanical Engineering, University of Quebec at Trois-Rivières (UQTR), since 2017, where he started the novel DUAL approach in the Drummondville Campus of UQTR. He is the Scientific Co-Director of the UQTR’s Research Center on Intelligent Manufacturing.

He is the holder of an Industrial Chair in the development of manufacturing intelligence, powered by Noovelia. On top of his original expertise, he is working with the Canada Research Chair in Energy Optimization of Intelligent Transport Systems with Prof. Kelouwani on energy optimization of autonomous industrial vehicles.



**ALI AMAMOU** (Member, IEEE) received the B.S. degree in industrial computing and automatic science from the National Institute of Applied Sciences and Technology, Tunis, Tunisia, in 2013, the M.S. degree in embedded systems science from the Arts et Métiers ParisTech University, Aix en Provence, France, in 2014, and the Ph.D. degree in electrical engineering from the University of Quebec at Trois-Rivières (UQTR), Trois-Rivières, QC, Canada, in 2018. In May 2018, he started as a

Postdoctoral Fellow at the Hydrogen Research Institute. His main research interests include optimization of energy systems for stationary and mobile applications, hybridization of energy sources for vehicular applications, and eco-energy navigation of the low-speed autonomous electric vehicle.



**BILEL ALLANI** received the B.S. degree in industrial and automatic computing from the National Institute of Applied Sciences and Technologies, Tunisia, in 2020. He is currently pursuing the master’s degree in electrical and computer engineering with the University of Quebec at Trois-Rivières (UQTR), Trois-Rivières, QC, Canada. His research interests include multiple mobile robot systems and charging strategies.



**LOTFI ZEGHMI** received the B.S. degree in control systems from the University of Science and Technology Houari Boumediene (USTHB), Algiers, Algeria, in 2017, and the master’s degree in electrical engineering from the University of Quebec at Trois-Rivières (UQTR), Trois-Rivières, QC, Canada, in 2020. He is currently a Research Assistant with the UQTR. His research interests include mobile robotics and control systems.



**MASSINISSA GRABA** received the B.S. degree in control and automation engineering from the Institute of Electrical and Electronic Engineering (IGEE-UMBB), Algeria, and the M.Sc. degree in smart aerospace and autonomous systems from the Université de Paris-Saclay, France, and Poznan University of Technology, Poland. He is currently pursuing the Ph.D. degree in electrical and computer engineering with the University of Quebec at Trois-Rivières (UQTR), Trois-Rivières, QC,

Canada. His research interest includes safe and energy-efficient trajectory planning of self-guided industrial vehicles in the context of sustainable manufacturing.

...

.2.3 *L'article 3*



# Energy-efficient motion planning of an autonomous forklift using deep neural networks and kinetic model

Mohammad Mohammadpour<sup>a,\*</sup>, Sousso Kelouwani<sup>a</sup>, Marc-André Gaudreau<sup>a</sup>, Lotfi Zeghmi<sup>b</sup>, Ali Amamou<sup>b</sup>, Hossein Bahmanabadi<sup>c</sup>, Bilel Allani<sup>b</sup>, Massinissa Graba<sup>b</sup>

<sup>a</sup> Department of Mechanical Engineering, Hydrogen Research Institute, University of Québec at Trois-Rivières, Trois-Rivières, G8Z 4M3, QC, Canada

<sup>b</sup> Department of Electrical and Computer Engineering, Hydrogen Research Institute, University of Québec at Trois-Rivières, Trois-Rivières, G8Z 4M3, QC, Canada

<sup>c</sup> Department of Mechanical Engineering, Sharif University of Technology, Tehran, Iran

## ARTICLE INFO

### Keywords:

Industry 4.0  
Energy efficiency  
Autonomous forklift  
Motion planning  
Deep neural networks  
Kinetic model  
Optimization

## ABSTRACT

Autonomous Forklifts (AFs) play a vital role in smart factories, particularly in the transportation of heavy loads. However, their energy consumption poses a significant challenge as they need to operate for extended periods on a single battery charge. Therefore, energy-efficient motion is necessary to raise their availability. The AF's movement is dynamically determined by a motion planning algorithm within its navigation system. In light of this, this article introduces a strategy to improve energy efficiency during the motion planning phase. This strategy involves a cooperative approach, utilizing the Deep Neural Networks (DNNs) and AF's kinetic model to achieve this energy-saving goal. Unlike traditional methods that rely solely on the vehicle's kinematic model, our approach considers an additional factor, incorporating the influence of the vehicle's kinetic model for a more comprehensive and accurate energy consumption analysis. First, the kinetic model of an AF is developed by considering the effect of the front-powered wheel. Second, the kinetic model is employed within a time-energy optimization technique, aiming to find the AF's ideal acceleration. This optimization process generates a dataset that covers a range of AF maneuvers and dynamic parameters. Third, a DNNs model is trained using this dataset to predict the optimal acceleration for the AF. Finally, the trained model is integrated into a motion planning algorithm to determine the optimal and acceptable limits for both linear and angular acceleration. Experiments illustrate that the suggested motion planning method can generate trajectories that are both feasible and optimized for energy consumption. This differs significantly from the typical algorithms which generally results in higher energy use by the AF, occasionally leading to the generation of infeasible trajectories.

## 1. Introduction

Industry 4.0, also known as the Fourth Industrial Revolution, is a term used to describe the integration of advanced technologies such as artificial intelligence, the Internet of Things, cloud computing, and big data analytics into industrial processes (Ahmed, Jeon, & Piccialli, 2022). The smart factory is one of the main applications of Industry 4.0, where production processes are optimized through the use of advanced technologies (Dey, Bhuniya, & Sarkar, 2021). Regarding the reduction of costs and the improvement of environmental sustainability, energy efficiency is a critical issue in smart factories (Chen, Zhong, Mumtaz, Zhou, & Zhu, 2023). It can be achieved through the use of renewable energy sources, energy-efficient technologies, energy management

systems, and energy optimization consumption in real-time (Abbas & Zhang, 2023; Cai et al., 2022).

One of the most important parts of smart factories is Autonomous Vehicles (AVs) such as Autonomous Forklifts (AF), Automated Guided Vehicles (AGVs), and Autonomous Mobile Robots (AMRs). According to the level of their autonomy, they are equipped with sensors, cameras, and mapping technology that allow them to navigate autonomously on the factory floor and avoid obstacles (Bonab, Ghouschi, Deveci, & Haseli, 2023). They play a crucial role in the transportation of goods and materials within smart factories (Gültekin, Cinar, Özkan, & Yazıcı, 2022). Moreover, they include many advantages like the increase in efficiency, safety, flexibility, and decrease in cost. However, since they

\* Corresponding author.

E-mail addresses: [mohammad.mohammadpour@uqtr.ca](mailto:mohammad.mohammadpour@uqtr.ca) (M. Mohammadpour), [sousso.kelouwani@uqtr.ca](mailto:sousso.kelouwani@uqtr.ca) (S. Kelouwani), [marc-andre.gaudreau@uqtr.ca](mailto:marc-andre.gaudreau@uqtr.ca) (M.-A. Gaudreau), [lotfi.zeghmi@uqtr.ca](mailto:lotfi.zeghmi@uqtr.ca) (L. Zeghmi), [ali.amamou@uqtr.ca](mailto:ali.amamou@uqtr.ca) (A. Amamou), [hossein.bahmanabadi@mech.sharif.edu](mailto:hossein.bahmanabadi@mech.sharif.edu) (H. Bahmanabadi), [bilel.allani@uqtr.ca](mailto:bilel.allani@uqtr.ca) (B. Allani), [massinissa.graba@uqtr.ca](mailto:massinissa.graba@uqtr.ca) (M. Graba).

<sup>1</sup> This work was supported by the Industrial Research Chair Noovelvia and by the Natural Science and Engineering Research Council of Canada.

rely on batteries to power their motors and control systems, any energy and battery problems can significantly affect the performance of these vehicles (Graba et al., 2020). In addition, the increasing demand for electric vehicles is driving up the cost of batteries, creating significant pressure to find cost-saving solutions (Allani et al., 2022). One possible solution is to improve the energy efficiency of these vehicles and extend the lifespan of the batteries. Lithium-ion batteries are known to be sensitive to the depth-of-discharge (DoD), and since most electric AVs are designed to operate for a full shift, optimizing energy efficiency during motion can reduce DoD and prolong the battery's life (Mejri, Kelouwani, Dubé, Henao, & Agbossou, 2022). Therefore, it is essential to optimize the energy efficiency of the entire navigation system in these vehicles to address this issue.

AV's navigation is initiated by perception, which involves identifying essential information regarding the vehicle's environment (Patle, Pandey, Parhi, Jagadeesh, et al., 2019). The collected data is then used in the mapping stage to generate an environment model (Meysami, Cuillière, François, & Kelouwani, 2022). Using the model, the localization determines the vehicle's position (Zeghmi, Amamou, Kelouwani, Boisclair, & Agbossou, 2022). Path planning specifies the appropriate path from the start to the goal points and the motion planner generates proper trajectories to follow the global path (Liu et al., 2023). Finally, the motion control executes the necessary inputs (force, torque) of motors to move the AV in a controlled manner. Among the navigation stages, path planning, motion planning, and motion control affect directly AV's motors energy consumption. Hence, they have been improved by different methods and algorithms in the literature to achieve an energy-efficient application (Mohammadpour et al., 2021). For instance, the path planner has been upgraded by considering conflict-free paths in a transport road map (Graba et al., 2023; Xin, Wei, D'Ariano, Zhang, & Negenborn, 2023), employing optimization algorithms (Wu, Huang, Cui, Liu, & Xiao, 2023; Zhang, Wu, Zhang, Peng, & Zheng, 2021) and adding energy cost model (Zhang, Zhang, Liu, & Zhang, 2023). Moreover, motion control methods have been improved by using optimal control theory to achieve optimal velocity trajectory (Kim & Kim, 2008), adding energy costs to model-based methods (Parra et al., 2020; Salazar, Alessandretti, Aguiar, & Jones, 2015), and acceleration curve optimization (Li & Liu, 2019).

Several studies have proposed various methods to improve energy-efficient motion, a crucial aspect for optimizing the operation of robots without frequent charging. However, limited attention has been given to examining the motion planning component. The energy-efficient motion planners have been proposed by adding energy terms into the cost function of dynamic window methods (Mohammadpour et al., 2022), solving the problem of local minima (Szczepanski, Tarczewski, & Erwinski, 2022) and combining of classic methods (Wang, Meng, & Khatib, 2020). Gupta, Ordonez, and Collins (2017) delved into the development of dynamic models for skid-steered wheeled vehicles, a significant class of AGVs. These models were experimentally verified and used to create a power consumption model for such vehicles. Using sampling-based model predictive optimization, the authors devised a methodology for generating energy-efficient trajectories. The findings revealed that even a slight increase in trajectory distance could result in substantial energy savings for the AGV.

Varghese and Jisha (2018) presented an efficient method for planning the motion of AMRs, building on the Rapidly Exploring Random Tree (RRT) algorithm. The authors discussed an enhanced RRT variant tailored for differential-driven mobile robots. This enhanced variant included a closed-loop post-process for generating the robot's control sequence. The motion planning system was integrated with a controller, utilized in two specific ways: (i) to minimize the positional errors between the planned and actual paths, and (ii) to correct errors in orientation. Two types of controllers, a PI (Proportional-Integral) controller, and a pure pursuit controller, were employed to achieve these objectives. Xie, Henkel, Stol, and Xu (2018) proposed the energy-efficient algorithm by using the Dynamic Window Approach (DWA),

which incorporated the robot's energy consumption model into the cost function. By adjusting the constant gains, they were able to achieve varying degrees of reduction in energy consumption.

Xidias and Azariadis (2019) described an approach for designing an energy-efficient motion and task scheduling for an AV that was moving in complicated environments in the industrial sector or in large warehouses. The vehicle was requested to serve a number of workstations while moving safely and efficiently in the environment. In the proposed approach, the overall problem was formulated as a constraint optimization problem by using the Bump-Surface concept. Then, a Pareto-based multi-objective optimization strategy was adopted, and a modified genetic algorithm was developed to determine the Pareto optimum solution. The efficiency of the developed method was investigated and discussed through simulated experiments. Zhang, Zhang, et al. (2023) addressed the significant concern of energy consumption in the navigation of AGVs. While existing research focused primarily on skid or differential steering vehicles, this study aimed to fill the gap concerning Ackermann steering vehicles. An energy cost model was first established based on the kinematic constraints of the vehicle. Energy-aware motion primitives were then precomputed offline, using this model to assess the energy cost of various primary trajectories. The proposed motion planner's effectiveness was validated through simulations on 150 randomly generated maps and real vehicle tests.

Szczepanski et al. (2022) proposed an energy-efficient motion planning approach utilizing predictive Artificial Potential Field (APF) in recent research on this topic. Their approach was able to decrease energy consumption in small robots. However, they ignored the effect of the robot's kinetic (dynamic) model and changes in the robot's inertia parameters. In a recent study, although Mohammadpour et al. (2022) considered the load effect on an AMR's inertia parameters to define energy-efficient motion planning, they ignored the impact of AMR's acceleration. Consequently, the articles under consideration did not investigate the effects of the feasibility of trajectories on energy consumption.

While both the global planning and motion control stages influence the energy consumption of AVs, the motion planning stage holds the most significant impact. Global planning methods might only take into account the vehicle's kinematic constraints (Graba, Mamala, Bieniek, & Sroka, 2021; Wang, Li, & Meng, 2021). Moreover, motion control is tasked with generating the appropriate inputs for the AV's motors to adhere to defined trajectories, optimal or not. In contrast, the motion planning stage extends beyond these considerations. It accommodates the constraints of the AV's dynamic parameters and dynamically adjusts to environmental changes, such as unforeseen obstacles (Deng, Li, Zhao, Wang, & Gui, 2021). Given that factory and warehouse environments are highly dynamic, the motion planner algorithm must be capable of updating trajectories in short time intervals dynamically (Malviya & Kala, 2021). Thus, any suboptimal decisions made during trajectory generation have the potential to significantly affect the AV's energy consumption.

The motion planner stage includes different types of methods which among them dynamic windows (Fox, Burgard, & Thrun, 1997), model predictive control (Rösmann, Makarow, & Bertram, 2021), and trajectory optimization (Zhang, Chai, Chai, Xia, & Tsourdos, 2023) are more popular. Despite the considerable research that has been conducted in the field of motion planning, one important aspect that has escaped the attention of researchers, particularly in energy-efficient problems, is the impact of acceleration on energy consumption. Moreover, since most AVs' main task is load transportation, their dynamic inertia parameters such as mass, moment of inertia (MoI), and position of center of mass (PoCoM) change on each mission. The effect of these changes can be seen in the AV's kinetic model. Therefore, motion planner methods require reasonably a kinetic model to consider changes affected by load and acceleration which is discussed in the following by focusing on AFs.

According to load transportation tasks in the indoor industry, AFs are more useful to lift and move heavy loads, with some models capable

of carrying up to many tons (Dormehl, 2020; Pamučar & Ćirović, 2015). In contrast, AGVs and AMRs have lower load capacities and may not be suitable for heavy-duty lifting applications. AFs are typically designed with a car-like steering system, however, AGVs and AMRs use more different types of drivers depending on their design and application such as differential and omnidirectional drives. Regarding the complexity of a car-like dynamic system, motion planning for AFs can be more challenging than for AGVs and AMRs. Since the AF's motion is a combination of translational and rotational motion, it is more difficult for the motion planner algorithm to predict how the vehicle will move in different situations (Scheuer & Fraichard, 1997). For example, the turning radius of a car-like system is dependent on both the vehicle's linear velocity and its steering angle, whereas, in differential or omnidirectional drives, the turning radius can be controlled independently of the vehicle's linear velocity.

