جامعة سيدي محمد بن عبد الله بفاس
UNIVERSITÉ SIDI MOHAMED BEN ABDELLAH DE FES

كلية العلوم والتقنيات فاس
FACULTÉ DES SCIENCES ET TECHNIQUES DE FÈS

N° d'ordre : 77/2023

Centre des Etudes Doctorales : Sciences et Techniques et Sciences Médicales
Formation Doctorale : Sciences de l'Ingénieur, Sciences Physiques, Mathématiques et Informatique.
Discipline : Génie électrique
Spécialité* : Génie électrique/Systèmes embarqués
Laboratoire : Systèmes Intelligents, Géoressources et Énergies Renouvelables (SIGER)

Résumé en français de la thèse de DOCTORAT

Advanced AI-Based Strategies for Electric Vehicle Energy and Battery Management Systems

Préparée par : Mr Yahia MAZZI

Soutenue le 28/10/2023 devant le jury :

Nom et Prénom	Grade	Etablissement	Qualité
Ali Ahaitouf	PES	Faculté des Sciences et Techniques de Fès	Président
Abdeslam Lachhab	PES	Ecole Supérieure de Technologie de Meknès	Rapporteur
Hassane El Markhi	PES	Faculté des Sciences et Techniques de Fès	Rapporteur
Malika Alami Marktani	PH	Ecole Nationale des Sciences Appliquées de Fès	Rapporteur
Najia Es-Sbai	PES	Faculté des Sciences et Techniques de Fès	Examinateur
Hicham Hihi	PES	Ecole Nationale des Sciences Appliquées de Fès	Examinateur
Fatima Errahimi	PES	Faculté des Sciences et Techniques de Fès	Directeur de thèse

Remerciements

Je remercie Dieu Tout-Puissant de m'avoir aidé tout au long de mon parcours.

Je tiens à exprimer ma sincère gratitude au **Pr. Fatima ERRAHIMI** pour m'avoir généreusement offert l'opportunité d'entamer mon parcours de doctorat sous sa direction et supervision expertes. Sa sagesse, sa vision, son expertise, ses conseils, son implication enthousiaste et ses encouragements constants ont été d'une grande valeur lors de la planification et du développement de cette recherche. J'apprécie également grandement ses efforts minutieux pour examiner attentivement et améliorer les manuscrits, sans lesquels ce travail n'aurait pu être achevé.

Je dois énormément au Pr. Hicham BEN SASSI pour ses échanges inestimables, son esprit collaborative et son mentorat d'expert.

Je tiens également à exprimer ma sincère reconnaissance au **Pr. Ali AHAITOUF**, le directeur du laboratoire SIGER où ce travail a été mené. Son soutien indéfectible tout au long de cette thèse, ainsi que sa mise à disposition de ressources essentielles ont été déterminants pour ma progression. Ma gratitude s'étend également aux enseignants dévoués du laboratoire SIGER. Mes remerciements spéciaux au **Pr. El Houssine ALILOU** pour son soutien constant et ses conseils éclairés.

J'exprime toute ma sincère reconnaissance au **Pr. Ali AHAITOUF**, pour avoir gracieusement accepté de présider le jury de ma thèse.

Ma gratitude s'étend également aux **Pr. Abdeslam LACHHAB**, **Pr. Hassane EL MARKHI** et **Pr. Malika ALAMI MARKTANI** pour leur volonté de servir en tant que rapporteurs de mon travail et pour leurs commentaires constructifs. J'exprime également ma reconnaissance aux **Pr. Najia ES-SBAI** et **Pr. Hicham HIHI** pour leur participation au jury de ma thèse et pour leurs commentaires perspicaces.

J'étends ma gratitude éternelle à ma mère, à mes frères et surs et aux autres membres de ma famille, pour leur soutien inébranlable et leur confiance en moi tout au long de mes études. Sans leurs sacrifices infinis, atteindre les étapes que j'ai franchies aurait été un défi insurmontable. Merci.

Je souhaite exprimer ma gratitude envers mes amis et aux collègues chercheurs du laboratoire SIGER pour leur aide et leur motivation tout au long de mes travaux de recherche.

Je dédie cette thèse à la mémoire précieuse de mon défunt père et de ma soeur, dont la présence me manque profondément. Je suis convaincu qu'ils auraient été très fiers d'assister à mes réalisations.

Résumé

À l'ère de la mobilité durable, la technologie des véhicules électriques (EVs) s'est imposée comme une force essentielle pour remodeler les paradigmes de transport. L'évolution rapide de la technologie des EVs a suscité le besoin d'une exploration exhaustive visant à améliorer leurs performances, leur efficacité et leur durabilité. Cette thèse présente une investigation globale dans des domaines clés du développement des EVs, englobant l'architecture de la chaîne de traction, les systèmes de stockage d'énergie (ESS), les stratégies de contrôle avancées et les techniques d'estimation d'état.

L'étude explore en profondeur la chaîne de traction des EVs, y compris sa configuration générale, les différentes technologies de moteur utilisées et les dernières avancées dans les ESSs et la gestion de la batterie. Compte tenu du rôle critique de la batterie en tant que composant à la fois coûteux et essentiel d'un EV, son fonctionnement sûr nécessite une surveillance en temps réel de ses états clés, notamment l'état de charge (SOC) et l'état de santé (SOH). Une attention particulière est portée à l'estimation du SOC, tout en examinant méticuleusement diverses techniques, y compris des méthodes basées sur des modèles et des approches orientées données, particulièrement, les algorithmes d'apprentissage profond. Étant donné que ces méthodes sont souvent destinées à être implémentés dans des systèmes embarqués à ressources limitées, leur faisabilité de mise en oeuvre est examinée. Alors que le SOC fournit des données instantanées sur la capacité de la batterie restante, évitant l'épuisement, le SOH sert à évaluer la dégradation au fil des cycles, déclenchant des alertes de remplacement. Ainsi, une nouvelle technique hybride, fusionnant deux algorithmes DL est présentée pour parvenir à une estimation précise du SOH. Des tests rigoureux ont été menés couvrant différents aspects pour évaluer les performances de la technique. Du côté de la chaîne de traction, des stratégies de contrôle avancées sont développées, exemplifiées par la combinaison d'un contrôleur de mode glissant terminal non singulier et d'un réseau de neurones à fonctions de base radiale pour une régulation de vitesse affinée et un rejet des perturbations d'un moteur synchrone à aimant permanent (PMSM). De plus, deux contrôleurs à double mode glissant intégral supervisent le transfert de puissance via un convertisseur à double pont actif isolé bidirectionnel, reliant la batterie et le PMSM. Par ailleurs, afin de prolonger la durée de vie de la batterie, un ESS hybride (HESS) est envisagé. Néanmoins, assurer une répartition efficace de la puissance au sein du HESS représente un défi. Par suite, un système de gestion dénergie robuste basée sur un algorithme d'apprentissage par renforcement est proposé, qui révèle une adaptabilité et une efficacité remarquable dans divers scénarios de conduite.

En résumé, cette thèse offre une perspective globale sur le développement des EVs en explorant le contrôle de la chaîne de traction, la gestion de l'énergie et l'estimation d'état. Les méthodologies avancées proposées contribuent de manière significative à l'amélioration des performances, de l'efficacité et de la durabilité des EVs dans le contexte automobile moderne.

Mots-clés : Véhicules électriques ; Intelligence artificielle, État de charge ; État de santé ; Apprentissage profond ; Apprentissage par renforcement ; Système de gestion de l'énergie ; Système de stockage d'énergie hybride ; Moteur synchrone à aimant permanent ; Régulation de vitesse ; systèmes embarqués ; Contrôle en mode glissant non singulier.

Abstract

In the era of sustainable mobility, electric vehicle (EV) technology has emerged as a pivotal force in reshaping transportation paradigms. The rapid evolution of EV technology has brought forth the need for a comprehensive exploration aimed at augmenting their performance, efficiency, and sustainability. This thesis presents a holistic investigation into key areas of EV development, encompassing powertrain architecture, energy storage systems (ESS), advanced control strategies, and state estimation techniques.

The study delves into the EV powertrain, covering diverse motor technologies and powertrain configurations while highlighting cutting-edge ESSs and battery management methodologies. Considering the batterys vital role as the costliest and most crucial component of an EV, its safe operation requires real-time monitoring of key states, notably state of charge (SOC) and state of health (SOH). Consequently, special attention is given to real-time SOC estimation while meticulously examining various techniques, including model-based methods and data-driven approaches, particularly deep learning (DL) algorithms. Given that these methods are often intended to be implemented in resource-constrained embedded systems, their implementation feasibility on a STM32F4 board is explored. While SOC provides instant data on remaining battery capacity, averting depletion, SOH serves to gauge degradation over cycles, prompting replacement alerts. Thus, a novel hybrid technique, merging 1D Convolutional Neural Networks (1D CNN) with bidirectional Gated Recurrent Units (Bi-GRU), is presented to achieve precise SOH estimation. Rigorous investigations cover various dimensions to ascertain the techniques performance.

On the powertrain front, advanced control strategies are developed, exemplified by the combination of a nonsingular terminal sliding mode controller (NTSMC) and a radial basis function neural network (RBFNN) for refined speed regulation and disturbance rejection of a permanent magnet synchronous motor (PMSM). Furthermore, a double integral sliding mode controller (DISMC) oversees power transfer via an isolated bidirectional dual-active bridge converter (IBDAB), linking the battery and PMSM. Furthermore, in order to extend the battery's lifespan, a hybrid energy storage system (HESS) is considered. However, ensuring efficient power distribution in HESS is challenging. As a result, a resilient energy management system (EMS) based on a reinforcement learning (RL) algorithm was proposed, which revealed remarkable adaptability and efficiency across various driving scenarios, ultimately resulting in significant enhancements in energy allocation performance.

This thesis offers a comprehensive framework for advancing EV technology, encompassing powertrain control, energy management, and state estimation. The proposed methodologies significantly contribute to the realization of high-performance, sustainable EVs within a dynamic automotive landscape.

Keywords: EVs; Artificial intelligence; State of charge; State of health; Deep learning; reinforcement learning; Energy management system; Hybrid energy storage system; Permanent magnet synchronous motor; Speed control;embedded systems; Nonsingular terminal sliding mode control.

Contents

Remerciements i

Résumé ii

Abstract iii

Liste des figures vii

Liste des tableaux ix

Liste des abréviations x

Introduction 1

1 Généralités sur les véhicules électriques 7

1.1 Introduction . . . 7
1.2 Véhicules électriques . . . 7
1.3 Architecture générale de la chaîne de traction . . . 8
1.3.1 Moteur de traction électrique . . . 9
1.3.2 Système d'électronique de puissance . . . 10
1.3.3 Système de stockage d'énergie . . . 10
1.3.4 Système de gestion de batterie . . . 11
1.3.5 Système de gestion de l'énergie . . . 11
1.4 Batterie Li-ion . . . 12
1.4.1 Terminologies et propriétés des batteries lithium-ion . . . 12
1.4.2 Modélisation de la batterie . . . 13
1.5 Méthodes d'estimation d'état . . . 15
1.5.1 Méthodes conventionnelles . . . 15
1.5.2 Méthode d'estimation basée sur un modèle . . . 16
1.5.3 Méthodes basées sur les données . . . 17
1.6 Conclusion . . . 19

2 Estimation de l'état de charge 20

2.1 Introduction . . . 20

2.2 Méthodes basées sur un modèle et FFNN 20
2.2.1 Modélisation de la batterie et identification des paramètres . . 21
2.2.2 Résultats et discussion 22
2.3 Approches basées sur l'apprentissage profond 24
2.3.1 Méthodologie 24
2.3.2 Base de données et Framework de profilage de complexité . . 25
2.3.3 Résultats et discussion 26
2.3.3.1 Résultats du test 26
2.3.3.2 Analyse de complexité sur le MCU 27
2.4 Conclusion 30

3 Estimation de l'État de Santé 31
3.1 Introduction 31
3.2 L'approche proposée pour l'estimation du SOH 32
3.2.1 Méthodologie 32
3.3 La base de données expérimental 33
3.4 Simulation et analyse des résultats 34
3.4.1 Résultats d'optimisation 34
3.4.2 Résultats d'estimation 34
3.4.2.1 Estimation du SOH sur l'ensemble de la durée de vie de la batterie 34
3.4.2.2 Estimation du SOH à différentes capacités initiales . 36
3.4.2.3 Indicateur d'EOL 37
3.5 Conclusion 38

4 Contrôle de la vitesse du PMSM et de la charge/décharge de la batterie 40
4.1 Introduction 40
4.2 Méthodologie 41
4.3 Le convertisseur IBDAB 42
4.4 Modélisation du PMSM 43
4.5 Résultats et discussion 44
4.5.1 Cas 1 (Mode de charge) 44
4.5.2 Cas 1 (Mode de décharge) 45
4.6 Conclusion 48

5 Gestion de l'énergie pour HESS dans les EVs 49
5.1 Introduction 49

5.2 L'HESS et approches de contrôle du EMS 50
5.3 La stratégie de contrôle EMS proposée 51
5.3.1 Méthodologie 51
5.3.2 Configuration des approches RB et SAC pour le EMS 52
5.4 Résultats et discussion 54
5.4.1 Configuration des simulations 54
5.4.2 Performances d'apprentissage 54
5.4.3 Validation des performances 55
5.5 Conclusion 58

Conclusion générale et travaux futurs **59**

Bibliographie **63**

List of Figures

1.1 Configuration générale et architecture détaillée du BEV 9
1.2 Étapes principales de l'estimation du SOC/SOH basée sur un modèle 16
1.3 Étapes de l'estimation du SOC/SOH basées sur des méthodes de ML et DL 18

2.1 Variation des paramètres internes par rapport à SOC 22
2.2 Courbes d'estimation du SOC de EKF, AGSMO et FFNN 23
2.3 Résumé du processus d'estimation du SOC 25
2.4 Profil de charge/décharge 26
2.5 Résultats des tests des modèles 1D CNN et GRU 27
2.6 Résultats du modèle 1D CNN quantifié et du modèle à virgule flottante 32 bits. (a) Taille de la RAM (Ko) et taille du flash (Ko), et cycles/MACC obtenus avec STM32Cube.AI. (b) Taille de la RAM (Ko) et taille du flash (Ko) obtenues avec TFLite Micro. 29

3.1 Processus d'estimation du SOH de la batterie 32
3.2 Courbes de dégradation de capacité des cellules sélectionnées 33
3.3 Estimation du SOH de l'ensemble de batterie #07. (a) Résultats d'estimation. (b) Erreur d'estimation 35

4.1 Illustration du concept de la méthode proposée 41
4.2 Courbe de réponse du convertisseur IBDAB en mode de charge avec le profile MSCC 45
4.3 La réponse de vitesse avec une variation de charge soudaine à une vitesse de 300 rad/s. 46
4.4 Courbes de réponse de vitesse dans des conditions de conduite variables 47
4.5 Courbes de réponse de vitesse avec une variation soudaine de J à une vitesse de 200 rad/s 48

5.1 Illustration de la méthodologie de l'EMS proposé 52
5.2 Stratégie de gestion de l'énergie basée sur RB 53
5.3 Courbes de vitesse et de puissance sous le cycles de conduite LA92 . 54

5.4 Récompenses moyennes et par épisode dans le processus d'entraînement de l'EMS basé sur SAC 55
5.5 Puissance de sortie du SC sous le cycle de conduite LA92 57
5.6 Puissance de sortie de la batterie sous le cycle de conduite LA92 . . . 57
5.7 Trajectoire de variation du SOC de la batterie et du SC sous LA92 . 57

List of Tables

2.1 Valeur moyenne des paramètres identifiés de batterie 21
2.2 Erreurs de prédiction du SOC des trois méthodes 23
2.3 Erreurs de prédiction du SOC pour les modèles proposés 27
2.4 Validation sur le MCU des modèles avec l'ensemble de données de test 28
2.5 Analyse de complexité des modèles à virgule flottante 32 bits 28
2.6 Erreurs de prédiction SOC du modèle 1D CNN quantifié et dégradation des performances associées 29

3.1 Erreurs d'estimation du SOH pour l'ensemble de batterie #07 35
3.2 Comparaison de l'approche d'estimation du SOH proposée avec des recherches récentes 36
3.3 Erreurs d'estimation du SOH des ensembles B, D et H 37
3.4 L'indicateur d'EOL des ensembles de batteries A et C 38

4.1 Performances des contrôleurs à une vitesse de référence de 300 rad/s . 46

5.1 Résultats de comparaison des performances de la configuration basée sur SAC, sur batterie uniquement et RB 58

Liste des abréviations

AGSMO	Adaptive Gain Sliding Mode Observer
ANN	Artificial Neural Network
BEV	Battery Electric Vehicle
BiGRU	Bidirectional Gated Recurrent Unit
BMS	Battery Managemenet System
BO	Bayesian optimization
BTMS	battery Thermal Management System
DISMC	Dual Integral Sliding Mode Controller
DL	Deep Learning
DNN	Deep Neural Network
EC	electrochemical Model
ECM	Equivalent Circuit Model
EKF	Extended Kalman Filter
EMS	Energy Management System
EOL	End of Life
ESS	Energy Storage System
EV	Electric vehicle
FC	Fuel Cell
FFNN	Feedforward Neural Network
FOTM	First-Order Thevenin Model
FTP	Federal Test Procedure
GPR	Gaussian Process Regression
GRU	Gated Recurrent unit
HESS	hybrid Energy Storage System

HEV	Hybrid Electric Vehicle
HWFET	Highway Fuel Economy Test
IBC	Integral Backstepping Controller
IBDAB	Isolated Bidirectional Dual-Active Dridge
ISMC	Integral Sliding Mode Controller
LSTM	Long Short-Term Memory
MACC	Multiplier ACCumulator
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
MCU	Microcontroller Unit
ML	Machine Learning
MPC	model Predictive Control
MSCC	Multistep Constant Current
MSE	Mean Squared Error
NN	Neural Network
NTSMC	Nonsingular Terminal Sliding Mode Controller
NYCC	New York City Cycle
OB	Optimization-based
OCV	Open-Circuit Voltage
PES	Power Electronic System
PHEV	Plug-in Hybrid Electric Vehicle
PI	Proportional Integral
PIL	Processor In the Loop
PMSM	Permanent Magnet Synchronous Motor
PNGV	Partnership for a New Generation of Vehicles
RB	Rule-based
RBFNN	Radial Basis Function Neural Network
RF	Random Forest
RL	Reinforcement Learning

RMSE	Root Mean Squared Error
RNN	Recurrent Neural Network
SAC	Soft-Actor Critic
SC	Supercapacitor
SMO	Sliding mode Observer
SOC	State of Charge
SOH	State of Health
SOTM	Second-Order Thevenin Model
SVPWM	Space Vector Pulse Width Modulation
TFLite	Tensorflow Lite
TFLite Micro	Tensorflow Lite for Microcontroller
VSI	Voltage Source Inverter

Introduction

Contexte général

Les préoccupations liées au changement climatique ont conduit les constructeurs automobiles à repenser leurs méthodes de production pour s'aligner sur les évolutions mondiales et respecter les réglementations strictes en matière d'environnement [1]. Les EV sont apparus comme une solution essentielle, offrant de nombreux avantages par rapport aux véhicules à combustion interne traditionnels, notamment des émissions nulles, une réduction de la pollution et des coûts opérationnels moindres [2, 3]. Selon le dernier rapport de l'Agence internationale de l'énergie [4], l'expansion de la flotte de EV permettrait d'éviter environ 460 millions de tonnes d'équivalent dioxyde de carbone ($CO_2 - eq$) d'ici 2030. Cette tendance soutient une croissance annuelle d'environ 30% dans le stock mondial d'EV. En se concentrant sur le marché marocain des EVs, le gouvernement vise à doubler la production d'EV d'ici 2024, bénéficiant d'une infrastructure industrielle solide et d'investissements internationaux [5, 6].

Les préoccupations mondiales concernant le changement climatique ont stimulé l'adoption des EVs, en particulier les EVs à batterie (BEV) qui émettent zéro pollution. Pour répondre à cette demande croissante, les batteries au lithium-ion (Li-ion) sont largement utilisées dans les BEVs en raison de leurs performances exceptionnelles [7]. Cependant, en raison de leur coût élevé, ces batteries sont équipées de systèmes de gestion de batterie ("battery management system" (BMS)) pour surveiller et estimer avec précision le SOC et le SOH des batteries. Ces informations sont cruciales pour prédire l'autonomie, éviter les problèmes et anticiper les pannes. Étant donné que la mesure directe de ces états est complexe et qu'ils sont influencés par divers facteurs, la création d'un estimateur d'état précis est essentielle pour les BEV. Aux côtés d'ESS de l'EV, la chaîne de traction comprend le système de propulsion (moteur de traction et transmission) et le système électronique de puissance ("electronic power system" (EPS)). Il convient de noter que le PMSM est privilégié comme moteur de traction EV parmi d'autres technologies [8–10], en raison de sa densité de puissance élevée, de sa conception simple et de son efficacité [11, 12]. Le EPS, quant à lui, gère la répartition de la puissance entre batterie, dispositifs embarqués et moteur grâce à des convertisseurs en utilisant des convertisseurs DC-DC et DC-AC [13]. À cet égard, une distribution efficace de la puissance et des systèmes de la chaîne de traction résilients

dépende d'une conception et d'un contrôle minutieux des convertisseurs pour diverses exigences de conduite. Ce contrôle s'étend au PMSM, où un contrôle précis de la vitesse est essentiel pour les performances du véhicule et le confort des passagers, mais sa nature non linéaire exige un contrôleur robuste [14, 15].

Traditionnellement, les EVs ont compté sur un seul ESS pour alimenter à la fois la traction et les composants, ce qui entraîne une dégradation rapide de la batterie [16]. Pour y remédier à cela, le concept d'un HESS émerge [17], incorporant un ESS secondaire comme les supercondensateurs (SCs) ou les piles à combustible (FCs) pour gérer les surtensions soudaines et capturer efficacement l'énergie lors du freinage régénératif [18, 19]. Bien que le HESS offre des avantages tels qu'une réduction de la contrainte sur la batterie et une autonomie accrue, le développement d'un EMS pour une allocation optimale de la puissance au sein du HESS demeure un défi complexe dans la technologie des EVs [17, 20].

Problématiques et objectifs

Les récentes recherches se sont concentrées sur des aspects essentiels des véhicules électriques, tels que le BMS, l'EMS, le contrôle PES et la régulation de la vitesse du moteur. Les méthodes d'estimation de SOC ont été explorées. Une lacune notable dans ces études concerne le manque d'investigation pratique et d'analyse de faisabilité au sein de microcontrôleurs (MCUs). Cette thèse a comblé cette lacune en testant les méthodes d'estimation du SOC sur une carte STM32F429. Par la suite, dans le domaine de l'estimation du SOC, cette thèse a proposé une contribution originale en dévoilant la faisabilité d'intégrer des algorithmes de DL dans des MCUs aux ressources limitées.

En abordant l'estimation de SOH, les travaux prédominants dans ce domaine se penchent souvent sur l'extraction complexe des caractéristiques à partir de données de la batterie. Dans cette thèse, en utilisant un modèle hybride de DL, les données de décharge de batteries collectées dans des conditions variées ont été utilisées directement. De plus, pour gérer les nombreux hyperparamètres du modèle, l'optimisation bayésienne (BO) est employée pour identifier automatiquement les meilleures configurations, évitant ainsi les ajustements manuels laborieux.

Dans le domaine de la chaîne de traction, l'accent a souvent été mis sur la régulation de la vitesse des moteurs PMSM ou d'autres moteurs, souvent sans une intégration complète dans le contexte global de la chaîne de traction. La thèse propose

un système complet qui intègre l'ESS, le PES et un PMSM en intégrant aussi des méthodes de contrôle avancées et robustes.

Généralement, au sein de la chaîne de traction, un dysfonctionnements dans l'un de ses éléments pourrait avoir des répercussions sur les autres en raison des interactions complexes entre ces composants interconnectés. Un EMS efficace joue alors un rôle crucial pour orchestrer harmonieusement la propulsion, l'électronique de puissance et le stockage d'énergie. L'efficacité globale dépend de l'intégration fluide et coordonnée de ces éléments. Malgré cela, de nombreuses stratégies d'EMS existantes ne répondent pas pleinement aux besoins des VEs avec un HESS et rencontrent des limitations. Pour relever ce défi, cette thèse propose une approche novatrice basée sur un algorithme de RL pour une allocation de puissance optimale au sein du HESS. Cette méthode permet une adaptation plus efficace aux diverses conditions de conduite, se distinguant des méthodes traditionnelles basées sur l'optimisation.

En récapitulation, cette thèse examine et analyse minutieusement les systèmes étudiés, les méthodes d'estimation et les stratégies de contrôle au sein des EVs. Chaque chapitre se focalise sur un sous-système spécifique, exposant comment ces éléments interconnectés collaborent pour améliorer l'efficacité et les performances globales des EVs.

Contributions

Compte tenu du contexte établi, des défis soulignés et des objectifs globaux, les principales contributions de cette thèse peuvent être succinctement résumées comme suit:

- Une comparaison approfondie entre les techniques basées sur les modèles et les réseaux de neurones artificiels (ANN) est effectuée pour l'estimation du SOC. Deux approches DL sont développées, mettant en évidence l'efficacité du modèle CNN 1D et sa mise en oeuvre réussie sur des MCUs limités en ressources.
- Un modèle novateur basé sur les données est introduit pour le diagnostic en temps réel du SOH en utilisant une fusion de modèles CNN et BiGRU. La technique BO est employée pour identifier les meilleurs hyperparamètres du model proposé.
- Une approche efficace basée sur NTSMC-RBF est conçu pour le contrôle de la vitesse du PMSM, assurant une convergence rapide et une robustesse accrue.
- Un contrôleur DISMC fiable régit le flux d'énergie à travers un convertisseur

IBDAB, assurant une charge/décharge stable de la batterie et la conformité au BMS.

- Une approche innovante basée sur un algorithme du RL est introduite pour optimiser l'allocation de puissance dans un système HESS, visant à améliorer l'efficacité énergétique et les performances globales des EVs.

Structure de la thèse

Cette thèse se compose de cinq chapitres, brièvement décrits comme suit :

Chapitre 1 : Ce chapitre offre une vue globale des EVs, en mettant l'accent sur les composants essentiels de la chaine de traction. Il souligne également l'importance des techniques de contrôle, de la modélisation des batteries, ainsi que des méthodes d'estimation du SOC et du SOH.

