



Estimation de la résistance et de l'état de santé d'une batterie en utilisant des techniques d'apprentissage automatique et un modèle de diffusion

par Fousseni Arafat

Mémoire présenté à l'Université du Québec à Chicoutimi en vue de l'obtention du grade de Maitre ès sciences appliquées (M. Sc. A.) en ingénierie

Jury :

Duygu Kocaefe, Ph.D, Professeure, Université du Québec à Chicoutimi, Présidente du Jury;
Martin Otis, ing., Ph.D, Professeur, Université du Québec à Chicoutimi, Directeur de recherche;
Dilip Sarkar, Ph.D, Professeur, Université du Québec à Chicoutimi, Évaluateur interne;
Mehdi Adda, Ph.D, Professeur, Université du Québec à Rimouski, Évaluateur externe.

Québec, Canada

© Arafat Fousseni, 2024

RÉSUMÉ

Les batteries sont le plus souvent utilisées pour le stockage de l'énergie afin d'assurer une consommation énergétique ultérieure, le soutien du réseau électrique ou encore la propulsion des véhicules électriques. Le projet de recherche proposé porte sur l'estimation de la résistance et de l'état de santé d'une batterie. Il est pertinent pour deux raisons fondamentales décrites ci-dessous. Premièrement, les systèmes de stockages d'énergie à batteries dans un micro-réseau permettent de fournir des services essentiels de fiabilité qui sont principalement le soutien de la fréquence, de la capacité de satisfaire à la demande et du maintien de la tension. Une estimation de la résistance et de l'état de santé des batteries du système de stockage permet d'anticiper d'éventuelles pannes et d'intervenir plus rapidement sur les systèmes. Récemment, l'estimation de la santé des batteries a été largement étudiée dans plusieurs travaux de recherche. Ces recherches sont souvent basées sur des données acquises à une température et un courant de décharge fixes, ce qui ne reflète pas les conditions de fonctionnement des batteries. Aussi, les études ne couvrent généralement pas les batteries dont les données de l'état de santé sont inférieures à 60%. Or, après la fin de la durée de vie de la batterie dans un véhicule électrique, elle peut être utilisée dans une application secondaire comme le stockage d'énergie. En effet, les approches basées sur les équations paramétriques et des techniques d'apprentissage automatique proposées dans ce mémoire pour estimer la résistance et l'état de santé d'une batterie prennent en considération la batterie sur toute sa durée de vie. La tension, le courant, l'état de charge et la température cumulée constituent les paramètres qui permettent de mieux estimer la résistance et l'état de santé de la batterie. De plus, ces approches proposées pourraient être utilisées pour estimer l'état de santé de la batterie dans des applications secondaires. L'utilisation des méthodes proposées dans ce mémoire pour estimer la résistance et l'état de santé permettra de faciliter indirectement le reconditionnement des batteries pour des applications en énergie renouvelable, de contribuer à la réduction des déchets des véhicules électriques et ainsi à la réduction de leurs emprunts sur l'environnement. Ceci constitue un second point pertinent de ce projet. Par ailleurs, la contribution majeure du projet réside dans l'utilisation d'un modèle de diffusion en phase solide pour l'estimation de l'état de santé de la batterie. Cette étude a également montré que les paramètres de ce modèle sont liés à la température ambiante par une fonction polynomiale de troisième degré.

ABSTRACT

Batteries are most often used for energy storage for subsequent energy consumption, grid support or electric vehicle traction. The proposed research project focuses on estimating battery resistance and its the state of health. It is relevant for two fundamental reasons, described below. Firstly, battery energy storage systems in a microgrid provide essential reliability services, mainly frequency support, demand response and voltage maintenance. Determining the state of health of the storage system's batteries enables possible failures to be anticipated and systems to be addressed more rapidly. Recently, battery health estimation has been widely studied in several research studies. This research is often based on data acquired at a fixed temperature and discharge current, which does not reflect battery operating conditions. Also, studies don't generally cover batteries with less than 60% health data. However, after the end of a battery's lifetime in an electric vehicle, it can be used in a secondary application such as energy storage. Indeed, the approaches based on parametric equations and machine learning techniques proposed in this thesis for estimating the resistance and state of health of a battery take into account the battery over its entire lifetime. Voltage, current, state-of-charge and cumulative temperature are the parameters that best estimate battery resistance and state-of-health. In addition, these proposed approaches could be used to estimate battery state of health in secondary applications. Using the methods proposed in this thesis to estimate resistance and state of health will indirectly facilitate the reconditioning of batteries for renewable energy applications, contribute to the reduction of waste from electric vehicles and thus reduce their environmental footprint. This is a second relevant aspect of the project. In addition, the project's major contribution lies in the use of a solid-phase diffusion model to estimate the battery's state of health. This study also showed that the parameters of this model are related to ambient temperature by a third-degree polynomial function.

TABLE DES MATIÈRES

RÉSUMÉ	i
ABSTRACT	ii
TABLE DES MATIÈRES	iii
LISTE DES TABLEAUX	v
LISTE DES FIGURES	vi
LISTE DES SIGLES	viii
DÉDICACE	ix
REMERCIEMENTS	x
CHAPITRE 1	1
INTRODUCTION	1
1.1 CONTEXTE	1
1.2 PROBLÉMATIQUE	3
1.3 OBJECTIFS	4
1.4 MÉTHODOLOGIE GÉNÉRALE	5
1.5 ORGANISATION DES CHAPITRES	5
CHAPITRE 2	8
REVUE DE LA LITTÉRATURE	8
2.1 INTRODUCTION	8
2.2 MÉTHODOLOGIE PRISMA POUR LA REVUE DE LA LITTÉRATURE	8
2.2.1 FONCTIONNEMENT D'UNE BATTERIE AU LITHIUM	10
2.2.2 LES MODÈLES DE LA BATTERIE	12
2.2.2.1 MODÈLES ÉLECTROCHIMIQUES	12
2.2.2.2 MODÈLES DE CIRCUITS ÉLECTRIQUES ÉQUIVALENTS	14
2.3 REVUE DE LA LITTÉRATURE SUR L'ESTIMATION DE LA RÉSISTANCE ET DU <i>SoH</i> DE LA BATTERIE	18
2.3.1 IDENTIFICATION DES PARAMÈTRES DU MODÈLE DE LA BATTERIE	19
2.3.2 MÉTHODES BASÉES SUR L'EXTRACTION DES CARACTÉRISTIQUES DE LA BATTERIE	20
2.3.2.1 ANALYSE DE LA CAPACITÉ INCRÉMENTALE	20
2.3.2.2 ANALYSE DE LA TENSION DIFFÉRENTIELLE	21
2.3.3 MÉTHODES AXÉES SUR LES DONNÉES	21
2.4 ANALYSE DE LA PERSPECTIVE DE RECHERCHE	27
2.5 CONCLUSION	30
CHAPITRE 3	31
MÉTHODOLOGIE	31
3.1. INTRODUCTION	31
3.2. HYPOTHÈSES DE RECHERCHE	31
3.3 MÉTHODOLOGIE	32
3.3.1 ACQUISITION ET PRÉTRAITEMENT DES DONNÉES	33
3.3.2 ESTIMATION DE LA RÉSISTANCE INTERNE EN UTILISANT DES MODÈLES BASÉS SUR LES ÉQUATIONS PARAMÉTRIQUES	36
3.3.3 ESTIMATION DU <i>SoH</i> À PARTIR D'UN MODÈLE DE DIFFUSION EN PHASE SOLIDE	37

3.3.4 ESTIMATION DE LA RÉSISTANCE ET DU <i>SoH</i> À PARTIR D'UN RÉSEAU DE NEURONES ARTIFICIELS	38
3.3.4.1 PRINCIPE DE FONCTIONNEMENT D'UN RÉSEAU DE NEURONES À ACTION DIRECTE	39
3.3.4.2 APPRENTISSAGE PAR LA MÉTHODE DE VALIDATION CROISÉE	41
3.4.3 ESTIMATION DE LA RÉSISTANCE et du <i>SoH</i> EN UTILISANT UN RÉSEAU DE NEURONES	43
3.4.4 ÉVALUATION DES PERFORMANCES	44
3.5 CONCLUSION	44
CHAPITRE 4	46
RÉSULTATS ET DISCUSSIONS	46
4.1 INTRODUCTION	46
4.2 PRÉSENTATION DES DONNÉES	46
4.3 ESTIMATION DE LA RÉSISTANCE INTERNE DE LA BATTERIE	48
4.3.1 ESTIMATION DE LA RÉSISTANCE INTERNE DE LA BATTERIE EN UTILISANT LES ÉQUATIONS PARAMÉTRIQUES	48
4.3.2 ESTIMATION DE LA RÉSISTANCE INTERNE DE LA BATTERIE EN UTILISANT UN RÉSEAU DE NEURONES À ACTION DIRECTE	55
4.4 ESTIMATION DU <i>SoH</i>	61
4.4.1 ESTIMATION DU <i>SoH</i> EN UTILISANT UN MODÈLE DE DIFFUSION EN PHASE SOLIDE	62
4.4.2 ESTIMATION DU <i>SoH</i> EN UTILISANT UN RÉSEAU DE NEURONES À ACTION DIRECTE	68
4.4.3 ESTIMATION DU <i>SoH</i> EN UTILISANT UNE MÉTHODE HYBRIDE	71
4.5 COMPARAISON DES DIFFÉRENTES APPROCHES	73
4.5 CONCLUSION	76
CHAPITRE 5	78
CONCLUSION	78
LISTE DE RÉFÉRENCES	80