Changes in AF's dynamic inertia parameters can affect its acceleration. The more massive the load, the more energy is required to accelerate the vehicle. Therefore, the acceleration must be adjusted regarding the load properties, and this can have a significant impact on energy consumption (Galvin, 2017). One way to manage the AF's acceleration is to set online its bounds when the motion planner is generating trajectories. If the acceleration is limited too much, it can have a negative impact on energy consumption. In this condition, the vehicle needs to maintain a higher power output (regarding acceleration bounds) for a longer period of time to reach its desired speed, and this can cause the battery to drain faster. Furthermore, this situation increases the overall travel time of the vehicle to finish a maneuver which is another reason to raise the energy consumption (Chen & Liao, 2011). This is especially important in a warehouse or factory environment where the AF is required to perform multiple tasks and complete them in a timely manner (Tang, Cheng, Jiang, & Chen, 2021). On the contrary, the high acceleration bound in the motion planning stage causes the AF performs maneuvers quickly and reach the goal point in less time. However, it causes more frequent and abrupt changes in speed. This can result in higher energy consumption due to increased rolling resistance (Duleba & Sasiadek, 2003). Additionally, the AF may need to operate at a higher torque level for shorter periods of time, but more frequently, to achieve the desired acceleration and deceleration, which can also increase energy consumption (Karamuk, SAVCI, & Ocakli, 2022).

The setting of acceleration limits during the motion planning stage can also impact the energy consumption of an AF in different ways. Since motion planning algorithms typically overlook the vehicle's kinetic model, they may not adequately consider the feasible acceleration for the AF in each time step. This oversight can lead to the generation of trajectories that are not dynamically viable or comfortable for the vehicle (Hegedüs, Bécsi, Aradi, & Gápár, 2017). Consequently, the AF could get trapped in complex maneuvers, oscillating between different trajectories as it seeks a feasible path. This process could continue until the motion planner identifies a physically plausible solution or a manual reset of the navigation stack is performed (Li, Yamashita, Asama, & Tamura, 2012; Zhong, Zhong, & Peng, 2014). This oscillation can increase the time required to complete a mission and consume more energy than necessary, as the AF is constantly changing its speed and direction. To address this issue, it is crucial to integrate the AF's dynamic constraints into the trajectory generation process. This could be accomplished by integrating the kinetic model of the AF into the motion planning algorithm. Alternatively, acceleration bounds for each time interval could be defined dynamically, aligned with the AF's capabilities in performing maneuvers, ensuring both efficiency and feasibility (Zhang, Wu, Zhang, Xiao, & Guo, 2013).

The kinematic and kinetic models of a vehicle represent two distinct frameworks for understanding and predicting vehicular motion (Lee & Alandoli, 2020). A kinematic model describes the geometry of motion without accounting for the forces that cause it, typically using variables like position, and velocity to describe movement. On the other hand,

a kinetic model goes a step further by incorporating the forces and torques responsible for motion, taking into account factors such as inertia parameters. For advanced motion planning algorithms that require a thorough understanding of a vehicle's performance capabilities, the kinetic model is generally more appropriate. This is because the kinematic model is unable to capture the effect of inertia parameters and acceleration, critical variables when understanding how a vehicle responds to control inputs. Ignoring these elements can lead to suboptimal or even unfeasible paths in complex scenarios where precision and responsiveness are crucial. Therefore, when the impact of forces and inertia parameters is non-negligible, the kinetic model provides a more comprehensive framework for motion planning.

According to the above discussion, this paper has two major contributions: (i) The first contribution involves predicting the optimal bounds for the AF's linear and angular acceleration online using Deep Neural Networks (DNNs) and the AF's kinetic model. Initially, the kinetic model of an AF is designed by using the Euler-Lagrange dynamic method. This model calculates the AF's acceleration by taking into account its dynamic constraints and the changes in dynamic inertia parameters. Subsequently, a minimum time-energy optimization method is applied using AF's kinetic model as the main constraint. The optimization aims to identify the AF's optimal acceleration, seeking a balance between maximum acceleration, minimum energy, and time spent. This process is used to generate a dataset that includes eight inputs (initial conditions and energies) and two outputs (linear and angular acceleration). And lastly, a DNNs model is trained on this dataset to predict the optimal acceleration for the AF under different circumstances. (ii) The main contribution of this work is the integration of the trained DNNs model into a motion planning algorithm, thereby enabling the generation of energy-efficient and feasible trajectories. Therefore, at each time step, the motion planner algorithm utilizes the DNNs model's outputs as dynamic boundaries for the AF's linear and angular acceleration. By incorporating the constraint of the AF's kinetic model into this online guidance, navigation is facilitated in ways that optimize energy consumption while remaining practically achievable. The widely used industry application, the Timed Elastic Band (TEB) algorithm (Rösmann, Hoffmann, & Bertram, 2017), is chosen to implement the proposed method. As a result, an energy-efficient version of TEB referred to as ETEB, is created and integrated into the AF's navigation system.

The remainder of this paper is organized as follows. The necessity of considering variable optimal acceleration bounds in motion planning is investigated in the next section. In the third section, the different parts of the methodology of the proposed method are described. The fourth section displays the results of the experiment and discusses them followed by a conclusion.

## 2. Necessity of considering variable optimal acceleration bounds

In this section, first, we explore the problems outlined in the introduction section through the lens of theorems. This exploration commences with a discussion on the effects of acceleration on energy consumption and the feasibility of movement, using mathematical formulas for clarification. Subsequently, we conduct experiments using an AF sourced from the industrial partner, allowing us to see the mentioned problems practically.

The power consumed by a robot can be modeled as a function of the forces and torques exerted by its motors, which are in turn functions of the robot's acceleration (Study.com, 2023). The relationship between these forces (which provide torque to make the robot move) and the robot's acceleration can be described by a model known as the kinetic model of the robot (Hendzel et al., 2017). Generally, in linear systems, the energy consumption is directly proportional to the force applied and the velocity at which the work is being done (Knight, 2022). Hence,  $P_F = F \cdot v$ , which describes power  $P_F$  in terms of force  $F$  and velocity  $v$  in linear systems. Moreover, in rotational systems, the energy

consumption is directly proportional to the torque  $\tau$  and the angular velocity  $w$  (Monte, Bertuccio, Magris, & Zamparo, 2021). Therefore,  $P_\tau = \tau \cdot \omega$  where  $P_\tau$  describes the power in terms of torque. Hence, increasing the torque (e.g., using a machine to lift heavier loads) or the angular velocity (e.g., making a machine operate at higher RPM) will increase the power, and hence the energy consumption (Sandoval, Kelly, Santibáñez, & Villalobos-Chin, 2022). This is seen in applications like electric motors, where running the motor at higher speeds or under greater load will consume more energy (Saidur, Mekhilef, Ali, Safari, & Mohammed, 2012).

Algorithms for motion planning anticipate the subsequent moves of a robot. We can represent a discretized sequence of  $n$  robot configurations as  $(q_k)_{k=1,2,\dots,n}$ . Similarly, a sequence of strictly positive time intervals can be symbolized as  $(\Delta T_k)_{k=1,2,\dots,n-1}$ , where  $\Delta T_k \in \mathbb{R}^+$ . Each time interval  $\Delta T_k$  corresponds to the duration required for the transition from one configuration  $q_k$  to the next  $q_{k+1}$ . Therefore, the robot's linear and angular acceleration  $(a_k, \alpha_k)$  can be presented as (Rösmann, Feiten, Wösch, Hoffmann, & Bertram, 2012):

$$a_k = \frac{2(v_{k+1} - v_k)}{\Delta T_k + \Delta T_{k+1}} \quad (1a)$$

$$\alpha_k = \frac{2(w_{k+1} - w_k)}{\Delta T_k + \Delta T_{k+1}} \quad (1b)$$

The feasibility of a trajectory generated by the motion planner can be assessed by checking whether the robot's acceleration satisfies the constraints. If the motion planner algorithm considers the robot acceleration limits for the next trajectory samples, it can be described as:

$$a_{\max} - |a_k| \geq 0 \quad (2a)$$

$$\alpha_{\max} - |\alpha_k| \geq 0 \quad (2b)$$

Where  $a_{\max}$  and  $\alpha_{\max}$  determine the bounds of acceleration in the optimization process of the motion planner algorithm. By considering acceleration bounds as constant values, some problems might appear. When the algorithm operates with high acceleration limits, it can produce trajectories that require intense acceleration. However, such high-acceleration maneuvers may not be feasible for the robot to execute. For example, let us assume that we have set maximum linear acceleration,  $a_{\max}$ , to  $1 \text{ m/s}^2$  and maximum angular acceleration,  $\alpha_{\max}$ , to  $1 \text{ rad/s}^2$ . Under these conditions, our motion planning algorithm is tasked with generating trajectories for a complex maneuver such as parking. However, given the robot's dynamic constraints (which are factored into the robot's kinetic model), some trajectories may require less acceleration, perhaps  $a_{\max} = 0.5 \text{ m/s}^2$  and  $\alpha_{\max} = 0.5 \text{ rad/s}^2$ . If the algorithm does not accommodate this, the robot may not be able to follow the generated high-acceleration trajectories. Consequently, the robot could end up in a situation where it oscillates uncontrollably, requiring the algorithm to regenerate more appropriate trajectories.

In order to explore the problem in a practical context, subsequent experiments have been conducted. The AF is displayed in Fig. 1: (a) without load and (b) with the load. In addition, its properties are presented in Table 1. The load's mass is 300 kg approximately. The AF includes two motors for traction and steering of the front wheel. Moreover, it has two fixed caster wheels at the rear of the body. The directions in which they move are solely along the body's longitudinal axis. In addition, the AF is equipped with sensors for localization, mapping, and estimating its linear and angular velocities (Castellano-Quero, Fernández-Madrigal, & García-Cerezo, 2021). It is configured by an industrial PC with Linux operating system and Robot Operating System (ROS) Navigation Stack (Stanford Artificial Intelligence Laboratory et al., 2018). The experiment tests were performed in a warehouse-like environment where the floor is painted concrete and leveled to avoid slipping. Fig. 2 displays the experiment world and its mapping with the AF and waypoints in Rviz (3D visualization tool for ROS). Hence, there are three waypoints ( $w_{a-c}$ ) which the AF must reach them respectively.



Fig. 1. (a) The AF; (b) The AF with the load.

Table 1  
AF's characteristics.

Parameter	Value
Mass ( $m_i$ )	1000 kg
Distance of front wheel to center of two caster wheels ( $L$ )	1.7 m
Front wheel's radius ( $r$ )	0.15 m
Dimensions (length $\times$ width $\times$ height)	2.63 m $\times$ 1.22 m $\times$ 2.75 m

AFs are required to execute parking maneuvers in factories and warehouses for tasks such as picking up and dropping off loads. These maneuvers necessitate precise planning of the AF's position and orientation, leading the AF to experience both linear and angular accelerations. Thus, this study focuses on parking maneuvers to demonstrate the impact of acceleration boundaries on the energy consumption of AFs and the feasibility of these maneuvers. Three scenarios were conducted which allowed the AF (without load) to start from the first waypoint ( $w_a$ ), proceed to the second waypoint ( $w_b$ ), and subsequently navigate to the third waypoint ( $w_c$ ). In Scenario 1, the bounds of linear and angular acceleration in AF's motion planner algorithm were considered at  $0.05 \text{ m/s}^2$  and  $0.05 \text{ rad/s}^2$  (limited too much). The bounds changed into  $0.1 \text{ m/s}^2$  and  $0.1 \text{ rad/s}^2$  in Scenario 2 (moderate range), and  $1 \text{ m/s}^2$  and  $1 \text{ rad/s}^2$  in Scenario 3 (high acceleration bounds). These limits were selected because of parking maneuver constraints. Every scenario was attempted five times to consider all uncertainties. Although multiple attempts were conducted with extensive testing and repetitions, for the sake of clarity, only the results from the first attempt are displayed in Fig. 3 (the time spent to stop in waypoints is ignored). However, the results' details of the five attempts are presented in Table 2.

Fig. 3 illustrates the AF's linear and angular acceleration (a) and the power consumption of AF's traction and steering motors (b) in each of three scenarios (first attempt). Where, S.1, S.2, and S.3 display Scenarios 1 to 3. The power consumption of a motor ( $P_M$ ) can be defined as a function of the motor's voltage ( $V_M$ ) and current ( $i_M$ ):

$$P_M = V_M i_M \quad (3)$$

Therefore, to measure the motor's power consumption in this study, the total energy consumed by the motor  $E_M$  over time  $T$  can be represented by the following equation:

$$E_M = \int_0^T P_M dt \quad (4)$$

When acceleration was limited to  $0.05 \text{ m/s}^2$  and  $0.05 \text{ rad/s}^2$  (blue graph), the peaks of graphs of motors' power consumption were less than others most of the time. However, S.1 took more time to finish the scenario. On the opposite side, when acceleration was limited to  $1 \text{ m/s}^2$  and  $1 \text{ rad/s}^2$  (yellow dash-dotted graph), AF experienced more acceleration. Although the peaks of motors' power in S.2 were more than others, it spent less time than S.1 to finish the scenario. By setting

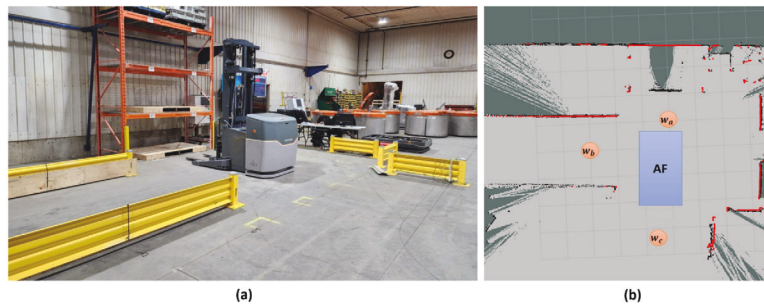


Fig. 2. The world of the experiment (a); and its map in Rviz (b).

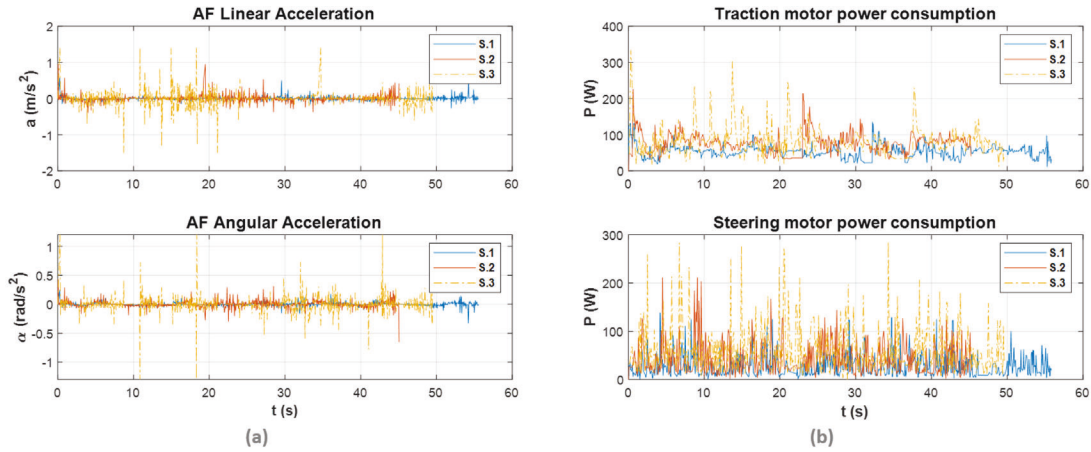


Fig. 3. Experiment results (first attempt) by using three different acceleration bounds in the motion planner. (a) and (b) display AF's acceleration and motors' power respectively.

the acceleration limit to  $0.1 \text{ m/s}^2$  and  $0.1 \text{ rad/s}^2$  in S.2, the acceleration and power consumption ranges of AF (red graphs) fell between those of S.1 and S.3. Furthermore, in S.2, AF reached  $w_c$  faster than the other scenarios.