Chapitre 2 : Ce chapitre se penche sur les techniques d'évaluation du SOC, couvrant un éventail d'approches allant des méthodes basées sur des modèles aux méthodes basées sur des algorithmes DL, et mettant en particulier l'accent sur leur mise en oeuvre dans des MCUs.

Chapitre 3 : Dans ce chapitre, une approche sophistiquée pour l'estimation du SOH est présentée, reposant sur le modèle CNN-BiGRU. Une évaluation de la fiabilité et de la précision de ce modèle pour prédire le SOH et la fin de vie des batteries est également détaillée, tout comme l'application de la technique BO pour ajuster les paramètres du modèle.

Chapitre 4 : Ce chapitre mis en place deux contrôleurs DISMC pour gérer l'échange d'énergie entre une batterie Li-ion et le moteur de traction (PMSM) via un convertisseur IBDAB. Pour établir un contrôle de vitesse fiable et robuste, une nouvelle combinaison d'un contrôleur NTSMC et d'un RBFNN adaptatif est élaborée.

Chapitre 5 : Ce chapitre aborde la gestion de l'énergie au sein des EVs équipés d'un HESS en adoptant une technique de RL pour parvenir à une répartition optimale de la puissance et ainsi améliorer l'efficacité énergétique.

Conclusion et perspectives : En conclusion, la thèse offre un résumé des éléments clés abordés tout en proposant des directions possibles pour des recherches à venir.

Liste des Publications

Journals International

- **Y. Mazzi**, H. Ben Sassi, and F. Errahimi, "Lithium-ion battery state of health estimation using a hybrid model based on a convolutional neural network and bidirectional gated recurrent unit", **Engineering Applications of Artificial Intelligence**, 2024, vol. 127, p. 107199.
- **Y. Mazzi**, H. Ben Sassi, A. Gaga, and F. Errahimi, "State of charge estimation of an electric vehicle's battery using tiny neural network embedded on small microcontroller units", **International Journal of Energy Research**, 2022, vol. 46, no 6, p. 8102-8119.
- **Y. Mazzi**, A. Gaga, and F. Errahimi, "Benchmarking and comparison of two open-source RTOSs for embedded systems based on ARM Cortex-M4 MCU", **Indian Journal of Science and Technology**, 2021, vol. 14, no 16, p. 1261-1273.
- H. Ben sassi,**Y. Mazzi**, and F. Errahimi, "Power transfer control within the framework of vehicle-to-house technology", **International Journal of Electrical and Computer Engineering (IJECE)**, 2023, vol. 13, no 4, p. 3817-3828.
- **Y. Mazzi**, H. Ben Sassi, and F. Errahimi, "Advanced Speed Control and Battery Power Regulation for Electric Vehicle Propulsion Systems using Robust Control Strategies", **Ain Shams Engineering Journal**, Under review
- **Y. Mazzi**, H. Ben Sassi, and F. Errahimi, "Energy management strategy for hybrid energy storage system in electric vehicle based on a soft actor-critic reinforcement learning", **Energy Conversion and Management**, Under review.

Chapitres de Livre

- **Y. Mazzi**, H. Ben Sassi, F. Errahimi, and N. Es-Sbai, "PIL implementation of adaptive gain sliding mode observer and ANN for SOC estimation", In : Artificial Intelligence and Industrial Applications (A2IA) 2020. Springer International Publishing, Cham, 2021: pp. 270278.
- H. Ben Sassi, **Y. Mazzi**, F. Errahimi, N. Es-Sbai, "Processor in the Loop Implementation of State of Charge Estimation Strategies for Electric Vehicle

Applications", in Proceedings of the 2nd International Conference on Electronic Engineering and Renewable Energy Systems (ICEERE) 2020, Springer, Singapore, 2021: pp. 495501.

- **Y. Mazzi**, H. Ben Sassi, F. Errahimi, and N. Es-Sbai, "State of charge estimation using extended kalman filter", In : 2019 International Conference on Wireless Technologies, Embedded and Intelligent Systems (WITS). IEEE, 2019. p. 1-6.

Conférences Internationales

- H. Ben Sassi, **Y. Mazzi**, F. Errahimi, N. Es-Sbai, "Power transfer control of an IBDAB-based Vehicle-to-grid charging station", In the 2nd Edition of the International Congress on Sustainable Buildings and Cities 2023.
- **Y. Mazzi**, H. Ben Sassi, F. Errahimi, and N. Es-Sbai, "A nonsingular terminal sliding mode controller for speed regulation of a permanent magnet synchronous motor drive system for electric vehicles", In the First Euro-Mediterranean Conference on Materials, Devices and Systems, 2022.
- **Y. Mazzi**, H. Ben Sassi, F. Errahimi, and N. Es-Sbai, "PIL implementation of adaptive gain sliding mode observer and ANN for SOC estimation", In the International Conference on Artificial Intelligence & Industrial Applications (A2IA) 2020.
- H. Ben Sassi, **Y. Mazzi**, F. Errahimi, N. Es-Sbai, "Processor in the Loop Implementation of State of Charge Estimation Strategies for Electric Vehicle Applications", in Proceedings of the 2nd International Conference on Electronic Engineering and Renewable Energy Systems (ICEERE) 2020.
- **Y. Mazzi**, H. Ben Sassi, F. Errahimi, and N. Es-Sbai, "State of charge estimation using extended kalman filter", In 2019 International Conference on Wireless Technologies, Embedded and Intelligent Systems (WITS).

Chapter 1

GÉNÉRALITÉS SUR LES VÉHICULES ÉLECTRIQUES

1.1 Introduction

Avec la croissance de la popularité des EVs, la nécessité de développer une technologie de batterie capable d'améliorer l'autonomie, de réduire les temps de charge et d'optimiser les performances de ces véhicules devient de plus en plus impérieuse. Les batteries Li-ion demeurent actuellement la technologie dominante dans les EVs. Ce chapitre débute en proposant une vue d'ensemble approfondie de la chaîne de traction des EVs et de ses composantes essentielles, tout en mettant en avant l'importance des techniques de contrôle pour garantir des performances optimales et une efficacité accrue. En outre, différentes méthodes de modélisation des batteries sont exposées, soulignant particulièrement l'importance des méthodes d'estimation du SOC et du SOH, en couvrant aussi bien des approches basées sur des modèles que des méthodes basées sur les données.

1.2 Véhicules électriques

En raison de l'impact des carburants à base de pétrole sur l'environnement, de nombreux gouvernements entreprennent des réformes pour réduire leur consommation de carburant dans divers secteurs, notamment l'énergie et les transports. Cette démarche vise à parvenir à un transport de marchandises et de personnes plus sûr, moins coûteux et plus efficace. De nos jours, une part importante des moyens de

transport, que ce soit par air, terre ou mer, dépend fortement des carburants fossiles tels que le diesel et l'essence, ce qui engendre d'importantes émissions de CO2. Pour y remédier, de nombreux pays adoptent la technologie des EVs pour électrifier leur secteur automobile, offrant ainsi une solution prometteuse pour réduire les émissions de CO2 et augmenter l'efficacité énergétique. Les EVs ont un impact environnemental positif par rapport aux véhicules à essence, car ils ne produisent aucune émission à l'échappement, contribuant ainsi à réduire la pollution de l'air et les problèmes de santé associés. Fonctionnant avec des moteurs électriques plutôt qu'avec des moteurs à combustion interne (ICE), les EVs sont généralement plus écoénergétiques et plus silencieux. Ils convertissent un pourcentage plus élevé de l'énergie électrique stockée par rapport à la conversion de l'essence, réduisant ainsi la consommation de carburant fossile. Toutefois, il est essentiel de prendre en compte le cycle de vie complet d'un EV, de la fabrication à la source d'électricité utilisée pour le charger. Bien que la production de EV ait un certain impact environnemental, il reste inférieur à celui de la production et de l'utilisation de véhicules à ICE. Les récents progrès en matière de technologie des batteries, particulièrement les batteries au Li-ion, ont transformé le paysage des EVs, améliorant leurs performances et leur autonomie. Le passage mondial aux EVs a gagné en ampleur [21,22], avec un parc mondial de EVs dépassant 11 millions d'unités en 2021, contre seulement 16 875 en 2010, et des ventes prévues de 130 millions d'unités d'ici 2030 [4].

Dans l'ensemble, le marché des véhicules électriques connaît une croissance et une évolution rapides, avec de nouvelles technologies et modèles qui sont développés et introduits régulièrement. Ainsi, les fabricants automobiles proposent certaines catégories de EV basées sur leurs sources d'énergie et leurs systèmes de propulsion : véhicule électrique pur/batterie (P/BEV), véhicule hybride électrique (HEV) et véhicule hybride rechargeable (PHEV).

1.3 Architecture générale de la chaîne de traction

À mesure que les technologies matérielles, logicielles et mécatroniques continuent de progresser, les risques de défaillances systématiques et de déficiences matérielles augmentent. Pour prévenir de tels dangers, il est crucial d'établir une approche solide et fiable de la sécurité fonctionnelle [23], impliquant l'identification des exigences et des mesures de sécurité. De plus, pour optimiser l'efficacité des véhicules, il est recommandé d'exploiter au mieux les nouveaux équipements de pointe, tels que les circuits convertisseurs, les capteurs et les dispositifs de stockage. Cependant, l'intégration de

ces technologies peut augmenter les coûts de production et la complexité des EVs. En conséquence, les chercheurs explorent différentes approches, comme la modification de l'architecture de la chaîne de traction [24], l'ajustement des tailles de l'ESS et du moteur de traction [25, 26], ou l'amélioration du EPS [27], pour atténuer ces problèmes.

Les éléments centraux d'un système de chaîne de traction sont le ESS, le EPS et le moteur de traction. Ces composants forment le coeur de ce système, comme illustré à la Figure 1.1, auxquels s'ajoutent d'autres systèmes et unités de contrôle, tels que le BMS, le EMS, l'unité de contrôle moteur et l'unité de contrôle du véhicule ("vehicle control unit" (VCU)), dans le rôle est de contrôler et de garantir le bon fonctionnement de ces composants et du véhicule dans son ensemble.

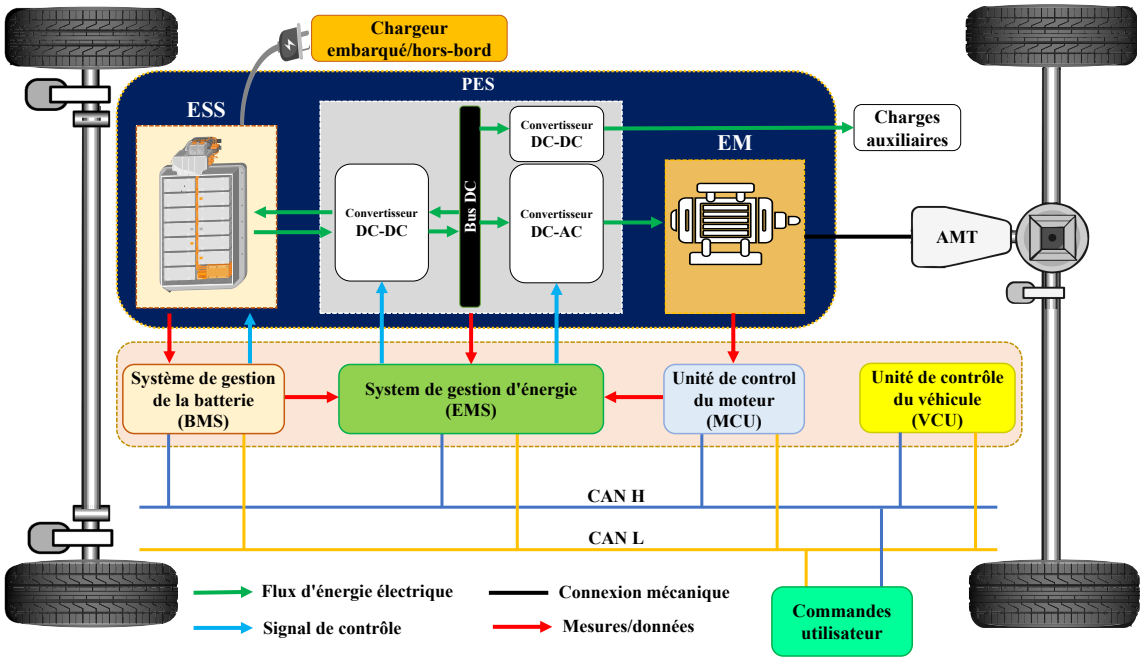


Figure 1.1: Configuration générale et architecture détaillée du BEV

1.3.1 Moteur de traction électrique

Les EVs diffèrent des véhicules conventionnels à ICE en ce qu'ils utilisent un moteur électrique pour la propulsion. Ces moteurs sont plus efficaces, fiables et moins complexes que les ICE, et présentent un couple élevé ainsi qu'une densité de puissance élevée, avec un rendement de conversion d'énergie compris entre 80% et 96% [28]. Le moteur électrique convertit l'énergie électrique provenant du ESS à travers le PES en énergie mécanique pour entraîner les roues du véhicule.

Ces derniers temps, la demande croissante de moteurs électriques sur le marché

des EVs a conduit à une percée dans l'ingénierie électromécanique et les matériaux de production, offrant aux fabricants une base solide pour renforcer la variété de moteurs de traction électrique avec une fiabilité accrue et une plage de vitesse élargie. Les technologies de moteur électrique les plus couramment utilisées dans les EVs modernes sont les moteurs à induction (MI), les PMSM, les moteurs à courant continu sans balais (BLDC) et les moteurs à réluctance commutée [29]. Le choix d'un moteur électrique est principalement influencé par la taille, le poids et les exigences de conduite du véhicule, ainsi que par les coûts et la faisabilité de la fabrication [30, 31].

1.3.2 Système d'électronique de puissance

Dans un EV, le PES joue un rôle crucial dans la gestion du flux d'énergie électrique entre le ESS, le moteur de traction électrique et d'autres systèmes du véhicule tels que les systèmes d'éclairage et de climatisation. Pour faciliter la conversion de la puissance électrique entre différentes formes, telles que le courant alternatif en courant continu ou vice versa, le PES intègre une gamme de dispositifs électroniques, notamment des convertisseurs. Ces convertisseurs permettent un fonctionnement efficace et fiable du véhicule sur une large gamme de conditions de puissance et de température. De plus, le PES inclut des circuits de contrôle et des logiciels pour gérer le flux d'énergie et assurer une performance optimale de la chaîne de traction [32, 33]. En général, deux types de convertisseurs, à savoir les convertisseurs DC-DC [34,35] et les convertisseurs DC-AC (également appelés onduleurs), sont utilisés dans les EVs modernes [36]

1.3.3 Système de stockage d'énergie

L'ESS, un ensemble de batteries Li-ion à haute capacité dans les EV, joue un rôle essentiel en tant que réservoir de stockage d'énergie électrique pour alimenter le véhicule [37]. Au-delà de la propulsion du moteur, l'ESS fournit également de l'énergie à divers systèmes tels que le contrôle climatique et le système de divertissement, facilité par le PES. De plus, les EVs modernes intègrent une fonctionnalité de freinage régénératif, permettant de récupérer l'énergie cinétique lors du freinage, qui est ensuite stockée dans l'ESS. Néanmoins, du fait de sa densité de puissance relativement modeste et de sa réponse temporelle lente, l'ESS peut faire face à des défis de surchauffe lorsque des pics de demande d'énergie surviennent subitement. Pour répondre à cette préoccupation, une approche novatrice implique la création d'un HESS en intégrant un ESS auxiliaire, tel qu'un SC, caractérisé par une haute densité de puissance et une densité d'énergie plus faible [38]. Cette synergie entre le SC et la batterie exploite judicieusement leurs atouts respectifs, permettant ainsi au HESS de stocker

l'énergie avec efficacité, de gérer habilement les hauts pics de puissance et d'absorber rapidement la puissance générée lors du freinage régénératif. Par conséquent, la batterie subit un stress réduit, ce qui prolonge sa durée de vie [39], tout en contribuant à une amélioration notable de la récupération d'énergie [38]. De nos jours, les piles à combustible (FC) sont envisagées comme une option prometteuse pour remplir la même fonction qu'un SC [40]. Dans cette configuration, la pile à combustible génère de l'électricité en convertissant l'hydrogène et l'oxygène en eau, ce qui présente de nombreux avantages tels qu'une autonomie accrue et des temps de ravitaillement plus rapides. Cependant, l'intégration d'une pile à combustible dans un HESS peut augmenter la complexité et le coût du système.

1.3.4 Système de gestion de batterie

Face à de nombreux défis tels que la complexité des véhicules, les préoccupations en matière de sécurité, les coûts élevés des ESS et les diverses demandes des consommateurs, il est urgent de développer un BMS intégré avec des fonctionnalités de polyvalence pour les EVs [41]. En général, le BMS est responsable de surveiller l'état de charge, la tension, la température et d'autres paramètres de la batterie pour assurer un fonctionnement sûr et efficace [42].

1.3.5 Système de gestion de l'énergie

Un autre cadre essentiel contribuant à l'efficacité de la chaîne de traction est le EMS, qui joue un rôle clé dans l'optimisation de l'utilisation de l'énergie provenant de la batterie et d'autres sources, améliorant ainsi l'efficacité globale, l'autonomie et les performances du véhicule. À l'aide des algorithmes et de stratégies de contrôle, l'EMS surveille en permanence la consommation d'énergie, les conditions de conduite et d'autres facteurs connexes pour trouver la bonne politique de distribution d'énergie. De plus, l'EMS a la capacité de hiérarchiser différents systèmes du véhicule en fonction de la disponibilité d'énergie et des circonstances de conduite, en faisant ainsi un élément fondamental de la conception de la chaîne de traction. Dans le contexte d'un HESS, un EMS sophistiqué est indispensable pour une allocation efficace de l'énergie et de la puissance entre la batterie et le SC (ou/et la FC), maximisant ainsi les avantages globaux. Pour atteindre cet objectif et garantir un fonctionnement cohérent, sécurisé et performant du HESS, une approche de gestion pragmatique et robuste s'avère essentielle [17].

1.4 Batterie Li-ion

Le concept d'une batterie englobe des dispositifs capables de stocker de l'énergie électrique sous forme chimique et de la libérer lorsqu'ils sont connectés à une charge [43]. Le parcours de la technologie des batteries a commencé avec l'introduction de la cellule non rechargeable par Alessandro Volta en 1800, démontrant le flux d'électrons à travers une réaction électrochimique. L'innovation de Gaston Planté en 1859 a marqué l'avènement de la batterie rechargeable, présentant des réactions chimiques/électriques réversibles entre des électrodes en plomb immergées dans une solution d'acide sulfurique. D'autres conceptions ont suivi, telles que la batterie nickel-cadmium (NiCd), développée par Waldemar Junger au début du XXe siècle, et l'introduction de la batterie nickel-hydrure métallique (NiMH) sans cadmium en 1990. Une avancée significative a été réalisée avec la commercialisation des batteries rechargeables au Li-ion par Sony en 1991 [44]. Ces batteries offrent une densité d'énergie élevée, une autodécharge minimale, une durée de vie prolongée et l'absence d'effet mémoire, ce qui les positionne comme un choix préféré par rapport à d'autres technologies [45]. Les batteries Li-ion sont de plus en plus adoptées dans les EVs pour pallier les disparités entre l'offre et la demande d'énergie. Les efforts de recherche visent à prolonger leur durée de vie, améliorer leur autonomie et renforcer leur sécurité.

Les fabricants de systèmes de stockage proposent actuellement une gamme de formes et d'options d'emballage pour différentes applications, en tenant compte de facteurs tels que le poids, les propriétés mécaniques et la gestion thermique. Principalement, les EVs nécessitent une quantité substantielle de puissance, ce qui rend nécessaire l'assemblage de packs de batteries composés de nombreuses cellules. Ces cellules sont organisées en modules de batterie, qui sont ensuite regroupés pour former un pack de batteries [46]. Les cellules de chaque module peuvent être connectées en série ou en parallèle pour atteindre la capacité et la tension souhaitées du pack de batteries. Plusieurs modules sont ensuite combinés pour former le pack de batteries complet, comprenant divers systèmes de contrôle et de protection, tels que le système de refroidissement et le BMS [47].

1.4.1 Terminologies et propriétés des batteries lithium-ion

Le progrès et la viabilité future des EVs dépendent largement des technologies de stockage de batterie qui offrent une sécurité optimale, une efficacité énergétique, une haute densité d'énergie, un coût faible, un poids réduit, un long cycle de vie, etc. Un

élément essentiel pour évaluer la faisabilité et l'adéquation du stockage de batterie pour les EVs consiste à parvenir à un équilibre approprié et à évaluer divers critères et paramètres. En ce sens, parmi les paramètres cruciaux et les terminologies qui définissent la cellule/pack de batterie, particulièrement les batteries Li-ion, on peut citer : capacité nominale, tension de coupure, tension à circuit ouvert (OCV), densité d'énergie, densité de puissance, taux de décharge, SOC, SOH, Cycle de vie.

1.4.2 Modélisation de la batterie

En raison de la nature électrochimique inhérente des batteries Li-ion, une analyse précise, une description du comportement et une estimation appropriée des états de la batterie et de la gestion dépendent grandement d'une modélisation précise de la batterie. La modélisation de batterie consiste à élaborer des modèles mathématiques qui simulent le comportement d'une batterie. Cependant, en raison de la nature complexe des batteries Li-ion, la complexité de la modélisation augmente en raison de la non-linéarité du système, des propriétés variables dans le temps et de la sensibilité aux facteurs externes. En se basant sur une analyse du mécanisme des batteries Li-ion et des modèles existants de batterie [48], le modèle peut être développé d'un point de vue chimique ou électrique, ou d'une combinaison des deux. De plus, considérant l'effet de la température sur la batterie, les effets sont aussi analysés à travers un modèle thermique [49].

Le modèle électrochimique (EC) décrit avec précision la chimie de la batterie en simulant les interactions au sein des composants de la batterie [50]. Il analyse les mesures microscopiques en simulant la distribution de quantités microscopiques et les mesures macroscopiques en prédisant le courant, la tension et d'autres grandeurs. Cependant, le modèle EC implique des équations complexes avec des paramètres inconnus, ce qui pose des défis [51]. Pour réduire cette complexité, des versions simplifiées ont été proposées et des techniques d'identification des paramètres ont été appliquées [50, 52]. Ces modèles sont précieux pour prédire les performances des batteries et concevoir des matériaux et des systèmes dans des conditions diverses [53].

La modélisation thermique joue un rôle crucial dans la modélisation des batteries Li-ion, car la température de la batterie peut avoir un impact significatif sur ses performances, sa sécurité et sa durée de vie [54]. Ces modèles permettent d'obtenir des informations précieuses sur les caractéristiques thermiques de la batterie, la répartition de la température et les transferts de chaleur entre la batterie et l'environnement. Les modèles thermiques peuvent être classés en différents types en fonction de la complexité et de la direction de la distribution de la température, notamment : les

modèles à zéro dimension ou à paramètres regroupés [55], les modèles à une dimension [56], les modèles à deux dimensions [57] et les modèles à trois dimensions [58].

Le modèle empirique est une représentation mathématique du comportement d'une batterie Li-ion basée sur des données expérimentales, offrant la capacité de prédire les performances d'une batterie Li-ion sous différentes conditions. Ces modèles sont élaborés en ajustant les données expérimentales à des expressions mathématiques. Dans le cas des batteries Li-ion, les modèles empiriques courants comprennent le modèle de particule unique, le modèle pseudo-bidimensionnel et le modèle de circuit électrochimique équivalent. Cependant, bien que ces modèles soient simples et utiles, ils ne peuvent pas prédire avec précision le comportement en dehors des conditions utilisées pour la collecte de données.

Enfin, le modèle de circuit équivalent (ECM) simplifie la modélisation complexe basée sur les lois physiques (chimiques et thermiques) des batteries Li-ion, offrant un équilibre pratique entre précision et efficacité computationnelle. Il représente la batterie sous forme d'un circuit électrique avec des composants passifs et actifs, permettant de prédire la tension, le courant et la puissance dans différentes conditions. Les ECM courants comprennent le modèle de résistance interne, les modèles de Thévenin [59], le modèle non linéaire général et le modèle Partenariat pour une Nouvelle Génération de Véhicules (PNGV) [60]. Ces modèles permettent une analyse efficace du comportement de la batterie dans différents domaines.

L'exactitude de chaque modèle susmentionné dépend de son architecture et des paramètres correspondants. Par conséquent, l'identification des paramètres est nécessaire pour déterminer les valeurs des paramètres internes de la batterie [55]. Pour identifier ces paramètres, divers méthodes ont été utilisées [61, 62].

Contrairement aux autres approches, les modèles basés sur les données, également désignés sous le terme de modèles boîte noire, voient leur popularité croître grâce aux progrès réalisés dans les techniques d'exploration de données, d'apprentissage automatique ("machine Learning" (ML)) et de DL, ainsi qu'à l'amélioration des capacités matérielles. Ces modèles établissent des relations entre les paramètres de la batterie en utilisant des données historiques de charge/décharge, sans nécessiter une connaissance approfondie des comportements de la batterie [63, 64]. Le processus implique de former des algorithmes de ML ou DL avec les données collectées pour créer un modèle capable de prédire la tension terminale en se basant sur les valeurs d'entrées correspondantes (courant, température,).

1.5 Méthodes d'estimation d'état

Une fois qu'un modèle approprié est sélectionné et ses paramètres déterminés, il est utilisé pour concevoir des algorithmes d'estimation des états de la batterie. Les batteries Li-ion sont préférées pour les EVs, mais leur protection et leur fiabilité nécessitent des améliorations. En conséquence, concevoir un BMS pour surveiller les états de la batterie tels que le SOC et le SOH est essentiel. Le SOC est défini comme la capacite restante dans la batterie avant son épuisement, vital pour la planification des déplacements, tandis que le SOH reflète le taux de déclin de la capacité et de la dégradation au fil du temps. La surveillance précise de ces états améliore l'autonomie des EVs, prolonge la durée de vie de la batterie et prévient les dangers. Bien que le SOC et le SOH ne puissent pas être mesurés directement, d'autres paramètres tels que le courant et la tension sont utilisés pour l'estimation. Cette section offre un aperçu des méthodes d'estimation du SOC et du SOH. Certaines de ces méthodes seront validées dans les chapitres suivants.