LISTE DES TABLEAUX

TABLEAU 1 : REQUÊTE DE MOTS UTILISÉS DANS LA BASE DE DONNÉES SCOPUS	10
TABLEAU 2 : DIFFÉRENCE ENTRE L'APPROCHE PROPOSÉE ET LA REVUE LITTÉRAIRE....	28
TABLEAU 3 : COEFFICIENTS DES ÉQUATIONS PARAMÉTRIQUES	54
TABLEAU 4 : PARAMÈTRES UTILISÉS POUR L'ESTIMATION DE LA RÉSISTANCE	56
TABLEAU 5 : COEFFICIENTS DE L'ÉQUATION MODIFIÉE DE VAN GENUCHTEN-GUPTA	64
TABLEAU 6 : PERFORMANCES D'ESTIMATION DU <i>SOH</i> PAR UN RÉSEAU DE NEURONES ARTIFICIELS.....	68
TABLEAU 7 : COMPARAISON DES APPROCHES PROPOSÉES POUR ESTIMER LA RÉSISTANCE	74
TABLEAU 8 : COMPARAISON DES APPROCHES PROPOSÉES POUR ESTIMER LE <i>SOH</i>	75

LISTE DES FIGURES

FIGURE 1 : MÉTHODOLOGIE GÉNÉRALE	5
FIGURE 2 : ORGANISATION DES CHAPITRES DU MÉMOIRE	7
FIGURE 3: REVUE DE LA LITTÉRATURE : A) NOMBRE D'ARTICLES PUBLIÉS ; B) : MÉTHODOLOGIE PRISMA ADOPTÉE	10
FIGURE 4 : FONCTIONNEMENT D'UNE BATTERIE LITHIUM-ION LORS DE LA CHARGE ET LA DÉCHARGE	12
FIGURE 5 : MODÈLE SIMPLE DE LA BATTERIE (MODIFIÉ) [36].	15
FIGURE 6 : MODÈLE DE THEVENIN DE PREMIER ORDRE (MODIFIÉ) [36].....	15
FIGURE 7 : MODÈLE DE THEVENIN DE SECOND ORDRE (MODIFIÉ) [40].....	16
FIGURE 8 : MODÈLE PNGV (MODIFIÉ) [39].....	17
FIGURE 9 : RÉSUMÉ STRUCTURÉ DES MÉTHODES D'APPRENTISSAGE AUTOMATIQUE CONSIDÉRÉES ET ANALYSÉES	22
FIGURE 10 : STRUCTURE GÉNÉRALE D'UN NEURONE (MODIFIÉE) [85]	23
FIGURE 11 : STRUCTURE GÉNÉRALE D'UN RÉSEAU DE NEURONES À ACTION DIRECTE (MODIFIÉE) [85].....	24
FIGURE 12 : STRUCTURE GÉNÉRALE D'UN RÉSEAU DE NEURONES RÉCURRENTS (MODIFIÉE) [94].....	26
FIGURE 13 : GRANDES ÉTAPES DE LA MÉTHODOLOGIE ADOPTÉE	32
FIGURE 14 : ILLUSTRATION DU SCHÉMA <i>SIMULINK</i> DU SIMULATEUR DE BATTERIE DANS LA <i>SIMSCAPE</i> DE <i>MATWORKS</i>	33
FIGURE 15 : MODÈLE DE CIRCUIT ÉQUIVALENT DE <i>SIMSCAPE</i> BATTERIE (MODIFIÉ) [52].	33
FIGURE 16 : ILLUSTRATION DU PRÉTRAITEMENT EN UTILISANT LA VALEUR MOYENNE ...	35
FIGURE 17 : ILLUSTRATION DE LA NORMALISATION DES DONNÉES DE TENSION	36
FIGURE 18 : STRUCTURE D'UN RÉSEAU DE NEURONES À ACTION DIRECTE (MODIFIÉE) [111].....	39
FIGURE 19 : PRINCIPE DE L'APPRENTISSAGE PAR LA VALIDATION CROISÉE EN K-JEUX DE DONNÉES.....	42
FIGURE 20 : MÉTHODOLOGIE POUR L'ESTIMATION DE LA RÉSISTANCE (MODIFIÉE) [113]	43
FIGURE 21 : <i>SOH</i> ET RÉSISTANCE $I_D = 10A$ POUR PLUSIEURS TEMPÉRATURES AMBIANTES [113].....	47
FIGURE 22 : <i>SOH</i> ET RÉSISTANCE À $T_A = 293K$ POUR PLUSIEURS COURANTS DE DÉCHARGE [113].....	47
FIGURE 23 : PERFORMANCES DES ÉQUATIONS PARAMÉTRIQUES POUR $I_D = 10 A$	49
FIGURE 24 : RÉSISTANCE ESTIMÉE À PARTIR D'UNE ÉQUATION PARAMÉTRIQUE POUR $I_D =$ $10A$	50
FIGURE 25 : PERFORMANCES DES ÉQUATIONS PARAMÉTRIQUES POUR $I_D = 20 A$	50
FIGURE 26 : RÉSISTANCE ESTIMÉE À PARTIR D'UNE ÉQUATION PARAMÉTRIQUE POUR $I_D =$ $20A$	51
FIGURE 27 : PERFORMANCES DES ÉQUATIONS PARAMÉTRIQUES POUR $I_D = 27 A$	52
FIGURE 28 : RÉSISTANCE ESTIMÉE À PARTIR D'UNE ÉQUATION PARAMÉTRIQUE POUR $I_D =$ $27A$	52
FIGURE 29 : PERFORMANCES DES ÉQUATIONS PARAMÉTRIQUES POUR $I_D = 55 A$	53
FIGURE 30 : RÉSISTANCE ESTIMÉE À PARTIR D'UNE ÉQUATION PARAMÉTRIQUE POUR $I_D =$ $55A$	54
FIGURE 31 : RÉSISTANCE RÉELLE ET ESTIMÉE PAR UN RÉSEAU DE NEURONES À $I_D = 10A$	57
FIGURE 32 : RÉSISTANCE RÉELLE ET ESTIMÉE PAR UN RÉSEAU DE NEURONES À $I_D = 20A$	58
FIGURE 33 : RÉSISTANCE RÉELLE ET ESTIMÉE PAR UN RÉSEAU DE NEURONES À $I_D = 27A$	58
FIGURE 34 : RÉSISTANCE RÉELLE ET ESTIMÉE PAR UN RÉSEAU DE NEURONES À $I_D = 55A$	59
FIGURE 35 : RÉSISTANCES RÉELLE ET ESTIMÉE PAR LES DEUX APPROCHES PROPOSÉES ($I_D = 10A$) [113].....	59

FIGURE 36 : RÉSISTANCES RÉELLE ET ESTIMÉE PAR LES DEUX APPROCHES PROPOSÉES ($I_D = 20A$) [113].....	60
FIGURE 37 : RÉSISTANCES RÉELLE ET ESTIMÉE PAR LES DEUX APPROCHES PROPOSÉES ($I_D = 27A$) [113].....	60
FIGURE 38 : RÉSISTANCES RÉELLE ET ESTIMÉE PAR LES DEUX APPROCHES PROPOSÉES ($I_D = 55A$) [113].....	61
FIGURE 39 : ILLUSTRATION GÉNÉRALE DE LA MÉTHODE D'ESTIMATION DE LA RÉSISTANCE ET DU SOH	61
FIGURE 40 : ILLUSTRATION DE L'ESTIMATION DE SOH_G	62
FIGURE 41 : PERFORMANCES DU MODÈLE MODIFIÉ DE VAN GENUCHTEN-GUPTA POUR ESTIMER LE SOH_G	62
FIGURE 42 : SOH ESTIMÉ PAR LE MODÈLE MODIFIÉ DE VAN GENUCHTEN-GUPTA ($I_D = 10A$)	65
FIGURE 43 : SOH ESTIMÉ PAR LE MODÈLE MODIFIÉ DE VAN GENUCHTEN-GUPTA ($I_D = 20A$)	66
FIGURE 44 : SOH ESTIMÉ PAR LE MODÈLE MODIFIÉ DE VAN GENUCHTEN-GUPTA ($I_D = 27A$)	66
FIGURE 45 : SOH ESTIMÉ PAR LE MODÈLE MODIFIÉ DE VAN GENUCHTEN-GUPTA ($I_D = 55A$)	67
FIGURE 46 : ILLUSTRATION DE L'ESTIMATION DE SOH_{FFN}	68
FIGURE 47 : SOH ESTIMÉ PAR RÉSEAU DE NEURONES ($I_D = 10A$).....	69
FIGURE 48 : SOH ESTIMÉ PAR RÉSEAU DE NEURONES ($I_D = 20A$).....	70
FIGURE 49 : SOH ESTIMÉ PAR RÉSEAU DE NEURONES ($I_D = 27A$).....	70
FIGURE 50 : SOH ESTIMÉ PAR RÉSEAU DE NEURONES ($I_D = 55A$).....	71
FIGURE 51 : ILLUSTRATION DE LA MÉTHODE HYBRIDE POUR L'ESTIMATION DU SOH	72
FIGURE 52 : ESTIMATION DU SOH PAR UNE MÉTHODE HYBRIDE ($I_D = 10A$).....	72
FIGURE 53 : ESTIMATION DU SOH PAR UNE MÉTHODE HYBRIDE ($I_D = 20A$).....	73