Table 2 presents the results of the experiment after five attempts. The number designating each scenario is displayed in the initial column. Each scenario delineates the boundaries for both linear and angular acceleration, which can be found in the subsequent second and third columns. Additionally, essential details like the experiment duration (Time), the Traction Motor's Energy Consumption (TMEC), the Steering Motor's Energy Consumption (SMEC), and the Cumulative Energy Consumption for both motors (CEC) are presented, summarizing the data across all attempts. In Scenario 1, the AF completed the mission in 386 s (a duration longer than that in other scenarios), resulting in a CEC of 45.9 kJ. For Scenario 3, AF successfully reached the end goal in 369 s, albeit with a higher CEC of 47.6 kJ. However, the most favorable outcome transpired in Scenario 2, where the Time and CEC were optimally minimized to 351 s and 43.6 kJ, respectively. It is noteworthy that despite Scenario 3 having greater acceleration limits than Scenario 2, the mission duration in Scenario 3 exceeded that of Scenario 2. The occurrence was a result of the motion planner producing unattainable trajectories, causing the AF to become trapped in a complex maneuver and exhibiting oscillatory behavior as it alternated between various trajectories until the motion planner generated appropriate trajectories.

The results of the experiment indicated that placing a limit on acceleration had a negative effect on energy consumption, leading to increased travel time. Conversely, high acceleration bounds led to frequent and sudden changes in speed, resulting in greater energy consumption. Furthermore, the motion planning algorithm generated some trajectories that were not dynamically feasible for the AF during complex maneuvers, leading to oscillation and higher energy usage. In order to address this problem, the motion planner can be enhanced

by taking into account the AF's kinetic model. It can establish online acceleration limits consistent with the AF's dynamic capabilities for maneuver execution. This approach allows for the realization of trajectories that are not only energy-efficient but also physically viable. This is particularly crucial in a warehouse or factory setting, where the AFs must complete multiple tasks within a specified time frame. Thus, this work aims to tackle this issue by proposing an innovative methodology which is discussed in the following section.

### 3. Methodology

The methodology section includes four subsections. It begins by driving motion equations of AF where the Euler-Lagrange dynamic approach is employed. Then, the minimum time-energy optimization problem is studied to find AF's optimal acceleration. In the third subsection, the way to generate a proper dataset is explained, and creating a DNNs model is studied to predict the AF's optimal acceleration. Finally, adding the DNNs model to the motion planning algorithm is discussed.

#### 3.1. AF's kinetic model

Fig. 4 displays the AF's body diagram. The front wheel (main wheel) with rotation angle  $\phi$  is on point  $P$  which is the powered and steered wheel. Hence, it includes two motors to generate steering and driving torques. There are two caster wheels at the rear of AF and at a distance of  $L$  from the front wheel. They are not powered and their directions of motion are just along the longitudinal axis of the body. Hence, they can be considered as one caster wheel on the center of the two caster wheels (point  $O$ ) (Sayyaadi, Kouhi, & Salarieh, 2011). The AF's Center of Mass (CoM) is shown by point  $G$  which has a distance of  $l_1$  from the front wheel and a distance of  $l_2$  from point  $O$ . The change in PoCoM along the lateral axis of AF is ignored. The reference (fixed) and body coordinates are displayed by OXY and Pxy. In addition,  $\delta$  and  $\theta$  indicate steering

**Table 2**  
Experiment results (after five attempts) by using different acceleration bounds in the motion planner.

Scenario	Limit $a$ (m/s <sup>2</sup> )	Limit $\alpha$ (rad/s <sup>2</sup> )	Time (s)	TMEC (kJ)	SMEC (kJ)	CEC (kJ)
1	0.05	0.05	386	27.1	18.8	45.9
2	0.1	0.1	351	25.9	17.7	43.6
3	1	1	369	26.7	20.9	47.6




Fig. 4. AF's body diagram.

and body angles. It is assumed that the vehicle moves on the horizontal plane (2D), the vehicle is rigid and there is no slippage between the wheels and the surface. Hence, the generalized coordinate vector  $q$  is described as:

$$q = [x, y, \theta, \delta, \phi] \quad (5)$$

By considering the front wheel as the reference point and defining  $\dot{\phi}$  and  $w$  as angular velocities of the front wheel and body, the AF's kinematic model is defined as (Klancar, Zdesar, Blazic, & Skrjanc, 2017):

$$\dot{x} = r\dot{\phi} \cos(\delta + \theta) \quad (6a)$$

$$\dot{y} = r\dot{\phi} \sin(\delta + \theta) \quad (6b)$$

$$\dot{\theta} = r\dot{\phi} \sin(\delta)/L \quad (6c)$$

Where  $r$  is the radius of the front wheel,  $\dot{x}$  and  $\dot{y}$  are the velocities of AF (point  $P$ ) and  $\dot{\theta}$  is the angular velocity of body ( $\dot{\theta} = w$ ).

To obtain the AF's kinetic model, the Lagrange dynamic approach (Ginsberg, 1998) is employed. This method derives the equations of motion by considering the kinetic and potential energies of the given system. The Lagrange equation is described in the following form:

$$\frac{d}{dt} \left[ \frac{\partial L_F(\vec{q}, \dot{\vec{q}})}{\partial \dot{\vec{q}}} \right] - \frac{\partial L_F(\vec{q}, \dot{\vec{q}})}{\partial \vec{q}} - C^T(\vec{q})\vec{\lambda} = \vec{F} \quad (7)$$

where  $L_F = T_E - V_E$  is the Lagrangian function,  $T_E$  and  $V_E$  are the kinetic and potential energies of the system. Since this work assumes the AF's motion is on the horizontal plane (2D), the potential energy is ignored ( $L_F = T_E$ ). The external generalized force vector is displayed by  $F$ , and  $\lambda$  is the vector of Lagrange multipliers associated with the constraints which are shown by  $C$ .

Since caster wheels are undriven wheels, their kinetic energies are ignored. Hence, the kinetic energy of the AF is described as:

$$T_E = \frac{1}{2}[(\dot{x} + l_1\dot{\theta} \sin(\theta))^2 + (\dot{y} - l_1\dot{\theta} \cos(\theta))^2]$$

$$+ \frac{1}{2}J\dot{\theta}^2 + \frac{1}{2}m_2[\dot{x}^2 + \dot{y}^2] + \frac{1}{2}I_h\dot{\phi}^2 + \frac{1}{2}I_v(\dot{\delta} + \dot{\theta})^2 \quad (8)$$

Where  $m_1$  and  $m_2$  describe AF and powered wheel masses ( $m_T = m_1 + m_2$ ). Moreover,  $J$ ,  $I_h$ , and  $I_v$  are the MoI of the body (around  $z$  axis) and the powered wheel (around the wheel's horizontal and vertical axes) respectively. By substituting Eq. (8) in Eq. (7) and simplifying, the Euler-Lagrange equation with Lagrangian multipliers can be written as:

$$M(\vec{q})\ddot{\vec{q}} + B(\vec{q}, \dot{\vec{q}}) - C^T(\vec{q})\vec{\lambda} = \vec{U} \quad (9)$$

Where:

$$M(q) = \begin{bmatrix} m_T & 0 & m_1 l_1 \sin(\theta) & 0 & 0 \\ 0 & m_T & -m_1 l_1 \cos(\theta) & 0 & 0 \\ m_1 l_1 \sin(\theta) & -m_1 l_1 \cos(\theta) & m_1 l_1^2 + J + I_v & 0 & 0 \\ 0 & 0 & I_v & I_v & 0 \\ 0 & 0 & 0 & 0 & I_h \end{bmatrix} \quad (10a)$$

$$C = \begin{bmatrix} 1 & 0 & 0 & 0 & -r \cos(\theta + \delta) \\ 0 & 1 & 0 & 0 & -r \sin(\theta + \delta) \\ 0 & 0 & 1 & 0 & -r \sin(\theta)/L \end{bmatrix} \quad (10b)$$

$$B(\vec{q}, \dot{\vec{q}}) = \begin{bmatrix} m_1 l_1 \cos(\theta) \dot{\theta}^2 \\ m_1 l_1 \sin(\theta) \dot{\theta}^2 \\ 0 \\ 0 \\ 0 \end{bmatrix} \quad (10c)$$

$$\vec{\lambda} = \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \lambda_3 \end{bmatrix} \quad (10d)$$

$$\vec{U} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ u_1 \\ u_2 \end{bmatrix} \quad (10e)$$

Through the application of the AF's kinetic model (Eq. (9)), we can understand the connection between the model's input, which are the torques, and the acceleration of the AF. Essentially, this relationship provides us with insights into how the changes in torque influence the AF's acceleration. This knowledge is then used to develop the motion planning in the subsequent sections.

### 3.2. Optimal acceleration

Regarding the experiment results and the discussion in Section 2, the AF's energy consumption can be affected by acceleration bounds and time spent to finish a mission. Thus, this subsection aims to find the optimal acceleration by defining a minimum time-energy optimization problem. The first constraint in the optimization is the AF's kinetic model (8) to be sure that all motion constraints of AF are considered. The second constraint is the limitation of steering acceleration (Rösmann et al., 2021). Since the motion planner achieves linear and angular velocities, this constraint guarantees the acceptable limit of steering acceleration ( $\ddot{\delta}$ ) by considering the maximum allowed steering rate ( $\dot{\delta}_{\max}$ ) and current steering rate ( $\dot{\delta}_k$ ). Therefore, it is described as:

$$\ddot{\delta} \leq \frac{\dot{\delta}_{\max} - \dot{\delta}_k}{\Delta t} \quad (11)$$



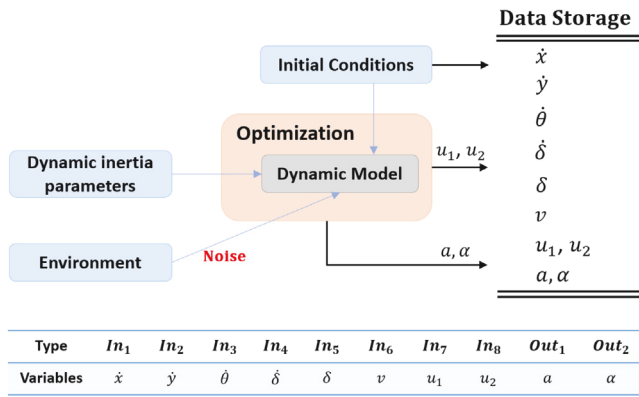


Fig. 5. The data flow map with the dataset structure.

Where the time interval between every command is denoted by  $\Delta t$ . Regarding the minimum and maximum values of inputs of the AF's dynamic model, the third constraint is defined as:

$$|u_i| \leq u_{i_{\max}} \quad (12)$$

where  $i \in [1, 2]$ .

The objective function should be designed to find the maximum acceleration in the possible minimum time which leads to the optimal energy (inputs). Thus, a nonlinear mathematical model is presented as follows by using the relaxation method (Giesen & Laue, 2019):

$$\min_{u_1, u_2} \Gamma = \int_0^T (\zeta_1 + \zeta_2 u_1^2 + \zeta_3 u_2^2 + \zeta_4 [\max(a_{\max}, |a|)]^2 + \zeta_5 [\max(\alpha_{\max}, |\alpha|)]^2) dt \quad (13)$$

s.t. Eq. (9), (11), (12)

Where  $\zeta_{1-5}$  are tunable constant weights to adjust the relative importance of different terms in the objective function. Therefore,  $\zeta_1$  is considered to guarantee the minimum time optimization,  $\zeta_2$  and  $\zeta_3$  are weights related to energy,  $\zeta_4$  and  $\zeta_5$  are weights of acceleration. Moreover,  $a_{\max}$  and  $\alpha_{\max}$  are AF's maximum allowed linear and angular acceleration respectively. The inputs of the kinetic model ( $u_1, u_2$ ) are considered as optimization variables. By using the relaxation method, the acceleration constraints shift to the objective function from optimization constraints. Hence, the optimization problem considers the maximum acceleration constraint while minimizing time and energy.

### 3.3. Prediction of optimal acceleration

A proper dataset is a crucial part of the prediction task by the DNNs (Cebollada, Payá, Flores, Peidró, & Reinoso, 2021). Fig. 5 displays the process of generating data and the dataset structure. To generate the dataset, AF's kinetic model (9) and the optimization method (13) are employed. Hence, different inertia parameters ( $m_2, J, I_1, I_2$ ) and initial conditions are considered as the inputs of the kinetic model. Then, the optimization algorithm uses the kinetic model to find the optimal linear and angular acceleration (dataset outputs) regarding the inputs. To incorporate disturbances into the dataset, Gaussian noise is introduced into the kinetic model. All data are saved in the data storage to complete the dataset. Hence, the dataset with 64520 rows includes eight inputs ( $In_i$ ) and two outputs ( $Out_j$ ). Where  $i \in [1, 8]$  and  $j \in [1, 2]$ .

Since the dataset includes known inputs and outputs, a supervised learning approach is required. The learning model must also be able to handle the non-linearity of AF's dynamic model. In addition, the selected approach must be capable of dealing with multi-output issues. Given these requirements, the Multi-Layer Perceptron (MLP) method is a suitable option that satisfies all of these criteria (Xu, Jung, & Chang, 2022). MLP is well-suited for addressing complicated nonlinear

problems and can manage large volumes of input data. Furthermore, it can generate rapid online predictions after just one round of training. Therefore, it is a suitable DNNs method for online tasks.

In this work, MLP should train a model to learn the prediction of AF's linear and angular acceleration by using the generated dataset. Table 3 illustrates the results of the trained model and properties of simulations. Hence, MLP was implemented via scikit-learn's MLPRegressor. The model architecture consisted of an input layer with eight neurons, and five hidden layers with neurons [128, 64, 32, 16, 8] in each layer respectively. The presented values were the optimal ones that were achieved after a trial and error process. The Rectified Linear Unit (ReLU) activation function was used in the hidden layers and Adam was selected as the solver. In the study, an 80–20 split was employed for partitioning the dataset into training and test sets. For training, the maximum number of iterations was set at 5000, and data was normalized using scikit-learn's StandardScaler. Regarding the literature, a proper way to display the accuracy of the prediction task is Root-Mean-Square Error (RMSE) (Abbas & Zhang, 2021). The unit of the RMSE is similar to the unit of variables. So, RMSE's units are  $m/s^2$  and  $rad/s^2$  for the prediction of linear and angular acceleration respectively. The range of changes of  $a$  and  $\alpha$  are  $\pm 1 m/s^2$  and  $\pm 1 rad/s^2$ . In order to have a better understanding of the results, Symmetric Mean Absolute Percentage Error (SMAPE) (Hyndman & Koehler, 2006) is employed to measure the accuracy based on the percentage error. The SMAPE range is between 0 to 100% and a lower percentage means a lower error.

In real missions, the DNNs model's inputs are generated (either directly or indirectly) by AF's sensors and actuators which contain many noises. Therefore, to demonstrate the robustness of the DNNs model when dealing with different levels of noise, three types of datasets are considered to be tested. Type 1 includes data without noise. Type 2 and 3 contain Gaussian noise with 70 dB and 50 dB Signal-to-noise ratio (SNR) respectively. Regarding RMSE and SMAPE of results in Table 3, MLP achieves acceptable results to predict both acceleration for different dataset types. To comprehend clearly the difference between results, the results are presented in Fig. 6. Blue and green lines correspond to  $a$  and  $\alpha$  parameters. Thus, the data without noise obtains the best result. By increasing the SNR in datasets 2 and 3, the values of errors grow gradually. Hence, the predictions' RMSE of  $a$  and  $\alpha$  are  $0.005 m/s^2$  and  $0.008 rad/s^2$  for the data without noise. However, it reaches  $0.02 m/s^2$  and  $0.04 rad/s^2$  for the data with 70 dB SNR and  $0.06 m/s^2$  and  $0.1 rad/s^2$  for the data with 50 dB SNR. Also, predictions' SMAPE of  $a$  and  $\alpha$  are 11.4% and 13.5% for data type 1. It increases to 14.4% and 17.3% in data type 2 and 22.1% and 26.7% in data type 3. The total results prove the proper performance of the generated DNNs model. It achieves admissible results even by increasing the noise ratio.