1.5.1 Méthodes conventionnelles

Les approches classiques pour déterminer le SOC et le SOH de la batterie incluent principalement le comptage de Coulomb, les méthodes basées sur l'OCV et celles utilisant la résistance interne, offrant ainsi des méthodes simples pour ces estimations.

La méthode largement utilisée du comptage de Coulomb estime le SOC et le SOH en mesurant le courant électrique pendant la charge et la décharge, en l'intégrant dans le temps pour déterminer la charge stockée ou déchargée [65]. Mathématiquement, le SOC est calculé comme le rapport de la capacité disponible sur la capacité totale, tandis que le SOH évalue la capacité totale d'une batterie à la fin d'un cycle par rapport à la capacité nominale d'une batterie neuve, comme exprimé dans les équations suivantes:

$$\mathrm{SOC}(t) = \frac{C_{\mathrm{current}}}{C_{\mathrm{full}}} \times 100(\%) = \mathrm{SOC}(t_0) - \frac{1}{C_{\mathrm{full}}} \int_{t_0}^{t} \eta\, i(\tau)\, d\tau \tag{1.1}$$

$$\mathrm{SOH}(t) = \frac{C_{\mathrm{full}}}{C_{\mathrm{nom}}} \times 100(\%) \tag{1.2}$$

Où C_{full}, C_{nom} sont la capacité totale et la capacité nominal (fournie par le fabricant) de la batterie, tandis que $C_{current}$ est la capacité actuelle disponible et η définie le coefficient de Coulombs. La méthode du comptage de Coulomb, bien qu'elle soit simple et efficace sur le plan computationnel, est sujette à l'accumulation d'erreurs au

fil du temps et est influencée par les variations initiales du SOC [66]. Par conséquent, elle est souvent utilisée dans des environnements de laboratoire contrôlés pour évaluer le SOC et/ou le SOH en vue d'applications ultérieures.

Une autre méthode conventionnelle, basée sur la mesure de la tension, estime le SOC et le SOH en établissant la relation entre le OCV et le SOC/SOH à travers plusieurs cycles de charge/décharge à différents niveaux. Cela crée un tableau OCV-SOC/OCV-SOH [67]. Pour mesurer l'OCV pour un SOC/SOH spécifique, la tension aux bornes est observée après une période prolongée de relaxation sans charge, permettant ainsi qu'elle se stabilise à l'état d'équilibre de l'OCV [68]. Bien qu'exacte, la méthode OCV est peu pratique pour les applications en temps réel en raison du temps de relaxation prolongé nécessaire, la dépendance envers des valeurs d'OCV précises et l'exigence d'une grande précision de tension lors des mesures de charge et de décharge.

1.5.2 Méthode d'estimation basée sur un modèle

Bien que les méthodes précédentes présentent leur simplicité, elles présentent des limites telles que l'accumulation d'erreurs, la dépendance aux conditions initiales, la sensibilité à la précision des capteurs et la vulnérabilité aux perturbations externes. Pour surmonter ces inconvénients, l'approche basée sur le modèle s'est imposée comme un choix privilégié pour une estimation précise du SOC et du SOH des batteries Li-ion. Cette technique consiste à élaborer un modèle mathématique qui intègre plusieurs variables pour parvenir à une estimation précise du SOC/SOH, impliquant deux étapes clés : la modélisation de la batterie et le développement d'algorithmes d'estimation (Figure 1.2).

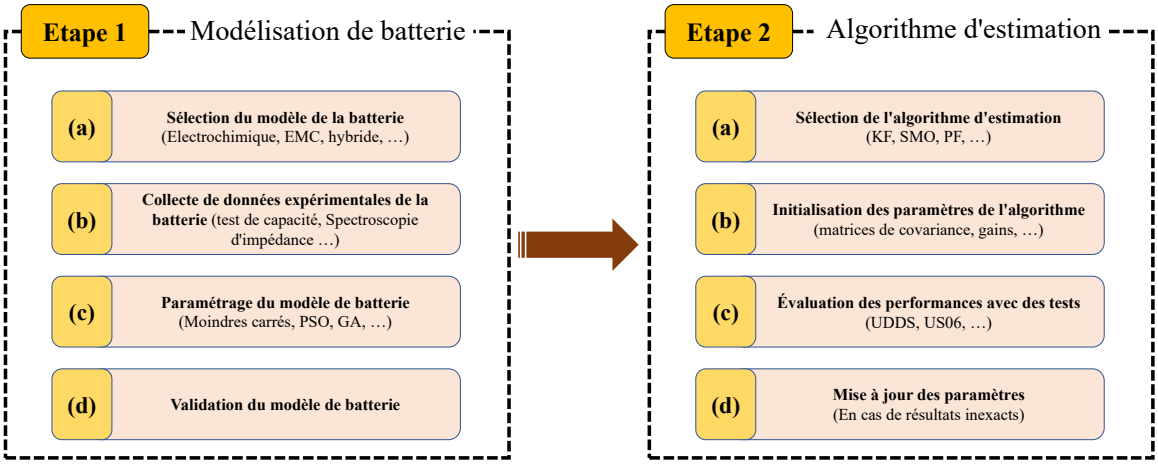


Figure 1.2: Étapes principales de l'estimation du SOC/SOH basée sur un modèle

Concernant l'étape d'estimation, le choix d'une technique d'estimation appropriée

est déterminé par les besoins spécifiques de l'application, en mettant principalement l'accent sur la précision et la complexité computationnelle. La littérature présente de nombreuses approches non linéaires pour l'estimation du SOC et du SOH, se répartissant largement en deux catégories principales : les méthodes basées sur les filtres adaptatifs et les méthodes basées sur les observateurs non linéaires, toutes conçues pour atteindre une précision supérieure. Les approches basées sur les filtres adaptatifs englobent principalement les algorithmes de la famille des filtres de Kalman ("Kalman filter" (KF)) [69, 70] et le filtre à particules (PF) ainsi que ses variations [71, 72]. D'autre part, les techniques basées sur les observateurs non linéaires incluent principalement l'observateur en mode glissant ("sliding mode observer" (SMO)) [73, 74], l'observateur H-infini [75, 76], l'observateur de Luenberger [77] et l'observateur proportionnel intégral [78].

1.5.3 Méthodes basées sur les données

La précision des méthodes basées sur des modèles repose sur des modèles détaillés de batterie et une identification précise des paramètres. Le développement de tels modèles exige une compréhension approfondie des comportements électrochimiques des batteries et implique des calculs intensifs. En conséquence, les approches basées sur les données gagnent en popularité pour combler le fossé entre le prototypage rapide et la compréhension des comportements des batteries. Avec les avancées dans l'extraction de données et les algorithmes d'AI, les techniques basées sur les données pour l'estimation du SOC et du SOH deviennent de plus en plus attrayantes. L'AI implique la création de machines intelligentes qui imitent les processus cognitifs humains, apprennent de l'expérience et s'adaptent aux nouvelles données d'entrée.

La méthode basée sur les données considère la batterie comme une boîte noire, utilisant des algorithmes d'AI pour extraire des caractéristiques essentielles à partir d'un ensemble de données de batterie étendus, qu'elles soient obtenues directement ou indirectement. Cette approche relie ces caractéristiques à la SOC/SOH et gagne en popularité dans divers secteurs technologiques. Les techniques basées sur les données pour estimer la SOC et la SOH peuvent être largement classées en approches de ML et de DL, toutes deux relevant de l'ombrelle de l'AI. Étant donné le coût de collecte des données de batterie, de nombreux ensembles de données sont disponibles pour la recherche scientifique, y compris ceux de la NASA, d'Oxford, de CALCE et du MIT.

Généralement, les algorithmes ML et DL s'appuient sur des expériences passées ou des données pour entraîner un algorithme à prendre des décisions et à tirer des conclusions. L'algorithme utilise un code simplifié pour obtenir des résultats pré-

cis sans nécessiter d'intervention humaine. Le processus typique de construction de ces modèles (ML et DL) pour l'estimation de la batterie implique trois étapes principales, illustrées à la Figure 1.3. Ce processus inclut la collecte de données de la batterie telles que la tension, le courant et la température à l'aide d'équipements spécialisés, la détermination des valeurs réelles de SOC et SOH par la méthode du comptage de Coulomb dans des conditions contrôlées, la formation du modèle ML avec ces données, et l'affinement des poids et des biais du modèle par le biais de l'entraînement et de la validation. Finalement, des modèles optimaux sont développés et le modèle d'estimation SOC/SOH est testé avec des données distinctes de l'ensemble d'entraînement.

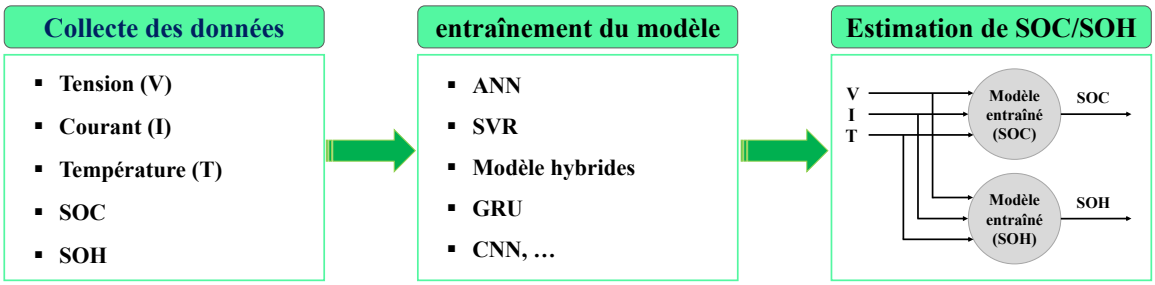


Figure 1.3: Étapes de l'estimation du SOC/SOH basées sur des méthodes de ML et DL

Concernant les algorithmes de ML, plusieurs approches ont été bien explorés dans la littérature englobent la machine à vecteur de support ("support vector machine" (SVR)) [79,80], les forêts aléatoires ("random forest" (RF)) [81,82], le RBFNN [83,84], la régression par processus gaussien (Gaussian process regression (GPR)) [85,86] et autres [87,88]. D'autre part, le concept du DL est une sous-catégorie du ML et représente une avancée significative dans la programmation des réseaux neuronaux. Bien que le processus de construction de modèles DL partage des similitudes avec l'apprentissage supervisé, sa complexité de programmation dépasse celle du ML traditionnel en raison de son émulation du système cognitif humain. Cela lui permet d'analyser et de résoudre des problèmes complexes de manière autonome, sans nécessiter l'intervention humaine [89]. Malgré les avancées significatives du ML dans l'estimation du SOC et du SOH, un enjeu majeur subsiste dans l'extraction laborieuse des caractéristiques à partir des courbes de charge/décharge. Cette étape requiert une expertise spécifique au domaine et est généralement réalisée manuellement [82,85], ce qui peut potentiellement entraîner une omission de certains détails.

À la lumière des succès notables des applications du DL, diverses classes de modèles de DL ont été examinées pour l'estimation du SOC et du SOH des batteries, incluant les techniques telles que les réseaux de neurones convolutifs (CNN), les unités

récurrentes du GRU, les mémoires à long terme et court terme ("Long short-term memory" (LSTM)), les approches fondées sur les réseaux d'encodeur-décodeur [90], ainsi que les réseaux de neurones Transformer [91].

1.6 Conclusion

Ce chapitre a offert un aperçu général des EVs, les classant en fonction de leurs aspects technologiques, et a plongé dans quelques détails des technologies de batterie utilisées dans les EVs, en mettant particulièrement l'accent sur les batteries Li-ion. L'estimation précise du SOC et du SOH revêt une importance primordiale étant donné que la batterie est un composant essentiel des EVs. Le chapitre a examiné aussi diverses méthodes pour estimer le SOC et le SOH, englobant à la fois des approches basées sur des modèles et des méthodes basées sur les données, suite à une exposition des modèles de batterie populaires pour la reproduction du comportement de la batterie. De plus, il a présenté les composants clés du système de chaîne de traction, incluant l'ESS, le BMS, l'EMS, le PES et les moteurs de traction électriques, renforçant ainsi la compréhension des EVs.

Chapter 2

ESTIMATION DE L'ÉTAT DE CHARGE

2.1 Introduction

Améliorer la précision des prédictions du SOC est l'un des besoins essentiels pour protéger la batterie contre une décharge totale ou une surcharge. Bien que le SOC en lui-même ne puisse pas être mesuré directement, sa valeur peut être estimée à partir d'autres grandeurs telles que le courant, la tension et la température. Dans ce chapitre, différentes méthodes d'estimation sont explorées, commençant par les méthodes basées sur les modèles, puis ceux utilisant un réseau neuronal à propagation avant ("feedforward neural network" (FFNN)), et enfin les méthodes de DL. Les dernières avancées dans les algorithmes de DL ont conduit à leur adoption extensive dans les nouveaux BMS pour EVs. Parallèlement, l'augmentation du nombre de systèmes embarqués dans les VE a suscité la recherche de nouvelles stratégies d'estimation optimisées pour le SOC, adaptées à la mise en oeuvre sur des MCUs disposant de ressources de calcul limitées. Dans cette optique, la dernière section de ce chapitre expose le processus de conception et de quantification des algorithmes de DL proposés, dédiés à l'estimation du SOC.

2.2 Méthodes basées sur un modèle et FFNN

Dans ce contexte, cette section met en évidence et examine l'estimation du SOC selon deux approches différentes : les techniques basées sur les modèles, comprenant le filtre

de Kalman étendu (EKF) et l'observateur à mode glissant à gain adaptatif (AGSMO), ainsi qu'une approche basée sur un FFNN.

2.2.1 Modélisation de la batterie et identification des paramètres

Compte tenu de l'incapacité de mesurer directement le SOC pendant le fonctionnement de la batterie, il est estimé au moyen de capteurs virtuels. Les estimateurs choisis (EKF et AGSMO) reposent sur la modélisation de la batterie, en particulier le modèle de Thévenin de premier ordre, qui englobe des éléments tels que le tension OCV (V_{oc}), une résistance interne (R_0), une banche de capacitée et une résistance de polarisation (C_p, et R_p). Ces valeurs varient en fonction du SOC, de la température et du taux de décharge. Une fois le modèle établi, il devient impératif d'identifier les paramètres du système dynamique. À cette fin, l'algorithme Levenberg Marquardt a été sélectionné. Cet algorithme fait partie de la catégorie des algorithmes de moindres carrés récursifs (RLS), conçus pour ajuster un modèle non linéaire à une séquence d'observations. Son objectif est de minimiser les différences au carré entre la tension terminale mesurée V_t et les prédictions du modèle.

Les résultats de l'identification des paramètres mettent en évidence la dépendance des paramètres de la batterie vis-à-vis du SOC, comme illustré dans la Figure 2.1. La relation non linéaire entre le SOC et V_{oc} est représentée dans la Figure 2.1(a). Par ailleurs, les Figures 2.1(b) et (d) montrent que R_p et R_0 conservent des valeurs presque constantes, sauf lors des dernières étapes du cycle de décharge, où ils atteignent des valeurs maximales correspondant à la chute de tension dans V_{oc}. Dans le même contexte, la courbe de la Figure 2.1(c) affichant C_p par rapport au SOC présente un motif exponentiel, reflétant la chute de tension observée dans la courbe V_{oc} dans cette plage. Pour simplifier la complexité de calcul, les valeurs moyennes des paramètres identifiés sont utilisées et répertoriées dans le Tableau 2.1.

Table 2.1: Valeur moyenne des paramètres identifiés de batterie

paramètres	R_0 (Ω)	R_p (Ω)	C_p (F)
Valeur	0.24	0.1	920

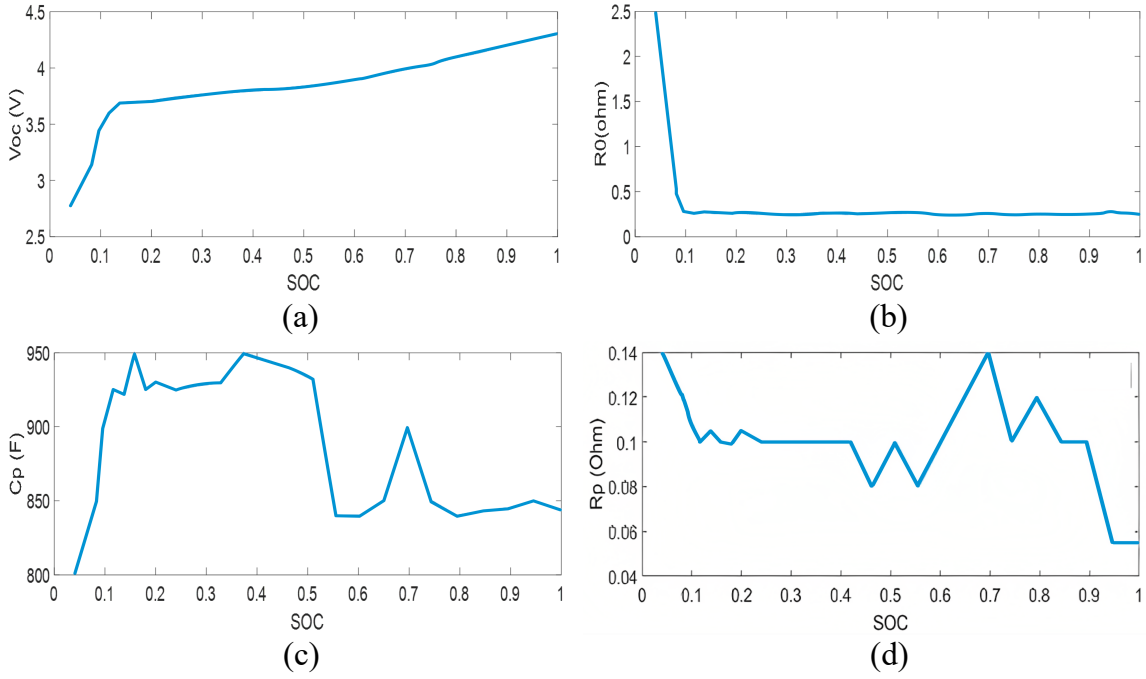


Figure 2.1: Variation des paramètres internes par rapport à SOC

2.2.2 Résultats et discussion

Afin de garantir une comparaison équitable entre les méthodes EKF, FFNN et AGSMO, il est crucial d'établir des conditions de test cohérentes. Un profil de courant d'impulsion atteignant 10 A est employé pour les phases de décharge et de charge de la batterie. Étant donné que ces algorithmes sont destinés à être mis en oeuvre dans les BMS des EVs, leur validité est évaluée par une validation de type PIL sur une carte STM32F429. Cette approche permet une évaluation approfondie dans des conditions réalistes, reflétant leur utilisation prévue dans le monde réel. La comparaison des trois méthodes d'estimation du SOC est présentée dans la Figure 2.2. De plus, pour évaluer l'estimation du SOC, des critères d'évaluation des performances tels que l'erreur absolue moyenne (MAE), l'erreur quadratique moyenne (RMSE) et le coefficient de détermination (R2) sont pris en compte pour les trois méthodes, comme résumé dans le Tableau 2.2.

D'après la Figure 2.2 et le Tableau 2.2. AGSMO se révèle être la méthode la plus précise avec une erreur maximale de seulement 1.08% au début de l'estimation. Elle obtient un RMSE de 1.9340%, un MAE de 1.0205%, et une remarquable valeur de R2 de 97.60%. Bien que l'EKF offre des estimations précises, l'AGSMO la surpasse légèrement, particulièrement lors des transitions de courant. D'autre part, FFNN présente des résultats moins favorables, avec un R2 de 92.12%, un RMSE de 5.7083%

et un MAE de 3.6935%. Il convient de souligner que la réaction de FFNN est sensible aux changements instantanés de courant. En ce qui concerne la convergence, FFNN et EKF affichent une convergence rapide, alors qu'AGSMO présente une convergence plus lente.

D'après l'évaluation PIL réalisée, il ressort que l'AGSMO se révèle être la méthode la plus précise et robuste comparée à l'EKF et du FFNN. Cependant, l'AGSMO souffre d'une convergence plus lente, ce qui peut influencer les performances lorsque le SOC initial est inconnu. Les méthodes AGSMO et EKF reposent toutes deux sur une modélisation précise et une identification complexe, ce qui entraîne des exigences computationnelles plus élevées. En revanche, le FFNN nécessite un ensemble de données conséquent pour établir une corrélation efficace. Ces limitations pourraient entraver la mise en oeuvre de ces algorithmes dans des EVs qui requièrent précision, robustesse et efficacité computationnelle.

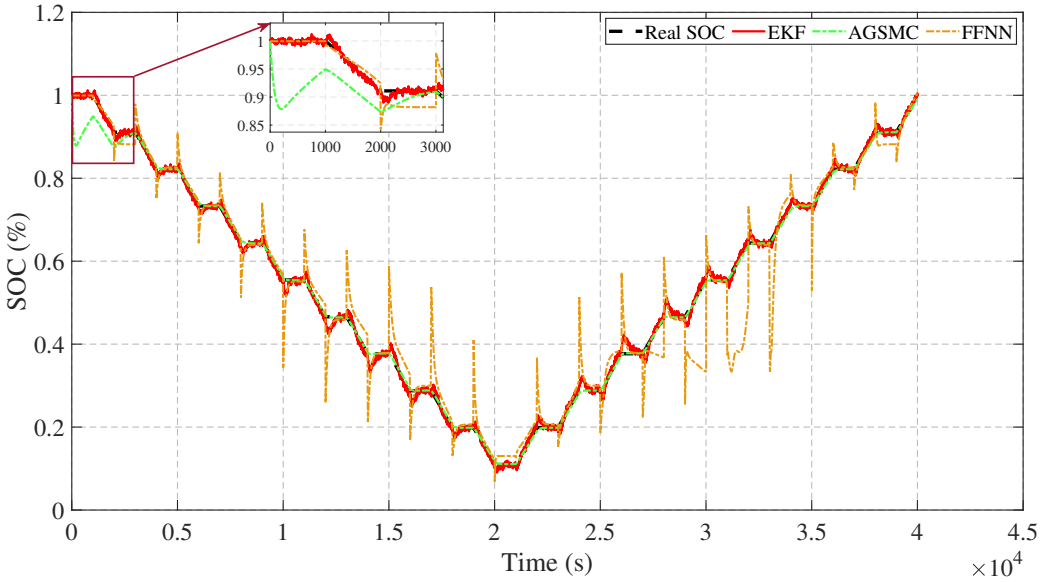


Figure 2.2: Courbes d'estimation du SOC de EKF, AGSMO et FFNN

Table 2.2: Erreurs de prédiction du SOC des trois méthodes

Méthode	Max. erreur	RMSE (%)	MAE (%)	R^2(%)
EKF	0.0459	2.0760	1.368	96.1
AGSMO	0.0108	1.9340	1.0205	97.60
FFNN	0.2497	5.7083	3.6935	92.12

2.3 Approches basées sur l'apprentissage profond

Les méthodes basées sur des modèles exigent une compréhension approfondie de la chimie et des réactions des batteries, ce qui pose des défis pour équilibrer précision et complexité de calcul. Pour remédier à cela, la thèse introduit une nouvelle contribution utilisant des algorithmes de DL tels que CNN et GRU, réputés pour leur capacité à extraire des caractéristiques clés des données de séries temporelles. Ces techniques sont utilisées pour estimer le SOC des batteries Li-ion. Cependant, les fortes exigences en calcul des réseaux de DL peuvent entraver leur mise en oeuvre, notamment dans les BMS à base de MCU. L'étude propose une stratégie d'optimisation consistant à convertir les réseaux de DL en modèles plus légers à l'aide de TensorFlow Lite, puis à appliquer une quantification avec TFLite pour microcontrôleurs (TFLite Micro) et STM32Cube.AI. L'évaluation est réalisée sur une carte STM32F429ZI.

2.3.1 Méthodologie

Le processus suivis dans cette thèse pour l'estimation du SOC des batteries Li-ion en utilisant les deux algorithmes 1D CNN et GRU est illustré dans la Figure 2.3. Il comprend quatre étapes principales: la collecte de données, la conception de modèles, l'estimation du SOC et la quantification des modèles. La collecte de données implique l'extraction du courant, de la tension, de la température et des valeurs de SOC des processus de charge et de décharge de la batterie. Ces données sont divisées en ensembles d'entraînement, de validation et de test. La construction du modèle consiste à concevoir et entraîner les modèles 1D CNN et GRU à l'aide des données d'entraînement et de validation. Ainsi, des modèles optimaux sont générés par le biais de l'entraînement et de la validation croisée.

Dans la phase d'estimation du SOC, les données de test sont introduites dans les modèles affinés pour produire des valeurs de SOC estimées. Le calcul de l'erreur consiste à comparer ces valeurs estimées avec les valeurs de référence de SOC pour calculer l'accumulation d'erreur. La performance du modèle est évaluée à l'aide de mesures statistiques telles que l'erreur quadratique moyenne (MSE), le RMSE et le MAE. Ces mesures sont également appliquées pour évaluer les modèles quantifiés et non quantifiés dans la phase de quantification. De plus, une comparaison de performance entre X-Cube-AI et TFLite Micro est réalisée pour les modèles quantifiés et non quantifiés.