LISTE DES SIGLES

Sigles	Définition (Français)	Definition (English)
ACI	Analyse de la Capacité Incrémentale	Incremental Capacity Analysis
AIE	Agence International de l'Énergie	International Energy Agency
ATD	Analyse de la Tension Différentielle	Differential Voltage Analysis
CC	Courant Continu	Direct Current
CI	Capacité Incrémentale	Incremental Capacity
COP21	vingt-et-unième session de la Conférence des Parties	twenty-first session of the Conference of the Parties
CO ₂	Dioxyde de Carbone	Carbon Dioxide
LSTM	Mémoire à long terme et à court terme	Long Short Term memory
NRMSE	Racine carrée de l'erreur quadratique moyenne normalisée	Normalized root mean square
PMC	Perceptron Multicouche	Multi-layer Perceptron
PRISMA	Critères d'évaluation pour les revues systématiques et les méta-analyses	Preferred Reporting Items for Systematic Reviews and Meta-Analyses
RNA	Réseau de Neurones Artificiels	Artificial Neural Networks
RNR	Réseaux de Neurones Récurrents	Recurrent Neural Networks
SEI	Spectroscopie Electrochimique de l'Impédance	Electrochemical Impedance Spectroscopy
<i>SoC</i>	État de Charge	State of Charge
<i>SoH</i>	État de Santé	State of Health
SSEB	Systèmes de Stockage d'Énergie à Batteries	Battery Energy Storage Systems
SVM	Machines à Vecteurs de Support	<i>Support-Machine Vectors</i>
SVR	Régression Vectorielle de Soutien	<i>Support-Machine Regressor</i>

DÉDICACE

À la mémoire de Micheline Massan Okamba, ta sagesse, ton amour et ton soutien inébranlable ont été toujours des sources d'inspiration. Bien que tu ne sois plus parmi nous, ton esprit continue de guider et d'encourager chaque étape de mon parcours. Ce mémoire t'est dédié, avec une gratitude éternelle et un amour profond.

À mes parents, frères et sœurs, pour leur amour inconditionnel et leur soutien indéfectible tout au long de ce parcours académique.

À mes professeurs et mentors, pour leur guidance précieuse et leur encouragement constant.

À mes amis, pour leur compréhension et leur patience durant les moments difficiles.

À tous ceux qui ont cru en moi et m'ont inspiré à persévérer.

REMERCIEMENTS

Je tiens à remercier le Professeur Martin Otis pour avoir accepté diriger ce mémoire. Votre aide précieuse a été indispensable sur le plan scientifique, moral et financier.

Merci également à Monsieur Khaled Ziane, superviseur académique de ce mémoire.

Merci aux autres membres du jury d'avoir accepté d'en faire partie et d'avoir fait des suggestions pour améliorer ce document.

Merci à toute l'administration de l'université du Québec à Chicoutimi et à tous les enseignants.

Merci à mes très chers amis et camarades.

Ce travail a été réalisé au Laboratoire d'Automatique et de Robotique interactive (LAR.i) en collaboration avec le Centre de Recherche et d'Innovation en intelligence énergétique (CR2ie) grâce aux financements des Fonds de Recherche du Québec Nature et Technologie (FRQNT) à travers la bourse de formation en partenariat avec la régie de l'énergie du Québec (N. 334395) et la bourse de stage en centre collégial de transfert de technologie (N. 338610).

CHAPITRE 1

INTRODUCTION

L'intérêt des batteries dans notre quotidien ne cesse de croître, que ce soit pour les appareils électroniques [1], les véhicules électriques [2] ou les systèmes de stockage d'énergie renouvelable [3]. Pour l'adoption à grande échelle de ces batteries, leur performance et leur fiabilité sont des facteurs cruciaux. Ainsi, la résistance interne et l'état de santé sont des paramètres essentiels pour évaluer cette performance.

La résistance de la batterie est une caractéristique fortement liée aux performances et à la sécurité de la batterie [4]. Une résistance élevée peut entraîner des pertes d'énergie significatives et une diminution de la performance globale. Par conséquent, une estimation précise de cette résistance est indispensable pour optimiser l'utilisation des batteries.

L'état de santé (*SoH*) d'une batterie quant à lui est une mesure de sa capacité à stocker et à délivrer de l'énergie par rapport à ses spécifications initiales. Divers facteurs tels que les cycles de charge et de décharge, la température et les conditions d'utilisation sont à l'origine de sa diminution avec le temps. De ce fait, une estimation précise du *SoH* permet de planifier son remplacement ou sa maintenance de manière proactive. Dans les prochaines sections de ce chapitre introductif, le projet est placé dans son contexte, suivi de la problématique puis des objectifs visés. L'organisation général de ce mémoire est donnée à la fin de ce chapitre.

1.1 CONTEXTE

Les émissions mondiales de CO_2 provenant de la combustion d'énergie et des processus industriels s'élèvent à 36,3 gigatonnes en 2019. En 2020, les émissions ont diminué de 5,23% selon l'agence internationale de l'énergie (*AIE*) [5]. Cette baisse est due à la pandémie de la covid-19. Cependant, à partir de 2022 lorsque les activités économiques ont véritablement repris, les émissions de CO_2 ont connu une hausse passant de 36,8 gigatonnes en 2022 à 37,2 gigatonnes en 2023 [5].

Ainsi, chaque année, l'utilisation massive des énergies fossiles compromet un peu plus l'ambition mondiale de contenir l'augmentation de la température moyenne de la planète nettement en dessous de 2°C et de poursuivre les efforts pour limiter l'augmentation de la température à 1,5°C par rapport aux niveaux préindustriels comme le prévoit l'Accord de Paris. Le développement des énergies renouvelables, l'accélération de l'électrification des transports [6], la mise en œuvre de mesures d'efficacité énergétique [7] et la valorisation des déchets [8] sont des solutions qui peuvent contribuer de manière significative à limiter la pollution. Malgré cela, l'utilisation des énergies renouvelables présentent des défis majeurs. En effet, compte tenu des phénomènes météorologiques qui sont de plus en plus violents, la puissance de sortie des sources de production d'énergies renouvelables est de plus en plus variable et présente des défis en matière d'opérabilité et de fiabilité. Pour remédier à ce problème, un système de stockage d'énergie à batteries pouvant jouer le rôle de fournisseur d'énergie à court terme, de pointe de puissance, de maintien de la stabilité de la tension ou de la fréquence, et d'amélioration des performances du micro réseau est indispensable [9]. Ce faisant, avec le développement de l'électrification des transports, une forte croissance mondiale de véhicules électriques est observée avec un passage de 130k de véhicules électriques vendus en 2012 à 14 millions en 2023 [5]. Cette orientation a occasionné une augmentation de la disponibilité des batteries usagées de véhicules électriques avec un état de santé de 80% [10] les rendant bien disposées pour des applications stockage d'énergie à batteries dans un micro réseau [11].

La résistance et l'état de santé d'une batterie sont des paramètres qui influencent non seulement la fiabilité mais jouent également un rôle essentiel dans l'optimisation et la stabilité des systèmes d'énergie renouvelable. Par conséquent, ce projet de recherche porte sur l'estimation de la résistance et de l'état de santé d'une batterie. Il est pertinent pour deux raisons fondamentales décrites ci-après : **1-Fiabilité de la source** : l'estimation de la résistance et de l'état de santé d'une batterie à partir des approches proposées dans le cadre de ce projet permettront de fournir des services essentiels de fiabilité qui sont principalement le soutien de la fréquence, de la capacité de satisfaire à la demande et du maintien de la tension. En effet, la détermination de l'état de santé des systèmes de stockage d'énergie à batteries permettra d'anticiper d'éventuels pannes et d'intervenir plus rapidement sur ces systèmes. **2-Effets environnementaux** : les approches proposées peuvent

être utilisées pour les sources d'énergie constituées de batteries de seconde vie issues des véhicules électriques en considérant les mêmes paramètres de fonctionnement. L'avantage de la connaissance de la résistance et surtout de l'état de santé réside dans le fait qu'ils faciliteront le reconditionnement des batteries pour des applications en énergie renouvelable, ce qui contribuera directement à la réduction des déchets des véhicules électriques et ainsi l'amenuisement de leurs empreintes sur l'environnement. De ce fait, ce projet rencontre au moins un des objectifs de développement durable de l'ONU, soit l'objectif 7 : Énergie propre et d'un coût abordable, en plus de favoriser une lutte contre les changements climatiques. Par ailleurs, les performances et le fonctionnement d'une batterie dépendent intrinsèquement des conditions de charge et de décharge ainsi que l'environnement [12]. Comme ces derniers peuvent varier considérablement au cours du fonctionnement, il est assez difficile de mesurer directement la résistance et l'état de santé qui constituent les paramètres de vieillissement de la batterie.