### 3.4. Energy-efficient motion planning

Up until this section, AF's optimal linear and angular acceleration have been obtained by using the DNNs and the kinetic models. Regarding the aim of this paper, the DNNs model should be added to a motion planning method to improve it as an energy-efficient one. Thus, TEB as a popular motion planner in the literature is selected for this work. Like similar works in the literature, although TEB uses the robot's kinematic constraints, it ignores the dynamic constraints which are seen in the kinetic model. Hence, it could not consider the robot's dynamic feasibility and energy issues when generating trajectories. These issues become more important when there are consecutive inertia parameters changes such as an AF whose main task is to carry loads.

TEB is a trajectory optimization algorithm that is used to plan and execute the movement of a robot from an initial position to a goal position while avoiding obstacles and respecting the robot's constraints. TEB optimizes a trajectory that is represented as a sequence of poses (i.e., position and orientation) over time. Thus, the high-dimensional

**Table 3**  
Properties and results of the prediction of linear and angular acceleration by using MLP method.

Parameter	Data without noise		Data with noise (SNR=70 db)		Data with noise (SNR=50 db)	
	RMSE	SMAPE(%)	RMSE	SMAPE(%)	RMSE	SMAPE(%)
$a$	0.005 m/s <sup>2</sup>	11.4	0.02 m/s <sup>2</sup>	14.4	0.06 m/s <sup>2</sup>	22.1
$\alpha$	0.008 rad/s <sup>2</sup>	13.5	0.04 rad/s <sup>2</sup>	17.3	0.1 rad/s <sup>2</sup>	26.7
–	<b>Deep Neural networks method</b>			MLP		
–	<b>Numbers of neurons in three hidden layers</b>			[128,64,32,16,8]		
–	<b>Activation function</b>			Relu		
–	<b>Solver</b>			Adam		

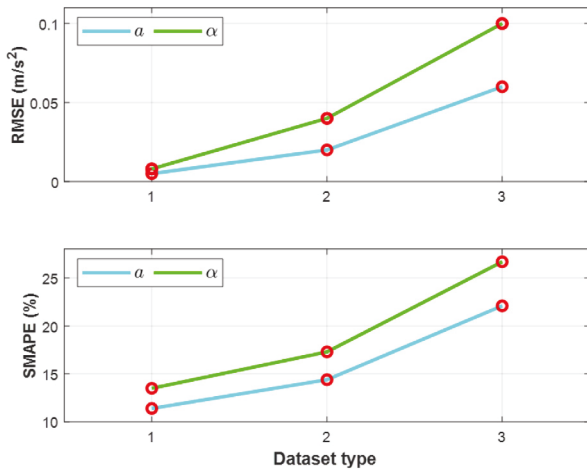


Fig. 6. The results of prediction of linear and angular acceleration by MLP.

search problem of motion planning should be solved. The sequence of AF's poses in configuration space is expressed as:

$$Q = \{q_{jk}\}_{j=1:3; k=0\dots n-1}; \quad n \in \mathbb{N} \quad (14)$$

where  $n$  denotes the number of vertices in each trajectory.

$\Delta T$  represents the time interval between every two poses and the collection of vertices that correspond to these time intervals is represented as:

$$B = \{\Delta T_k\}_{k=0\dots n-2}; \quad n \in \mathbb{N} \quad (15)$$

Therefore, the trajectory is expressed as a combination of a series of poses and time intervals, which serve as the optimization variables for the solution that follows:

$$S = \{Q, B\} \quad (16)$$

The motion planner's multi-objective function is expressed as:

$$\begin{aligned} \min_S \quad & A = \sum_{k=1}^{n-1} \Delta T_k^2 \\ \text{s.t.} \quad & o_k(q_k) \geq 0 \\ & \tilde{r}_k(q_{k+1}, q_k) \geq 0 \\ & h_k(q_{k+1}, q_k) = 0 \\ & 0 \leq \Delta T_k \leq \Delta T_{\max} \\ & v_k(q_{k+1}, q_k, \Delta T_k) \geq 0; \quad (k = 1, 2, \dots, n-1) \\ & acc_k(q_{k+2}, q_{k+1}, q_k, \Delta T_{k+1}, \Delta T_k) \geq 0; \quad (k = 2, 3, \dots, n-2) \end{aligned} \quad (17)$$

The constraints include their corresponding weights and denote obstacle avoidance ( $o_k$ ), turning radius ( $\tilde{r}_k$ ), curvature movement ( $h_k$ ), transition time ( $\Delta T_k$ ), velocity ( $v_k$ ) and acceleration ( $acc_k$ ). The optimization problem is solved by the graph optimization framework of

g2o (Kümmerle, Grisetti, Strasdat, Konolige, & Burgard, 2011) to obtain efficient motion.

The AF's acceleration at every vertex along a trajectory is determined using Eq. (1a) for linear acceleration and Eq. (1b) for angular acceleration. These calculated accelerations then help to establish the limits for acceleration, which are defined in Eq. (2a) and (2b). When we consider the parameters  $a_{\max}$  and  $\alpha_{\max}$  as fixed values, we could encounter the issues discussed in Section 2. Therefore, to avoid these potential problems, it is necessary for the motion planning algorithm to dynamically adapt these parameters in real time to their optimal values as the trajectory is being formed. In this regard, we propose integrating a pre-established DNNs model (explained in Section 3.3) into the trajectory evaluation and optimization process. This allows us to continually and proactively determine the best acceleration limits for each point along the trajectory.

The block diagram of the proposed method is illustrated in Fig. 7. Sensor data (indicated by the green dashed line) is directed to the ETEB module, as well as to other navigation stages, which include mapping, localization, and global path planning. The global path, generated by the global path planning algorithm, is then combined with a local cost map and the AF position, and this information is sent to the ETEB module (purple dashed line). Within the ETEB module, the trajectory generation component creates samples of possible paths and velocities. These samples are then sent to both the DNNs model and the hyper-graph components (orange dashed lines). The DNNs model receives eight inputs and predicts the optimal acceleration. The first six inputs ( $I_{n_{1-6}}$ ) are derived from the path and velocity information of each trajectory sample. The final two inputs ( $I_{n_{7,8}}$ ) are received from the traction and steering motors (red dashed lines). The relationship between the motor outputs (current,  $i_M$ ) and the DNNs model inputs 7 and 8 (torque,  $\tau$ ) is defined by the equation:

$$\tau = i_M K_\tau \quad (18)$$

where  $K_\tau$  represents the torque constant. The DNNs model dynamically determines the optimal bounds of the acceleration ( $a_{\max}$ ,  $\alpha_{\max}$ ) and forwards them to the hyper-graph generation component (orange solid line). The resulting hyper-graph, which includes vertices and constraints, is then sent to the g2o optimizer (black solid line). The g2o algorithm processes this information to find the optimal trajectory, generating reference values for linear velocity and steering angle that are used by the motion controller (purple solid line). The motion controller then prepares the appropriate motor inputs to guide the AF in a feasible and optimal manner (gray solid line). This process continues iteratively until the AF reaches the local goal. To better illustrate the workings of the ETEB module, a pseudo-code corresponding to it is provided in Algorithm 1.

#### 4. Experiment results and discussion

In order to experimentally validate the proposed method, several experiments were carried out by using the AF of the industry partner. The properties of the AF, loads, and test environment have been described in Section 2. Before the practical test, many simulations had been done

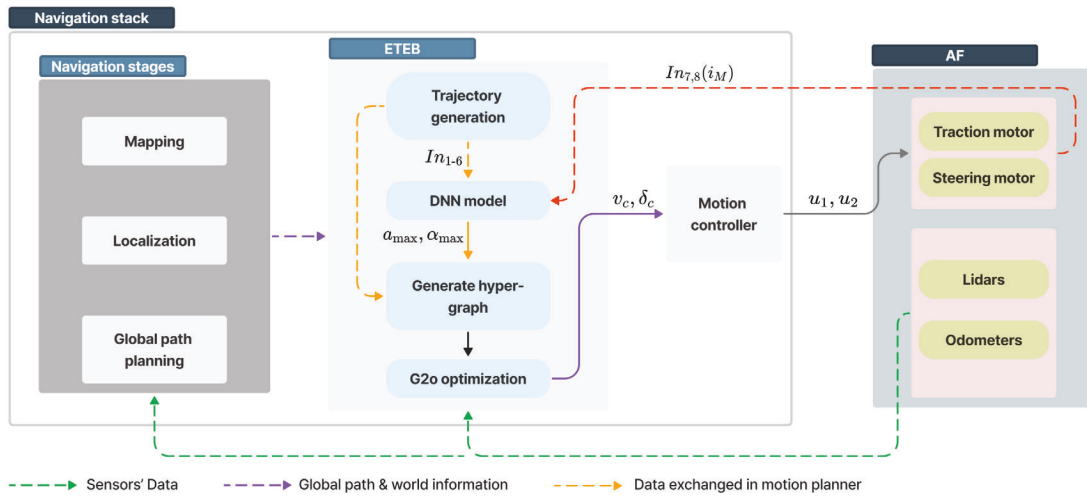


Fig. 7. The block diagram of energy-efficient motion planner (ETEB).

#### Algorithm 1 Energy-efficient Timed Elastic Band (ETEB) Algorithm

```

1: function ETEB_PLANNER(start, goal, DNN_model)
2: Initialize path  $P$ 
3: Initialize velocities  $V$ 
4: Initialize motor currents  $i_m$ 
5: Initialize time interval  $T$  between points to a constant value
6: Initialize boolean flag reached_goal to False
7: Initialize iteration counter iter to zero
8: while not reached_goal and iter < MAX_ITERATIONS do
9:   for each  $i$  in range(MAX_OPTIMIZATION_ITERATIONS) do
10:     $A \leftarrow$  DNN_model( $P, V, i_m$ ) {Use DNN model to determine
11:    accelerations}
12:    cost  $\leftarrow$  COMPUTE_COST( $P, V, A, T$ ) {Cost includes obstacle
13:    avoidance, smoothness, etc.}
14:    Initialize g2o optimizer
15:    Add vertices (states) to g2o optimizer {States include positions,
16:    velocities, and time intervals}
17:    Add edges (constraints) to g2o optimizer {Constraints include
18:    non-holonomic constraints, acceleration, etc.}
19:    Run g2o optimization to update  $P, V,$  and  $T$  {Use Levenberg-
20:    Marquardt method}
21:  end for
22:  if DISTANCE_TO_GOAL( $P[-1]$ ) < GOAL_THRESHOLD then
23:    reached_goal  $\leftarrow$  True
24:  end if
25:  UPDATE_ROBOT_POSITION( $P[0]$ ) {Move the robot along the
26:  first segment of the path}
27:  Remove first segment from  $P$ 
28:  Add new segment to  $P$  based on current robot position and goal
29:  {Extend the path towards the goal}
30:   $i_m \leftarrow$  GET_CURRENT_MOTOR_CURRENTS() {Retrieve the current
31:  motor currents}
32:  iter  $\leftarrow$  iter + 1
33: end while
34: end function

```

to tune the required parameters and ensure the effectiveness of this method. The ROS Navigation Stack had been used to implement navigation tools and algorithms in the simulations. Moreover, Gazebo (Koenig & Howard, 2004) had been used to create the world of the simulation. Fig. 8 shows the simulated AF and the world of simulation in Gazebo. The AF's properties in the simulation had been as same as the properties of the real AF in the experiment (Table 1).




Fig. 8. The simulated AF and the world of the simulation in Gazebo.

When considering the intricacy of various operations, parking is undoubtedly one of the most challenging maneuvers for an AF to perform. This maneuver entails precisely navigating the AF to a designated location within the smart factory or warehouse, where it then parks and awaits further instructions. This task is difficult because it requires the AF to place precisely itself with respect to the goal's position and orientation. With regards to energy, rotational motions such as those associated with steering or turning, tend to have a greater impact on AF's energy consumption than linear motions, such as moving straight forward or backward. This is because rotational motion requires the AF to overcome greater inertia and rotational resistance, which requires more energy to be expended to perform the same amount of work. Therefore, three waypoints were considered in such a way that the rotational motion and the parking maneuver are performed consecutively.

To facilitate a more robust comparison of the results yielded by the proposed method, we employ the DWA. DWA is a widely recognized algorithm for collision avoidance in navigation, originally proposed by Dieter Fox and colleagues (Fox et al., 1997). As an online reactive method, DWA has seen numerous extensions to its cost function over the years. The algorithm aims to select optimal translational  $v$  and rotational  $w$  velocities for a robot by generating velocity profiles. These profiles take into account the robot's dynamics, as well as limitations on velocity and acceleration. The algorithm searches within a main velocity space,  $V_r$ , which is the intersection of three subspaces: (i) the set of possible velocities constrained by the robot's kinematics ( $V_s$ ), (ii)

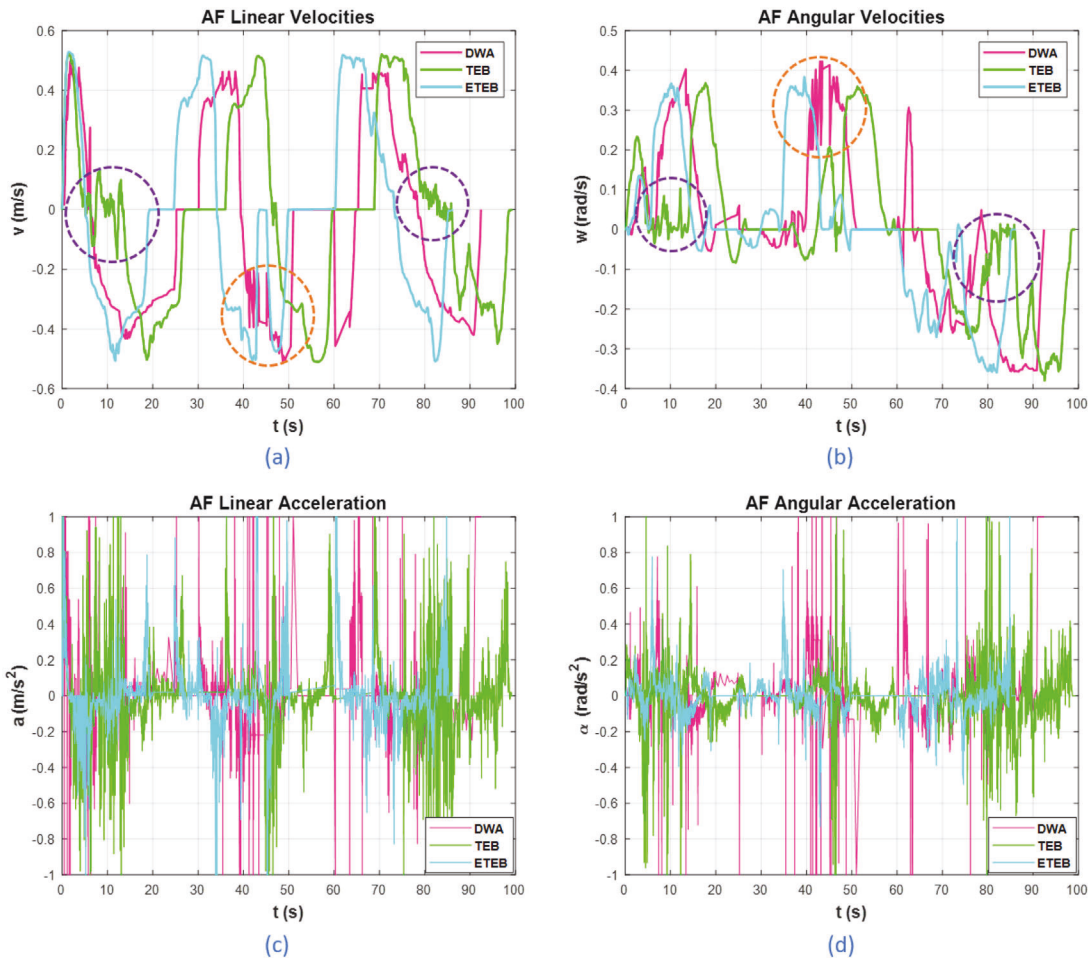


Fig. 9. Experiment results of Scenario 1, in the first attempt. AF's linear velocity (a), angular velocity (b), linear acceleration (c), and angular acceleration (d).

the set of admissible velocities that allow the robot to stop without colliding with obstacles ( $V_a$ ), and (iii) the set of velocities considering the robot's acceleration limits ( $V_d$ ). Mathematically, this is represented as:

$$V_r = V_s \cap V_a \cap V_d \quad (19)$$

To find the optimal velocities, DWA minimizes an objective function,  $G(v, w)$ , defined as:

$$G(v, w) = t_1 \cdot h(v, w) + t_2 \cdot d(v, w) + t_3 \cdot v_F(v, w) \quad (20)$$

Here,  $h$  measures the alignment of the robot with the target direction,  $d$  represents the distance to the closest obstacle, and  $v_F$  is the forward velocity of the robot. Moreover, the constants  $t_1$ ,  $t_2$ , and  $t_3$  are tunable weights.