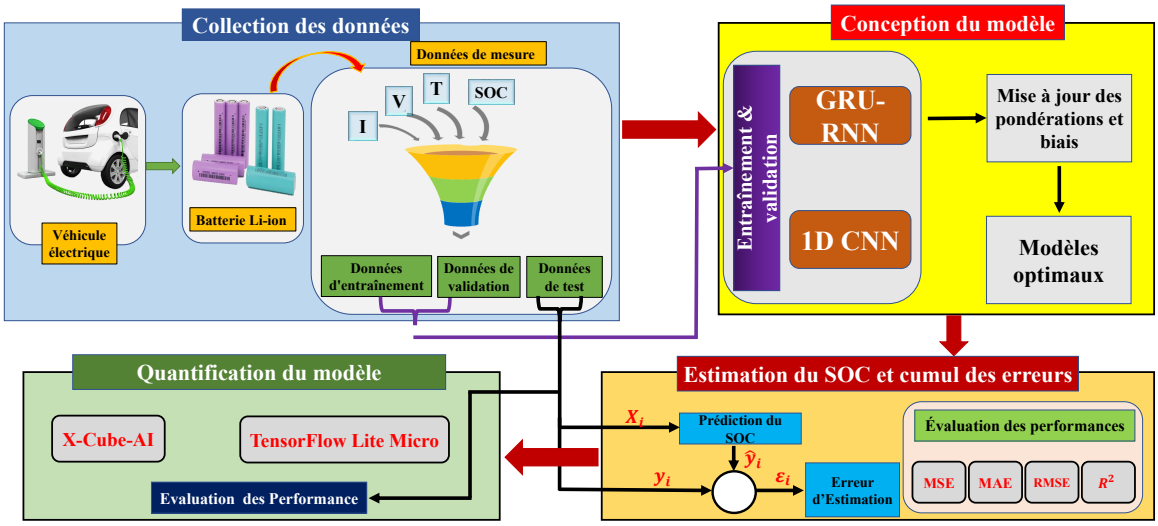


Figure 2.3: Résumé du processus d'estimation du SOC

2.3.2 Base de données et Framework de profilage de complexité

Pour former et tester les modèles de réseau neuronal proposés, une configuration expérimentale a été mise en place pour collecter des données SOC à partir d'une cellule de batterie Panasonic Sanyo UR18650ZY commerciale dotée d'une cathode en oxyde de nickel, de cobalt et d'aluminium (NCA). Pendant les processus de charge et de décharge, des données comprenant le courant, la tension et la température ont été enregistrées sur un PC. Pour évaluer les modèles 1D CNN et GRU, un ensemble de données comprenait environ 350 000 échantillons a été créé (Figure 2.4). Le courant, la tension et la température ont été choisis comme entrées, avec le SOC comme cible d'estimation. Par ailleurs, l'ensemble de données est réparti en ensembles de test (15%), de validation (10%) et d'entraînement (75%).

En général, le format standard en virgule flottante de 32 bits domine les applications de DL et est dédié aux dispositifs puissants tels que les serveurs. Cependant, il pose des problèmes sur les MCU disposant de ressources limitées. Pour surmonter ces problèmes, la quantification intervient en compressant le réseau en un format d'entier sur 8 bits. Cela permet un exécution plus rapide, une consommation d'énergie réduite, une perte minimale de précision et une utilisation réduite de la mémoire [92].

La quantification post-training est appliquée après l'entraînement et la validation du modèle. Étant donné que les outils logiciels existants ne prennent pas en charge la quantification des réseaux récurrents tels que LSTM et GRU, une comparaison initiale a été effectuée en utilisant des modèles TFLite avec le format en virgule flottante pour

1D CNN et GRU. Cependant, l'analyse de quantification s'est concentrée exclusivement sur le modèle 1D CNN. Le modèle TensorFlow entraîné est converti au format TFLite, qui est ensuite utilisé pour générer le modèle quantifié via TFLite Micro. Tandis que STM32Cube.AI emploie directement le modèle Tensorflow. Il convient de noter que les modèles CNN quantifiés et non quantifiés ont été mis en oeuvre sur une carte STM32F429, dotée d'un MCU ARM Cortex-M4 32 bits avec 2 Mo de mémoire flash, 256 Ko de RAM et une fréquence allant jusqu'à 180 MHz.

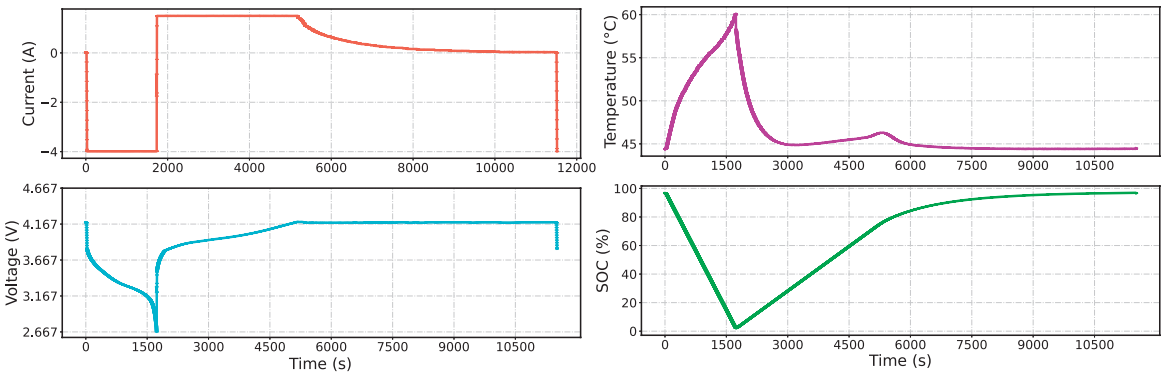


Figure 2.4: Profil de charge/décharge

2.3.3 Résultats et discussion

2.3.3.1 Résultats du test

Les résultats de l'estimation du SOC sous le profil de test spécifié sont affichés dans la Figure 2.5. Les modèles 1D CNN et GRU montrent une bonne performance dans l'estimation du SOC en mode charge et décharge. Dans ce profil de test, le modèle 1D CNN présente une légère supériorité par rapport au modèle GRU. Les pics d'erreur observés dans le modèle 1D CNN (Figure 2.5) sont attribués aux transitions rapides du courant, et l'ajout de filtres ou des couches de convolution pourrait potentiellement conduire à un surajustement du réseau. De plus, des mesures statistiques plus détaillées dans le Tableau 2.3 renforcent la supériorité du 1D CNN, avec un MSE, un RMSE et un MAE respectifs de 5.548×10^{-4}, 2.355% et 1.62%, comparés à 8.784×10^{-4}, 2.963% et 2.029% obtenus par le modèle GRU. En outre, le temps de prédiction pour le 1D CNN est plus court que celui du GRU.

Table 2.3: Erreurs de prédiction du SOC pour les modèles proposés

Modèle	Temps moy. (s)	MSE (10^{-4})	RMSE (%)	MAE (%)	R^2
1D CNN	6.061	5.548	2.355	1.62	98.72365
GRU	7.104	8.784	2.963	2.029	98.06417

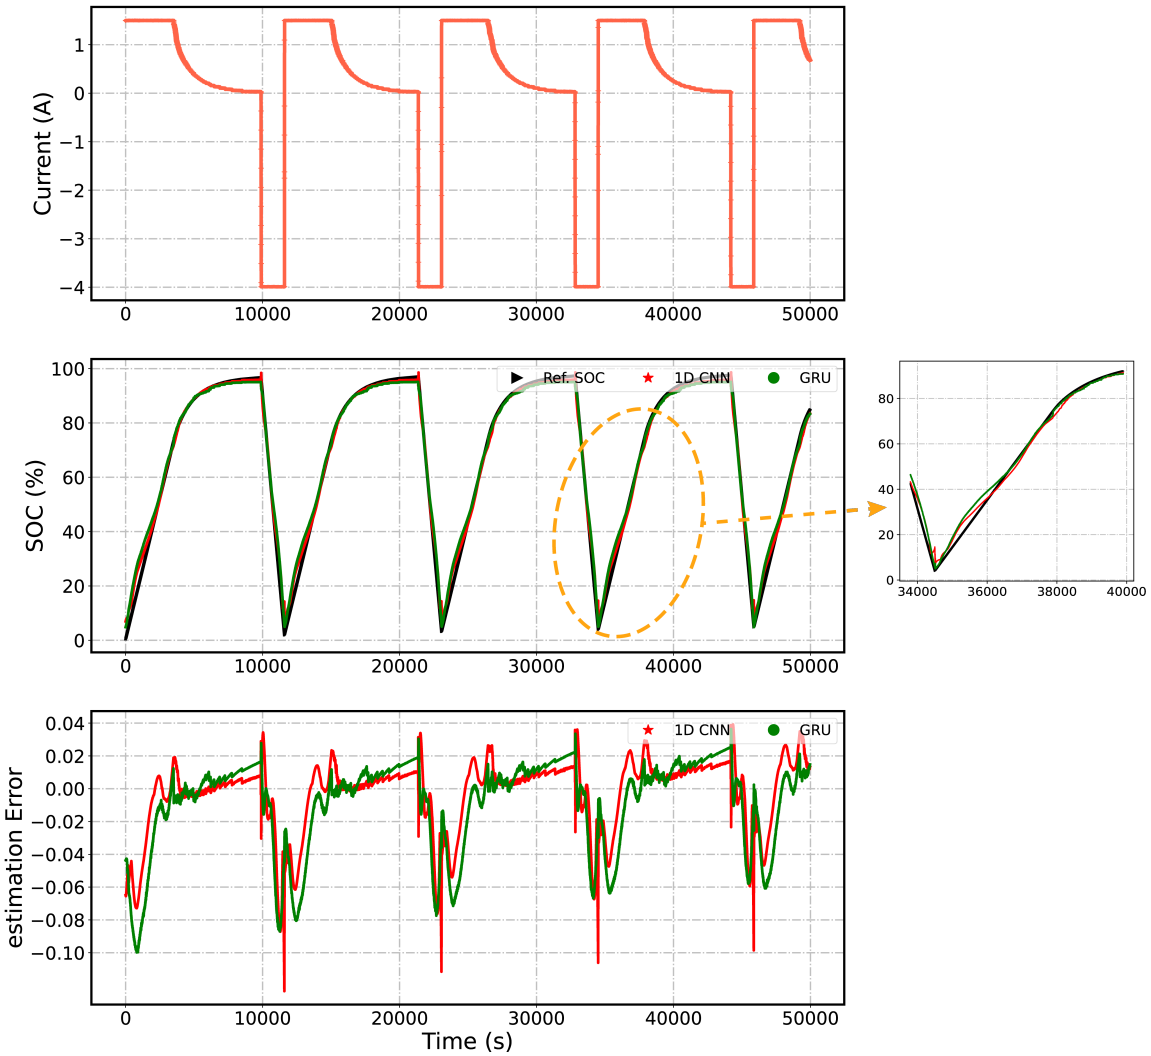


Figure 2.5: Résultats des tests des modèles 1D CNN et GRU

2.3.3.2 Analyse de complexité sur le MCU

Avant l'étape de quantification, les modèles pré-entraînés en virgule flottante 32 bits ont d'abord été vérifiés sur le MCU à l'aide de STM32Cube.AI. Le Tableau 2.4 présente une comparaison entre les valeurs du MSE, du RMSE et du MAE du modèle-C STM32 implémenté sur le MCU sélectionné et les modèles pré-entraînés d'origine. De plus, la précision croisée est calculée, où la sortie du modèle d'origine sert de

référence pour le modèle-C. Les résultats indiquent clairement que les modèles pré-entraînés ont été convertis avec succès en modèle-C sans perte de performance. En ce qui concerne les tailles de RAM Flash et l'utilisation de MACC (Multiplicateur ACCumulateur), le Tableau 2.5 présente les ressources utilisées par chaque modèle. Il est évident que le modèle 1D CNN proposé utilise moins de mémoire RAM et Flash que le modèle GRU, ainsi que moins d'opérations MACC.

Table 2.4: Validation sur le MCU des modèles avec l'ensemble de données de test

Modèle	Evaluation	MSE (10^{-4})	RMSE (%)	MAE (%)
1D CNN	Modèle d'origine	5.54822	2.35546	1.62015
	Modèle-C STM32	5.54822	2.35546	1.62015
	Précision croisée	5.776 x 10^{-6}	7.6 x 10^{-6}	5.7 x 10^{-6}
GRU	Modèle d'origine	8.78448	2.96386	2.02985
	Modèle-C STM32	8.78448	2.96386	2.02985
	Précision croisée	5.904 x 10^{-6}	2.43 x 10^{-5}	1.94 x 10^{-5}

Table 2.5: Analyse de complexité des modèles à virgule flottante 32 bits

Modèle	MACC	Flash (KB)	RAM (KB)
1D CNN	19537	10.82	2.49
GRU	445473	88.63	6.74

Ensuite, la procédure de quantification a été appliquée au modèle 1D CNN pré-entraîné. Le Tableau 2.6 présente les résultats de l'évaluation du modèle 1D CNN quantifié sur le système embarqué en utilisant le même profil de test. L'impact de la quantification sur les performances, mesuré à l'aide des métriques RMSE et MAE, est ensuite évalué. Les résultats obtenus indiquent que la quantification a entraîné un RMSE supplémentaire de 2.619% et un MAE de 2.73%. Cela met en évidence que malgré la réduction de précision introduite par le processus de quantification, les bénéfices en matière d'efficacité computationnelle et de rapidité d'exécution justifient cette perte de performance.

La Figure 2.6(a) et 2.6(b) fournissent des analyses de complexité pour les modèles 1D CNN quantifiés et non quantifiés, respectivement avec STM32Cube.AI et TFLite

Micro. Le framework STM32Cube.AI révèle une diminution significative des cycles par opération MACC, ainsi qu'une réduction de quatre fois de la mémoire Flash et une réduction de plus de 50% de l'utilisation de la RAM pour le MCU sélectionné. La même tendance est observée en utilisant TFLite Micro.

La mesure du temps d'exécution constitue un facteur critique lors de la mise en oeuvre d'un réseau DL pour une application spécifique dans le monde réel. Par conséquent, le temps d'exécution moyen, calculé comme la moyenne de 30 itérations, pour les modèles 1D CNN quantifiés et non quantifiés utilisant TFLite Micro et STM32Cube.AI, met en évidence une amélioration des performances du modèle quantifié. Cette amélioration est particulièrement remarquable avec STM32Cube.AI, où le modèle quantifié atteint un temps d'inférence de 0.971 ms, comparé à 1.412 ms avec TFLite Micro. En revanche, le modèle non quantifié nécessite 1.939 ms avec STM32Cube.AI et 2.811 ms avec TFLite Micro.

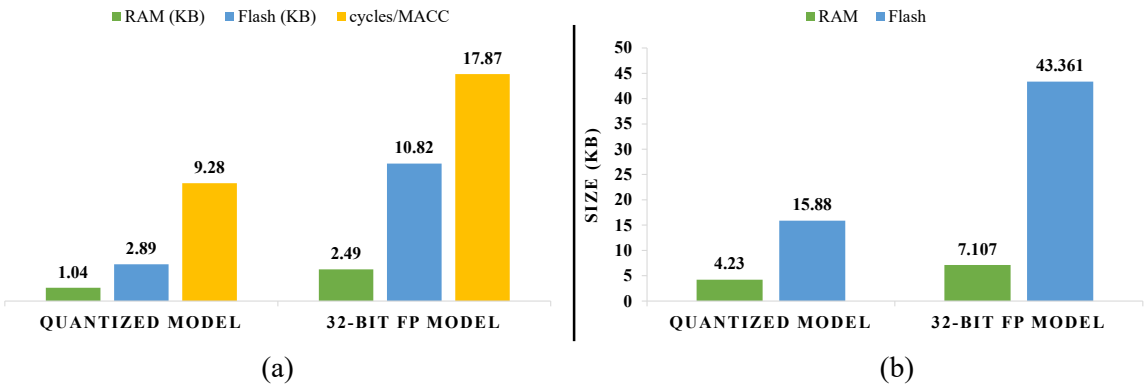


Figure 2.6: Résultats du modèle 1D CNN quantifié et du modèle à virgule flottante 32 bits. (a) Taille de la RAM (Ko) et taille du flash (Ko), et cycles/MACC obtenus avec STM32Cube.AI. (b) Taille de la RAM (Ko) et taille du flash (Ko) obtenues avec TFLite Micro.

Table 2.6: Erreurs de prédiction SOC du modèle 1D CNN quantifié et dégradation des performances associées

	RMSE (%)	MAE (%)
Valeur des métriques	4.974	4.35
Dégradation	2.619	2.73

À la suite de l'analyse de la complexité effectuée, il est clair que STM32Cube.AI surpasse TFLite Micro en termes de taille de RAM occupée, de taille de Flash et

de temps d'inférence moyen. De plus, ces améliorations s'accompagnent d'une légère dégradation de la précision du modèle quantifié, qui reste néanmoins acceptable.

2.4 Conclusion

L'objectif central de ce chapitre était de déterminer la stratégie la plus efficace pour estimer le SOC. Initialement, une analyse approfondie a été menée sur les méthodes EKF, AGSMO et FFNN. Parmi celles-ci, AGSMO a affiché la plus grande précision, tandis qu'EKF et FFNN ont montré une convergence plus rapide. Concernant les méthodes DL, la supériorité du 1D CNN par rapport aux réseaux GRU a été établie. Pour la mise en oeuvre dans les MCU disposant de ressources limitées, la conversion et l'évaluation des modèles pré-entraînés ont été facilitées à l'aide de STM32Cube.AI et TFLite Micro. Ce processus a maintenu efficacement les niveaux de performance. En outre, le modèle 1D CNN a été soumis à une quantification, entraînant une légère dégradation de précision en échange d'une réduction significative de la complexité (tailles de RAM, de Flash, cycles/ MACC). STM32Cube.AI a démontré sa supériorité en matière de gestion de la taille de la RAM et du Flash. L'évaluation du temps d'exécution a mis en évidence l'influence positive de la quantification. En conséquence, le modèle 1D CNN quantifié, utilisant STM32Cube.AI, émerge comme la solution recommandée pour une estimation précise du SOC dans les applications de véhicules équipés de petits microcontrôleurs.

Chapter 3

ESTIMATION DE L'ÉTAT DE SANTÉ

3.1 Introduction

La sécurité et la fiabilité des batteries dans différentes situations de conduite dépendent du BMS, qui surveille en continu des paramètres importants tels que le SOC et le SOH de la batterie [56]. Alors que la prédiction du SOC est essentielle pour éviter une décharge totale ou une surcharge, comme expliqué dans le chapitre précédent, la surveillance du SOH est cruciale pour détecter la dégradation de la batterie et permettre un remplacement opportun avant d'atteindre la fin de vie ("End of Life" (EOL)) [93]. Cependant, surveiller avec précision le vieillissement de la batterie présente des défis en raison de plusieurs facteurs internes et externes qui influencent ce processus [94]. Pour relever ces défis, ce chapitre présente une approche de pointe basée sur un cadre de DL pour estimer en temps réel le SOH de la batterie. Le modèle hybride CNN-BiGRU est utilisé pour analyser les données de capteurs du BMS et évaluer les performances du modèle avec une base de données de batteries Li-ion. Étant donné que la recherche d'hyperparamètres pour les modèles DL est une tâche difficile, le présent travail s'appuie sur l'algorithme d'OB pour trouver le modèle optimal. Finalement, le modèle est évalué en termes de précision, de robustesse et de capacité à estimer l'EOL de la batterie. Une analyse comparative est également réalisée avec d'autres modèles.

3.2 L'approche proposée pour l'estimation du SOH

3.2.1 Méthodologie

Le processus d'estimation du SOH en utilisant le modèle CNN-BiGRU proposé dans cette thèse comprend trois étapes principales : le traitement des données, l'optimisation des hyperparamètres et l'estimation du SOH, comme indiqué dans la Figure 3.1.

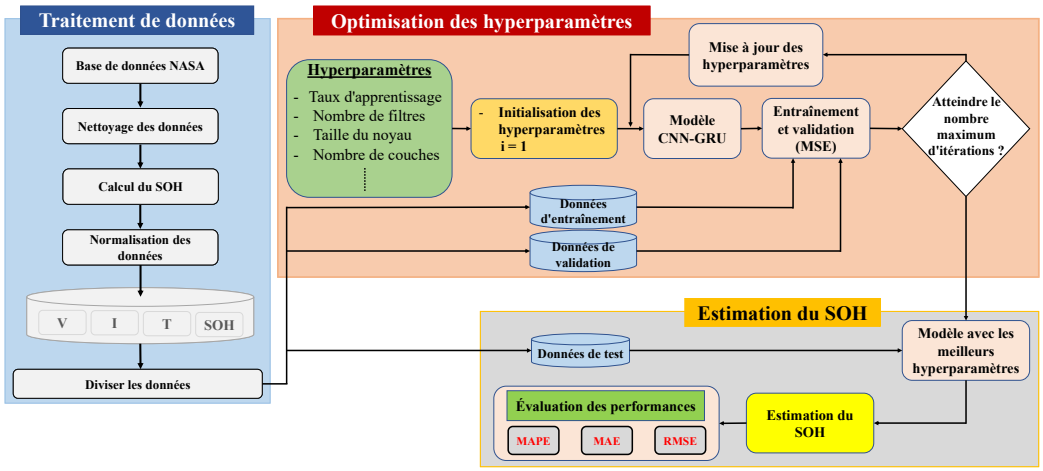


Figure 3.1: Processus d'estimation du SOH de la batterie

Pendant le processus de traitement des données, les informations pertinentes telles que le courant, la tension, la température et le SOH calculé sont extraites des cycles de décharge de l'ensemble de données expérimentales fournies par la NASA. Ces données sont ensuite soumises à des processus de prétraitement. Ensuite, elles sont divisées en ensembles d'entraînement, de validation et de test pour faciliter le développement et l'évaluation du modèle. L'étape d'optimisation des hyperparamètres utilise l'algorithme BO pour rechercher la meilleure combinaison d'hyperparamètres pour le modèle CNN-BiGRU. Ce processus comprend l'entraînement et la validation du modèle pour identifier la configuration optimale. En résultat, un modèle CNN-BiGRU est obtenu en exploitant les hyperparamètres optimisés. Dans la dernière phase, le modèle entraîné a été mis à profit pour estimer le SOH de la batterie. Un ensemble de test distinct est utilisé pour évaluer les performances du modèle proposé dans cette tâche. Une analyse comparative est effectuée avec d'autres algorithmes couramment utilisés pour l'estimation du SOH afin d'évaluer l'efficacité et la supériorité de l'approche proposée.

3.3 La base de données expérimental

Cette thèse vise à développer une approche fiable pour estimer le SOH des batteries Li-ion utilisées dans les EVs. Pour cela, un ensemble de données réaliste est essentiel, reflétant le comportement dynamique et les conditions variées auxquelles les batteries sont soumises. Contrairement à de nombreuses études antérieures, cette thèse adopte une approche réaliste en incluant des profils de décharge variés et des variations de température. L'utilisation du référentiel de données du NASA Ames Prognostics Center of Excellence (PCOE) est pertinente car il contient des mesures complètes pour une cellule Li-ion 18650 NCA. Cela permettra une évaluation plus précise de l'estimation du SOH pour les batteries des EVs.

Dans chaque ensemble de batteries (#05, #06, #07, #25, #29, #47 et #48), la capacité des cellules diminue à mesure que le nombre de cycles de décharge augmente, comme le montre la Figure 3.2. Il est à noter que différentes atténuations de capacité des batteries en fin de vie (EOL = 1,4 Ah) sont observées dans des conditions variables.

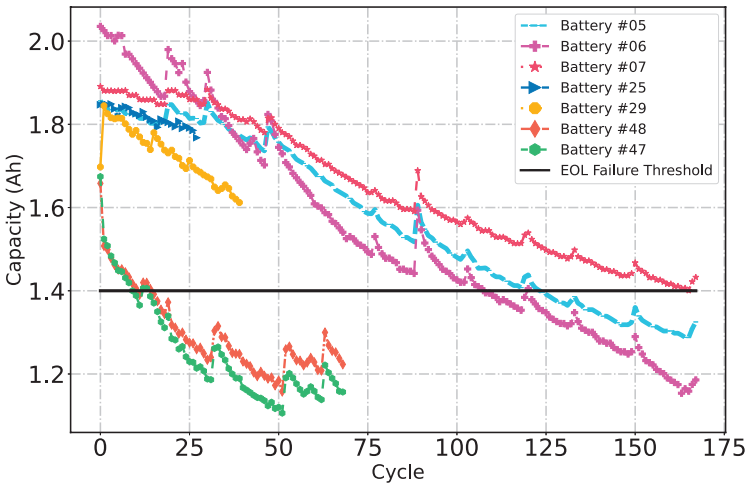


Figure 3.2: Courbes de dégradation de capacité des cellules sélectionnées

Pour détecter le vieillissement de la batterie au cours d'un cycle de décharge tout en évitant des processus d'extraction de caractéristiques longs et complexes, la température (T), le courant (I) et la tension (V) correspondant au cycle de décharge sont directement utilisés comme entrées pour le modèle développé, tandis que la capacité de la batterie pendant le même cycle est définie comme l'objectif de l'estimation. Le SOH utilisé pour l'entraînement est déterminé en utilisant l'équation (1.2).

La méthode proposée pour estimer le SOH comprend deux étapes : l'entraînement et les tests. Les ensembles de données spécifiques de batteries (#05, #25, #29 et #48) ont été utilisés pour l'entraînement, tandis que les ensembles (#06, #07 et

#47) ont été réservés pour les tests. De plus, 20% de l'ensemble d'entraînement a été choisi aléatoirement pour créer un ensemble de validation, afin d'affiner le modèle et d'optimiser ses paramètres.

3.4 Simulation et analyse des résultats

Les résultats d'optimisation des hyperparamètres du modèle CNN-BiGRU utilisés dans les expériences sont présentés dans cette section. En outre, les résultats de l'estimation du SOH sont comparés avec ceux d'autres architectures de réseaux neuronaux, y compris le 1D CNN, le CNN-LSTM, le BiGRU, le réseau ANN avec une couche cachée (ANN-1) et un autre avec deux couches cachées (ANN-2). Pour évaluer la précision et les performances de ces modèles, le MAE, le RMSE, et l'Erreur Pourcentage Absolue Moyenne (MAPE), ont été sélectionnées comme indicateurs de performance dans le présent travail.

3.4.1 Résultats d'optimisation

Les résultats finaux du processus d'optimisation montrent que l'algorithme BO a réussi à obtenir des hyperparamètres optimaux avec une MSE minimale de 1.2×10^{-5} après 19 itérations. Le modèle hybride CNN-BiGRU optimal comprend quatre couches de convolution avec 48, 48, 128 et 128 filtres respectivement, ainsi que deux couches empilées de BiGRU avec 96 unités dans la première couche et 32 unités dans la deuxième couche. Le noyau pour les couches de CNN est de taille 5, et le taux d'apprentissage pour l'optimiseur Adam est configuré à 0,00032619368.

3.4.2 Résultats d'estimation

Cette section présente les résultats de l'estimation du SOH en utilisant le modèle optimisé proposé. L'étude inclut une analyse de la robustesse du modèle hybride CNN-BiGRU en utilisant différents ensembles de données. De plus, l'impact de différentes capacités initiales sur l'estimation est examiné. En outre, l'évaluation de la précision du modèle dans la prédiction de la valeur exacte de l'EOL est également considérée.