1.2 PROBLÉMATIQUE

L'analyse de la santé des batteries au lithium est un sujet complexe qui a reçu beaucoup d'attention dans la communauté scientifique ces dernières années. En effet, la dégradation d'une batterie au lithium est un phénomène assez complexe, qui se manifeste souvent par une perte de la capacité et une diminution de la puissance [13]. Ce vieillissement est dû aussi bien aux facteurs internes qu'externes à la batterie. Ainsi, tout facteur défavorable interne à la batterie et qui augmente la consommation de lithium favorise l'apparition des réactions secondaires pouvant entraîner sa dégradation rapide. Aussi, au cours des cycles de charge et de décharge, il existe des facteurs externes défavorables qui accélèrent la dégradation susmentionnée de la batterie [14]. Parmi ces facteurs, la température de fonctionnement, le courant de charge et de décharge ainsi que leur tension de coupure sont les plus impactant. Bien que les batteries au lithium aient une bonne tolérance aussi bien pour les températures élevées que pour les températures basses, la température joue toujours un rôle essentiel dans leur efficacité de fonctionnement. C'est l'exemple de Qin et al. 2015 [15] qui ont exposé dans leur travaux l'effet de la température sur les batteries au lithium. Par

ailleurs, les conditions de cyclage d'une batterie affectent également sa durée de vie. En effet, un courant de charge élevée favorise une chute de capacité, une augmentation de l'impédance et un surchauffage interne des cellules [16]. La batterie est alors dans l'incapacité de délivrer des courants élevés lors de la décharge et le surchauffage pourrait entraîner un emballement thermique. Aussi, un courant de décharge élevé entraîne les chutes de tension réduisant la puissance disponible. Jon et al. 2006 [17] sont arrivés à la conclusion selon laquelle plus la tension de coupure lors de la décharge est faible, plus la batterie se détériore rapidement. Ainsi, pour estimer la résistance et l'état de santé de la batterie qui sont difficilement mesurables, il est nécessaire de s'appuyer sur les autres quantités mesurées par les capteurs, telles que la tension, le courant et la température [18, 19]. En outre, la batterie doit être correctement modélisée de manière à saisir la dynamique interne et les phénomènes de dégradation. Toutefois, dépendamment des données, certains paramètres sont négligés au profit d'autres par les auteurs dans leurs travaux relatifs à l'estimation de la résistance et du *SoH*.

1.3 OBJECTIFS

Il est reconnu que l'opération fréquente des batteries, considérant leurs structures et les conditions de fonctionnement, se dégradent de manière non-linéaire. L'objectif directeur de ce projet est de déterminer des modèles pour estimer la résistance interne de la batterie considérant plusieurs courants de décharge et températures ambiantes. Plus spécifiquement, les paramètres qui permettent de mieux estimer la résistance interne seront identifiés en utilisant les équations paramétriques. Ces paramètres sont ensuite utilisés comme les entrées d'un réseau de neurones pour estimer la résistance interne et le *SoH*.

Un objectif secondaire vise à déterminer un modèle de diffusion en phase solide pour estimer le *SoH* à partir de la résistance calculée. En effet, au cours du processus de charge et décharge, les ions lithium subissent deux (02) diffusions, à savoir la diffusion en phase solide dans le matériau actif et la diffusion en phase liquide dans l'électrolyte. D'après les travaux de Ming et al. 2013 [20], la diffusion en phase solide est plus lente qu'en phase liquide et crée une différence de concentration

ionique plus importante. De ce fait, le *SoH* de la batterie est plus impacté par la diffusion en phase solide et peut être décrit par un modèle de diffusion. La section 1.4 présente la méthodologie générale adoptée pour atteindre les objectifs définis.

1.4 MÉTHODOLOGIE GÉNÉRALE

La méthodologie générale adoptée dans le cadre de ce mémoire est présentée à la figure 1. Après le chapitre introductif et la revue de la littérature, deux hypothèses sont émises. La première hypothèse permet d'identifier les paramètres idéaux pour l'estimation de la résistance en utilisant les équations paramétriques. Une fois identifiés, ces paramètres sont ensuite pris comme entrée d'un réseau de neurones pour l'estimation du *SoH*. La seconde hypothèse est relative à l'estimation du *SoH* à partir d'un modèle de diffusion.

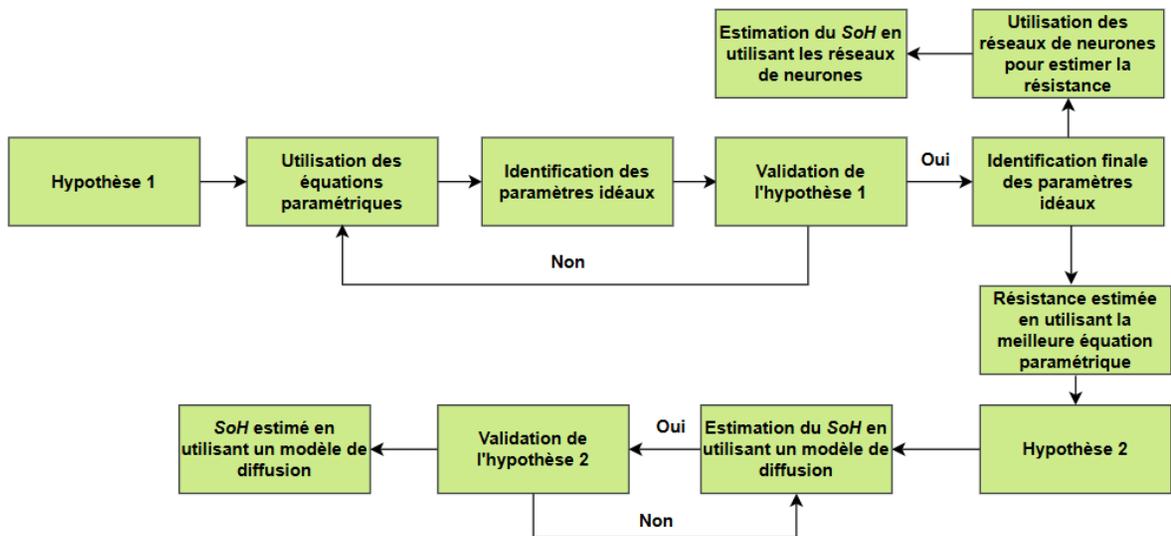


Figure 1 : Méthodologie générale

1.5 ORGANISATION DES CHAPITRES

Ce mémoire est composé de cinq (05) chapitres tel qu'illustré sur la figure 2. Ces chapitres abordent respectivement les thèmes suivants :

- ❖ le présent chapitre (chapitre 1) oriente le projet dans son contexte, présente la problématique et les objectifs ;
- ❖ le chapitre 2 présente une revue de la littérature relative à l'estimation de la résistance et du *SoH* ;
- ❖ la méthodologie adoptée pour atteindre les objectifs de ce projet et qui est proposée au chapitre 3 présente les équations paramétriques pour l'estimation de la résistance interne, suivie d'une présentation du modèle modifié de Van Genuchten-Gupta qui constitue la principale contribution de ce projet ainsi que l'architecture de réseau de neurones utilisées ;
- ❖ les résultats sont exposés et discutés au chapitre 4 ;
- ❖ le chapitre 5 présente les différentes conclusions tirées de ce projet de recherche ainsi que les recommandations qui en découlent.