Regarding Fig. 2, the AF started from the first waypoint ( $w_a$ ) to reach the second and third waypoints ( $w_{b,c}$ ) respectively. Then, it returned to  $w_a$  to repeat the same scenario. The effect of optimal or non-optimal motions on AF's energy consumption intensifies by loads (Mohammadpour et al., 2022). Thus, some loads were considered to see this effect. In total, six scenarios were performed by using DWA, TEB, and Energy-efficient TEB (ETEB) as the AF's motion planner. AF moved without a load in Scenarios 1 and 5, however, it included loads in the rest of the scenarios. The loads' masses were considered 300 kg, 600 kg, and 1000 kg in Scenarios 2–4 respectively. Although ETEB dynamically considered optimal acceleration limits at every time step, DWA and TEB employed constant values for the entirety of the scenarios. Through a trial and error process, the acceleration limits in DWA and TEB were established as  $0.5 \text{ m/s}^2$  and  $0.5 \text{ rad/s}^2$ . Because

AF performs long-time scenarios in a workday, Scenarios 1–4 were repeated ten times (nonstop) to be guaranteed more than 10 min of movement. This causes into take account uncertainties in localization and mapping which may extend mission duration and impact motion planning efficiency. Conversely, Scenario 5 was attempted five times, and Scenario 6, only three. The rationale for fewer repetitions of Scenarios 5 and 6 will be discussed subsequently.

Due to the extensive testing and numerous repetitions, only the results from the first attempt of Scenario 1 are presented in Figs. 9 and 10 (the time spent to stop in waypoints 2 and 3 is included) to see clearly the difference between results of DWA (pink graphs), TEB (green graphs) and ETEB (blue graphs). Moreover, this particular attempt is selected for illustration due to the presence of velocity oscillation, clearly demonstrating the concept employed in this study. By highlighting the occurrence of velocity oscillation in this specific attempt, the meaning and significance of this phenomenon within the context of the research can be effectively elucidated. Regarding the results in Fig. 9, the AF finished the first attempt sooner by using ETEB than TEB and DWA. The purple dashed line circles in AF's linear and angular velocities demonstrate the oscillations in both velocities when the motion planner was TEB and the orange dashed line circles display the oscillations caused by DWA (a,b). This issue arose because the DWA and TEB generated unfeasible trajectories, which led the AF into a complex maneuver. Consequently, the AF oscillated between various trajectories until the motion planner was able to produce viable trajectories (after several seconds). However, ETEB was capable of generating optimal trajectories that not only considered energy constraints but also respected the possible movement limitations of the AF. Consequently, it successfully guided the AF without causing any oscillations. The

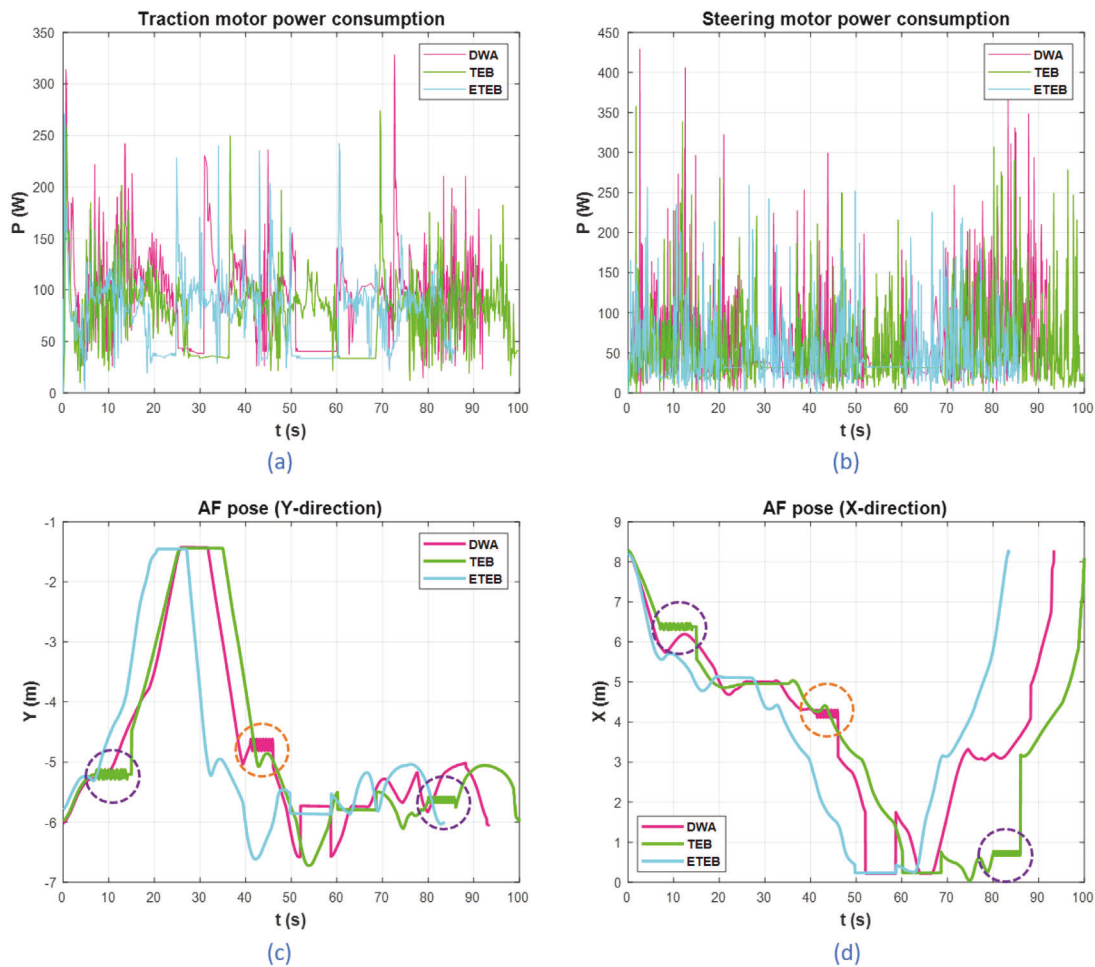


Fig. 10. Experiment results of Scenario 1, in the first attempt. Power consumption of traction (a) and steering (b) motors, AF's poses in X-direction (c) and Y-direction (d).

ETEB tried to keep the amount of linear and angular acceleration to a minimum value but allowed to increase them when necessary by setting the acceleration bounds online (c,d). Therefore, according to the results in Fig. 10, the peaks of the graphs of traction and steering motors' power consumption were less than those in DWA and TEB (a,b). Although the linear and angular acceleration limits were set to  $0.5 \text{ m/s}^2$  and  $0.5 \text{ rad/s}^2$  in TEB, they broke the limits sometimes. It happened because the graph optimization framework of g2o considered the type of constraints as soft. The acceleration also broke the limits in DWA caused by soft constraints considered in the optimization process. The positions of the AF in both the X and Y directions are shown in Fig. 10 (c,d). These positions help visualize the impact of generated oscillations on the AF's movement. Specifically, the purple dashed line circles indicate the oscillations resulting from the TEB, while the orange dashed line circles highlight the oscillations attributed to DWA.

The results obtained at the conclusion of each scenario are presented in Table 4, where the first column shows the Scenario's number (Scn). In addition, the second and third columns display the Number of Attempts (NoA) and the presence of the load in each scenario (Load) respectively. Hence, the load was ignored in Scenarios 1 and 5. The Load's Mass (LM) is related to the masses of loads placed on the AF. The Velocity Oscillation displays the presence of oscillations in linear and angular velocities using DWA, TEB, and ETEB like the oscillations illustrated in Fig. 9 (dashed line circles). Therefore, the check mark symbol confirms the existence of oscillations of velocities in the experiment, and X-mark denies it. Time presents the time of each scenario from start to goal. The total motors' energy consumption (sum up energy consumption of traction and steering motors) is illustrated in the

column of Energy Consumption. The achieved improvement in energy consumption caused by ETEB than DWA and TEB is demonstrated by the Energy Consumption Reduction (ECR) parameter. In addition, the last row displays the sum of results obtained by DWA, TEB, and ETEB in terms of Time, Energy Consumption, and ECR.

As per the results presented in Table 4, it is noticeable that using the ETEB as the motion planner resulted in zero oscillations in both linear and angular velocities. On the contrary, when the DWA and TEB were utilized as the motion planner, oscillations were observed in Scenarios 1–4. In Scenario 1, when the load was not considered, the AF was able to complete the mission 41 s and 45 s faster using ETEB compared to TEB and DWA respectively. This resulted in a 10.4% energy savings compared to TEB and an 11.6% energy savings compared to DWA. By considering the load in Scenario 2, the effectiveness of the proposed method was highlighted more where AF reached the goal 47 s and 49 s faster compared to TEB and DWA and obtained a 13.8% and 13.9% energy consumption reduction. It is noteworthy that the efficiency improved as the masses of the loads increased. Thus, with the utilization of the ETEB, the AF completed the mission quicker (59 s and 58 s sooner in Scenario 3; 65 s and 70 s sooner in Scenario 4 compared to TEB and DWA respectively). Consequently, a substantial reduction in energy consumption was observed (20.1% and 19.4% in Scenario 3; 22.1% and 22.3% in Scenario 4 than TEB and DWA respectively), where the masses of the loads were 600 kg and 1000 kg.

In Scenarios 1–4, which were designed to be repeated ten times, the ETEB method consistently maintained a time range of 630 s to 640 s for each scenario. This indicates a high level of stability and efficiency in the execution of these scenarios, as the time taken remained within

**Table 4**  
Experiment results using DWA, TEB, and ETEB as the AF's motion planner algorithms.

Scn	NoA	Load	LM (kg)	Velocity Oscillation			Time (s)			Energy Consumption (kJ)			ECR (%)	
				DWA	TEB	ETEB	DWA	TEB	ETEB	DWA	TEB	ETEB	DWA	TEB
1	10	✗	–	✓	✓	✗	675	671	630	89.5	88.3	79.1	11.6	10.4
2	10	✓	300	✓	✓	✗	688	686	639	115.9	115.8	99.8	13.9	13.8
3	10	✓	600	✓	✓	✗	693	694	635	142.1	143.4	114.5	19.4	20.1
4	10	✓	1000	✓	✓	✗	710	705	640	181.9	181.3	141.3	22.3	22.1
5	5	✗	–	✗	✗	✗	338	334	315	43.9	43.1	39.8	9.3	7.7
6	3	✓	1000	✗	✗	✗	212	214	188	46.8	47.4	41.9	10.5	11.6
Total							3316	3304	3047	622.2	619.3	516.4	17.1	16.6

the specific limit throughout the repetitions. In contrast, when utilizing the TEB and DWA methods, the time constraint expanded as the mass of the load increased. Specifically, the time taken ranged from 671 s to 705 s (TEB) and 675 s to 710 s (DWA), reflecting an increase in the required duration for scenarios as the load mass became heavier. These observations underscore the robustness of our proposed method, demonstrating its resilience to changes in dynamic inertia parameters.

One of the objectives of this study is to compare results between conventional motion planning algorithms and the improved model when the typical methods do not produce any infeasible trajectories. In such a condition, we should not observe any oscillations in velocities. This assessment facilitates a logical comparison between DWA, TEB, and our proposed method, thereby ascertaining that ETEB is indeed more optimal than the standard approaches. Accordingly, we designed Scenario 5 to see this comparison. This scenario was repeated multiple times using TEB and DWA until we reached a maximum count of five repetitions without detecting any velocity oscillations. We then conducted the same scenario five times using ETEB for a fair comparison. The load factor was disregarded in this scenario. The results showed that the AF completed the mission 19 s and 23 s earlier with ETEB, resulting in 7.7% and 9.3% reduction in energy consumption compared to TEB and DWA.

Scenario 6 closely resembles Scenario 5, with the added consideration of load. In this scenario, the load used is regarded as the maximum value, set at 1000 kg. This scenario was attempted three times at most with TEB and DWA, without any observable oscillations. Consequently, to maintain a consistent comparison, the scenario was also performed three times with ETEB. The results demonstrated that the AF was able to complete the mission 26 s and 24 s quicker using ETEB, leading to 11.6% and 10.5% decrease in energy consumption than TEB and DWA respectively.

The outcomes from Scenarios 5 and 6 underline that efficiency improved with the increase in load masses, even in the absence of oscillations. In total, the AF performed 48 attempts (Scenarios 1–6) in 3047 s, 516.4 kJ energy consumption, and without getting stuck in any situation using ETEB. On the other hand, AF experienced trapping and oscillating sometimes which caused it to reach the final goal point in 3304 s and 3316 s using TEB and DWA, and consumed 619.3 kJ and 622.2 kJ energy respectively. Hence, the proposed method helped AF to finish the total mission 257 s and 269 s faster, and achieved 16.6% and 17.1% energy consumption reduction compared to TEB and DWA respectively.

The results from our experiments strongly highlight the effectiveness of the proposed method in reducing the motors' energy consumption of the AF. Additionally, using the ETEB method has expedited the completion of the mission by the AF, a noteworthy accomplishment. An important observation in the results was the correlation between the increase in load mass and the corresponding improvement in efficiency. As the mass of the load increases, the significance of acceleration bounds becomes even more pronounced. The TEB and DWA methodologies, which overlook constraints inherent to the vehicle's kinetic model, sometimes resulted in trajectories with accelerations that were not optimal and feasible. These trajectories posed practical problems as

they could lead to inefficient and possibly unsuccessful missions. Conversely, the ETEB took into account the current conditions of the AF by acquiring feedback from the motors' currents and dynamically limited the acceleration bounds in each time step. Even with an increase in the load's mass during the experiment, the duration for each scenario stayed within certain limits when using the ETEB method, in contrast to the other methods. Therefore, this demonstrates the robustness of our proposed method in adapting to changes in AF's inertia parameters. This approach ensures that the accelerations are not only feasible but also optimal in terms of energy usage and time. In two scenarios of the experiment, where there were no oscillations, ETEB outperformed TEB and DWA, yielding superior results. Therefore, adding the proposed tool to a motion planning algorithm enables it to yield more energy-efficient results compared to the standard method, irrespective of the oscillations' presence. Consequently, when the proposed method is applied to any motion planning algorithm, it assures that the resulting trajectories balance energy efficiency with feasible maneuverability. The considerable disparity in the experiment results underscores the effectiveness and superiority of our proposed method. This presents a promising path for future research and enhancements in the field of autonomous vehicles and their energy management.

## 5. Conclusion

In this study, a new approach to facilitate energy-efficient motion planning for an AF's navigation was proposed. This approach involved several stages. Initially, the AF's kinetic model was established using the Euler–Lagrange dynamic method to factor in the impact of the front-powered wheel. Then, by using a minimum time-energy optimization method and considering the constraints of the kinetic model, the optimal linear and angular acceleration of the AF was determined. This process resulted in a comprehensive dataset encompassing all potential maneuvers, dynamic inertia parameters, and optimization results. Subsequently, the DNNs (specifically, the MLP method) was employed to train a model using the created dataset. The purpose of this model was to predict the AF's optimal acceleration. Ultimately, this trained model was incorporated into a motion planning algorithm (TEB), enabling the calculation of permissible acceleration boundaries dynamically during the trajectory generation process. This integration resulted in the creation of the ETEB. The experimental results clearly demonstrated the efficacy of the proposed motion planner ETEB. Unlike traditional methods (TEB and DWA), ETEB was capable of producing energy-optimized and dynamically feasible trajectories, leading to a considerable reduction in the AF's energy consumption.