3.4.2.1 Estimation du SOH sur l'ensemble de la durée de vie de la batterie

L'estimation du SOH est effectuée sur trois ensembles de batteries neuves : #06, #07 et #47. Les résultats de l'estimation du SOH par cycle des modèles CNN-BiGRU, CNN, CNN-LSTM, BiGRU, ANN-1 et ANN-2 pour l'ensemble #07 sont représentés

dans la Figure 3.3. Les performances des modèles comparés sont aussi résumées dans le Tableau 3.1, en fonction de leurs critères respectifs RMSE, MAE et MAPE.

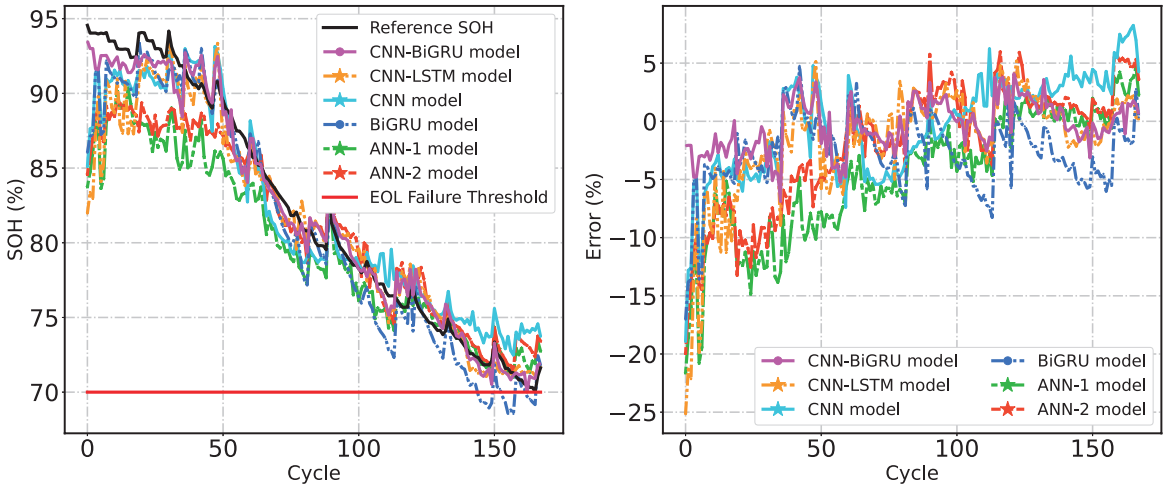


Figure 3.3: Estimation du SOH de l'ensemble de batterie #07. (a) Résultats d'estimation. (b) Erreur d'estimation

Table 3.1: Erreurs d'estimation du SOH pour l'ensemble de batterie #07

Batterie no.	Modèle	MAE (%)	RMSE (%)	MAPE (%)
#07	CNN-BiGRU	**1.861**	**2.252**	**1.114**
	CNN-LSTM	3.188	5.123	1.910
	BiGRU	2.233	4.218	2.022
	1D CNN	3.673	4.445	2.240
	ANN-1	5.467	7.150	3.283
	ANN-2	5.413	5.682	2.573

Les résultats montrent que le modèle CNN-BiGRU fournit de manière cohérente des estimations du SOH plus précises pour les trois ensembles de batteries, avec une erreur d'estimation maximale de 6% pour l'ensemble #07. De plus, le modèle détecte efficacement le phénomène de régénération de capacité local tout en maintenant un suivi précis de la tendance générale de dégradation de la capacité. On remarque aussi que, pour l'ensemble de batteries #07, le modèle CNN-BiGRU produit des estimations de SOH précises dès les cycles initiaux, tandis que les autres méthodes montrent des écarts significatifs nécessitant plus de cycles pour converger vers les valeurs réelles.

D'après le tableau 3.1, on constate que le modèle CNN-BiGRU atteint systématiquement des performances supérieures et les plus précises pour l'estimation du SOH,

obtenant des valeurs de RMSE, MAE et MAPE très faibles. En revanche, le modèle ANN-1 présente les performances les plus faibles en raison de sa structure plus simple.

Pour une comparaison objective, les performances du modèle proposé CNN-BiGRU sont évaluées par rapport à celles de quelques modèles hybrides et complexes présentés dans la littérature. Pour garantir une comparaison statistiquement significative, seules les études utilisant les mêmes ensembles de données que ceux utilisés pour tester le CNN-BiGRU dans cette thèse sont prises en compte. Les résultats de cette comparaison sont résumés dans le Tableau 3.2.

Table 3.2: Comparaison de l'approche d'estimation du SOH proposée avec des recherches récentes

Méthode	MAE (%)	RMSE (%)	MAPE (%)	Batterie
CNN-BiGRU	**2.448**	**3.177**	**1.579**	# 06
	1.861	**2.252**	**1.114**	# 07
ADLSTM-MC [95]	2.7	3.3	—	# 06
CNN-GRU [96]	4.04 0.10	4.86 0.02	—	# 05
CNN-LSTM [96]	4.34 0.01	6.33 1.12	—	# 05
Auto-CNN-LSTM [97]	—	5.03	—	# 07
Auto-CNN-LSTM + Linear filter [97]	—	4.84	—	# 07
ADNN [97]	—	11.80	—	# 07

Pour l'ensemble de batteries #06, l'approche CNN-BiGRU surpasse l'ADLSTM-MC (Dropout adaptatif LSTM avec simulation de Monte Carlo) [95] avec un RMSE de 3,177% contre 3,3%. De même, pour l'ensemble #07, l'approche CNN-BiGRU obtient un RMSE de 2,252%, bien meilleur que le modèle Auto-CNN-LSTM qui [97] a un RMSE de 5,03%. Enfin, pour l'ensemble #05, l'approche CNN-BiGRU surpasse également le modèle hybride CNN-GRU et CNN-LSTM [96] en termes de performances. En conclusion, l'approche CNN-BiGRU semble être plus efficace que les autres modèles testés pour l'estimation du SOH des batteries.

3.4.2.2 Estimation du SOH à différentes capacités initiales

Généralement, un modèle robuste et fiable est censé fournir des estimations précises du SOH même lorsque l'état actuel de la batterie est inconnu, qu'elle soit neuve ou

déjà utilisée. Pour évaluer les performances du modèle CNN-BiGRU dans ce contexte, neuf ensembles de batteries avec différentes valeurs de capacité initiale sont pris en compte: ensembles A et B avec 30 cycles déjà utilisés, ensembles C et D avec 70 cycles déjà utilisés, ensembles E et F avec 100 cycles déjà utilisés, et ensembles G, H et I avec 15, 35 et 50 cycles déjà utilisés respectivement. Le Tableau 3.3 présente un résumé des performances des modèles basé sur les critères RMSE, MAE et MAPE pour les ensembles B, D et H. Il est clair que l'approche CNN-BiGRU offre les meilleurs résultats, à l'exception de l'ensemble de batteries D où le modèle CNN surpasse légèrement les autres.

D'après les résultats indiqués, le modèle CNN-BiGRU démontre une robustesse supérieure par rapport aux autres modèles, en particulier lorsqu'on considère différentes valeurs initiales de la capacité. Ces conclusions renforcent davantage les résultats précédents et mettent en évidence l'efficacité du modèle CNN-BiGRU pour estimer le SOH dans différentes conditions.

Table 3.3: Erreurs d'estimation du SOH des ensembles B, D et H

Ensemble de batterie	Critères	CNN-BiGRU	CNN-LSTM	BiGRU	1D CNN	ANN-1	ANN-2
B	MAE (%)	**1.748**	2.388	3.158	3.111	4.734	3.507
	RMSE (%)	**2.285**	3.254	3.767	3.739	6.109	4.688
	MAPE (%)	**1.092**	1.675	2.061	1.974	2.941	2.551
D	MAE (%)	1.794	1.608	3.628	**1.563**	2.188	2.178
	RMSE (%)	2.101	2.175	4.514	**2.076**	2.872	2.774
	MAPE (%)	1.180	1.159	2.268	**1.010**	1.425	1.401
H	MAE (%)	**2.110**	2.510	2.487	2.707	2.416	2.206
	RMSE (%)	**2.540**	3.292	3.353	3.610	3.140	3.040
	MAPE (%)	**1.841**	2.19	2.178	2.379	2.096	1.940

3.4.2.3 Indicateur d'EOL

L'indicateur d'EOL des batteries est défini comme le cycle où la capacité disponible atteint 70% de la capacité nominale et indiquant le besoin de remplacer la batterie dans les EVs. La précision de la prédiction de l'EOL est essentielle pour assurer le bon fonctionnement des EVs, bien qu'après l'EOL, les batteries peuvent encore

être utilisées dans d'autres applications ou recyclées pour réduire les impacts environnementaux négatifs [98].

Pour déterminer l'indicateur d'EOL, le point d'intersection de la courbe de prédiction du SOH et du seuil de défaillance défini par le fabricant peut être identifié. L'estimation de l'indicateur EOL est réalisée pour deux ensembles de batteries : A et C. Les résultats de cette estimation sont présentés dans le Tableau 3.4. Le modèle CNN-BiGRU montre la meilleure précision dans la prédiction de l'indicateur EOL de la batterie, avec une erreur nulle pour la plupart des cycles, sauf pour l'ensemble C où il est légèrement devancé par les modèles CNN-LSTM et BiGRU. Cela démontre l'efficacité et la fiabilité du modèle CNN-BiGRU dans l'estimation de l'EOL de la batterie.

Table 3.4: L'indicateur d'EOL des ensembles de batteries A et C

Modèle	Indicateur d'EOL	Erreur (cycle)
	Set A ($EOL_{True} = 78$)	
CNN-BiGRU	**78**	**0**
CNN-LSTM	70	8
BiGRU	74	4
1D CNN	74	4
ANN-1	76	2
ANN-2	74	4
	Set C ($EOL_{True} = 39$)	
CNN-BiGRU	36	3
CNN-LSTM	**38**	**1**
BiGRU	**38**	**1**
1D CNN	35	4
ANN-1	35	4
ANN-2	30	9

3.5 Conclusion

Dans ce chapitre, un modèle d'estimation en temps réel du SOH des batteries pour les véhicules électriques a été présenté. Le modèle combine un réseau 1D CNN avec un

réseau BiGRU pour une estimation efficace du SOH. Les couches CNN extraient les caractéristiques pertinentes des données d'entrée, tandis que les couches BiGRU capturent et apprennent les dépendances de séquences longues dans les deux directions, à la fois en avant et en arrière. Le modèle utilise les mesures de courant, de tension et de température disponibles dans le BMS du véhicule, éliminant ainsi la nécessité de méthodes d'extraction de caractéristiques complexes. Les hyperparamètres du modèle ont été optimisés à l'aide de l'optimisation bayésienne. Les résultats montrent que le modèle proposé surpasse d'autres modèles couramment utilisés en termes de précision et de fiabilité. Il a également réussi à prédire avec précision l'indicateur d'EOL de la batterie. En conclusion, le modèle hybride CNN-BiGRU est robuste et bien adapté à l'estimation du SOH des batteries pour les EVs.

Chapter 4

CONTRÔLE DE LA VITESSE DU PMSM ET DE LA CHARGE/DÉCHARGE DE LA BATTERIE

4.1 Introduction

Ce chapitre aborde la conception d'un contrôleur DISMC pour réguler le flux de puissance entre un pack de batteries Li-ion et le moteur de traction à l'aide d'un convertisseur IBDAB. Le PMSM est utilisé comme moteur de traction, exploitant ses performances exceptionnelles. Pour obtenir un contrôle de vitesse fiable et robuste, une nouvelle combinaison d'un contrôleur NTSMC et d'un RBFNN adaptatif est développée. Le NTSMC assure un suivi précis de la vitesse, des fluctuations minimales et une réduction de l'erreur en régime permanent. Pendant ce temps, le RBFNN adaptatif est conçu pour compenser les incertitudes du modèle causées par les variations de paramètres et gérer les perturbations externes liées à diverses conditions routières. L'objectif est de garantir une gestion efficace du flux de puissance et le bon fonctionnement des composants du véhicule.

4.2 Méthodologie

La structure générale du système étudié dans la présente étude est résumée dans la Figure 4.1. Comme on peut le voir dans cette figure, l'architecture comprend deux sous-systèmes dépendants avec leurs systèmes de contrôle : le convertisseur DC-DC IBDAB et le système de propulsion PMSM.

Le premier sous-système dans le groupe motopropulseur est le convertisseur IBDAB est responsable de réguler le flux de puissance en modes de charge et de décharge. En mode de décharge, le contrôleur DISMC assure la régulation de tension du bus-DC tout en fournissant de l'énergie au système de propulsion et aux autres dispositifs embarqués. En mode de charge, un autre contrôleur DISMC garantit une charge sûre et efficace de la batterie en utilisant une politique de charge à plusieurs étapes au lieu de la méthode couramment utilisée CC-CV. L'énergie pour la charge peut provenir du freinage régénératif ou d'un chargeur externe connecté au bus-DC.

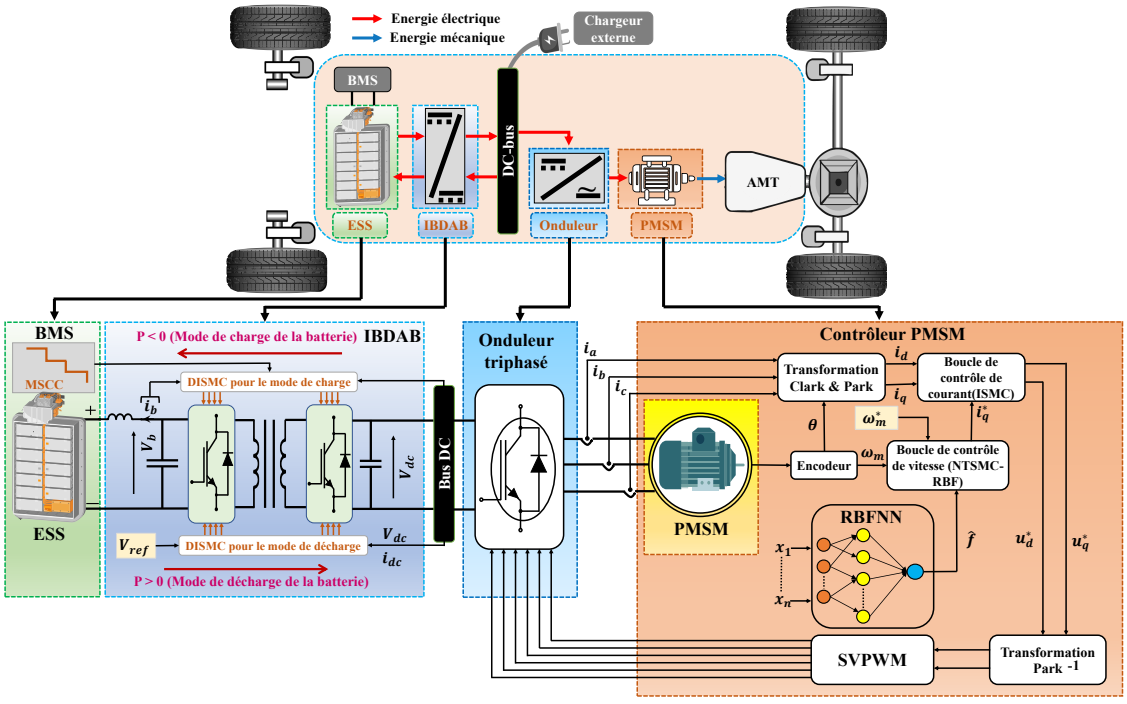


Figure 4.1: Illustration du concept de la méthode proposée

Le deuxième sous-système est le système de propulsion, qui se compose d'un PMSM entraîné par un onduleur de source de tension à deux niveaux ("Voltage Source Inverter" (VSI)). Le contrôle de vitesse du PMSM est réalisé grâce à l'approche de commande à flux orienté ("Field-Oriented Control" (FOC)), qui utilise les transformations de Clark et de Park pour représenter les courants du stator dans un système non variable dans le temps avec deux coordonnées (coordonnées directes et quadratiques

(d-q)). Dans le schéma de FOC, la boucle de contrôle interne nécessite deux références d'entrée : le courant de l'axe d (i_d^*) et le courant de l'axe q (i_q^*). La référence i_d^* est fixée à zéro pour atteindre un couple maximal par ampère, tandis que la référence i_q^* est obtenue à partir de la boucle de contrôle externe en utilisant le contrôleur NTSMC-RBFNN proposé. Le rôle de l'algorithme RBFNN est d'approximer les perturbations globales de tout le système, en prenant en compte l'erreur de vitesse et la variable de surface de glissement de vitesse en tant qu'entrées.

Les références i_d^* et i_q^* provenant de la boucle de contrôle externe sont ensuite utilisées dans la boucle de contrôle interne. Dans cette thèse, le contrôle en mode glissant intégral (ISMC) est utilisé dans la boucle de contrôle interne pour générer les tensions de référence V_d^* et V_q^* correspondant aux valeurs souhaitées de i_d^* et i_q^*. Ces tensions de référence sont ensuite transformées dans un repère fixe (α, β) à l'aide de la transformée de Clark. Dans la dernière étape du système de contrôle du PMSM, la modulation de largeur d'impulsion vectorielle spatiale ("Space Vector Pulse Widtch Modulation" (SVPWM)) est utilisée pour générer les états de commutation afin de produire les tensions triphasées souhaitées fournies au moteur

Enfin, pour évaluer les performances et la robustesse de l'ensemble du système de contrôle représenté dans la Figure 4.1, des évaluations approfondies sont réalisées dans des conditions de conduite complexes et réalistes.

4.3 Le convertisseur IBDAB

Les caractéristiques intrinsèques de l'IBDAB, telles que la sécurité grâce à l'isolation galvanique, la commutation sans tension, le contrôle du courant et de la tension, l'efficacité élevée et le taux de conversion élevé, font de ce convertisseur un choix idéal pour les applications de EVs. Grâce à sa capacité bidirectionnelle, l'IBDAB peut charger la batterie du véhicule à partir du bus DC ou injecter de l'énergie dans ce dernier. Cependant, pour assurer un flux d'énergie efficace dans les deux directions, il est essentiel de concevoir une stratégie de contrôle robuste et fiable.

Dans ce cadre, deux contrôleurs DISMC ont été développés pour assurer la régulation du flux de puissance entre la batterie et le bus DC, dans les deux sens. Le premier DISMC a été conçu pour maintenir le bus DC à une tension de 480V tout en fournissant l'énergie nécessaire au système de propulsion et aux différents éléments du véhicule. La loi de contrôle finale est exprimée dans l'équation (4.1). D'un autre côté, le deuxième DISMC a été élaboré pour réguler le courant de charge de la bat-

terie en suivant le protocole de charge défini par le BMS, ou pour transférer l'énergie générée pendant le freinage. La loi de contrôle finale de ce DISMC est exprimée dans l'équation (4.2).

$$P_o = I_{dc}V_{dc} + \frac{C_2}{C_1} C_{dc}V_{dc}\, e_v + \frac{C_3}{C_1} C_{dc}V_{dc} \int e_v dt + \frac{C_s}{C_1} \tanh \frac{s_v}{\varepsilon_v} \tag{4.1}$$

$$u_I = \frac{\gamma_i x_1 + k_1 y_2 + k_2 y_1 + k_3 \int y_1 dt + k_{si} \tanh(\frac{s_I}{\varepsilon_I})}{\rho_i} \tag{4.2}$$

Les constantes positives ε_I, ε_v, C_s, C_1, C_2, C_3, k_1, k_2, k_3, et k_{si} sont utilisées dans le contexte donné. Les termes s_I et s_v font référence aux surfaces de glissement du contrôleur de courant et de tension respectivement, tandis que ρ_i est une variable auxiliaire. Les variables V_{dc}, I_{dc} et C_{dc} représentent respectivement la tension, le courant et la capacité mesurés aux bornes du bus-DC. Les variables e_v et e_I quantifient les erreurs de tension et de courant.

4.4 Modélisation du PMSM

Pour simplifier la modélisation et l'analyse du système PMSM, sans diminuer la précision du modèle, il est plus pratique de concevoir le modèle dynamique du PMSM dans le repère de référence d-q tournant synchrone. Ainsi, le modèle dynamique du PMSM peut être décrit comme suit :

$$\frac{di_d}{dt} = -\frac{R_s}{L_d} i_d + N_p \omega_m i_q + \frac{1}{L_d} V_d \tag{4.3}$$

$$\frac{di_q}{dt} = -\frac{R_s}{L_q} i_q - N_p \omega_m i_d - \frac{N_p \lambda_m}{L_q} + \frac{1}{L_q} V_q \tag{4.4}$$

$$\frac{d\omega_m}{dt} = \frac{T_e}{J} - \frac{B}{J}\omega_m - \frac{T_L}{J} \tag{4.5}$$

$$T_e = \frac{3}{2} N_p \left(\lambda_m i_q + (L_d - L_q) i_d i_q\right) \tag{4.6}$$

Où i_d et i_q sont les courants de phase dans les axes d-q, V_d et V_q sont les tensions dans les axes d-q, ω_m est la vitesse angulaire mécanique du rotor, R_s est la résistance du stator, N_p est le nombre de paires de pôles, λ_m est la liaison de flux d'aimant permanent, B est le coefficient de friction visqueuse, J est le moment d'inertie, T_L est le couple de charge appliqué, T_e est le couple électromagnétique, L_d et L_q sont les inductances du stator dans les axes d-q.

Le PMSM utilisé dans cette thèse est un PMSM monté en surface, où les parties à

aimants permanents sont installées à la surface du rotor. Dans ce cas, les inductances d'axe d-q sont considérées comme égales ($L_d = L_q = L_s$). Sur la base des équations dynamiques du PMSM, le système est fortement non linéaire et peut être affecté par des perturbations externes et des incertitudes. Par conséquent, la conception d'un régulateur de vitesse performant est indispensable pour assurer un suivi robuste de vitesse robuste. À cet égard, en utilisant la combinaison du NTSMC et du RBFNN, les lois de commande des deux boucles de vitesse de courant sont respectivement exprimées dans les équations (4.7) et (4.8).

$$\begin{aligned} \dot{i}_q^* &= \dot{i}_q^{eq} + \dot{i}_q^{sw} \\ &= R^{-1} \int_0^t \left[Dx_2 - \alpha \frac{m}{l} x_2^{2-\frac{l}{m}} - \hat{f} - K_s sign(\sigma_\omega) - K_{s1}\sigma_\omega \right] dt \end{aligned} \tag{4.7}$$

$$\begin{cases} V_d = G_d - L_s \dot{i}_d^* - L_s K_{d1} e_d - K_{ds} \tanh\left(\frac{\sigma_d}{\mu_{dq}}\right) - K_{d2}\,\sigma_d \\ V_q = G_q - L_s \dot{i}_q^* - L_s K_{q1} e_q - K_{qs} \tanh\left(\frac{\sigma_q}{\mu_{dq}}\right) - K_{q2}\,\sigma_q \end{cases} \tag{4.8}$$

4.5 Résultats et discussion

Dans le but de démontrer les performances des schémas proposés et d'illustrer la fiabilité et la robustesse des contrôleurs, diverses expériences ont été réalisées en utilisant les paramètres d'un véhicule électrique Nissan Leaf S. Afin d'évaluer de manière exhaustive les performances dynamiques et l'efficacité du système présenté dans la Figure 4.1, deux modes de fonctionnement sont pris en compte : le mode de décharge et le mode de charge. De plus, la performance du contrôleur proposé NTSMC-RBF est comparée à plusieurs schémas de contrôle puissants, dont le contrôleur proportionnel intégral (PI) conventionnel, le contrôleur de rétroaction intégrale ("integral backstepping controller" (IBC)) et le contrôleur SMC.

4.5.1 Cas 1 (Mode de charge)

Dans ce mode, le contrôleur de l'IBDAB est évalué en termes de vitesse de convergence, de robustesse et de précision du suivi du profil de charge du BMS. Pour atteindre ces objectifs, la stratégie courant constant à plusieurs étapes ("multistages constant current" (MSCC)) est utilisée pour la charge [99], offrant des avantages tels qu'une charge rapide, une faible variation de température et une meilleure efficacité énergétique, ce qui prolonge la durée de vie de la batterie [100].

Les résultats de simulation dans la Figure 4.2 démontrent l'efficacité du contrôleur

proposé pour atteindre un suivi précis du profil de courant de charge MSCC utilisé pour charger la batterie de 10% à 95%. La courbe verte représente le courant de charge réel, qui converge rapidement vers le courant de référence en seulement 0,4 seconde. Cette convergence rapide met en évidence la réactivité et l'agilité du contrôleur. De plus, la Figure 4.2 révèle que le courant de charge suit de près le courant de référence tout au long des cinq étapes du profil MSCC. Les fluctuations observées dans la courbe verte sont minimes, avec une magnitude maximale de 0,06 A. Cela indique la capacité du contrôleur à maintenir un contrôle précis sur le courant de charge, en s'assurant qu'il correspond étroitement au courant de référence souhaité à chaque étape du processus de charge. En conséquence, la performance remarquable du contrôleur confirme sa pertinence pour cette application spécifique.

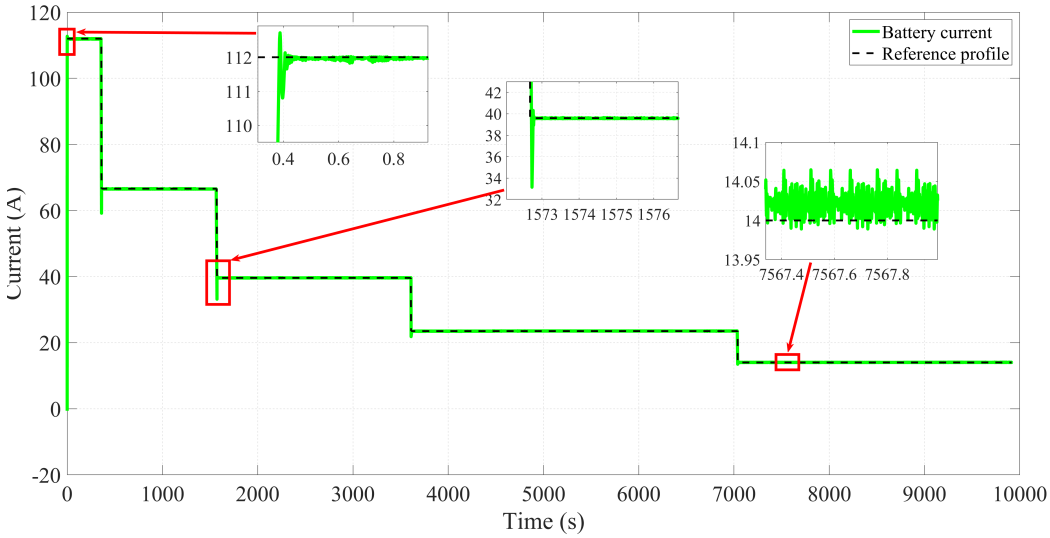


Figure 4.2: Courbe de réponse du convertisseur IBDAB en mode de charge avec le profile MSCC

4.5.2 Cas 1 (Mode de décharge)

i. *Performance de suivi en présence de perturbations de charge*

Comme le montre la figure 4.3, à une vitesse de référence de 300 rad/s, le moteur démarre initialement sans charge. Ensuite, pour évaluer la robustesse du contrôleur face aux perturbations soudaines, deux charges sont appliquées : une charge élevée de 20 N.m à t = 1,5s, suivie d'une charge faible de 10 N.m à t = 2,5s.