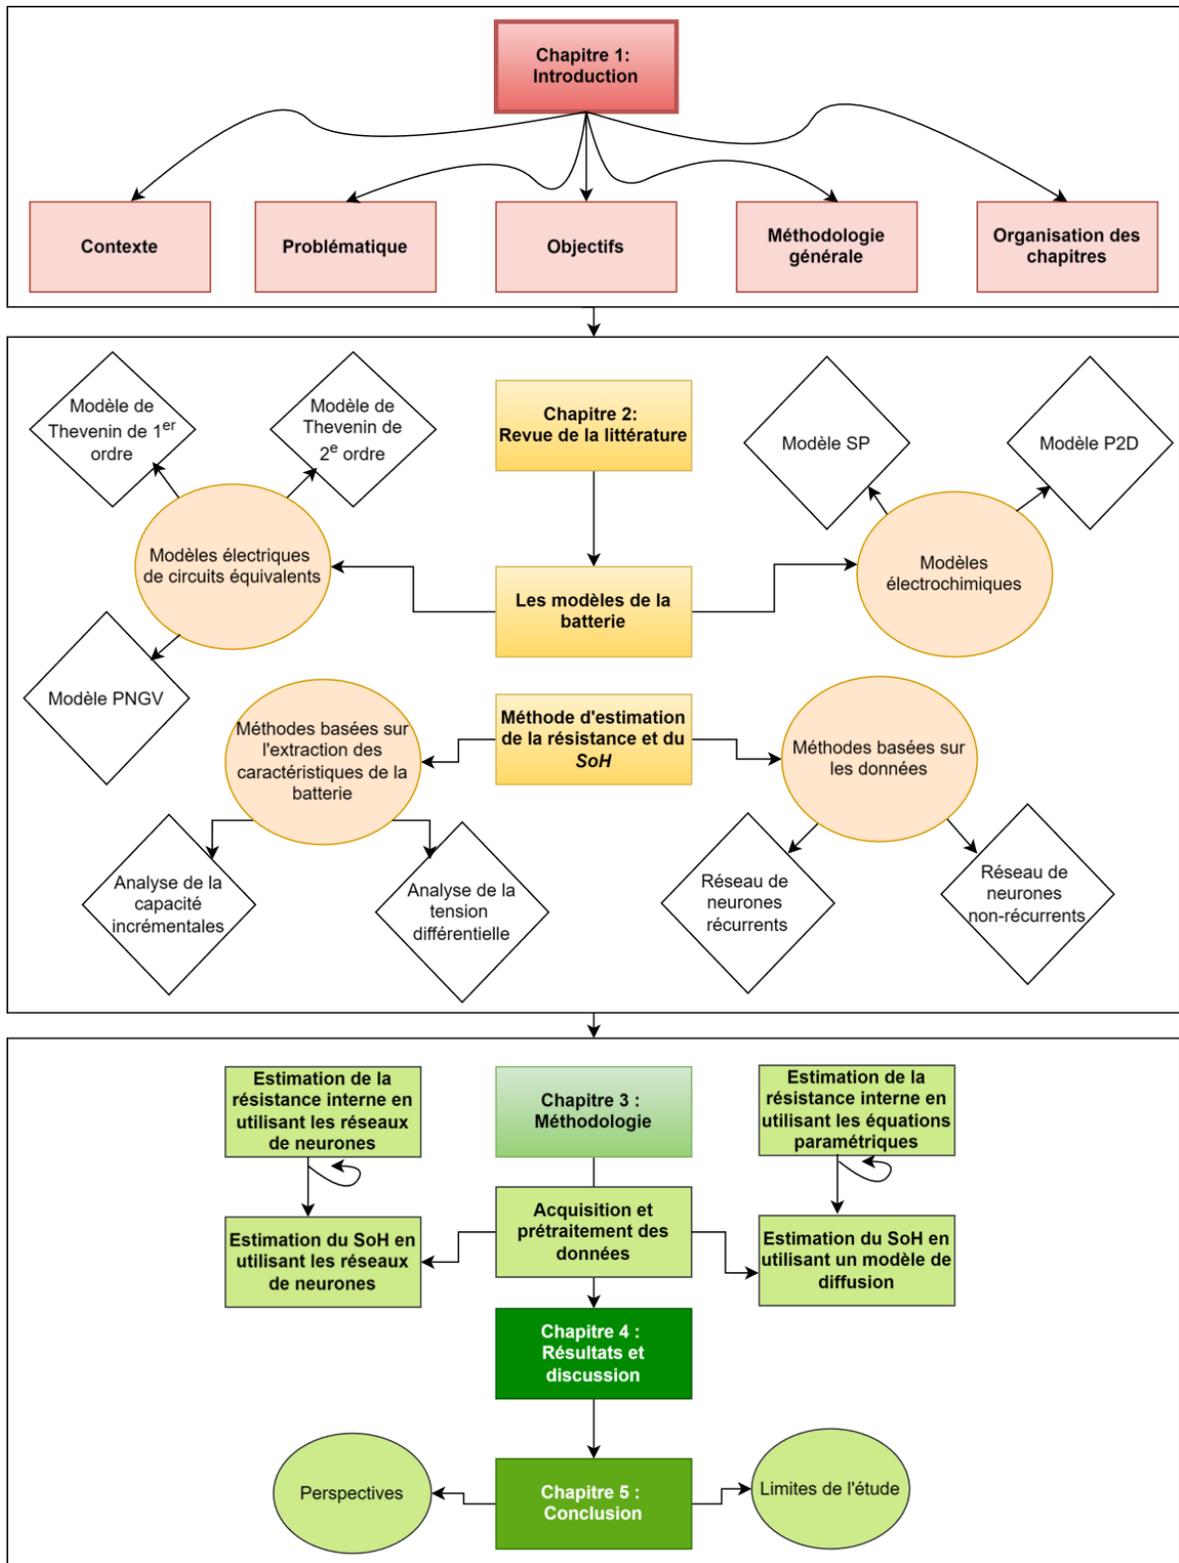


Figure 2 : Organisation des chapitres du mémoire

CHAPITRE 2 REVUE DE LA LITTÉRATURE

2.1 INTRODUCTION

La recherche sur l'estimation de la résistance et du *SoH* d'une batterie a connu une croissance exponentielle au cours des dernières décennies en raison de son importance cruciale pour la fiabilité des systèmes de gestion de l'énergie dans les micro-réseaux et l'électrification des transports. Malgré des avancées significatives, plusieurs questions clés restent sans réponses notamment les paramètres idéaux pour une bonne estimation de la résistance et du *SoH*. Cette revue de la littérature vise à explorer ces questions en examinant les études les plus récentes et pertinentes.

Les objectifs de cette revue de la littérature sont triples : (1) fournir une vue d'ensemble des recherches actuelles sur l'estimation de la résistance et du *SoH*, (2) identifier les lacunes dans la littérature existante, et (3) proposer des directions pour des futures recherches. Ainsi, pour atteindre ces objectifs, ce chapitre est structuré comme suit : la première section présente la méthode *PRISMA* adoptée pour la revue de la littérature. Ensuite le principe de fonctionnement d'une batterie au lithium ainsi que les différents modèles de batterie sont abordés. En fin, les méthodes d'estimations de la résistance et du *SoH* sont présentées.

2.2 MÉTHODOLOGIE PRISMA POUR LA REVUE DE LA LITTÉRATURE

Ces dernière décennies, l'estimation de la résistance interne et du *SoH* des batteries au lithium font l'objet d'un intérêt croissant dans la littérature scientifique. En effet, les batteries au lithium se sont imposées comme la pierre maîtresse des solutions de stockage d'énergie alimentant toute une série d'applications telles que les téléphones intelligents, les véhicules électriques et les énergies renouvelables [21, 22]. Cependant, la dégradation progressive de ces batteries au fil du temps

impacte directement leurs performances et leur capacité, ce qui représente un défi fondamental [23, 24]. Ce vieillissement de la batterie entraîne une réduction de la capacité de stockage d'énergie et dans certains cas des problèmes de sécurité. Ainsi, pour résoudre ces problèmes et maximiser l'efficacité opérationnelles des appareils utilisant les batteries au lithium, il est indispensable de disposer d'une estimation précise de la résistance ou du *SoH*. La revue de la littérature proposée dans le cadre de cette étude est basée sur la méthode PRISMA. Il s'agit d'une revue systématique de la littérature qui se fait généralement en quatre (04) étapes [25]. La première étape consiste à faire une requête de mots clés relatifs au sujet abordé dans une ou plusieurs bases de données puis à importer les références. La seconde étape comprend l'identification et la suppression des doublons. Après une lecture du titre et du résumé des différents articles, une identification des articles éligibles est faite à la troisième étape. Pour finir, la quatrième étape présente l'éligibilité des articles pour leur inclusion dans la revue sur la base de la lecture entière du manuscrit.

Dans le cadre de notre projet, la requête de mots clés utilisés dans la base de données Scopus est présenté au tableau 1. Un total de 10880 documents publiés entre 1975 et 2024 ont été identifiés. Cependant, l'analyse du nombre de documents publiés par année révèle que c'est à partir de 2015 que les documents comportant la requête demandée ont connu un essor. Cette croissance peut être expliquée par la tenue de la *COP21* pendant laquelle des mesures ont été prises pour réduire les émissions de CO_2 . Par conséquent, beaucoup de travaux de recherche et de développement portant sur les énergies renouvelables et l'électrification des transports ont été fortement encouragés. À partir des documents identifiés, un filtrage portant sur le type de document, la langue, le domaine, la source et l'année de parution a été effectué. Cette initiative a permis de réduire le nombre de documents à 4951. Les mots clés **"feedforward" OR "perceptron"** ont été ajoutés dans la requête afin d'avoir des données plus spécifiques à l'étude envisagée. Ainsi, sur les 209 articles éligibles, notre document fait mention d'un nombre d'articles inférieurs qui sont inclus.

TABLEAU 1 : Requête de mots utilisés dans la base de données scopus

Mots clés	<i>(“batter*” OR “cell*”) AND (“resistance”) AND (“SoH” OR “state of health”) AND (“estimation” OR “prediction” OR “forecasting”).</i>
------------------	---

La figure 3 présente la méthodologie adoptée pour la revue de la littérature. Les articles inclus dans le document à partir de la revue de la littérature basée sur la méthode PRISMA abordent dans un premier temps le fonctionnement de la batterie, ensuite les modèles de la batterie et pour finir les méthodes d'estimation de la résistance et du *SoH*. C'est sur cette base que les grandes sections de ce chapitre ont été définies et dont les détails sont présentés dans les sections subséquentes.

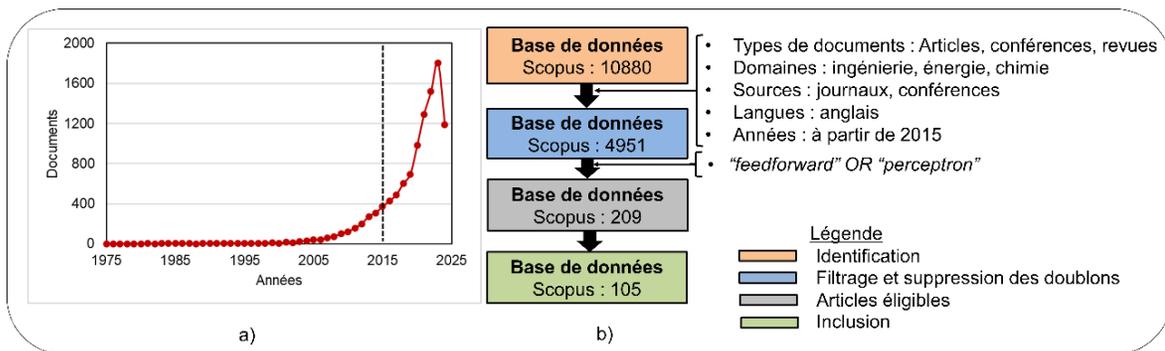
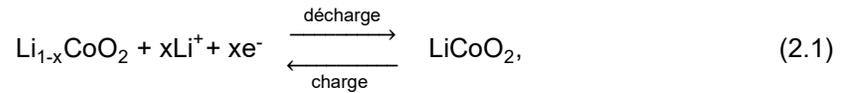