This approach can serve as a valuable tool for all motion planning algorithms developed for real-time missions. Unlike similar works, the proposed motion planner considers the optimal variable acceleration bounds to generate physically possible and energy-efficient trajectories using the vehicle's kinetic model and DNNs. The suggested method reduces hugely the AF's total energy consumption during a workday, raises the AF's availability, and diminishes the production cost. The proposed method can be improved for future works by using the following suggestions. First, the obstacle avoidance problem could be

considered. Smart factories include different types of dynamic obstacles like humans or AVs. Hence, the amount of acceleration or deceleration to pass obstacles have a major impact on AF's energy consumption. Second, since AF should pick up a load, its PoCoM changes along the body's  $z$ -axis. Therefore, it can affect the required acceleration of AF during rotational motion. Due to the dynamic model 2D nature, AF's kinetic model developed in this work cannot account for changes in PoCoM along the  $z$ -axis. Thus, a 3D kinetic model might be more appropriate for scenarios involving variations of PoCoM in all body's three axes.

### CRedit authorship contribution statement

**Mohammad Mohammadpour:** Conceptualization, Methodology, Software, Writing – original draft. **Souso Kelouwani:** Supervision, Funding acquisition, Reviewing, Editing. **Marc-André Gaudreau:** Supervision, Reviewing, Editing. **Lotfi Zeghmi:** Software, Experiment. **Ali Amamou:** Validation, Resources. **Hossein Bahmanabadi:** Methodology, Investigation. **Bilel Allani:** Software, Investigation. **Massinissa Graba:** Software, Reviewing.

### Declaration of competing interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

### Data availability

The authors do not have permission to share data.

### Declaration of Generative AI and AI-assisted technologies in the writing process

During the preparation of this work, the corresponding author used ChatGPT in order to improve the language and readability of the manuscript. After using this tool/service, the authors reviewed and edited the content as needed and take full responsibility for the content of the publication.

### References

- Abbas, Muhammad, & Zhang, Duanjin (2021). A smart fault detection approach for PV modules using adaptive neuro-fuzzy inference framework. *Energy Reports*, 7, 2962–2975.
- Abbas, Muhammad, & Zhang, Duanjin (2023). Revolutionizing low-carbon marine transportation: Prediction of wave energy via adaptive neuro-fuzzy inference framework in East China Sea. *Arabian Journal for Science and Engineering*, 1–23.
- Ahmed, Imran, Jeon, Gwanggil, & Piccialli, Francesco (2022). From artificial intelligence to explainable artificial intelligence in industry 4.0: A survey on what, how, and where. *IEEE Transactions on Industrial Informatics*, 18(8), 5031–5042.
- Allani, Bilel, Ammamou, Ali, Kelouwani, Souso, Ouameur, Messaoud Ahmed, Benarfa, Ghofrane, & Zeghmi, Lotfi (2022). Machine learning approach for charging queue waiting time prediction of electrical autonomous forklifts fleet. In *2022 IEEE vehicle power and propulsion conference* (pp. 1–6). IEEE.
- Bonab, Shabnam Rahnamay, Ghouschi, Saeid Jafarzadeh, Deveci, Muhammet, & Hasehli, Gholamreza (2023). Logistic autonomous vehicles assessment using decision support model under spherical fuzzy set integrated choquet integral approach. *Expert Systems with Applications*, 214, Article 119205.
- Cai, Wei, Wang, Lianguo, Li, Li, Xie, Jun, Jia, Shun, Zhang, Xugang, et al. (2022). A review on methods of energy performance improvement towards sustainable manufacturing from perspectives of energy monitoring, evaluation, optimization and benchmarking. *Renewable and Sustainable Energy Reviews*, 159, Article 112227.
- Castellano-Quero, Manuel, Fernández-Madrugal, Juan-Antonio, & García-Cerezo, Alfonso (2021). Improving Bayesian inference efficiency for sensory anomaly detection and recovery in mobile robots. *Expert Systems with Applications*, 163, Article 113755.
- Cebollada, Sergio, Payá, Luis, Flores, María, Peidró, Adrián, & Reinoso, Oscar (2021). A state-of-the-art review on mobile robotics tasks using artificial intelligence and visual data. *Expert Systems with Applications*, 167, Article 114195.
- Chen, Chun-Ta, & Liao, Te-Tan (2011). A hybrid strategy for the time-and energy-efficient trajectory planning of parallel platform manipulators. *Robotics and Computer-Integrated Manufacturing*, 27(1), 72–81.
- Chen, Yarong, Zhong, Jingyan, Mumtaz, Jabir, Zhou, Shengwei, & Zhu, Lixia (2023). An improved spider monkey optimization algorithm for multi-objective planning and scheduling problems of PCB assembly line. *Expert Systems with Applications*, Article 120600.
- Deng, Xin, Li, Ruifeng, Zhao, Lijun, Wang, Ke, & Gui, Xichun (2021). Multi-obstacle path planning and optimization for mobile robot. *Expert Systems with Applications*, 183, Article 115445.
- Dey, Bikash Koli, Bhuniya, Shaktipada, & Sarkar, Biswajit (2021). Involvement of controllable lead time and variable demand for a smart manufacturing system under a supply chain management. *Expert Systems with Applications*, 184, Article 115464.
- Dormehl, Luke (2020). Self-driving forklifts are here to revolutionize warehouses, for better or worse. URL <https://www.digitaltrends.com/news/third-wave-automation-autonomous-forklifts/>.
- Duleba, Ignacy, & Sasiadek, Jurek Z. (2003). Nonholonomic motion planning based on Newton algorithm with energy optimization. *IEEE Transactions on Control Systems Technology*, 11(3), 355–363.
- Fox, Dieter, Burgard, Wolfram, & Thrun, Sebastian (1997). The dynamic window approach to collision avoidance. *IEEE Robotics & Automation Magazine*, 4(1), 23–33.
- Galvin, Ray (2017). Energy consumption effects of speed and acceleration in electric vehicles: Laboratory case studies and implications for drivers and policymakers. *Transportation Research Part D: Transport and Environment*, 53, 234–248.
- Giesen, Joachim, & Laue, Sören (2019). Combining ADMM and the augmented Lagrangian method for efficiently handling many constraints. In *IJCAI* (pp. 4525–4531).
- Ginsberg, Jerry H. (1998). *Advanced engineering dynamics*. Cambridge University Press.
- Graba, MASSINISSA, Amamou, A, Kelouwani, SOUSSO, Allani, BILEL, Zeghmi, LOTFI, Agbossou, KODJO, et al. (2023). Toward safer and energy efficient global trajectory planning of self-guided vehicles for material handling system in dynamic environment. *IEEE Access*.
- Graba, Massinissa, Kelouwani, Souso, Zeghmi, Lotfi, Amamou, Ali, Agbossou, Kodjo, & Mohammadpour, Mohammad (2020). Investigating the impact of energy source level on the self-guided vehicle system performances, in the industry 4.0 context. *Sustainability*, 12(20), 8541.
- Graba, M., Mamala, J., Bieniek, A., & Sroka, Z. (2021). Impact of the acceleration intensity of a passenger car in a road test on energy consumption. *Energy*, 226, Article 120429.
- Gültekin, Özgür, Cinar, Eyup, Özkan, Kemal, & Yazıcı, Ahmet (2022). Multisensory data fusion-based deep learning approach for fault diagnosis of an industrial autonomous transfer vehicle. *Expert Systems with Applications*, 200, Article 117055.
- Gupta, Nikhil, Ordenez, Camilo, & Collins, Emmanuel G. (2017). Dynamically feasible, energy efficient motion planning for skid-steered vehicles. *Autonomous Robots*, 41, 453–471.
- Hegedüs, Ferenc, Bécsi, Tamás, Aradi, Szilárd, & Gáspár, Péter (2017). Model based trajectory planning for highly automated road vehicles. *IFAC-PapersOnLine*, 50(1), 6958–6964.
- Hendzel, Zenon, et al. (2017). Modelling of dynamics of a wheeled mobile robot with mecanum wheels with the use of Lagrange equations of the second kind. *International Journal of Applied Mechanics and Engineering*, 22(1), 81–99.
- Hyndman, Rob J., & Koehler, Anne B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688.
- Karamuk, Mustafa, SAVCI, İsmail, & Ocaklı, Hakan (2022). A survey on traction system development of automated guided vehicles. *European Journal of Technique (EJT)*, 12(1), 1–12.
- Kim, Hongjun, & Kim, Byung-Kook (2008). Minimum-energy translational trajectory planning for battery-powered three-wheeled omni-directional mobile robots. In *2008 10th International conference on control, automation, robotics and vision* (pp. 1730–1735). IEEE.
- Klancar, Gregor, Zdesar, Andrej, Blazic, Saso, & Skrjanc, Igor (2017). *Wheeled mobile robotics: From fundamentals towards autonomous systems*. Butterworth-Heinemann.
- Knight, Randall Dewey (2022). *Physics for scientists and engineers*. Pearson Education, Limited.
- Koenig, Nathan, & Howard, Andrew (2004). Design and use paradigms for gazebo, an open-source multi-robot simulator. In *2004 IEEE/RSJ international conference on intelligent robots and systems (IROS)*(IEEE Cat. No. 04CH37566), vol. 3 (pp. 2149–2154). IEEE.
- Kümmerle, Rainer, Grisetti, Giorgio, Strasdat, Hauke, Konolige, Kurt, & Burgard, Wolfram (2011). G 2 o: A general framework for graph optimization. In *2011 IEEE international conference on robotics and automation* (pp. 3607–3613). IEEE.
- Lee, T. S., & Alandoli, Esmail Ali (2020). A critical review of modelling methods for flexible and rigid link manipulators. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 42(9), 508.
- Li, Lifu, & Liu, Qin (2019). Acceleration curve optimization for electric vehicle based on energy consumption and battery life. *Energy*, 169, 1039–1053.
- Li, Guanghui, Yamashita, Atsushi, Asama, Hajime, & Tamura, Yusuke (2012). An efficient improved artificial potential field based regression search method for robot path planning. In *2012 IEEE international conference on mechatronics and automation* (pp. 1227–1232). IEEE.
- Liu, Lixing, Wang, Xu, Yang, Xin, Liu, Hongjie, Li, Jianping, & Wang, Pengfei (2023). Path planning techniques for mobile robots: Review and prospect. *Expert Systems with Applications*, Article 120254.

- Malviya, Abhinav, & Kala, Rahul (2021). Social robot motion planning using contextual distances observed from 3D human motion tracking. *Expert Systems with Applications*, 184, Article 115515.
- Mejri, Emna, Kelouwani, Sousso, Dubé, Yves, Henao, Nilson, & Agbossou, Kodjo (2022). Energy efficient order picking routing for a pick support automated guided vehicle (Ps-AGV). *IEEE Access*, 10, 108832–108847.
- Meysami, Ahmadrza, Cuillière, Jean-Christophe, François, Vincent, & Kelouwani, Sousso (2022). Investigating the impact of triangle and quadrangle mesh representations on AGV path planning for various indoor environments: With or without inflation. *Robotics*, 11(2), 50.
- Mohammadpour, Mohammad, Kelouwani, Sousso, Gaudreau, Marc-Andre, Allani, Bilel, Zeghmi, Lotfi, Amamou, Ali, et al. (2022). Energy-efficient local path planning of a self-guided vehicle by considering the load position. *IEEE Access*, 10, 112669–112685.
- Mohammadpour, Mohammad, Zeghmi, Lotfi, Kelouwani, Sousso, Gaudreau, Marc-André, Amamou, Ali, & Graba, Massinissa (2021). An investigation into the energy-efficient motion of autonomous wheeled mobile robots. *Energies*, 14(12), 3517.
- Monte, Alberto, Bertuccio, Matteo, Magris, Raffaele, & Zamparo, Paola (2021). Muscle belly gearing positively affects the force–Velocity and power–Velocity relationships during explosive dynamic contractions. *Frontiers in Physiology*, 12.
- Pamučar, Dragan, & Čirović, Goran (2015). The selection of transport and handling resources in logistics centers using multi-attributive border approximation area comparison (MABAC). *Expert Systems with Applications*, 42(6), 3016–3028.
- Parra, Alberto, Tavernini, Davide, Gruber, Patrick, Sorniotti, Aldo, Zubizarreta, Asier, & Pérez, Joshué (2020). On nonlinear model predictive control for energy-efficient torque-vectoring. *IEEE Transactions on Vehicular Technology*, 70(1), 173–188.
- Patle, BK, Pandey, Anish, Parhi, DRK, Jagadeesh, AJDT, et al. (2019). A review: On path planning strategies for navigation of mobile robot. *Defence Technology*, 15(4), 582–606.
- Rösmann, Christoph, Feiten, Wendelin, Wösch, Thomas, Hoffmann, Frank, & Bertram, Torsten (2012). Trajectory modification considering dynamic constraints of autonomous robots. In *ROBOTIK 2012; 7th German conference on robotics* (pp. 1–6). VDE.
- Rösmann, Christoph, Hoffmann, Frank, & Bertram, Torsten (2017). Kinodynamic trajectory optimization and control for car-like robots. In *2017 IEEE/RSJ international conference on intelligent robots and systems IROS*, (pp. 5681–5686). IEEE.
- Rösmann, Christoph, Makarow, Artemi, & Bertram, Torsten (2021). Online motion planning based on nonlinear model predictive control with non-euclidean rotation groups. In *2021 European control conference* (pp. 1583–1590). IEEE.
- Saidur, Rahman, Mekhilef, Saad, Ali, Mian Basharif, Safari, Azadeh, & Mohammed, Hussein A (2012). Applications of variable speed drive (VSD) in electrical motors energy savings. *Renewable and Sustainable Energy Reviews*, 16(1), 543–550.
- Salazar, Mauro, Alessandretti, Andrea, Aguiar, A Pedro, & Jones, Colin N (2015). An energy efficient trajectory tracking controller for car-like vehicles using model predictive control. In *2015 54th IEEE conference on decision and control* (pp. 3675–3680). IEEE.
- Sandoval, Jesús, Kelly, Rafael, Santibáñez, Víctor, & Villalobos-Chin, Jorge (2022). Energy regulation of torque-driven robot manipulators in joint space. *Journal of the Franklin Institute*, 359(4), 1427–1456.
- Sayyaadi, H., Kouhi, H., & Salarieh, H. (2011). Control of car-like (wheeled) multi robots for following and hunting a moving target. *Scientia Iranica*, 18(4), 950–965.
- Scheuer, Alexis, & Fraichard, Th (1997). Continuous-curvature path planning for car-like vehicles. In *Proceedings of the 1997 IEEE/RSJ international conference on intelligent robot and systems. Innovative robotics for real-world applications*, vol. 2 (pp. 997–1003). IEEE.
- Stanford Artificial Intelligence Laboratory et al. (2018). Robotic operating system. URL <https://www.ros.org>.
- Study. com (2023). Calculating the amount of power required for an object to maintain a constant non-zero acceleration: Explanation. URL <https://study.com/skill/learn/calculating-the-amount-of-power-required-for-an-object-to-maintain-a-constant-non-zero-acceleration-explanation.html#:~:text=The%20equation%20for%20power%20is,calculate%20the%20change%20in%20velocity.> (Online; Accessed on 13 July 2023).
- Szczepanski, Rafal, Tarczewski, Tomasz, & Erwinski, Krystian (2022). Energy efficient local path planning algorithm based on predictive artificial potential field. *IEEE Access*, 10, 39729–39742.
- Tang, Hongtao, Cheng, Xiaoya, Jiang, Weiguang, & Chen, Shouwu (2021). Research on equipment configuration optimization of AGV unmanned warehouse. *IEEE Access*, 9, 47946–47959.
- Varghese, Anisha Mariam, & Jisha, V. R. (2018). Motion planning and control of an autonomous mobile robot. In *2018 International CET conference on control, communication, and computing* (pp. 17–21). IEEE.
- Wang, Jiankun, Li, Baopu, & Meng, Max Q.-H. (2021). Kinematic constrained bi-directional RRT with efficient branch pruning for robot path planning. *Expert Systems with Applications*, 170, Article 114541.
- Wang, Jiankun, Meng, Max Q.-H., & Khatib, Oussama (2020). EB-RRT: Optimal motion planning for mobile robots. *IEEE Transactions on Automation Science and Engineering*, 17(4), 2063–2073.
- Wu, Lei, Huang, Xiaodong, Cui, Junguo, Liu, Chao, & Xiao, Wensheng (2023). Modified adaptive ant colony optimization algorithm and its application for solving path planning of mobile robot. *Expert Systems with Applications*, 215, Article 119410.
- Xidias, Elias, & Azariadis, Philip (2019). Energy efficient motion design and task scheduling for an autonomous vehicle. In *Proceedings of the design society: International conference on engineering design: vol. 1*, (no. 1), (pp. 2853–2862). Cambridge University Press.
- Xie, Li, Henkel, Christian, Stol, Karl, & Xu, Weiliang (2018). Power-minimization and energy-reduction autonomous navigation of an omnidirectional mecanum robot via the dynamic window approach local trajectory planning. *International Journal of Advanced Robotic Systems*, 15(1), Article 1729881418754563.
- Xin, Jianbin, Wei, Liuqian, D'Ariano, Andrea, Zhang, Fangfang, & Negenborn, Rudy (2023). Flexible time-space network formulation and hybrid metaheuristic for conflict-free and energy-efficient path planning of automated guided vehicles. *Journal of Cleaner Production*, 398, Article 136472.
- Xu, Yuanquan, Jung, Cheolkon, & Chang, Yakun (2022). Head pose estimation using deep neural networks and 3D point clouds. *Pattern Recognition*, 121, Article 108210.
- Zeghmi, Lotfi, Amamou, Ali, Kelouwani, Sousso, Boisclair, Jonathan, & Agbossou, Kodjo (2022). A Kalman-particle hybrid filter for improved localization of AGV in indoor environment. In *2022 2nd International conference on robotics, automation and artificial intelligence* (pp. 141–147). IEEE.
- Zhang, Runda, Chai, Runqi, Chai, Senchun, Xia, Yuanqing, & Tsourdos, Antonios (2023). Design and practical implementation of a high efficiency two-layer trajectory planning method for AGV. *IEEE Transactions on Industrial Electronics*.
- Zhang, Zhongwei, Wu, Lihui, Zhang, Wenqiang, Peng, Tao, & Zheng, Jun (2021). Energy-efficient path planning for a single-load automated guided vehicle in a manufacturing workshop. *Computers & Industrial Engineering*, 158, Article 107397.
- Zhang, Yunong, Wu, Huarong, Zhang, Zhijun, Xiao, Lin, & Guo, Dongsheng (2013). Acceleration-level repetitive motion planning of redundant planar robots solved by a simplified LVI-based primal-dual neural network. *Robotics and Computer-Integrated Manufacturing*, 29(2), 328–343.
- Zhang, Haojie, Zhang, Yudong, Liu, Chuankai, & Zhang, Zuoyu (2023). Energy efficient path planning for autonomous ground vehicles with ackermann steering. *Robotics and Autonomous Systems*, 162, Article 104366.
- Zhong, Xunyu, Zhong, Xungao, & Peng, Xiafu (2014). Velocity-change-space-based dynamic motion planning for mobile robots navigation. *Neurocomputing*, 143, 153–163.