Les résultats illustrés dans la Figure 4.3 présentent la réponse de vitesse du PMSM obtenue en utilisant l'approche NTSMC-RBF ainsi que trois autres méthodes. On remarque que l'approche NTSMC-RBF permet d'atteindre rapidement la vitesse de référence avec un dépassement négligeable (0.0093%) et un temps de réponse de t_r =

0.162, qui est meilleur que celui des autres méthodes. En outre, parmi les méthodes évaluées, le contrôleur NTSMC-RBF se distingue par sa stabilité et ses performances en régime permanent, tout en maintenant des fluctuations minimales.

Table 4.1: Performances des contrôleurs à une vitesse de référence de 300 rad/s

Vitesse	Indice de performance		NTSMC-RBF	SMC	IBC	PI
300 rad/s	Temps d'établissement (s)		0.162	0.2026	0.76	2.23
	Dépassement (%)		0.0093	0.256	60	99.8
	Chute de vitesse (rad/s)	Load up	1.099	1.829	2.831	5.84
		Load down	1.116	1.12	2.753	2.335
	Temps d'ajustement (s)	Load up	0.012	0.166	0.28	1.2
		Load down	0.0092	0.11	0.15	0.8

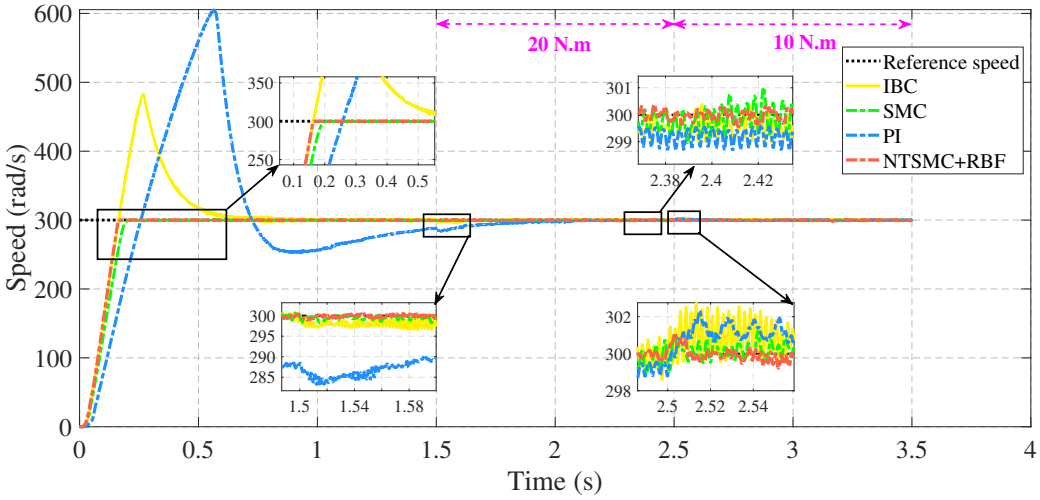


Figure 4.3: La réponse de vitesse avec une variation de charge soudaine à une vitesse de 300 rad/s.

Le Tableau 4.1 résume davantage de statistiques de performances pour les quatre méthodes. La colonne "load up" dans le tableau correspond à l'insertion d'un couple de charge de 20 N.m, tandis que la colonne "load down" représente la transition du couple de charge de 20 N.m à 10 N.m. Les résultats obtenus montrent que le NTSMC-RBF se distingue par sa robustesse en maintenant une vitesse stable du PMSM malgré les perturbations de charge. Le contrôleur ajuste rapidement la vitesse après de légères chutes, comme indiqué dans le tableau. Dans l'ensemble, le NTSMC-RBF surpasse les autres méthodes en termes d'erreur en régime permanent, de temps de réponse, de chute à basse vitesse et de robustesse, démontrant ainsi sa supériorité dans différentes catégories de performances.

Pour approfondir l'analyse des performances de l'algorithme proposé, cette section évalue l'efficacité et la robustesse de la méthode NTSMC-RBF proposée sous des vitesses variables et des couples de charge élevés. En termes de stabilité de la vitesse, les zones agrandies dans la Figure 4.4 montrent que le contrôleur NTSMC-RBF produit la plus faible amplitude de fluctuations. À t=16.8 s, le contrôleur NTSMC-RBF atteint une amplitude de ±0.02 rad/s, tandis que les contrôleurs SMC, IBC et PI produisent des amplitudes de fluctuations plus grandes de ±0.568 rad/s, ±0.628 rad/s et ±0.06 rad/s, respectivement. La Figure 4.4 démontre que le contrôleur NTSMC-RBF est le plus robuste face aux variations du couple de charge, avec des fluctuations minimales dans la réponse de vitesse. Il maintient des changements de vitesse minimes et atteint rapidement la vitesse de référence, contrairement aux autres contrôleurs qui présentent des fluctuations plus importantes et nécessitent plus de temps pour se stabiliser.

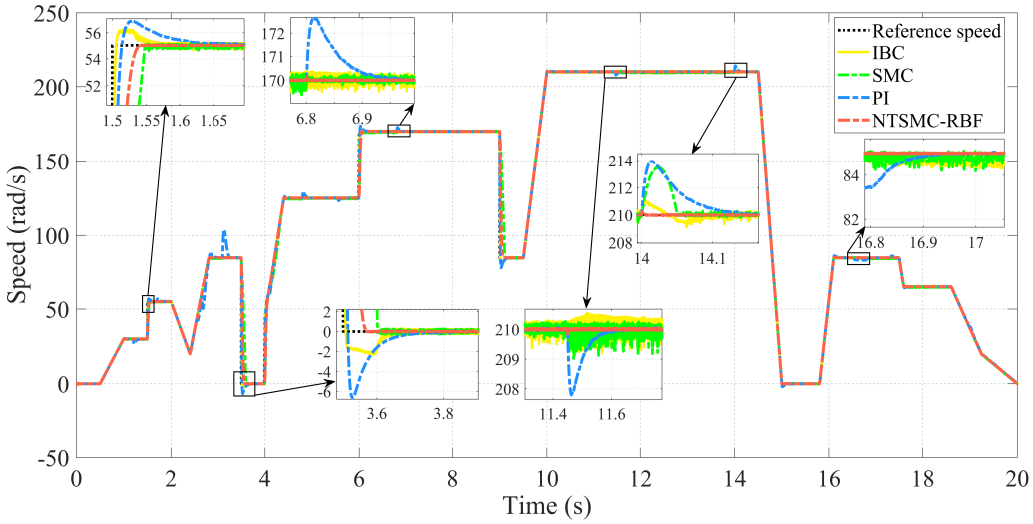


Figure 4.4: Courbes de réponse de vitesse dans des conditions de conduite variables

ii. *Performance de suivi en cas de changement de paramètres*

Cette section évalue les schémas de contrôle proposés face aux perturbations globales, qui incluent les perturbations externes représentées par le couple de charge, ainsi que les incertitudes liées aux paramètres. La vitesse de référence est maintenue constante à 200 rad/s, et le couple de charge est fixé à 10 N.m. Les variations des paramètres J sont testées avec trois valeurs différentes : 50%, 100% et 200% de leurs valeurs réelles. Comme le montre la Figure 4.5, les performances de tous les contrôleurs sont affectées par la variation de l'inertie J, ce qui entraîne une diminution de leurs performances, à l'exception du NTSMC-RBF qui maintient des performances satisfaisantes. De plus, pour une inertie de $2J$, le NTSMC-RBF démontre la plus petite erreur de fluctuation, avec une amplitude de ±0.045 rad/s. En comparaison, les

contrôleurs SMC, IBC et PI présentent des erreurs de fluctuation plus importantes de ±0.475 rad/s, ±0.539 rad/s et ±0.05 rad/s, respectivement. Cela met en évidence encore davantage les performances supérieures du NTSMC-RBF en termes de précision de suivi et de stabilité.

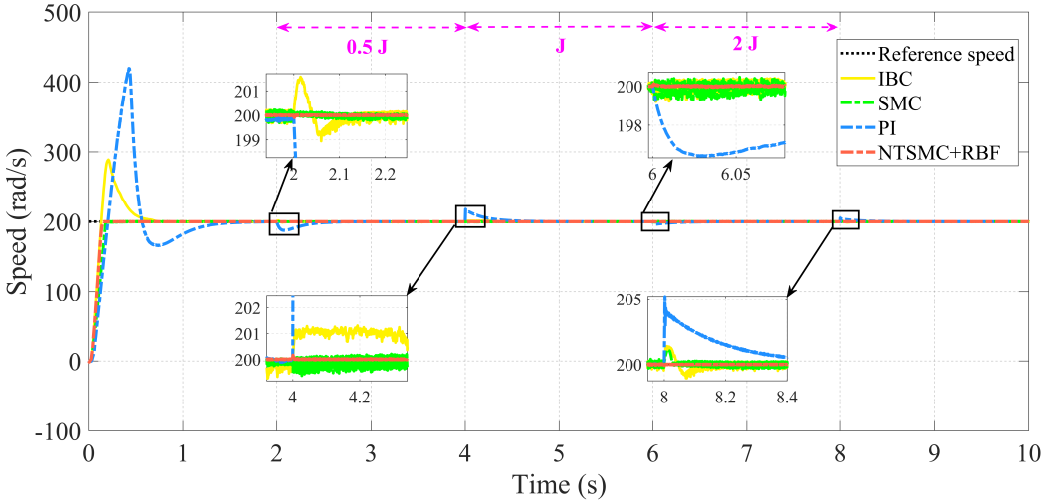


Figure 4.5: Courbes de réponse de vitesse avec une variation soudaine de J à une vitesse de 200 rad/s

4.6 Conclusion

Ce chapitre s'est concentré sur la conception d'un contrôleur robuste pour gérer le flux de puissance dans un convertisseur IBDAB, qui servait d'interface cruciale entre le pack de batteries et le PMSM dans la chaîne de traction du EV. De plus, une stratégie de contrôle hybride est proposée pour le contrôle efficace de la vitesse du PMSM en combinant un NTSMC et un RBFNN adaptatif. Le NTSMC assure un suivi précis de la vitesse, supprime le broutage et réagit rapidement, tandis que le RBFNN compense les perturbations dues aux fluctuations de charge et aux variations de paramètres. Les résultats obtenus de l'étude réalisée démontrent la supériorité du contrôleur NTSMC-RBF par rapport aux autres contrôleur en termes de précision et de robustesse face aux perturbations regroupées. De plus, le DISMC a réussi à suivre avec précision le courant de charge du MSCC tout en maintenant une tension DC-bus stable tout au long du scénario de conduite.

Chapter 5

GESTION DE L'ÉNERGIE POUR HESS DANS LES EVS

5.1 Introduction

Traditionnellement, les EVs sont équipés d'un seul ESS desservant l'intégralité du véhicule, ce qui peut solliciter une puissance variable de la batterie pour diverses conditions de conduite, notamment les accélérations et les freinages brusques. Afin d'optimiser la gestion de l'énergie, le concept de l'HESS a émergé, impliquant des unités de stockage supplémentaires aux côtés de la batterie principale. Parmi celles-ci, les SC se sont révélés être un ESS secondaire approprié en raison de leur capacité à gérer efficacement les demandes de puissance soudaines et à récupérer de l'énergie lors du freinage régénératif. L'intégration des SC dans le HESS présente des avantages tels que la réduction de la sollicitation de la batterie, l'amélioration de l'efficacité énergétique et l'allongement de la durée de vie de l'ESS. Cependant, la conception d'une stratégie efficace d'allocation et de gestion de l'énergie pour le HESS demeure un défi complexe. À cet égard, ce chapitre explore une approche novatrice utilisant le RL pour élaborer un EMS précis et robuste pour un HESS dans les EVs. Plus précisément, l'algorithme soft-actor critic (SAC) est employé en raison de ses avantages distinctifs. En combinant les forces du RL et de l'algorithme SAC, ce chapitre vise à optimiser l'allocation d'énergie, améliorer l'efficacité énergétique et renforcer les performances globales des EVs équipés d'un HESS.

5.2 L'HESS et approches de contrôle du EMS

En général, les EVs s'appuient principalement sur les batteries comme stockage d'énergie, ce qui peut causer des problèmes de surchauffe et de dégradation précoce. Pour remédier à cela, l'intégration d'un HESS avec des éléments supplémentaires comme les SC et les FC a été proposée. Ces éléments travaillent en synergie pour gérer efficacement les pics de puissance lors des accélérations et des freinages, réduisant ainsi le stress sur la batterie et prolongeant sa durée de vie [18, 19]. Cette configuration améliore la durabilité globale, l'efficacité et la disponibilité de l'énergie, tout en récupérant l'énergie du freinage régénératif [101].

Les SC gagnent en importance dans les ESS des EVs, principalement en raison de leur capacité exceptionnelle à fournir rapidement et efficacement une puissance élevée [102]. Par rapport aux batteries Li-ion, les SC présentent une densité de puissance plus élevée et une durée de vie plus longue [18], ce qui les rend idéaux pour gérer les fortes rafales de puissance requises par les EVs et pour récupérer efficacement l'énergie du freinage régénératif.

Les convertisseurs DC-DC jouent un rôle crucial dans le transfert de puissance entre le HESS et le bus DC, permettant un flux bidirectionnel ou unidirectionnel. Selon la configuration du HESS et du convertisseur, quatre topologies courantes ont été identifiées [20]: parallèle passive, semi-active (batterie-SC, SC-batterie), entièrement active (parallèle active) et reconfigurable en série. Chaque topologie offre des avantages uniques en termes de flux d'énergie et de performances du système.

Pour les diverses configurations, un EMS s'avère essentiel pour la gestion efficiente de l'énergie disponible dans le HESS [17]. Initialement, il reçoit des mesures de plusieurs capteurs, les instructions du conducteur et les données provenant d'autres unités telles que le BMS, puis calcule la demande d'énergie requise et génère des commandes de contrôle transmises au PES.

Le rôle crucial de l'EMS est d'optimiser et de répartir efficacement la puissance entre les éléments du HESS [103]. Cette optimisation peut entraîner des améliorations de l'autonomie, de la durée de vie de la batterie et des performances globales du véhicule. Afin d'atteindre cet objectif, diverses stratégies de contrôle ont été élaborées pour l'EMS du HESS, pouvant être classées en trois catégories principales : méthodes basées sur des règles (rule-based (RB)) [104, 105], méthodes basées sur l'optimisation [106, 107] et méthodes basées sur l'apprentissage [108, 109].

5.3 La stratégie de contrôle EMS proposée

Face aux défis complexes de la gestion du flux d'énergie dans les HESS au sein des EVs, les approches conventionnelles telles que les méthodes RB et la logique floue sont insuffisantes. De même, les techniques basées sur l'optimisation telles que le contrôle prédictif basé sur le modèle (MPC) et la programmation dynamique (DP) peinent à répondre aux diverses exigences des différents scénarios de conduite. Par conséquence, les méthodes RL émergent comme une solution prometteuse, avec des techniques telles que les gradients de politique déterministes profonds (DDPG) et SAC gagnant en popularité en raison de leur adaptabilité dans des situations de conduite complexes. Dans ce contexte, l'accent est mis sur un EMS innovant désigné pour un HESS comprenant des packs de batteries et de SC, exploitant les avantages de l'algorithme SAC pour relever les défis complexes et optimiser les performances de la gestion de l'énergie des EVs. Cette approche établit un modèle précis de la dynamique du EV, définit les défis de l'optimisation et présente un cadre global pour une gestion efficace de l'énergie.

5.3.1 Méthodologie

La Figure 5.1 illustre la structure du système EMS proposé, elle offre un aperçu des différents sous-systèmes impliqués. L'architecture se compose de deux sous-systèmes principaux dépendants : l'EMS basé sur l'algorithme SAC et l'environnement. Dans ce dernier, un cycle de conduite est incorporé dans le modèle dynamique du véhicule pour déterminer la puissance de conduite (P_{dri}) nécessaire pour atteindre la vitesse souhaitée. Les états du sous-système EMS sont définis par l'accélération (a_{cc}), le SOC du SC et la somme de P_{dri} et de la puissance demandée par les autres composants du véhicule (P_{load}).

L'algorithme SAC vise à allouer la puissance entre les dispositifs de stockage dans le HESS. À cet égard, la puissance de référence de la batterie et du SC ($P_{\mathrm{b_ref}}$ et $P_{\mathrm{sc_ref}}$) sont choisies comme actions de l'approche RL. Ces valeurs de puissance sont ajustées dynamiquement par l'algorithme SAC pour optimiser la gestion de l'énergie et réaliser une allocation de puissance efficace au sein du HESS.

Après l'exécution des actions, l'environnement réagit en fournissant une récompense r_i, reflétant l'efficacité des actions de l'algorithme SAC. Cette récompense guide l'apprentissage et l'affinement de la politique d'allocation de puissance pour les interactions futures. La méthodologie proposée combine divers composants et algorithmes

pour atteindre une allocation de puissance et un contrôle efficace dans le HESS, guidée par l'algorithme SAC. La performance et la robustesse de l'algorithme sont évaluées à l'aide des cycles de conduite complexes et réalistes, permettant d'évaluer son efficacité.

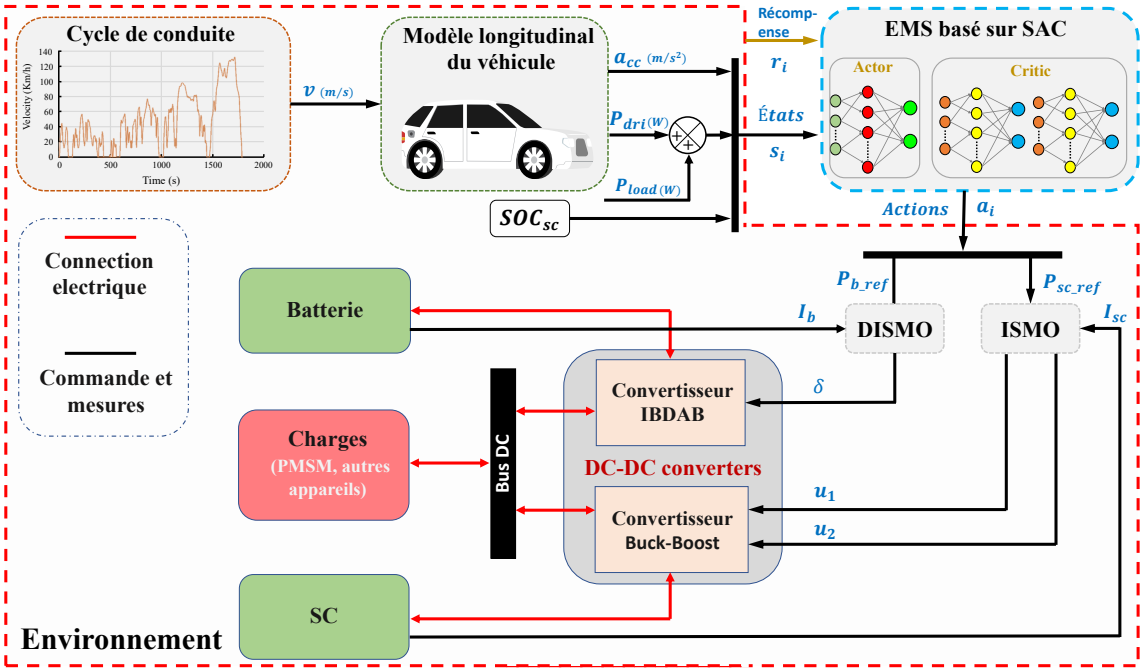


Figure 5.1: Illustration de la méthodologie de l'EMS proposé

5.3.2 Configuration des approches RB et SAC pour le EMS

La principale fonction de l'EMS est d'attribuer intelligemment la puissance au SC en réaction aux demandes soudaines de puissance, aux fluctuations significatives de charge ou pendant le freinage régénératif. Pendant ce temps, la batterie prend en charge les besoins en puissance à basse fréquence lors de conditions de conduite normales. Dans ce cadre, l'approche RL basée sur l'algorithme SAC émerge comme une solution nouvelle et prometteuse pour l'optimisation de l'EMS. À titre de référence, la méthode RB, représentée dans la Figure 5.2, est choisie comme approche de comparaison en raison de son adoption répandue dans les applications d'EMS. Basé sur la structure du diagramme présenté dans la Figure 5.1 et sur le principe de fonctionnement de l'EMS basé sur l'algorithme SAC, il est essentiel de définir les éléments clés de l'algorithme SAC : l'espace des états, l'espace des actions et la fonction de récompense. Choisir ces éléments de manière attentive peut grandement améliorer l'interaction avec l'environnement et accélérer le processus d'apprentissage de l'agent.

Ainsi, ces éléments sont définis dans l'équation suivante :

$$\begin{cases} S = \{SOC_{sc}, P_{dem}, a_{cc}\} \\ a = \{P_{\text{b_ref}}, P_{\text{sc_ref}}\} \\ r = -w_1 \left(SOC_{sc} - SOC_{\text{sc_ref}}\right)^2 - w_2 \dfrac{Price_{elec} P_b}{3600} - w_3 I_b^2 \end{cases} \tag{5.1}$$

où $P_{dem} = P_{dri} + P_{load}$ est la puissance totale sollicitée par le véhicule (puissance de traction et puissance des charges), SOC_{sc} est le SOC du SC, a_{cc} est l'accélération, $P_{\text{b_ref}}$ et $P_{\text{sc_ref}}$ représentent respectivement la puissance de référence de la batterie et du SC. Les termes w_1, w_2 et w_3 correspondent aux poids de pénalité, $SOC_{\text{sc_ref}}$ désigne le SOC de référence du SC, fixé à 0,7 dans cette thèse, $Price_{elec}$ indique le prix de l'électricité fixé à 1,17 MAD/KWh, et P_b fait référence à la puissance de la batterie.

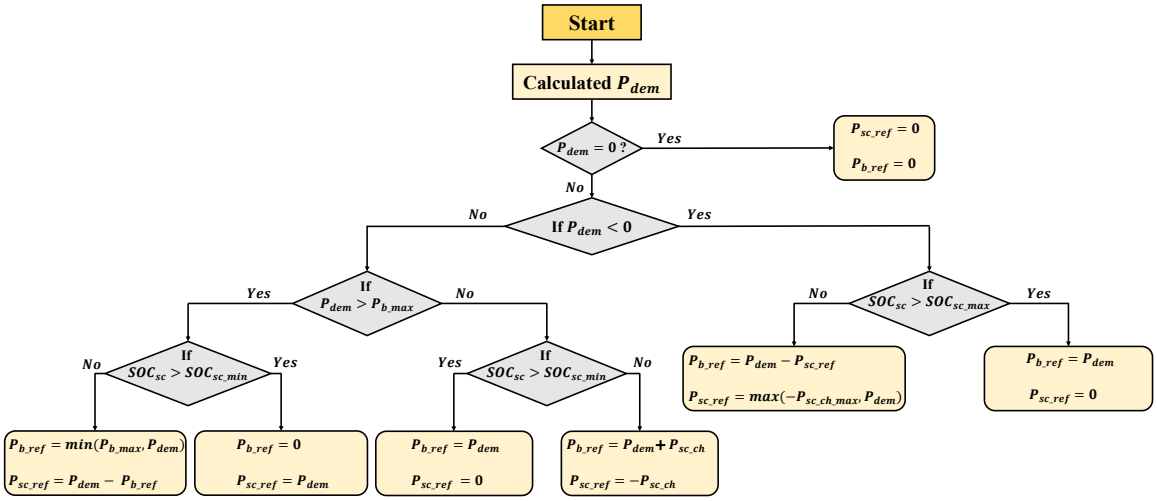


Figure 5.2: Stratégie de gestion de l'énergie basée sur RB

L'architecture du réseau neuronal utilisé pour l'algorithme SAC comporte cinq couches entièrement connectées. Le réseau d'acteurs, de dimensions 3-128-64-32-2, traite les informations d'état pour générer des actions appropriées. Le réseau de critique utilise à la fois les vecteurs d'état et d'action en entrée, combinés en une seule entrée pour évaluer la qualité des actions et produire la valeur Q correspondante. Le réseau de critique a une architecture de dimensions de 5-128-64-32-1. Les réseaux d'acteurs et de critique utilisent la fonction d'activation ReLU dans ce système proposé.

5.4 Résultats et discussion

5.4.1 Configuration des simulations

Un cycle de conduit dérivé du cycle "Worldwide Harmonized Light Vehicle Test Cycle (WLTC) Class 3" est considéré pour l'entrainement de l'algorithme SAC permet d'améliorer sa capacité de généralisation. De plus, d'autres configurations d'entraînement ont été considérées : un poids supplémentaire de 42,55 kg pour le SC a été incorporé en plus du poids d'origine de la Nissan Leaf S, une consommation de charge de 5 kW a été introduite pendant l'entraînement et le test, et l'état de charge initial de la batterie et du SC a été fixé initialement à 80% et 65%, respectivement, au début de chaque épisode d'entraînement. Cette configuration assure une quantité d'énergie adéquate pour l'intégralité du cycle de conduite.

Après l'entraînement, le système EMS a été évalué à l'aide de cycles de conduite LA92 (Los Angeles 92), choisis pour simuler divers scénarios du monde réel, dont la vitesse et la puissance correspondante pour ce cycle sont illustrées dans la Figure 5.3.