Figure 3: Revue de la littérature : a) nombre d'articles publiés ; b) : Méthodologie PRISMA adoptée

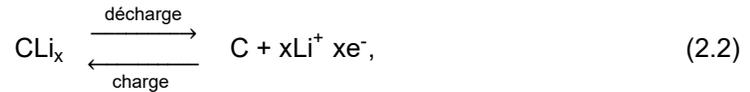
2.2.1 FONCTIONNEMENT D'UNE BATTERIE AU LITHIUM

Une batterie au lithium est composée de deux électrodes (positive et négative), de l'électrolyte et d'un séparateur [26]. L'électrode positive est généralement constituée soit de l'oxyde de lithium-cobalt, soit de lithium-fer-phosphate ou soit de l'oxyde de lithium-manganèse. L'électrode négative est fabriquée à partir de carbone spécial. Dans le cas spécifique d'une batterie dont la cathode est en oxyde de lithium cobalt, les différentes réactions chimiques s'écrivent sous la forme de :

❖ à l'électrode positive (cathode) :



❖ à l'électrode négative (anode) :



l'équation de la réaction est donnée par le bilan de (2.1) et (2.2) formulée en (2.3) :



Dans les équations 2.1, 2.2 et 2.3, $\text{Li}_{1-x}\text{CoO}_2$ est une portion de dioxyde de cobalt et de lithium, $x\text{Li}^+$ est une quantité x des ions lithium, LiCoO_2 est le dioxyde de cobalt et de lithium, xe^- représente un nombre x d'électrons, CLi_x la molécule de tétralithium de carbone et C l'atome de carbone.

Lors de la décharge, les atomes de lithium de l'électrode négative (anode) libèrent chacun un électron. Celui-ci revient à l'électrode positive (cathode) via le circuit électrique externe. Au cours de la même étape, les ions lithium de l'anode diffusent vers la surface et il se produit une réaction électrochimique à l'interface l'électrode/électrolyte. Ces ions pénètrent dans l'électrolyte, puis migrent vers la surface des particules de la cathode par le biais du processus de diffusion en phase liquide. Le phénomène inverse se produit pendant la charge. Au cours du processus de charge ou de décharge, les ions lithium subissent deux (02) diffusions, à savoir la diffusion en phase solide dans le matériau actif et la diffusion en phase liquide dans l'électrolyte. Cependant, le *SoH* de la batterie est plus impacté par la diffusion en phase solide et peut être décrit par un modèle de diffusion. En effet, selon les travaux de Ming et al. 2013 [20], la diffusion en phase solide est plus lente qu'en phase liquide et crée une différence de concentration ionique plus importante. La figure 4 illustrant le fonctionnement d'une batterie lithium-ion est réalisé en se basant sur les travaux de Liu et al. 2015 [26].

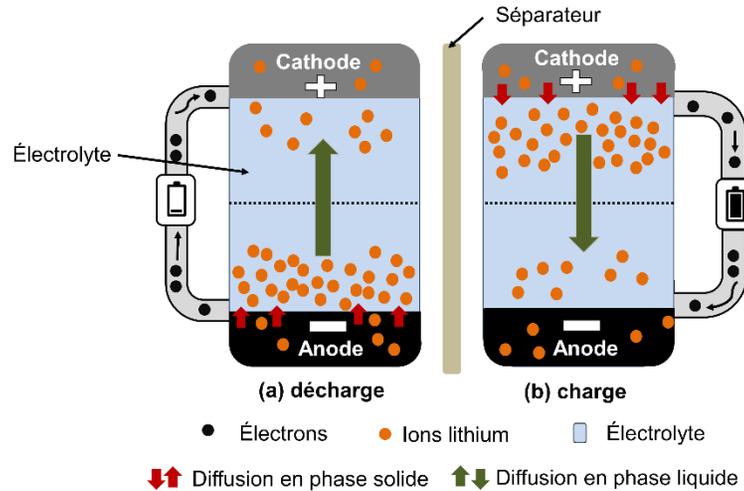


Figure 4 : Fonctionnement d'une batterie Lithium-ion lors de la charge et la décharge

2.2.2 LES MODÈLES DE LA BATTERIE

La modélisation d'une batterie joue un rôle important dans l'étude, l'estimation ou la prévision de son fonctionnement [27]. En effet, cette modélisation permet non seulement de développer des systèmes de gestion de batterie plus efficacement mais aussi d'améliorer la charge et la décharge de celle-ci. C'est le moyen le plus rapide et le plus sûr d'étudier le comportement des batteries dans les différentes conditions de fonctionnement tout en identifiant les limites de fonctionnement. Ceci permet ainsi d'obtenir de meilleure durée de vie pour des applications spécifiques. Ainsi, les modèles de la batterie peuvent être classés en deux catégories : les modèles électrochimiques et les modèles électriques dont les détails sont présentés dans les prochaines sections.

2.2.2.1 MODÈLES ÉLECTROCHIMIQUES

Les modèles électrochimiques sont décrits par un ensemble d'équations aux dérivées partielles. Ils illustrent les changements internes de la batterie tel que les réactions électrochimiques et peuvent donner une idée de l'état de l'électrode à un instant donné [28, 29]. En effet, les potentiels de l'électrolyte et de l'électrode sont souvent calculés en utilisant la loi d'Ohm et les concentrations

de l'électrolyte en utilisant la loi de diffusion de Fick. On distingue le pseudo-modèle bidimensionnel (P2D) et sa version simplifiée (SP).

❖ **Le modèle P2D**

Le mécanisme du modèle P2D souvent utilisé pour les batteries au lithium-ion est divisée conceptuellement en cinq (05) régions : l'électrode positive, l'électrode négative, le séparateur et les collecteurs de courant situés à proximité des électrodes. Pendant la charge, le champ électrique externe favorise l'extraction des ions lithium de l'électrode positive qui passent du matériau positif à l'électrolyte. Ils traversent ensuite le séparateur et s'intercalent finalement dans l'électrode négative ou dans le réseau de graphite. Inversement, au cours de la décharge, les ions lithium se désintègrent du réseau de graphite et s'intercalent à nouveau dans le matériau positif en suivant le chemin inverse. Les équations du modèle P2D et ses conditions limites sont présentées dans la référence [30]. Pour mieux refléter la concentration en ions lithium dans la phase solide et dans l'électrolyte, un ensemble de six (06) équations aux dérivées partielles sont généralement couplées et dont les équations mathématiques d'après les travaux de Wang et al. 2023 [30] portent sur :

- les équations de diffusion des ions lithium de l'électrolyte vers l'électrode positive, l'électrode négative et le séparateur selon la deuxième loi de Fick ;
- les équations de diffusion des ions lithium en phase solide dans les électrodes selon la seconde loi de Fick ;
- les équations d'Ohm des électrolytes dans les électrodes et le séparateur ;
- les équations d'Ohm en phase solide dans l'électrode positive et l'électrode négative ;
- les équations de conservation de la charge ;
- les équations cinétiques de Butler-Volmer (BV) à la surface des particules dans les électrodes ;
- d'autres détails et conditions limites sont énumérés dans le tableau 1 des travaux de Schmidt et al. 2013 [43].

Plusieurs auteurs dont Doyle et al. [31, 32] et de Fuller et al. 1994 [33] ont aussi proposé un pseudo-modèle bidimensionnel prenant en compte plusieurs processus électrochimiques dont la loi de Fick sur la diffusion en phase solide.

❖ **Le modèle à une particule (SP)**

Haran et al. 1998 [34] ont introduit le modèle à particule unique, simplifiant le modèle bidimensionnel en traitant l'électrode poreuse comme une seule particule sphérique. Ce modèle simplifié ne prend pas en compte la dynamique de l'électrolyte et permet d'alléger les charges de calcul. Toutefois, il convient de noter que cette méthode peut ne pas atteindre une grande précision, en particulier dans des conditions de courants élevés.

De façon générale, les expressions aux dérivées partielles que comportent souvent les modèles électrochimiques sont compliquées et nécessitent un grand nombre de paramètres complexes entraînant un coût de calcul élevé [35].

2.2.2.2 MODÈLES DE CIRCUITS ÉLECTRIQUES ÉQUIVALENTS

Le modèle simple de la batterie, les modèles de premier et de second ordre de Thevenin, le modèle *PNGV* (*PNGV : partnership for new generation of vehicles*) sont les modèles de circuits électriques équivalents qui sont souvent utilisés et dont la description est présentée ci-dessous.

❖ **Modèle simple de la batterie**

Une simple modélisation de la batterie peut être faite en utilisant la tension en circuit ouvert (V_0), la tension aux bornes de la batterie (V_t) et la résistance interne (R_0) tel qu'illustré à la figure 5 réalisée en s'inspirant de la référence [36]. Ce modèle est non seulement simple en termes de structure mais il s'agit également du modèle de circuit électrique équivalent de base. En contrepartie, le domaine d'application est réduit et les mesures ne sont pas assez précises. Il peut donc être représenté comme une caractéristique de courant continu, mais pas comme une caractéristique transitoire [37].

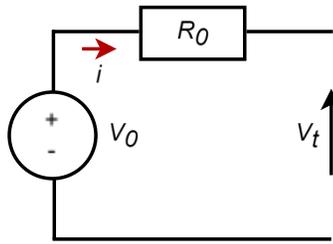


Figure 5 : Modèle simple de la batterie (modifié) [36].