## Bibliographie

- [1] *Canada's Energy Transition*, <https://www.cer-rec.gc.ca/en/data-analysis/canada-energy-future/2021/key-findings.html>, Accessed : 01-01-2024.
- [2] I. AHMED, G. JEON et F. PICCIALLI, « From artificial intelligence to explainable artificial intelligence in industry 4.0 : a survey on what, how, and where, » *IEEE Transactions on Industrial Informatics*, t. 18, n° 8, p. 5031-5042, 2022.
- [3] P. OSTERRIEDER, L. BUDDE et T. FRIEDLI, « The smart factory as a key construct of industry 4.0 : A systematic literature review, » *International Journal of Production Economics*, t. 221, p. 107 476, 2020.
- [4] M. RYALAT, H. ELMOAQET et M. ALFAOURI, « Design of a smart factory based on cyber-physical systems and internet of things towards industry 4.0, » *Applied Sciences*, t. 13, n° 4, p. 2156, 2023.
- [5] E. OZTEMEL et S. GURSEV, « Literature review of Industry 4.0 and related technologies, » *Journal of intelligent manufacturing*, t. 31, p. 127-182, 2020.
- [6] *The Smart Factory : Montreal*, <https://www2.deloitte.com/ca/en/pages/consulting/articles/the-smart-factory-montreal.html>, Accessed : 26-07-2023.
- [7] M. GHOBAKHLOO et M. FATHI, « Industry 4.0 and opportunities for energy sustainability, » *Journal of Cleaner Production*, t. 295, p. 126 427, 2021.
- [8] R. SELL, A. RASSÖLKIN, R. WANG et T. OTTO, « Integration of autonomous vehicles and Industry 4.0, » *Proceedings of the Estonian Academy of Sciences*, t. 68, n° 4, p. 389-394, 2019.

- [9] L. DORMEHL, *Self-driving forklifts are here to revolutionize warehouses, for better or worse*, 2020.
- [10] M. CHEN, A. SINHA, K. HU et M. I. SHAH, « Impact of technological innovation on energy efficiency in industry 4.0 era : Moderation of shadow economy in sustainable development, » *Technological Forecasting and Social Change*, t. 164, p. 120-151, 2021.
- [11] T. NISHI et R. MAENO, « Petri net decomposition approach to optimization of route planning problems for AGV systems, » *IEEE Transactions on Automation Science and Engineering*, t. 7, n° 3, p. 523-537, 2010.
- [12] R. HABA, M. OHZEKI et K. TANAKA, « Travel time optimization on multi-AGV routing by reverse annealing, » *Scientific reports*, t. 12, n° 1, p. 17753, 2022.
- [13] Z. XING, H. LIU, T. WANG, E. P. CHEW, L. H. LEE et K. C. TAN, « Integrated automated guided vehicle dispatching and equipment scheduling with speed optimization, » *Transportation Research Part E : Logistics and Transportation Review*, t. 169, p. 102993, 2023.
- [14] P. HANG, B. LOU et C. LV, « Nonlinear predictive motion control for autonomous mobile robots considering active fault-tolerant control and regenerative braking, » *Sensors*, t. 22, n° 10, p. 3939, 2022.
- [15] R. GIEL et A. DĄBROWSKA, « Autonomous Mobile Robot Study in the Context of Maintenance 4.0, » in *Reliability and Statistics in Transportation and Communication : Selected Papers from the 22nd International Multidisciplinary Conference on Reliability and Statistics in Transportation and Communication : Artificial Intelligence in Transportation, RelStat-2022, October 20-21, 2022, Riga, Latvia*, Springer, 2023, p. 213-222.
- [16] B. PATLE, A. PANDEY, D. PARHI, A. JAGADEESH et al., « A review : On path planning strategies for navigation of mobile robot, » *Defence Technology*, t. 15, n° 4, p. 582-606, 2019.

- [17] A. MEYSAMI, J.-C. CUILLIÈRE, V. FRANÇOIS et S. KELOUWANI, « Investigating the impact of triangle and quadrangle mesh representations on AGV path planning for various indoor environments : with or without inflation, » *Robotics*, t. 11, n° 2, p. 50, 2022.
- [18] C.-W. CHEN, C.-L. LIN, J.-J. HSU, S.-P. TSENG et J.-F. WANG, « Design and Implementation of AMR Robot Based on RGBD, VSLAM and SLAM, » in *2021 9th International Conference on Orange Technology (ICOT)*, IEEE, 2021, p. 1-5.
- [19] L. ZEGHMI, A. AMAMOU, S. KELOUWANI, J. BOISCLAIR et K. AGBOSSOU, « A Kalman-Particle Hybrid Filter For Improved Localization of AGV In Indoor Environment, » in *2022 2nd International Conference on Robotics, Automation and Artificial Intelligence (RAAI)*, IEEE, 2022, p. 141-147.
- [20] S. HE, T. SONG et X. WU, « An improved adaptive monte carlo localization (amcl) for automated mobile robot (amr), » in *CICTP 2022*, 2022, p. 171-181.
- [21] A. K. BAHAROM, S. ABDUL-RAHMAN, R. JAMALI et S. MUTALIB, « Towards modelling autonomous mobile robot localization by using sensor fusion algorithms, » in *2020 IEEE 10th international conference on system engineering and technology (ICSET)*, IEEE, 2020, p. 185-190.
- [22] O HACHOUR, « Path planning of Autonomous Mobile robot, » *International journal of systems applications, engineering & development*, t. 2, n° 4, p. 178-190, 2008.
- [23] H.-S. YOON et T.-H. PARK, « Motion planning of autonomous mobile robots by iterative dynamic programming, » *Intelligent Service Robotics*, t. 8, p. 165-174, 2015.
- [24] H. ZHANG, L. XU, J. LIANG et X. SUN, « Research on Guide Line Identification and Lateral Motion Control of AGV in Complex Environments, » *Machines*, t. 10, n° 2, p. 121, 2022.
- [25] M. MOHAMMADPOUR, L. ZEGHMI, S. KELOUWANI, M.-A. GAUDREAU, A. AMAMOU et M. GRABA, « An investigation into the energy-efficient motion of autonomous wheeled mobile robots, » *Energies*, t. 14, n° 12, p. 3517, 2021.

- [26] E. MEJRI, S. KELOUWANI, Y. DUBÉ, N. HENAO et K. AGBOSSOU, « Energy Efficient Order Picking Routing for a Pick Support Automated Guided Vehicle (Ps-AGV), » *IEEE Access*, t. 10, p. 108 832-108 847, 2022.
- [27] M. GRABA, S. KELOUWANI, L. ZEGHMI, A. AMAMOU, K. AGBOSSOU et M. MOHAMMADPOUR, « Investigating the impact of energy source level on the self-guided vehicle system performances, in the industry 4.0 context, » *Sustainability*, t. 12, n° 20, p. 8541, 2020.
- [28] E. A. SHAIKH et A. DHALE, « AGV path planning and obstacle avoidance using Dijkstra's algorithm, » *International Journal of Application or Innovation in Engineering & Management (IJAIEM)*, t. 2, n° 6, p. 77-83, 2013.
- [29] M. MOHAMMADPOUR, S. KELOUWANI, M.-A. GAUDREAU et al., « Energy-efficient local path planning of a self-guided vehicle by considering the load position, » *IEEE Access*, t. 10, p. 112 669-112 685, 2022.
- [30] B. VAN MELDERT et L. DE BOECK, « Introducing autonomous vehicles in logistics : a review from a broad perspective, » *FEB Research Report KBI\_1618*, 2016.
- [31] D. MARTIN et D. LITWHILER, « An investigation of acceleration and jerk profiles of public transportation vehicles, » in *2008 Annual Conference & Exposition*, 2008, p. 13-194.
- [32] P. C. FINO, T. E. LOCKHART et N. F. FINO, « Corner height influences center of mass kinematics and path trajectory during turning, » *Journal of biomechanics*, t. 48, n° 1, p. 104-112, 2015.
- [33] S. TAKANO, M. NAGAI, T. TANIGUCHI et T. HATANO, « Study on a vehicle dynamics model for improving roll stability, » *JSAE review*, t. 24, n° 2, p. 149-156, 2003.
- [34] R. GALVIN, « Energy consumption effects of speed and acceleration in electric vehicles : Laboratory case studies and implications for drivers and policymakers, » *Transportation Research Part D : Transport and Environment*, t. 53, p. 234-248, 2017.

- [35] H. TANG, X. CHENG, W. JIANG et S. CHEN, « Research on equipment configuration optimization of AGV unmanned warehouse, » *IEEE Access*, t. 9, p. 47 946-47 959, 2021.
- [36] I. DULEBA et J. Z. SASIADEK, « Nonholonomic motion planning based on Newton algorithm with energy optimization, » *IEEE transactions on control systems technology*, t. 11, n° 3, p. 355-363, 2003.
- [37] M. KARAMUK, İ. SAVCI et H. OCAKLI, « A Survey on Traction System Development of Automated Guided Vehicles, » *European Journal of Technique (EJT)*, t. 12, n° 1, p. 1-12, 2022.
- [38] F. HEGEDÜS, T. BÉCSI, S. ARADI et P. GÁPÁR, « Model based trajectory planning for highly automated road vehicles, » *IFAC-PapersOnLine*, t. 50, n° 1, p. 6958-6964, 2017.
- [39] A. SCHEUER et T. FRAICHARD, « Continuous-curvature path planning for car-like vehicles, » in *Proceedings of the 1997 IEEE/RSJ International Conference on Intelligent Robot and Systems. Innovative Robotics for Real-World Applications. IROS'97*, IEEE, t. 2, 1997, p. 997-1003.
- [40] A. J. MOSHAYEDI, L. JINSONG et L. LIAO, « AGV (automated guided vehicle) robot : Mission and obstacles in design and performance, » *Journal of Simulation and Analysis of Novel Technologies in Mechanical Engineering*, t. 12, n° 4, p. 5-18, 2019.
- [41] G. BÜCHI, M. CUGNO et R. CASTAGNOLI, « Smart factory performance and Industry 4.0, » *Technological forecasting and social change*, t. 150, p. 119 790, 2020.
- [42] M. TRIANANDA, D. A. SUMARSONO, F. ZAINURI, F. A. FALAH, F. ARRAFI et G. FAUZAN, « Analysis of effect of center of gravity change towards type M1 vehicle stability, » in *AIP Conference Proceedings*, AIP Publishing, t. 2376, 2021.
- [43] C. DING, L. ZHOU, Y. LI et X. RONG, « Locomotion control of quadruped robots with online center of mass adaptation and payload identification, » *IEEE Access*, t. 8, p. 224 578-224 587, 2020.

- [44] F. PEDREGOSA, G. VAROQUAUX, A. GRAMFORT et al., « Scikit-learn : Machine Learning in Python, » *Journal of Machine Learning Research*, t. 12, p. 2825-2830, 2011.
- [45] N. KOENIG et A. HOWARD, « Design and use paradigms for gazebo, an open-source multi-robot simulator, » in *2004 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)(IEEE Cat. No. 04CH37566)*, IEEE, t. 3, 2004, p. 2149-2154.
- [46] STANFORD ARTIFICIAL INTELLIGENCE LABORATORY ET AL., *Robotic Operating System*, version ROS Melodic Morenia, 23 mai 2018.
- [47] T. M. INC., *MATLAB version : 9.13.0 (R2022b)*, Natick, Massachusetts, United States, 2022.
- [48] J. KONG, M. PFEIFFER, G. SCHILDBACH et F. BORRELLI, « Kinematic and dynamic vehicle models for autonomous driving control design, » in *2015 IEEE intelligent vehicles symposium (IV)*, IEEE, 2015, p. 1094-1099.
- [49] C. ZHANG et L. ZHANG, « Kinematics analysis and workspace investigation of a novel 2-DOF parallel manipulator applied in vehicle driving simulator, » *Robotics and Computer-Integrated Manufacturing*, t. 29, n° 4, p. 113-120, 2013.
- [50] R. DHAOUADI et A. A. HATAB, « Dynamic modelling of differential-drive mobile robots using lagrange and newton-euler methodologies : A unified framework, » *Advances in Robotics & Automation*, t. 2, n° 2, p. 1-7, 2013.
- [51] B. B. MEVO, M. R. SAAD et R. FAREH, « Adaptive sliding mode control of wheeled mobile robot with nonlinear model and uncertainties, » in *2018 IEEE Canadian Conference on Electrical & Computer Engineering (CCECE)*, IEEE, 2018, p. 1-5.
- [52] M. A. ALI et M. MAILAH, « A simulation and experimental study on wheeled mobile robot path control in road roundabout environment, » *International Journal of Advanced Robotic Systems*, t. 16, n° 2, p. 1 729 881 419 834 778, 2019.