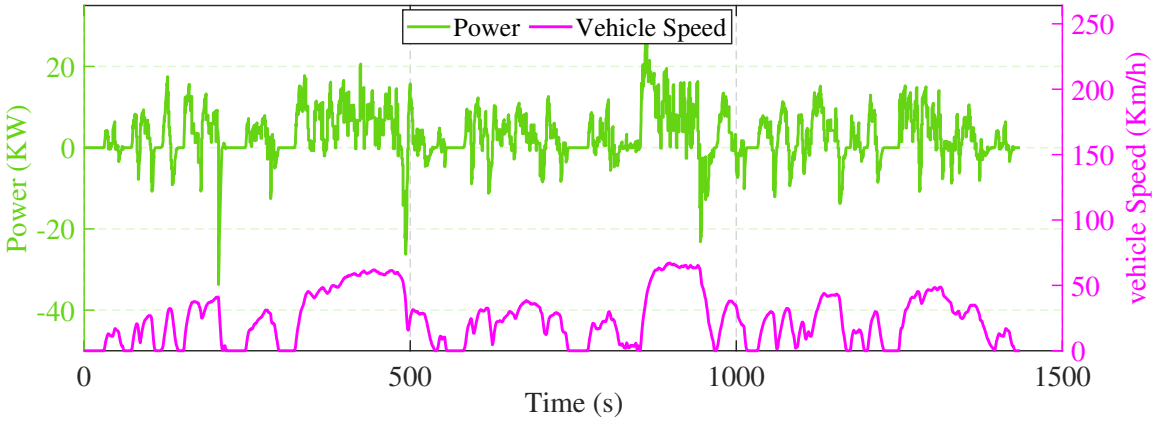


Figure 5.3: Courbes de vitesse et de puissance sous le cycles de conduite LA92

5.4.2 Performances d'apprentissage

La récompense moyenne est précieuse car elle offre une mesure plus stable de la progression d'apprentissage de l'agent par rapport aux récompenses individuelles par épisode. Cette métrique lisse les fluctuations inhérentes et le bruit dans le signal de récompense, offrant un aperçu plus clair des tendances de performance de l'algorithme et des schémas de convergence. L'implémentation de l'algorithme SAC-EMS, introduit dans cette thèse, a été réalisée sur une plateforme informatique, et sa performance d'apprentissage pour 260 épisodes est visualisée dans la Figure 5.4, présentant à la fois les récompenses par épisode et leurs moyennes.

L'entraînement initial de l'algorithme SAC-EMS montre des fluctuations notables dans la récompense cumulative, traduisant sa phase exploratoire. L'algorithme s'adapte à l'environnement en testant diverses actions, accumulant des expériences dans la mémoire de rejeu par sélection aléatoire d'actions, entraînant des oscillations significatives de la courbe d'entraînement. Environ au 50e épisode, un passage à des motifs de récompense plus réguliers reflètent une transition vers des politiques plus optimales et une exploration réduite. Cela s'accompagne d'ajustements appropriés aux poids du réseau de neurones. Avec un raffinement continu, la récompense cumulative converge vers environ 7×10^5, signalant une stratégie de planification optimale. Dans l'ensemble, cette trajectoire d'apprentissage souligne l'amélioration progressive de l'algorithme SAC-EMS et son aptitude à maximiser rapidement les récompenses dans le cadre du domaine problématique étudié.

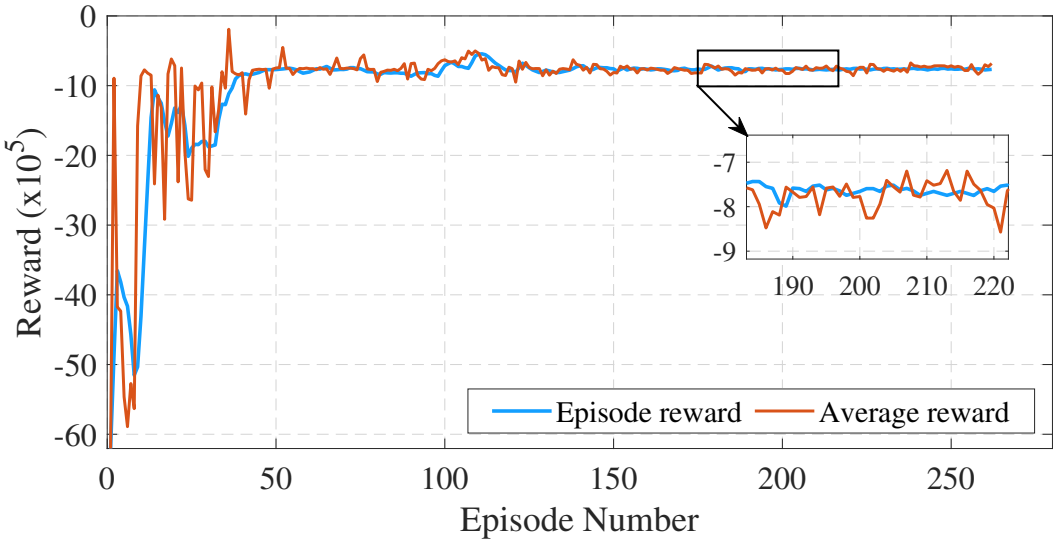


Figure 5.4: Récompenses moyennes et par épisode dans le processus d'entraînement de l'EMS basé sur SAC

5.4.3 Validation des performances

Les performances du SAC-EMS entraîné sont évaluées à travers des scénarios de conduite de test, qui impliquent l'examen de l'efficacité de l'allocation de puissance, de la puissance de la batterie et du SC, de consommation d'électricité et des trajectoires de SOC.

Pour reproduire un scénario réaliste, il est nécessaire de tenir compte de la consommation d'énergie au-delà de ce qui est requis pour la conduite (indiqué dans la figure 5.3). Pour ce faire, une charge d'énergie supplémentaire est introduite. Plus précisément, pour le cycle de conduite LA92, cette charge supplémentaire est intégrée

de la manière suivante: initialement, une charge de 1 kW est ajoutée. Ensuite, à t = 600 s, cette charge augmente à 5 kW pendant une période de 100 secondes avant de diminuer ensuite à 2,5 kW. Les résultats concernant la distribution d'énergie entre la SC et la batterie, ainsi que la variation du SOC sous le cycle de conduite LA92, sont illustrés respectivement dans les Figures 5.5, 5.6, et 5.7.

Les résultats montrent que le SAC-EMS réduit significativement la demande de puissance de la batterie, notamment pendant les pics de puissance, tandis que la technique RB augmente la demande de puissance sur la batterie. En conséquence, le SAC-EMS préserve la batterie en évitant de la soumettre à une demande élevé de puissance, favorisant ainsi sa durée de vie et réduisant la fréquence des cycles de charge et de décharge. De plus, le système alloue efficacement la puissance régénérative pour charger le SC et fournit la puissance nécessaire pendant les pics de puissance, ce qui réduit la charge sur la batterie. En revanche, la technique RB fournit rarement de lénergie pendant la conduite, ce qui sollicite la batterie et augmente la consommation électrique.

Les figures soulignent également les avantages de l'utilisation d'un HESS géré par l'algorithme SAC proposé par rapport à une configuration utilisant uniquement une batterie. Dans ce dernier cas, la batterie est soumise à une forte demande de puissance, ce qui illustre davantage l'efficacité de la configuration HESS.

Les observations susmentionnées sont davantage mises en évidence lors de l'examen de la trajectoire de variation du SOC, telle que représentée dans la Figure 5.7. Dans la Figure 5.7(b), la technique RB se concentre principalement sur la charge du SC pour atteindre la valeur de référence, sans fournir d'assistance à la batterie. En revanche, l'EMS basée sur SAC distribue de l'énergie pour charger le SC et fournit une assistance à la batterie, ce qui est particulièrement notable à t=600s lorsqu'une puissance supplémentaire de 5 kW est insérée. De plus, comme illustré dans la Figure 5.7(a), la variation du SOC de la batterie est légère, ce qui souligne l'efficacité de l'EMS basée sur SAC en matière d'allocation de puissance par rapport à la diminution significative du SOC de la batterie observée lors de l'utilisation de la technique RB et du scénario avec uniquement la batterie.

Une synthèse des résultats comparatifs est présentée dans le Tableau 5.1, comprenant la consommation d'électricité ainsi que les valeurs numériques du SOC final pour la batterie et le SC. Les résultats indiquent que l'EMS basée sur SAC parvient à réduire de manière significative la consommation d'électricité, atteignant une baisse de 47,87% par rapport à la configuration utilisant uniquement la batterie. De plus,

cette méthode réduit la demande énergétique de la batterie, surpassant ainsi les performances de la technique RB et de la configuration avec uniquement la batterie.

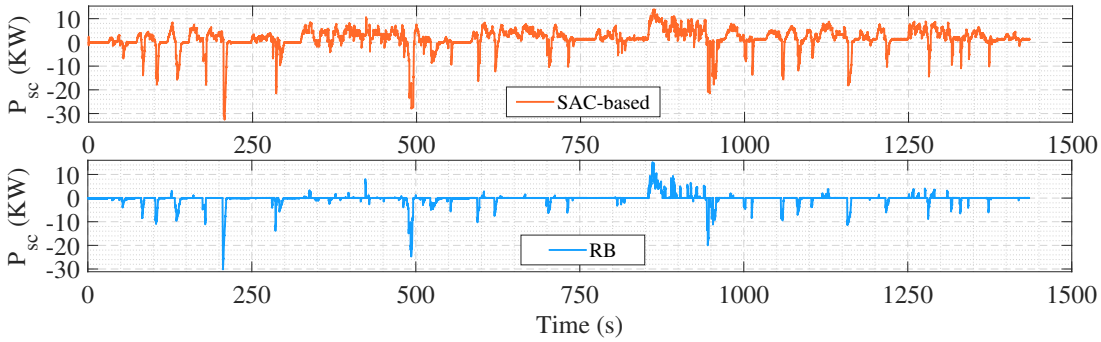


Figure 5.5: Puissance de sortie du SC sous le cycle de conduite LA92

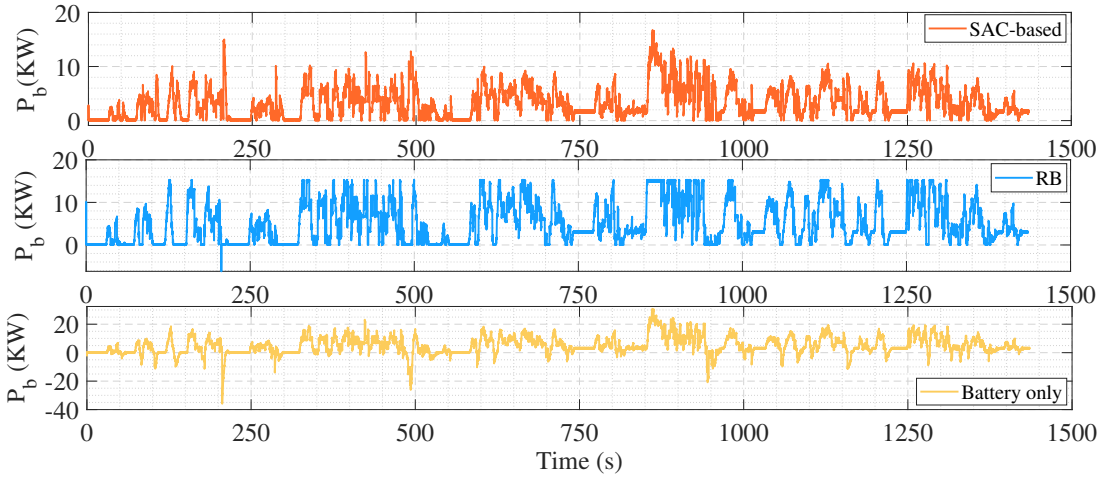


Figure 5.6: Puissance de sortie de la batterie sous le cycle de conduite LA92

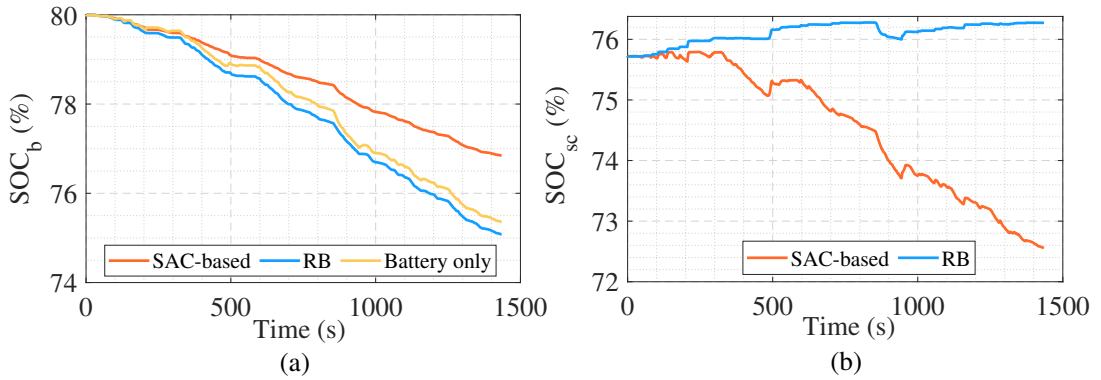


Figure 5.7: Trajectoire de variation du SOC de la batterie et du SC sous LA92

En résumé, l'approche proposée se distingue nettement de la méthode RB en offrant une gestion efficace de l'énergie, en réduisant la fréquence des cycles de charge/décharge

de la batterie, en exploitant de manière efficiente la puissance régénérative et en abaissant considérablement la consommation électrique, ce qui se traduit indirectement par une diminution des pertes énergétiques. Par ailleurs, la configuration HESS utilisée démontre sa viabilité par rapport à la configuration traditionnelle qui dépend exclusivement d'un pack de batteries.

Table 5.1: Résultats de comparaison des performances de la configuration basée sur SAC, sur batterie uniquement et RB

cycle de conduite	Méthode	Final SOC_b	Final SOC_{sc}	Cons. d'elect. (MAD)
LA92	SAC-based	76.8474%	72.5561%	1.0426
	RB	75.0789%	76.2725%	2.0000
	Battery only	75.3583%		2.0000

5.5 Conclusion

Ce chapitre conclut notre quête d'amélioration de l'autonomie, de la durabilité et de la sécurité des EVs. Il présente une stratégie avancée de RL basée sur l'algorithme SAC, spécialement conçue pour optimiser la distribution d'énergie dans un HESS. L'intégration d'un SC aux côtés de la batterie principale permet de répondre aux demandes d'énergie soudaines et de capturer efficacement l'énergie de freinage régénérative. L'analyse des resultats d'evaluation du SAC-EMS montre des performance signficative, en réduisant la fréquence de charge et de décharge de la batterie et en économisant de l'électricité par rapport à la technique RB. L'utilisation d'une configuration HESS se révèle donc plus efficace qu'un simple pack de batteries, illustrant la faisabilité et les avantages de cette approche pour l'amélioration des performances des EVs.

Conclusion générale et travaux futurs

À l'ère actuelle, le monde entier adoptent rapidement des sources d'énergie respectueuses de l'environnement et des systèmes de transport plus propres pour réduire leur dépendance aux combustibles fossiles et lutter contre les émissions. Cette transition a vu l'émergence de véhicules électriques respectueux de l'environnement, en particulier les BEVs, qui dépendent de batteries et de moteurs électriques pour un fonctionnement sans émissions. Assurer des batteries performantes et leur surveillance en temps réel est essentiel en raison de leur coût élevé et de leur rôle crucial. C'est la raison pour laquelle cette thèse accorde une grande importance à l'examen de la technologie des batteries Li-ion, en mettant particulièrement l'accent sur l'estimation de ses états essentiels. En outre, cette thèse aborde également divers autres composants de la chaîne de traction.

Le premier objectif était de fournir un aperçu des EVs, en mettant particulièrement l'accent sur les composants critiques du groupe motopropulseur. Nous avons présenté les types de EVs disponibles sur le marché, ainsi qu'une description détaillée du principal composant de chaque partie du groupe motopropulseur, y compris le ESS, le PES et le moteur de traction. De plus, ces trois parties sont généralement accompagnées d'algorithmes et de stratégies de contrôle pour surveiller leur fonctionnement sûr et fiable, tels que le BMS, le EMS et le régulateur de vitesse du moteur de traction. Étant donné le rôle potentiellement crucial des batteries Li-ion dans les EVs, nous avons également exploré en détail leur principe de fonctionnement, les méthodes de modélisation et les approches d'estimation de leur SOC et SOH.

Afin d'améliorer l'estimation précise du SOC de la batterie Li-ion, un effort initial a exploré une gamme de techniques d'estimation du SOC, allant des méthodes basées sur des modèles (EKF et AGSMO), des méthodes de ML (FFNN), et des approches de DL dans lesquelles des algorithmes 1D CNN et GRU ont été conçus. Pour remédier au manque d'investigation pratique et d'analyse de faisabilité de l'estimation du SOC avec des MCUs, cette thèse a soumis l'EKF, l'AGSMO et le FFNN à des tests PIL en utilisant une carte de développement STM32F429. Au cours de cette évaluation, l'AGSMO a démontré une précision supérieure, tandis que l'EKF et le FFNN ont montré des taux de convergence plus rapides.

Par la suite, afin de réduire la dépendance aux modèles de batterie et de tirer parti

d'algorithmes avancés, des réseaux 1D CNN et GRU ont été développés et évalués, révélant la supériorité du 1D CNN sur le GRU. Néanmoins, les exigences computationnelles de ces algorithmes entravent la faisabilité de leur intégration dans les MCU dotés de ressources limitées. Pour y remédier, la thèse a introduit une contribution novatrice dans ce contexte. Initialement, les modèles proposés ont été convertis d'une précision en virgule flottante de 32 bits en un code C optimisé et évalués sur une carte de développement STM32F429, confirmant une conversion réussie avec une légère dégradation des performances. Pour adapter davantage le modèle aux MCUs à ressources limitées, le modèle 1D CNN a subi une quantification, entraînant une légère réduction de la précision mais des exigences computationnelles considérablement réduites. De plus, une comparaison entre STM32Cube.AI et TFLite Micro a révélé la supériorité de la première en termes d'efficacité en matière de RAM et de taille de mémoire Flash. Plus précisément, STM32Cube.AI a montré une réduction significative de la consommation de mémoire Flash par un facteur de quatre, une réduction de plus de 50% de mémoire RAM et une diminution du temps moyen d'inférence.

La prédiction du SOC est cruciale pour éviter l'épuisement de la batterie et la surcharge, mais surveiller le SOH est tout aussi essentiel pour détecter la dégradation de la batterie et faciliter un remplacement opportun avant d'atteindre le stade d'EOL. Pour aborder ces aspects critiques, nous avons introduit une approche DL innovante (CNN-BiGRU) présentant une architecture hybride composée de 1D CNN et de Bi-GRU. Ce modèle hybride utilise directement les mesures de courant, de tension et de température disponibles à partir des capteurs du BMS. Nous avons entraîné et évalué le modèle à l'aide d'un ensemble de données de la NASA, en tenant compte de diverses conditions de décharge. Pour l'ajustement des hyperparamètres, nous avons utilisé l'algorithme d'OB, aboutissant à une combinaison optimale d'hyperparamètres en seulement 19 itérations. L'évaluation du modèle pré-entraîné a donné des résultats prometteurs, démontrant sa précision et sa fiabilité dans l'estimation du SOH, applicable tant aux batteries neuves qu'à celles déjà utilisées. De plus, le CNN-BiGRU a montré la capacité de prédire avec succès l'indicateur d'EOL, soulignant sa précision et sa fiabilité dans l'évaluation de la santé de la batterie.

Par la suite, cette thèse s'est plongée dans le domaine du contrôle de PES et de PMSM, qui jouent un rôle central dans la chaîne de traction. L'objectif principal, dans ce contexte, était de gérer efficacement le flux d'énergie, de garantir un fonctionnement sûr des composants du véhicule et d'atteindre un contrôle fiable de la vitesse. Pour atteindre cet objectif, deux contrôleurs DISMC ont été développés pour réguler l'échange d'énergie dans un convertisseur IBDAB, reliant le pack de bat-

terie et le PMSM. Le premier DISMC a réussi à suivre avec précision le courant de charge MSCC, tandis que le second a maintenu une tension de bus DC stable lors d'un scénario de conduite complexe. De plus, pour obtenir un contrôle efficace de la vitesse du PMSM, une nouvelle stratégie de contrôle hybride a été introduite. Des évaluations rigoureuses ont été réalisées dans diverses conditions, démontrant la précision supérieure et la robustesse du schéma de contrôle NTSMC-RBF par rapport à d'autres méthodes de contrôle telles que le SMC, l'IBC et le PI. Par conséquent, les schémas de contrôle proposés offrent des capacités améliorées en matière de géstion du transfert de puissance et garantissent simultanément un contrôle précis de la vitesse du PMSM.

Dans notre quête d'améliorer l'autonomie, la durabilité et les normes de sécurité des EVs, nous avons introduit une approche avancée de RL basée sur l'algorithme SAC pour optimiser la distribution d'énergie au sein d'un HESS. Ce HESS associe un SC au pack de batterie principal pour gérer efficacement les demandes soudaines de puissance et récupérer l'énergie de freinage régénératif. Tout au long du processus de formation du SAC-EMS développé, notre analyse a constamment révélé un schéma d'amélioration continue. Cela souligne la capacité de l'algorithme à maximiser rapidement les récompenses cumulatives et à affiner sa politique de prise de décision. Les évaluations ultérieures menées sur différents cycles de conduite mettent davantage en évidence l'efficacité du SAC-EMS formé. Notamment, le système excelle dans l'optimisation de l'allocation de puissance, réduisant ainsi la fréquence des cycles de charge et de décharge de la batterie. Cela contribue considérablement à prolonger la durée de vie de la batterie, ce qui est en ligne avec notre objectif d'améliorer les performances globales et la durabilité des EVs.

Travaux futurs

Dans le cadre de notre recherche sur le groupe motopropulseur des EVs et leurs systèmes de gestion de l'énergie et de la batterie, nous avons entrepris un examen approfondi de nombreux aspects cruciaux, mettant en avant l'efficacité de la mise en uvre d'algorithmes d'intelligence artificielle dans cette thèse. Afin de poser les bases pour de futurs progrès, plusieurs pistes prometteuses de recherche émergent. Dans nos futures initiatives, nous prévoyons d'aborder les points clés suivants :

❶ Notre recherche sur l'estimation du SOC s'est principalement concentrée sur des cellules de batterie individuelles. Cependant, il est essentiel de tenir compte du fait que les EVs utilisent des packs de batteries composés de milliers de cellules.

Ainsi, une extension potentielle de cette thèse pourrait consister à adapter nos stratégies d'estimation du SOC aux packs de batteries, en fonction des données publiques disponibles. De plus, il est important de noter que le déséquilibre du SOC entre les cellules de ces packs/modules peut affecter l'estimation du SOC pour l'ensemble du pack. Pour relever ce défi, nos futures recherches envisagent d'introduire une stratégie d'équilibrage visant à maintenir des niveaux de SOC cohérents des cellules du pack de batterie, avec pour objectif d'améliorer la précision globale de l'estimation du SOC pour les batteries des EVs.

❷ Tirant parti de notre succès dans le développement d'un algorithme de DL pour l'estimation du SOH, nous explorons des moyens d'incorporer cet algorithme avec l'estimation du SOC. Cette démarche découle du fait que l'estimation du SOC peut être significativement affectée par le vieillissement de la batterie. Par conséquent, notre objectif est d'améliorer la précision de l'estimation du SOC en prenant en compte les données relatives au SOH.

❸ Dans le chapitre 2, nous nous sommes concentrés sur la transformation de modèles de DL en versions quantifiées spécialement conçues pour simplifier leur déploiement sur des MCUs aux ressources computationnelles limitées. À l'avenir, nous prévoyons d'étendre cet effort de conversion à notre modèle proposé pour l'estimation SOH. Cela sera possible une fois que la faisabilité de la quantification des réseaux de neurones récurrents sera établie.

❹ Concernant le contrôle de la vitesse du moteur PMSM, notre stratégie actuelle repose sur des capteurs coûteux pour la mesure de la vitesse. Ces capteurs augmentent non seulement les coûts du système, mais introduisent également des défis en termes de stabilité. Nos futures recherches impliqueront l'intégration de méthodes d'estimation de vitesse ou de position plus économiques, telles que les observateurs de la réactance de flux et l'EKF, dans le contrôleur NTSMC-RBF.

❺ Dans nos efforts de développement de l'EMS, nous avons introduit une stratégie avancée de RL basée sur l'algorithme SAC. Des efforts continus sont consacrés à l'amélioration et au renforcement de la fiabilité de cette stratégie en prenant en compte divers facteurs qui influencent le système. Ces facteurs englobent des aspects tels que le vieillissement de la batterie et les pertes d'énergie dans le HESS et les convertisseurs. De plus, nous nous préparons à une analyse comparative approfondie pour évaluer l'efficacité de notre algorithme RL par rapport aux techniques d'optimisation et aux autres approches de RL.

BIBLIOGRAPHY

[1] Peter Rafaj, Gregor Kiesewetter, Timur Gül, Wolfgang Schöpp, Janusz Cofala, Zbigniew Klimont, Pallav Purohit, Chris Heyes, Markus Amann, Jens Borken-Kleefeld, et al. Outlook for clean air in the context of sustainable development goals. *Global Environmental Change*, 53:1–11, 2018.

[2] I López, E Ibarra, A Matallana, J Andreu, and I Kortabarria. Next generation electric drives for hev/ev propulsion systems: Technology, trends and challenges. *Renewable and Sustainable Energy Reviews*, 114:109336, 2019.

[3] Graeme Hill, Oliver Heidrich, Felix Creutzig, and Phil Blythe. The role of electric vehicles in near-term mitigation pathways and achieving the uks carbon budget. *Applied Energy*, 251:113111, 2019.

[4] Electric Vehicles Initiative Global EV Outlook 2022 Analysis.

[5] Jihane Rahhou-Morocco World News. Morocco to Scale Up Electric Car Production Over Next Two Years.

[6] Salman Zafar |. Morocco Aims To Double Electric Vehicle Production In Two Years, September 2022.

[7] Richard Schmuch, Ralf Wagner, Gerhard Hörpel, Tobias Placke, and Martin Winter. Performance and cost of materials for lithium-based rechargeable automotive batteries. *Nature energy*, 3(4):267–278, 2018.

[8] A Boukhlouf, MY Hammoudi, R Saadi, and MEH Benbouzid. Hardware-in-the-loop implementation of an unknown input observer for synchronous reluctance motor. *ISA transactions*, 133:485–494, 2023.