L'expression mathématique de ce modèle est formulée à l'équation (2.4) en utilisant la tension en circuit ouvert (V_0), la tension aux bornes de la batterie (V_t) et la résistance interne (R_0) et le courant i .

$$iR_0 = V_0 - V_t, \quad (2.4)$$

❖ Modèle de Thevenin de premier ordre

Le modèle de batterie de Thevenin avec un circuit RC parallèle supplémentaire de la figure 6 inspirée de la référence [36] peut représenter les caractéristiques du comportement correspondant au changement de la charge transitoire de la batterie. La résistance transitoire R_1 est décrite comme une résistance non linéaire qui caractérise la résistance de contact entre l'électrolyte et la plaque. La capacité transitoire C_1 représente la capacité de la plaque parallèle [38].

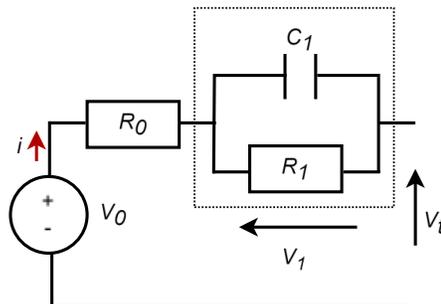


Figure 6 : Modèle de Thevenin de premier ordre (modifié) [36]

Pour ce modèle relativement simple, les équations mis en jeu sont en fonction de la tension en circuit ouvert (V_0), la tension aux bornes de la batterie (V_t), la résistance interne (R_0), la résistance de polarisation R_1 et la capacitance C_1 .

$$\frac{dV_1}{dt} = \frac{i}{C_1} - \frac{V_1}{R_1 C_1}, \quad (2.5)$$

$$V_t = V_0 - iR_0 - V_1, \quad (2.6)$$

Bien que ce modèle soit relativement simple, la précision de l'estimation de l'état de charge en se basant sur ce modèle diminue avec le vieillissement de la batterie [39].

❖ Modèle de Thevenin de second ordre

La figure 7 inspirée de [40] présente le modèle de Thevenin de second ordre composé d'une résistance interne ohmique R_0 et de deux structures parallèles ($R_1 C_1$ et $R_2 C_2$). Les deux structures RC décrivent les caractéristiques d'une polarisation électrochimique et d'une polarisation de la concentration de la batterie [41].

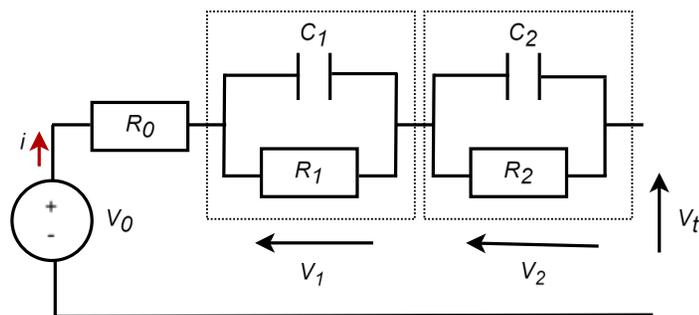


Figure 7 : Modèle de Thevenin de second ordre (modifié) [40]

Basée sur l'expression mathématique de la loi de Kirchhoff, les expressions mathématiques du modèle RC du second ordre sont les suivantes :

$$V_t = V_0 - iR_0 - V_1 - V_2, \quad (2.7)$$

$$\frac{dV_1}{dt} = \frac{i}{C_1} - \frac{V_1}{R_1 C_1}, \quad (2.8)$$

$$\frac{dV_2}{dt} = \frac{i}{C_2} - \frac{V_2}{R_2 C_2}, \quad (2.9)$$

❖ Modèle PNGV

Le modèle PNGV est un modèle de circuit équivalent proposé par Johnson et al. 2002 [42]. Il est basé sur le modèle de Thevenin de premier ordre auquel est ajouté une grande capacité C_b pour caractériser le changement de la tension en circuit ouvert de la batterie. Ce changement de tension est principalement causé par l'accumulation du courant de charge. La signification physique des autres paramètres est la même que celle du modèle de Thevenin. La structure du modèle équivalent PNGV est illustrée à la figure 8 inspirée de la référence [39].

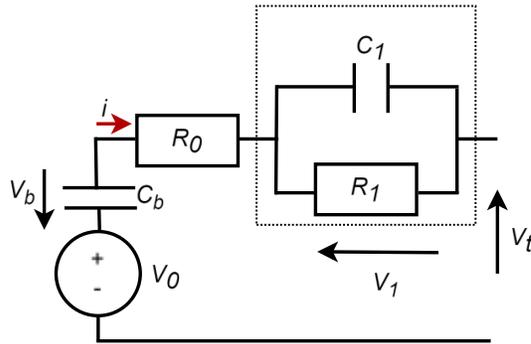


Figure 8 : Modèle PNGV (modifié) [39]

Ce modèle est régi par les équations ci-dessous :

$$\frac{dV_1}{dt} = \frac{i}{C_1} - \frac{V_1}{R_1 C_1}, \quad (2.10)$$

$$V_t = V_0 - iR_0 - V_1 - V_b, \quad (2.11)$$

$$V_b = C_b \int i(t) dt, \quad (2.12)$$

2.3 REVUE DE LA LITTÉRATUREE SUR L'ESTIMATION DE LA RÉSISTANCE ET DU *SoH* DE LA BATTERIE

Le vieillissement d'une batterie a deux origines principales. La première est la diminution de la capacité causée par la perte de substances actives à l'intérieur de la batterie et la seconde raison est la diminution de la puissance qui reflète l'augmentation de la résistance interne de la batterie [43]. La connaissance du *SoH* joue un rôle extrêmement vital dans les systèmes de gestion de batterie et constitue l'étape la plus critique pour améliorer la sécurité de fonctionnement de la batterie et minimiser sa dégradation [44]. En effet, le *SoH* indique un point de la durée de vie de la batterie et évalue le niveau des performances spécifiques actuelles par rapport à l'état neuf [45-48]. Il peut être estimé par une fonction mathématique à partir des paramètres de vieillissement tel que la résistance et la capacité de la batterie. De façon générale, le *SoH* basé sur la résistance interne (SoH_R) et celui basé sur la capacité (SoH_C) sont définis comme ci-après [49] :

$$SoH_R(i) = \frac{R_f - R(i)}{R_f - R_n} \times 100\% \quad (2.13)$$

$$SoH_C(i) = \frac{C(i)}{C_n} \times 100\% \quad (2.14)$$

R_n et C_n représentent respectivement la résistance et la capacité de batterie neuve; $R(i)$ et $C(i)$ les valeurs instantanées et R_f la résistance en fin de vie. Les méthodes d'estimation du *SoH* peuvent être regroupées en deux catégories : les méthodes basées sur l'extraction des quantités caractéristiques et les méthodes axées sur les données. L'utilisation de ces méthodes requiert des paramètres d'entrées comme la résistance, la température de la batterie, l'état de charge ou encore la tension qui peuvent servir à estimer le *SoH*. En se basant sur les mêmes méthodes, la résistance de la batterie qui est un paramètre non linéaire qui change en fonction de la température, du courant, et de l'état de charge [50, 51] peut également être estimer. Dans les sous-sections présentées ci-dessous, l'importance de l'identification des paramètres du modèle de la batterie sera premièrement abordée. Les méthodes basées sur l'extractions des caractéristiques de la batterie qui regroupent

l'analyse de la capacité incrémentale et l'analyse de la tension différentielle sont discutées en deuxième partie. La troisième sous-section expose les méthodes axées sur les données. L'accent serait d'abord mis sur les réseaux de neurones à action directe, les machines à support vectoriel et la régression de support vectoriel qui constituent la classe des réseaux de neurones non-récurrents. En fin, les réseaux de neurones récurrents tel que les réseaux de mémoire à long terme sont mis en évidence.

2.3.1 IDENTIFICATION DES PARAMÈTRES DU MODÈLE DE LA BATTERIE

Les circuits composés de sources de tension, de condensateurs et de résistances peuvent décrire les caractéristiques complexes des batteries. Il s'agit de modèles électriques de circuits équivalents, tels que le modèle de R_{int} [36], le modèle n-RC, qui modélise le comportement dynamique de la batterie, dont les plus connus sont le modèle 1-RC du premier ordre [52] et le modèle 2-RC du second ordre [40], le modèle de Thevenin [53] et sa version améliorée avec double polarisation [54]; et le modèle de Randles [55]. Liaw et al. 2004 [56] ont proposé un modèle qui peut simuler le comportement de la charge et de la décharge d'une batterie au lithium avec une grande fidélité et dont les résultats ont été validés par des données expérimentales. Le modèle dynamique de Gao et al. 2002 [57] prenant en compte la température ambiante, la source de chaleur et d'autres facteurs basés sur le modèle de circuit équivalent de Thevenin montre une bonne adaptabilité et une bonne précision. La batterie peut également être décrite par des modèles électrochimiques qui illustrent les changements internes de la batterie tels que les réactions électrochimiques et qui peuvent donner une idée de l'état de l'électrode à un moment donné [28, 29]. Au cours de la modélisation de la batterie, les paramètres du modèle sont identifiés à l'aide des filtres de Kalman [58], des filtres de Kalman doubles [59, 60], des filtres de Kalman doubles non accentués [61], la méthode des moindres carrés [62] ou des moindres carrés récursifs [63, 64]. Une fois que les paramètres du modèle de la batterie sont connus à partir des conditions de fonctionnement pendant le cycle initial, leur changement au cours des cycles suivants est un indicateur de la détérioration de la batterie et peut être utilisé pour estimer le SoH ou la résistance. Dans les sections 2.3.2 et 2.3.3,

l'estimation de la résistance et du *SoH* en utilisant la méthode basée sur l'extraction des caractéristiques de la batterie et celle basée sur les données sont présentée.