- [53] J. FELIX-RENDON, J. C. BELLO-ROBLES et R. Q. FUENTES-AGUILAR, « Control of differential-drive mobile robots for soft object deformation, » *ISA transactions*, t. 117, p. 221-233, 2021.
- [54] M. F. JARAMILLO-MORALES, S. DOGRU et L. MARQUES, « Generation of energy optimal speed profiles for a differential drive mobile robot with payload on straight trajectories, » in *2020 IEEE International Symposium on Safety, Security, and Rescue Robotics (SSRR)*, IEEE, 2020, p. 136-141.
- [55] R. M. DESANTIS, « Modeling and path-tracking control of a mobile wheeled robot with a differential drive, » *Robotica*, t. 13, n° 4, p. 401-410, 1995.
- [56] W. KHALIL, « Dynamic modeling of robots using newton-euler formulation, » in *Informatics in Control, Automation and Robotics : Revised and Selected Papers from the International Conference on Informatics in Control, Automation and Robotics 2010*, Springer, 2011, p. 3-20.
- [57] Y. LIU et H. YU, « A survey of underactuated mechanical systems, » *IET Control Theory & Applications*, t. 7, n° 7, p. 921-935, 2013.
- [58] F. N. MARTINS, M. SARCINELLI-FILHO et R. CARELLI, « A velocity-based dynamic model and its properties for differential drive mobile robots, » *Journal of intelligent & robotic systems*, t. 85, p. 277-292, 2017.
- [59] K. SHOJAEI, A. M. SHAHRI, A. TARAKAMEH et B. TABIBIAN, « Adaptive trajectory tracking control of a differential drive wheeled mobile robot, » *Robotica*, t. 29, n° 3, p. 391-402, 2011.
- [60] K. R. SHARMA, D. HONC et F. DUSEK, « Predictive Control Of Differential Drive Mobile Robot Considering Dynamics And Kinematics., » in *ECMS*, 2016, p. 354-360.
- [61] J. J. PARK, S. LEE et B. KUIPERS, « Discrete-time dynamic modeling and calibration of differential-drive mobile robots with friction, » in *2017 IEEE International Conference on Robotics and Automation (ICRA)*, IEEE, 2017, p. 6510-6517.

- [62] M. SIWEK, J. PANASIUK, L. BARANOWSKI, W. KACZMAREK, P. PRUSACZYK et S. BORYS, « Identification of differential drive robot dynamic model parameters, » *Materials*, t. 16, n° 2, p. 683, 2023.
- [63] R. PEPY, A. LAMBERT et H. MOUNIER, « Path planning using a dynamic vehicle model, » in *2006 2nd International Conference on Information & Communication Technologies*, IEEE, t. 1, 2006, p. 781-786.
- [64] H LAVACS et al., « A 2D car physics model based on Ackermann steering, » in *Institute of Distributed and Multimedia Systems*, University of Vienna, 2006.
- [65] H SAYYAADI, H KOUHI et H SALARIEH, « Control of car-like (wheeled) multi robots for following and hunting a moving target, » *Scientia Iranica*, t. 18, n° 4, p. 950-965, 2011.
- [66] X. JIN, G. YIN et N. CHEN, « Advanced estimation techniques for vehicle system dynamic state : A survey, » *Sensors*, t. 19, n° 19, p. 4289, 2019.
- [67] Q. LI, R. LI, K. JI et W. DAI, « Kalman filter and its application, » in *2015 8th International Conference on Intelligent Networks and Intelligent Systems (ICINIS)*, IEEE, 2015, p. 74-77.
- [68] I. DAVOODABADI, A. A. RAMEZANI, M. MAHMOODI-K et P. AHMADIZADEH, « Identification of tire forces using Dual Unscented Kalman Filter algorithm, » *Nonlinear Dynamics*, t. 78, p. 1907-1919, 2014.
- [69] N.-B. HOANG et H.-J. KANG, « A model-based fault diagnosis scheme for wheeled mobile robots, » *International Journal of Control, Automation and Systems*, t. 12, p. 637-651, 2014.
- [70] X. JIN et G. YIN, « Estimation of lateral tire–road forces and sideslip angle for electric vehicles using interacting multiple model filter approach, » *Journal of the Franklin Institute*, t. 352, n° 2, p. 686-707, 2015.
- [71] G. REINA, M. PAIANO et J.-L. BLANCO-CLARACO, « Vehicle parameter estimation using a model-based estimator, » *Mechanical Systems and Signal Processing*, t. 87, p. 227-241, 2017.



- [72] M. N. MAHYUDDIN, J. NA, G. HERRMANN, X. REN et P. BARBER, « Adaptive observer-based parameter estimation with application to road gradient and vehicle mass estimation, » *IEEE Transactions on Industrial Electronics*, t. 61, n° 6, p. 2851-2863, 2013.
- [73] R. RAJAMANI, G. PHANOMCHOENG, D. PIYABONGKARN et J. Y. LEW, « Algorithms for real-time estimation of individual wheel tire-road friction coefficients, » *IEEE/ASME transactions on mechatronics*, t. 17, n° 6, p. 1183-1195, 2011.
- [74] Y.-Q. ZHAO, H.-Q. LI, F. LIN, J. WANG et X.-W. JI, « Estimation of road friction coefficient in different road conditions based on vehicle braking dynamics, » *Chinese Journal of Mechanical Engineering*, t. 30, p. 982-990, 2017.
- [75] T. CHEN, L. CHEN, Y. CAI et X. XU, « Robust sideslip angle observer with regional stability constraint for an uncertain singular intelligent vehicle system, » *IET Control Theory & Applications*, t. 12, n° 13, p. 1802-1811, 2018.
- [76] J. ZHAO, J. ZHANG et B. ZHU, « Coordinative traction control of vehicles based on identification of the tyre–road friction coefficient, » *Proceedings of the Institution of Mechanical Engineers, Part D : Journal of Automobile Engineering*, t. 230, n° 12, p. 1585-1604, 2016.
- [77] M. CUI, W. LIU, H. LIU, H. JIANG et Z. WANG, « Extended state observer-based adaptive sliding mode control of differential-driving mobile robot with uncertainties, » *Nonlinear Dynamics*, t. 83, p. 667-683, 2016.
- [78] C. REN, X. LI, X. YANG et S. MA, « Extended state observer-based sliding mode control of an omnidirectional mobile robot with friction compensation, » *IEEE Transactions on Industrial Electronics*, t. 66, n° 12, p. 9480-9489, 2019.
- [79] G.-w. YOU, S. PARK et D. OH, « Real-time state-of-health estimation for electric vehicle batteries : A data-driven approach, » *Applied energy*, t. 176, p. 92-103, 2016.
- [80] Y. WEI, X. ZHANG, Y. SHI et al., « A review of data-driven approaches for prediction and classification of building energy consumption, » *Renewable and Sustainable Energy Reviews*, t. 82, p. 1027-1047, 2018.

- [81] C. M. NGUYEN, A.-T. NGUYEN et S. DELPRAT, « Neural-Network-Based Fuzzy Observer with Data-Driven Uncertainty Identification for Vehicle Dynamics Estimation under Extreme Driving Conditions : Theory and Experimental Results, » *IEEE Transactions on Vehicular Technology*, 2023.
- [82] H. TAUD et J. MAS, « Multilayer perceptron (MLP), » *Geomatic approaches for modeling land change scenarios*, p. 451-455, 2018.
- [83] S. KARAMAN et E. FRAZZOLI, « Sampling-based algorithms for optimal motion planning, » *The international journal of robotics research*, t. 30, n° 7, p. 846-894, 2011.
- [84] C. QUINTERO-PENA, A. KYRILLIDIS et L. E. KAVRAKI, « Robust optimization-based motion planning for high-DOF robots under sensing uncertainty, » in *2021 IEEE International Conference on Robotics and Automation (ICRA)*, IEEE, 2021, p. 9724-9730.
- [85] M. ZHU, C. XIAO, S. GU, Z. DU et Y. WEN, « A circle grid-based approach for obstacle avoidance motion planning of unmanned surface vehicles, » *Proceedings of the Institution of Mechanical Engineers, Part M : Journal of Engineering for the Maritime Environment*, t. 237, n° 1, p. 132-152, 2023.
- [86] O. BROCK et L. E. KAVRAKI, « Decomposition-based motion planning : A framework for real-time motion planning in high-dimensional configuration spaces, » in *Proceedings 2001 ICRA. IEEE International Conference on Robotics and Automation (Cat. No. 01CH37164)*, IEEE, t. 2, 2001, p. 1469-1474.
- [87] J. WANG, T. ZHANG, N. MA et al., « A survey of learning-based robot motion planning, » *IET Cyber-Systems and Robotics*, t. 3, n° 4, p. 302-314, 2021.
- [88] M. A. K. JARADAT, M. H. GARIBEH et E. A. FEILAT, « Autonomous mobile robot dynamic motion planning using hybrid fuzzy potential field, » *Soft Computing*, t. 16, p. 153-164, 2012.

- [89] Y. MEI, Y.-H. LU, Y. C. HU et C. G. LEE, « Energy-efficient motion planning for mobile robots, » in *IEEE International Conference on Robotics and Automation, 2004. Proceedings. ICRA '04. 2004*, IEEE, t. 5, 2004, p. 4344-4349.
- [90] A. LLAMAZARES, V. IVAN, E. MOLINOS, M. OCANA et S. VIJAYAKUMAR, « Dynamic obstacle avoidance using bayesian occupancy filter and approximate inference, » *Sensors*, t. 13, n° 3, p. 2929-2944, 2013.
- [91] C. HENKEL, A. BUBECK et W. XU, « Energy efficient dynamic window approach for local path planning in mobile service robotics, » *IFAC-PapersOnLine*, t. 49, n° 15, p. 32-37, 2016.
- [92] S. LIU et D. SUN, « Minimizing energy consumption of wheeled mobile robots via optimal motion planning, » *IEEE/ASME Transactions on Mechatronics*, t. 19, n° 2, p. 401-411, 2013.
- [93] L. XIE, C. HENKEL, K. STOL et W. XU, « Power-minimization and energy-reduction autonomous navigation of an omnidirectional Mecanum robot via the dynamic window approach local trajectory planning, » *International Journal of Advanced Robotic Systems*, t. 15, n° 1, p. 1 729 881 418 754 563, 2018.
- [94] A. ALAJLAN, K. ELLEITHY, M. ALMASRI et T. SOBH, « An optimal and energy efficient multi-sensor collision-free path planning algorithm for a mobile robot in dynamic environments, » *Robotics*, t. 6, n° 2, p. 7, 2017.
- [95] N. GUPTA, C. ORDONEZ et E. G. COLLINS, « Dynamically feasible, energy efficient motion planning for skid-steered vehicles, » *Autonomous Robots*, t. 41, p. 453-471, 2017.
- [96] A. M. VARGHESE et V. JISHA, « Motion planning and control of an autonomous mobile robot, » in *2018 International CET Conference on Control, Communication, and Computing (IC4)*, IEEE, 2018, p. 17-21.
- [97] E. XIDIAS et P. AZARIADIS, « Energy Efficient Motion Design and Task Scheduling for an Autonomous Vehicle, » in *Proceedings of the Design Society : International*

- Conference on Engineering Design*, Cambridge University Press, t. 1, 2019, p. 2853-2862.
- [98] H. ZHANG, Y. ZHANG, C. LIU et Z. ZHANG, « Energy efficient path planning for autonomous ground vehicles with ackermann steering, » *Robotics and Autonomous Systems*, p. 104 366, 2023.
- [99] R. SZCZEPANSKI, T. TARCZEWSKI et K. ERWINSKI, « Energy efficient local path planning algorithm based on predictive artificial potential field, » *IEEE Access*, t. 10, p. 39 729-39 742, 2022.
- [100] C. RÖSMANN, F. HOFFMANN et T. BERTRAM, « Kinodynamic trajectory optimization and control for car-like robots, » in *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, IEEE, 2017, p. 5681-5686.
- [101] D. FOX, W. BURGARD et S. THRUN, « The dynamic window approach to collision avoidance, » *IEEE Robotics & Automation Magazine*, t. 4, n° 1, p. 23-33, 1997.
- [102] STUDY.COM, *Calculating the Amount of Power Required for an Object to Maintain a Constant Non-Zero Acceleration : Explanation*, [Online ; accessed on 13-July-2023], 2023.
- [103] Z. HENDZEL et al., « Modelling of dynamics of a wheeled mobile robot with mecanum wheels with the use of Lagrange equations of the second kind, » *International Journal of Applied Mechanics and Engineering*, t. 22, n° 1, p. 81-99, 2017.
- [104] R. D. KNIGHT, *Physics for scientists and engineers*. Pearson Education, Limited, 2022.
- [105] J. SANDOVAL, R. KELLY, V. SANTIBÁÑEZ et J. VILLALOBOS-CHIN, « Energy regulation of torque-driven robot manipulators in joint space, » *Journal of the Franklin Institute*, t. 359, n° 4, p. 1427-1456, 2022.
- [106] R. SAIDUR, S. MEKHILEF, M. B. ALI, A. SAFARI et H. A. MOHAMMED, « Applications of variable speed drive (VSD) in electrical motors energy savings, » *Renewable and sustainable energy reviews*, t. 16, n° 1, p. 543-550, 2012.

- [107] C. RÖSMANN, W. FEITEN, T. WÖSCH, F. HOFFMANN et T. BERTRAM, « Trajectory modification considering dynamic constraints of autonomous robots, » in *ROBOTIK 2012 ; 7th German Conference on Robotics*, VDE, 2012, p. 1-6.
- [108] G. KLANCAR, A. ZDESAR, S. BLAZIC et I. SKRJANC, *Wheeled mobile robotics : from fundamentals towards autonomous systems*. Butterworth-Heinemann, 2017.
- [109] J. H. GINSBERG, *Advanced engineering dynamics*. Cambridge University Press, 1998.
- [110] D. GUO, Y. WU, S. S. SHITZ et S. VERDÚ, « Estimation in Gaussian noise : Properties of the minimum mean-square error, » *IEEE Transactions on Information Theory*, t. 57, n° 4, p. 2371-2385, 2011.
- [111] R. J. HYNDMAN et A. B. KOEHLER, « Another look at measures of forecast accuracy, » *International journal of forecasting*, t. 22, n° 4, p. 679-688, 2006.
- [112] C. RÖSMANN, A. MAKAROW et T. BERTRAM, « Online motion planning based on nonlinear model predictive control with non-euclidean rotation groups, » in *2021 European Control Conference (ECC)*, IEEE, 2021, p. 1583-1590.
- [113] J. GIESEN et S. LAUE, « Combining ADMM and the Augmented Lagrangian Method for Efficiently Handling Many Constraints., » in *IJCAI*, 2019, p. 4525-4531.
- [114] R. KÜMMERLE, G. GRISETTI, H. STRASDAT, K. KONOLIGE et W. BURGARD, « g2o : A general framework for graph optimization, » in *2011 IEEE International Conference on Robotics and Automation*, IEEE, 2011, p. 3607-3613.
- [115] C. DANIELSON, K. BERNTORP, A. WEISS et S. DI CAIRANO, « Robust motion planning for uncertain systems with disturbances using the invariant-set motion planner, » *IEEE Transactions on Automatic Control*, t. 65, n° 10, p. 4456-4463, 2020.
- [116] M. UNSER, « A note on BIBO stability, » *IEEE Transactions on Signal Processing*, t. 68, p. 5904-5913, 2020.
- [117] W. C. CHO, M. W. SEO, S. D. KIM et al., « Continuous operation characteristics of chemical looping hydrogen production system, » *Applied energy*, t. 113, p. 1667-1674, 2014.