[9] Fahimeh Shiravani, Patxi Alkorta, Jose Antonio Cortajarena, and Oscar Barambones. An improved predictive current control for im drives. *Ain Shams Engineering Journal*, 14(8):102037, 2023.

[10] Fahad Al-Amyal, László Számel, and Mahmoud Hamouda. An enhanced direct instantaneous torque control of switched reluctance motor drives using ant colony optimization. *Ain Shams Engineering Journal*, 14(5):101967, 2023.

[11] Guodong Feng, Chunyan Lai, K Lakshmi V Iyer, and Narayan C Kar. Improved high-frequency voltage injection based permanent magnet temperature estimation for pmsm condition monitoring for ev applications. *IEEE Transactions on Vehicular Technology*, 67(1):216–225, 2017.

[12] Yunjun Zheng, Han Zhao, Shengchao Zhen, and Hao Sun. Fuzzy-set theory based optimal robust constraint-following control for permanent magnet synchronous motor with uncertainties. *Control Engineering Practice*, 115:104911, 2021.

[13] Rejaul Islam, SM Sajjad Hossain Rafin, and Osama A Mohammed. Comprehensive review of power electronic converters in electric vehicle applications. *Forecasting*, 5(1):22–80, 2022.

[14] Aishwarya Apte, Vrunda A Joshi, Hrishikesh Mehta, and Rahee Walambe. Disturbance-observer-based sensorless control of pmsm using integral state feedback controller. *IEEE Transactions on Power Electronics*, 35(6):6082–6090, 2019.

[15] Yuchen Dai, Shuangfei Ni, Dezhi Xu, Liyan Zhang, and Xing-Gang Yan. Disturbance-observer based prescribed-performance fuzzy sliding mode control for pmsm in electric vehicles. *Engineering Applications of Artificial Intelligence*, 104:104361, 2021.

[16] Reza Hemmati and Hedayat Saboori. Emergence of hybrid energy storage systems in renewable energy and transport applications–a review. *Renewable and Sustainable Energy Reviews*, 65:11–23, 2016.

[17] Rayavarapu Srinivasa Sankarkumar and Rajasekar Natarajan. Energy management techniques and topologies suitable for hybrid energy storage system powered electric vehicles: An overview. *International Transactions on Electrical Energy Systems*, 31(4):e12819, 2021.

[18] Ephrem Chemali, Matthias Preindl, Pawel Malysz, and Ali Emadi. Electrochemical and electrostatic energy storage and management systems for electric drive vehicles: State-of-the-art review and future trends. *IEEE Journal of Emerging and Selected Topics in Power Electronics*, 4(3):1117–1134, 2016.

[19] Xiuliang Zhao, Lei Wang, Yinglong Zhou, Bangxiong Pan, Ruochen Wang, Limei Wang, and Xueqing Yan. Energy management strategies for fuel cell hybrid electric vehicles: Classification, comparison, and outlook. *Energy Conversion and Management*, 270:116179, 2022.

[20] Thanikanti Sudhakar Babu, Krishnakumar R Vasudevan, Vigna K Ramachandaramurthy, Suleiman Bala Sani, Sansubari Chemud, and Rosli Mat Lajim. A comprehensive review of hybrid energy storage systems: Converter topologies, control strategies and future prospects. *IEEE Access*, 8:148702–148721, 2020.

[21] Nico Goetzel and M Hasanuzzaman. An empirical analysis of electric vehicle cost trends: A case study in germany. *Research in Transportation Business & Management*, 43:100825, 2022.

[22] Shao-Chao Ma, Jin-Hua Xu, and Ying Fan. Characteristics and key trends of global electric vehicle technology development: A multi-method patent analysis. *Journal of Cleaner Production*, 338:130502, 2022.

[23] Yui-Yip Lau, Andrew Yang Wu, and Mak Wing Yan. A way forward for electric vehicle in greater bay area: Challenges and opportunities for the 21st century. *Vehicles*, 4(2):420–432, 2022.

[24] Dai-Duong Tran, Majid Vafaeipour, Mohamed El Baghdadi, Ricardo Barrero, Joeri Van Mierlo, and Omar Hegazy. Thorough state-of-the-art analysis of electric and hybrid vehicle powertrains: Topologies and integrated energy management strategies. *Renewable and Sustainable Energy Reviews*, 119:109596, 2020.

[25] Cong Thanh Nguyen, Paul D Walker, Shilei Zhou, and Nong Zhang. Optimal sizing and energy management of an electric vehicle powertrain equipped with two motors and multi-gear ratios. *Mechanism and Machine Theory*, 167:104513, 2022.

[26] Jiaming Zhou, Chunxiao Feng, Qingqing Su, Shangfeng Jiang, Zhixian Fan, Jiageng Ruan, Shikai Sun, and Leli Hu. The multi-objective optimization of powertrain design and energy management strategy for fuel cell–battery electric vehicle. *Sustainability*, 14(10):6320, 2022.

[27] Krishna Veer Singh, Hari Om Bansal, and Dheerendra Singh. A comprehensive review on hybrid electric vehicles: architectures and components. *Journal of Modern Transportation*, 27:77–107, 2019.

[28] Abhisek Karki, Sudip Phuyal, Daniel Tuladhar, Subarna Basnet, and Bim Prasad Shrestha. Status of pure electric vehicle power train technology and future prospects. *Applied System Innovation*, 3(3):35, 2020.

[29] Hicham El Hadraoui, Mourad Zegrari, Ahmed Chebak, Oussama Laayati, and Nasr Guennouni. A multi-criteria analysis and trends of electric motors for electric vehicles. *World Electric Vehicle Journal*, 13(4):65, 2022.

[30] Mustafa İnci, Mehmet Büyük, Mehmet Hakan Demir, and Göktürk İlbey. A review and research on fuel cell electric vehicles: Topologies, power electronic converters, energy management methods, technical challenges, marketing and future aspects. *Renewable and Sustainable Energy Reviews*, 137:110648, 2021.

[31] P Ramesh, M Umavathi, C Bharatiraja, G Ramanathan, and Sivaprasad Athikkal. Development of a pmsm motor field-oriented control algorithm for electrical vehicles. *Materials Today: Proceedings*, 65:176–187, 2022.

[32] Zhichao Zhu, Fei Xiao, Zhaojie Huang, Jilong Liu, Peng Chen, and Qiang Ren. Bidirectional power control strategy for super capacitor energy storage system based on mmc dc-dc converter. *IEEE Access*, 10:53225–53233, 2022.

[33] Hoai-An Trinh, Duc Giap Nguyen, Van-Du Phan, Tan-Quoc Duong, Hoai-Vu-Anh Truong, Sung-Jin Choi, and Kyoung Kwan Ahn. Robust adaptive control strategy for a bidirectional dc-dc converter based on extremum seeking and sliding mode control. *Sensors*, 23(1):457, 2023.

[34] S Vijayakumar and N Sudhakar. A review on unidirectional converters for on-board chargers in electric vehicle. *Frontiers in Energy Research*, 10:1011681, 2022.

[35] Yavuz Koç, Yaşar Birbir, and Hacı Bodur. Non-isolated high step-up dc/dc converters–an overview. *Alexandria Engineering Journal*, 61(2):1091–1132, 2022.

[36] Khairy Sayed, Abdulaziz Almutairi, Naif Albagami, Omar Alrumayh, Ahmed G Abo-Khalil, and Hedra Saleeb. A review of dc-ac converters for electric vehicle applications. *Energies*, 15(3):1241, 2022.

[37] Choton K Das, Octavian Bass, Ganesh Kothapalli, Thair S Mahmoud, and Daryoush Habibi. Overview of energy storage systems in distribution networks: Placement, sizing, operation, and power quality. *Renewable and Sustainable Energy Reviews*, 91:1205–1230, 2018.

[38] Muhammad Bin Fayyaz Ahsan, Saad Mekhilef, Tey Kok Soon, Marizan Binti Mubin, Prashant Shrivastava, and Mehdi Seyedmahmoudian. Lithium-ion battery and supercapacitor-based hybrid energy storage system for electric vehicle applications: A review. *International Journal of Energy Research*, 46(14):19826–19854, 2022.

[39] E Maximiliano Asensio, Guillermo A Magallán, Laura Pérez, and Cristian H De Angelo. Short-term power demand prediction for energy management of an electric vehicle based on batteries and ultracapacitors. *Energy*, 247:123430, 2022.

[40] K Kumar, Ramji Tiwari, P Venkata Varaprasad, Challa Babu, and K Jyotheeswara Reddy. Performance evaluation of fuel cell fed electric vehicle system with reconfigured quadratic boost converter. *International Journal of Hydrogen Energy*, 46(11):8167–8178, 2021.

[41] Hossam A Gabbar, Ahmed M Othman, and Muhammad R Abdussami. Review of battery management systems (bms) development and industrial standards. *Technologies*, 9(2):28, 2021.

[42] Yuanxin Bao and Le Ye. A power-efficient acquisition front end for the li-ion battery management systems. *Microelectronics Journal*, 129:105598, 2022.

[43] Arindam Dutta, Shirsendu Mitra, Mitali Basak, and Tamal Banerjee. A comprehensive review on batteries and supercapacitors: development and challenges since their inception. *Energy Storage*, 5(1):e339, 2023.

[44] Mogalahalli V Reddy, Alain Mauger, Christian M Julien, Andrea Paolella, and Karim Zaghib. Brief history of early lithium-battery development. *Materials*, 13(8):1884, 2020.

[45] Saifullah Mahmud, Mostafizur Rahman, Md Kamruzzaman, Md Osman Ali, Md Shariful Alam Emon, Hazera Khatun, and Md Ramjan Ali. Recent advances in lithium-ion battery materials for improved electrochemical performance: A review. *Results in Engineering*, 15:100472, 2022.

[46] MFR Zwicker, Maede Moghadam, Wenqi Zhang, and CV Nielsen. Automotive battery pack manufacturing–a review of battery to tab joining. *Journal of Advanced Joining Processes*, 1:100017, 2020.

[47] Suyash Vikram, Sagar Vashisht, and Dibakar Rakshit. Performance analysis of liquid-based battery thermal management system for electric vehicles during discharge under drive cycles. *Journal of Energy Storage*, 55:105737, 2022.

[48] Jinhao Meng, Guangzhao Luo, Mattia Ricco, Maciej Swierczynski, Daniel-Ioan Stroe, and Remus Teodorescu. Overview of lithium-ion battery modeling methods for state-of-charge estimation in electrical vehicles. *Applied sciences*, 8(5):659, 2018.

[49] Qian Wang, Bin Jiang, Bo Li, and Yuying Yan. A critical review of thermal management models and solutions of lithium-ion batteries for the development of pure electric vehicles. *Renewable and Sustainable Energy Reviews*, 64:106–128, 2016.

[50] Changlong Li, Naxin Cui, Chunyu Wang, and Chenghui Zhang. Simplified electrochemical lithium-ion battery model with variable solid-phase diffusion and parameter identification over wide temperature range. *Journal of Power Sources*, 497:229900, 2021.

[51] Scott J Moura, Nalin A Chaturvedi, and Miroslav Krstić. Adaptive partial differential equation observer for battery state-of-charge/state-of-health estimation via an electrochemical model. *Journal of Dynamic Systems, Measurement, and Control*, 136(1):011015, 2014.

[52] Hanqing Yu, Junfu Li, Yukun Ji, and Michael Pecht. Life-cycle parameter identification method of an electrochemical model for lithium-ion battery pack. *Journal of Energy Storage*, 47:103591, 2022.

[53] Kailong Liu, Yizhao Gao, Chong Zhu, Kang Li, Minrui Fei, Chen Peng, Xi Zhang, and Qing-Long Han. Electrochemical modeling and parameterization towards control-oriented management of lithium-ion batteries. *Control Engineering Practice*, 124:105176, 2022.

[54] Manh-Kien Tran, Anosh Mevawalla, Attar Aziz, Satyam Panchal, Yi Xie, and Michael Fowler. A review of lithium-ion battery thermal runaway modeling and diagnosis approaches. *Processes*, 10(6):1192, 2022.

[55] Chunyu Wang, Changlong Li, Guangfeng Wang, Chenghui Zhang, and Naxin Cui. Fast identification method for thermal model parameters of lithium-ion battery based on discharge temperature rise. *Journal of Energy Storage*, 44:103362, 2021.

[56] Ming Shen and Qing Gao. A review on battery management system from the modeling efforts to its multiapplication and integration. *International Journal of Energy Research*, 43(10):5042–5075, 2019.

[57] Joris Jaguemont, Alexandros Nikolian, Noshin Omar, Shovon Goutam, Joeri Van Mierlo, and Peter Van den Bossche. Development of a two-dimensional-thermal model of three battery chemistries. *IEEE Transactions on Energy Conversion*, 32(4):1447–1455, 2017.

[58] Wenjiong Cao, Chunrong Zhao, Yiwei Wang, Ti Dong, and Fangming Jiang. Thermal modeling of full-size-scale cylindrical battery pack cooled by channeled liquid flow. *International journal of heat and mass transfer*, 138:1178–1187, 2019.

[59] Xingxing Wang, Peilin Ye, Shengren Liu, Yu Zhu, Yelin Deng, Yinnan Yuan, and Hongjun Ni. Research progress of battery life prediction methods based on physical model. *Energies*, 16(9):3858, 2023.

[60] Congzhi Liu, Weiqun Liu, Lingyan Wang, Guangdi Hu, Luping Ma, and Bingyu Ren. A new method of modeling and state of charge estimation of the battery. *Journal of Power sources*, 320:1–12, 2016.

[61] Zhenhua Cui, Jiyong Dai, Jianrui Sun, Dezhi Li, Licheng Wang, and Kai Wang. Hybrid methods using neural network and kalman filter for the state of charge estimation of lithium-ion battery. *Mathematical Problems in Engineering*, 2022:1–11, 2022.

[62] Jianfeng Wang, Yongkai Jia, Na Yang, Yanbing Lu, Mengyu Shi, Xutong Ren, and Dongchen Lu. Precise equivalent circuit model for li-ion battery by experimental improvement and parameter optimization. *Journal of Energy Storage*, 52:104980, 2022.

[63] Massimiliano Luzi, Maurizio Paschero, Antonello Rizzi, Enrico Maiorino, and Fabio Massimo Frattale Mascioli. A novel neural networks ensemble approach for modeling electrochemical cells. *IEEE Transactions on Neural Networks and Learning Systems*, 30(2):343–354, 2018.

[64] M Lucu, E Martinez-Laserna, I Gandiaga, Kailong Liu, Haritza Camblong, Widanalage Dhammika Widanage, and James Marco. Data-driven nonparametric li-ion battery ageing model aiming at learning from real operation data–part a: Storage operation. *Journal of Energy Storage*, 30:101409, 2020.

[65] Kong Soon Ng, Chin-Sien Moo, Yi-Ping Chen, and Yao-Ching Hsieh. Enhanced coulomb counting method for estimating state-of-charge and state-of-health of lithium-ion batteries. *Applied energy*, 86(9):1506–1511, 2009.

[66] Caiping Zhang, Jiuchun Jiang, Linjing Zhang, Sijia Liu, Leyi Wang, and Poh Chiang Loh. A generalized soc-ocv model for lithium-ion batteries and the soc estimation for lnmco battery. *Energies*, 9(11):900, 2016.

[67] Anton Klintberg, Changfu Zou, Björn Fridholm, and Torsten Wik. Kalman filter for adaptive learning of two-dimensional look-up tables applied to ocv-curves for aged battery cells. *Control Engineering Practice*, 84:230–237, 2019.

[68] Ping Li, Xiaohong Jiao, and Yang Li. Adaptive real-time energy management control strategy based on fuzzy inference system for plug-in hybrid electric vehicles. *Control Engineering Practice*, 107:104703, 2021.

[69] Xin Lai, Ming Yuan, Xiaopeng Tang, Yi Yao, Jiahui Weng, Furong Gao, Weiguo Ma, and Yuejiu Zheng. Co-estimation of state-of-charge and state-of-health for lithium-ion batteries considering temperature and ageing. *Energies*, 15(19):7416, 2022.

[70] Jingjin Wu, Chao Fang, Zhiyang Jin, Lina Zhang, and Jiejie Xing. A multi-scale fractional-order dual unscented kalman filter based parameter and state of charge joint estimation method of lithium-ion battery. *Journal of Energy Storage*, 50:104666, 2022.

[71] Yonghong Xu, Xia Chen, Hongguang Zhang, Fubin Yang, Liang Tong, Yifan Yang, Dong Yan, Anren Yang, Mingzhe Yu, Zhuxian Liu, et al. Online identification of battery model parameters and joint state of charge and state of health estimation using dual particle filter algorithms. *International Journal of Energy Research*, 46(14):19615–19652, 2022.

[72] Mohamed Ahwiadi and Wilson Wang. An enhanced particle filter technology for battery system state estimation and rul prediction. *Measurement*, 191:110817, 2022.

[73] Omid Rezaei, Hossein Azizi Moghaddam, and Behnaz Papari. A fast sliding-mode-based estimation of state-of-charge for lithium-ion batteries for electric vehicle applications. *Journal of Energy Storage*, 45:103484, 2022.

[74] Cheng Xu, E Zhang, Shuai Yan, Kai Jiang, Kangli Wang, Zhuo Wang, and Shijie Cheng. State of charge estimation for liquid metal battery based on an improved sliding mode observer. *Journal of Energy Storage*, 45:103701, 2022.

[75] Lan Li, Minghui Hu, Yidan Xu, Chunyun Fu, Guoqing Jin, and Zonghua Li. State of charge estimation for lithium-ion power battery based on h-infinity filter algorithm. *Applied Sciences*, 10(18):6371, 2020.

[76] Zhansheng Ning, Zhongwei Deng, Jinwen Li, Hongao Liu, and Wenchao Guo. Co-estimation of state of charge and state of health for 48 v battery system based on cubature kalman filter and h-infinity. *Journal of Energy Storage*, 56:106052, 2022.

[77] Yong Feng, Jian Duan, Chen Xue, and Fengling Han. State-of-charge and state-of-health estimation algorithms of lithium-ion batteries using smo. In *2021 IEEE 5th Conference on Energy Internet and Energy System Integration (EI2)*, pages 2104–2108. IEEE, 2021.

[78] Xiaolong Yang, Yongji Chen, Bin Li, and Dong Luo. Battery states online estimation based on exponential decay particle swarm optimization and proportional-integral observer with a hybrid battery model. *Energy*, 191:116509, 2020.

[79] Boying Liu, Haiyu Wang, Ming-Lang Tseng, and Zhongtao Li. State of charge estimation for lithium-ion batteries based on improved barnacle mating optimizer and support vector machine. *Journal of Energy Storage*, 55:105830, 2022.

[80] Xiaojun Tan, Di Zhan, Pengxiang Lyu, Jun Rao, and Yuqian Fan. Online state-of-health estimation of lithium-ion battery based on dynamic parameter identification at multi timescale and support vector regression. *Journal of Power Sources*, 484:229233, 2021.

[81] MS Hossain Lipu, MA Hannan, Aini Hussain, Shaheer Ansari, SA Rahman, Mohamad HM Saad, and KM Muttaqi. Real-time state of charge estimation of lithium-ion batteries using optimized random forest regression algorithm. *IEEE Transactions on Intelligent Vehicles*, 8(1):639–648, 2022.

[82] Kodjo SR Mawonou, Akram Eddahech, Didier Dumur, Dominique Beauvois, and Emmanuel Godoy. State-of-health estimators coupled to a random forest approach for lithium-ion battery aging factor ranking. *Journal of Power Sources*, 484:229154, 2021.

[83] Dongdong Ge, Zhendong Zhang, Xiangdong Kong, and Zhiping Wan. Extreme learning machine using bat optimization algorithm for estimating state of health of lithium-ion batteries. *Applied Sciences*, 12(3):1398, 2022.

[84] Guanyong Zhang, Bizhong Xia, Jiamin Wang, Bo Ye, Yunchao Chen, Zhuojun Yu, and Yuheng Li. Intelligent state of charge estimation of battery pack based on particle swarm optimization algorithm improved radical basis function neural network. *Journal of Energy Storage*, 50:104211, 2022.

[85] Sahar Khaleghi, Yousef Firouz, Joeri Van Mierlo, and Peter Van Den Bossche. Developing a real-time data-driven battery health diagnosis method, using time and frequency domain condition indicators. *Applied Energy*, 255:113813, 2019.

[86] Zhongwei Deng, Xiaosong Hu, Xianke Lin, Yunhong Che, Le Xu, and Wenchao Guo. Data-driven state of charge estimation for lithium-ion battery packs based on gaussian process regression. *Energy*, 205:118000, 2020.

[87] Jiaming Dou, Hongyan Ma, Yingda Zhang, Shuai Wang, Yongxue Ye, Shengyan Li, and Lujin Hu. Extreme learning machine model for state-of-charge estimation of lithium-ion battery using salp swarm algorithm. *Journal of Energy Storage*, 52:104996, 2022.

[88] Lin Chen, Huimin Wang, Bohao Liu, Yijue Wang, Yunhui Ding, and Haihong Pan. Battery state-of-health estimation based on a metabolic extreme learning machine combining degradation state model and error compensation. *Energy*, 215:119078, 2021.

[89] Wei Emma Zhang, Quan Z Sheng, Ahoud Alhazmi, and Chenliang Li. Adversarial attacks on deep-learning models in natural language processing: A survey. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 11(3):1–41, 2020.

[90] Lifeng Wu and Yu Zhang. Attention-based encoder-decoder networks for state of charge estimation of lithium-ion battery. *Energy*, 268:126665, 2023.

[91] Heran Shen, Xingyu Zhou, Zejiang Wang, and Junmin Wang. State of charge estimation for lithium-ion battery using transformer with immersion and invariance adaptive observer. *Journal of Energy Storage*, 45:103768, 2022.

[92] Hao Wu, Patrick Judd, Xiaojie Zhang, Mikhail Isaev, and Paulius Micikevicius. Integer quantization for deep learning inference: Principles and empirical evaluation. *arXiv preprint arXiv:2004.09602*, 2020.

[93] Margaret Slattery, Jessica Dunn, and Alissa Kendall. Transportation of electric vehicle lithium-ion batteries at end-of-life: A literature review. *Resources, Conservation and Recycling*, 174:105755, 2021.

[94] G Vennam, A Sahoo, and S Ahmed. A survey on lithium-ion battery internal and external degradation modeling and state of health estimation. *Journal of Energy Storage*, 52:104720, 2022.

[95] Zheming Tong, Jiazhi Miao, Shuiguang Tong, and Yingying Lu. Early prediction of remaining useful life for lithium-ion batteries based on a hybrid machine learning method. *Journal of Cleaner Production*, 317:128265, 2021.

[96] Giulia Crocioni, Danilo Pau, Jean-Michel Delorme, and Giambattista Gruosso. Li-ion batteries parameter estimation with tiny neural networks embedded on intelligent iot microcontrollers. *IEEE Access*, 8:122135–122146, 2020.

[97] Lei Ren, Jiabao Dong, Xiaokang Wang, Zihao Meng, Li Zhao, and M Jamal Deen. A data-driven auto-cnn-lstm prediction model for lithium-ion battery remaining useful life. *IEEE Transactions on Industrial Informatics*, 17(5):3478–3487, 2020.

[98] Yash Kotak, Carlos Marchante Fernández, Lluc Canals Casals, Bhavya Satishbhai Kotak, Daniel Koch, Christian Geisbauer, Lluís Trilla, Alberto Gómez-Núñez, and Hans-Georg Schweiger. End of electric vehicle batteries: Reuse vs. recycle. *Energies*, 14(8):2217, 2021.

[99] Abdul Basit Khan, Van-Long Pham, Thanh-Tung Nguyen, and Woojin Choi. Multistage constant-current charging method for li-ion batteries. In *2016 IEEE Transportation Electrification Conference and Expo, Asia-Pacific (ITEC Asia-Pacific)*, pages 381–385. IEEE, 2016.

[100] Thanh Tu Vo, Xiaopeng Chen, Weixiang Shen, and Ajay Kapoor. New charging strategy for lithium-ion batteries based on the integration of taguchi method and state of charge estimation. *Journal of Power Sources*, 273:413–422, 2015.

[101] Ngoc-Duc Nguyen, Changwoo Yoon, and Young Il Lee. A standalone energy management system of battery/supercapacitor hybrid energy storage system for electric vehicles using model predictive control. *IEEE Transactions on Industrial Electronics*, 70(5):5104–5114, 2022.

[102] Sambit Satpathy, Neeraj Kumar Misra, Dhirendra kumar Shukla, Vishal Goyal, Bidyut K Bhattacharyya, and Chandra Shekhar Yadav. An in-depth study of the electrical characterization of supercapacitors for recent trends in energy storage system. *Journal of Energy Storage*, 57:106198, 2023.

[103] Junyi Shen and Alireza Khaligh. A supervisory energy management control strategy in a battery/ultracapacitor hybrid energy storage system. *IEEE Transactions on transportation electrification*, 1(3):223–231, 2015.

[104] João Pedro Fernandes Trovão and Paulo José Gameiro Pereirinha. Control scheme for hybridised electric vehicles with an online power follower management strategy. *IET Electrical Systems in Transportation*, 5(1):12–23, 2015.

[105] Yujie Wang, Zhendong Sun, and Zonghai Chen. Energy management strategy for battery/supercapacitor/fuel cell hybrid source vehicles based on finite state machine. *Applied energy*, 254:113707, 2019.

[106] Masoud Dahmardeh, Pouria Rahimirad, Masoud Masih-Tehrani, et al. A modern simple power prediction index for improving battery life. *International Transactions on Electrical Energy Systems*, 2022, 2022.

[107] Tao Zeng, Caizhi Zhang, Yanyi Zhang, Chenghao Deng, Dong Hao, Zhongwen Zhu, Hongxu Ran, and Dongpu Cao. Optimization-oriented adaptive equivalent consumption minimization strategy based on short-term demand power prediction for fuel cell hybrid vehicle. *Energy*, 227:120305, 2021.

[108] Dehao Min, Zhen Song, Huicui Chen, Tianxiang Wang, and Tong Zhang. Genetic algorithm optimized neural network based fuel cell hybrid electric vehicle energy management strategy under start-stop condition. *Applied Energy*, 306:118036, 2022.

[109] Chunhua Zheng, Wei Li, Weimin Li, Kun Xu, Lei Peng, and Suk Won Cha. A deep reinforcement learning-based energy management strategy for fuel cell hybrid buses. *International Journal of Precision Engineering and Manufacturing-Green Technology*, 9(3):885–897, 2022.