2.3.2 MÉTHODES BASÉES SUR L'EXTRACTION DES CARACTÉRISTIQUES DE LA BATTERIE

Les méthodes basées sur l'extraction des caractéristiques de la batterie se rapportent généralement à l'analyse de la capacité incrémentale et à l'analyse de la tension différentielle. Le principe reste le même pour les deux approches. En premier lieu, les caractéristiques de la batterie sont extraites. Ensuite, les techniques basées sur les données sont utilisées pour corrélérer les caractéristiques physiques avec le *SoH*. Le modèle appris est enfin utilisé pour estimer le *SoH* [65]. Les sections 2.3.2.1 et 2.3.2.2 donnent les détails sur ces deux méthodes.

2.3.2.1 ANALYSE DE LA CAPACITÉ INCRÉMENTALE

Dans la méthode d'Analyse de la Capacité Incrémentale (*ACI*), les courbes contenant des pics identifiables sont obtenues par différenciation du premier ordre de la capacité de charge ou de décharge de la batterie en fonction de la tension de la batterie (dQ/dV) [66]. Ces pics reflètent les mécanismes de dégradation à l'intérieur des batteries [67, 68]. Lu et al. 2023 [69] ont utilisé la méthode *ACI* pour identifier l'intervalle de tension contenant les pics de la courbe de capacité incrémentale (*CI*). Pour chaque variation de 0,1 mV dans l'intervalle de tension, le temps correspondant est calculé. Le vecteur temps est ensuite utilisé comme entrée d'un réseau de neurones récurrents (*RNR*) pour estimer le *SoH*. Quatre indicateurs de santé dérivés des courbes *CI* sont utilisés dans les travaux de Gismiro et al. 2023 [70]. Les auteurs ont démontré une relation linéaire entre les tensions de crête et de vallée et le *SoH*. Li et al. 2020 [71] ont utilisé les coordonnées des pics et des vallées ($dQ/dV, V$), les pentes gauche et droite et l'aire sous la courbe *CI* pour estimer le *SoH*. Dans les travaux ci-dessus, seules les caractéristiques de la courbe *CI* ont été utilisées

comme paramètres d'entrée pour l'estimation du *SoH*; pourtant, les caractéristiques de la courbe *CI* sont sensibles à la température de l'environnement et au taux de courant de charge ou de décharge. Dans les travaux de Peng et al. 2024 [72], en plus des caractéristiques de la courbe *CI* la résistance est également utilisée comme paramètres d'entrée pour établir un modèle hybride afin d'estimer le *SoH*.

2.3.2.2 ANALYSE DE LA TENSION DIFFÉRENTIELLE

La méthode d'analyse de la tension différentielle (*ATD*) est similaire à la méthode *ACI* et étudie l'état de vieillissement d'une batterie en utilisant la relation entre la capacité en charge ou en décharge (*Q*) et la tension différentielle (dV/dQ). Cette méthode s'est également avérée efficace pour l'estimation du *SoH* [73, 74]. Bien que les méthodes basées sur la méthode *ACI* et *ATD* puissent reconnaître les effets du cyclage et du vieillissement calendaire [75], et permettre une estimation facile du *SoH*, l'information clé de ces deux méthodes est liée à la chimie de la batterie [67]. De plus, pour estimer avec précision le *SoH* avec ces méthodes, la batterie doit être cyclée avec un faible courant de charge et de décharge afin que les pics puissent être détectés [66]. Dans la section 2.3.3, les méthodes basées sur les données dont le principe diffère de ce qui est présenté jusqu'ici sont exposées.

2.3.3 MÉTHODES AXÉES SUR LES DONNÉES

Les méthodes basées sur les données utilisent la relation entre les données d'entrée et de sortie pour estimer le *SoH* [76] ou la résistance. Sur cette base, de nombreuses caractéristiques sont élaborées en fonction de la compréhension de la dégradation des batteries, telles que les caractéristiques électriques [77, 78], les caractéristiques électrochimiques [79], les caractéristiques acoustiques [80], les caractéristiques mécaniques [81, 82] et les caractéristiques thermiques [83]. Ainsi, une fois que les caractéristiques sont extraites, elles sont mises en correspondance avec la dégradation du *SoH* ou de la résistance. Les méthodes d'apprentissage automatique basées sur les

réseaux de neurones artificiels considérées et analysées dans ce document sont présentées à la figure 9. Elles peuvent être regroupées en deux catégories : 1) les réseaux de neurones non-récurrents et 2) les réseaux de neurones récurrents. Ces deux catégories sont détaillées dans les sous-sections ci-après.

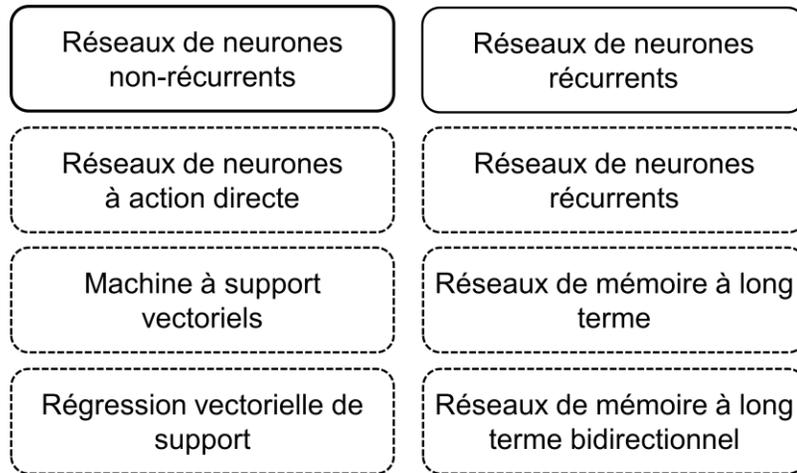


Figure 9 : Résumé structuré des méthodes d'apprentissage automatique considérées et analysées

❖ Les réseaux de neurones non-récurrents

○ Le réseau de neurones à action directe

Il s'agit d'un réseau de neurones artificiels non cyclique ou unidirectionnel composé d'une ou de plusieurs couches cachées. Pour une seule couche cachée, la somme pondérée des caractéristiques d'entrée et d'un biais est appliquée à une fonction d'activation dans les couches cachées de chaque neurone [84]. La fonction d'activation permet d'introduire la non-linéarité dans l'équation afin que le réseau ait la capacité de reproduire les modèles complexes. La figure 10 inspirée de la référence [85] montre la structure générale des neurones pour lequel le vecteur d'entrée (x_1, \dots, x_n) est associé à un coefficient appelé poids $(\omega_1, \dots, \omega_n)$.

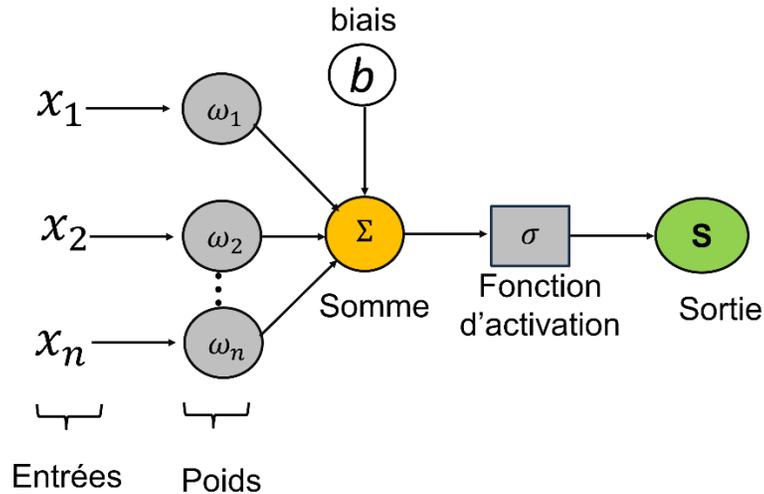


Figure 10 : Structure générale d'un neurone (modifiée) [85]

Pour améliorer les performances du réseau, la même procédure est répétée dans plusieurs couches cachées, produisant la (les) sortie(s) à la fin [84]. Dans la plupart des cas, une couche d'entrée contient les neurones responsables des données d'entrée. La dernière couche est la couche de sortie, qui contient la sortie du réseau. Les couches situées au milieu sont appelées couches cachées car leurs entrées et leurs sorties ne sont pas visibles au niveau de l'utilisateur. Ce type de réseau de neurones a fait l'objet de plusieurs travaux de recherche et de développement relatif à l'estimation du *SoH*. En effet, Degla et al. 2023 [18] ont considéré la tension de la batterie (U), le courant (I) et l'état de charge (*State of Charge* : SoC) comme des entrées pour estimer le *SoH*. Memon et al. 2022 [86] ont proposé un réseau hybride avec six couches cachées et un réseau en cascade prenant U , I et la température de la batterie (T_b) comme des entrées pour l'estimation du *SoH* et du SoC. La figure 11 inspirée de la référence [85] présente la structure générale d'un réseau de neurones à action directe.

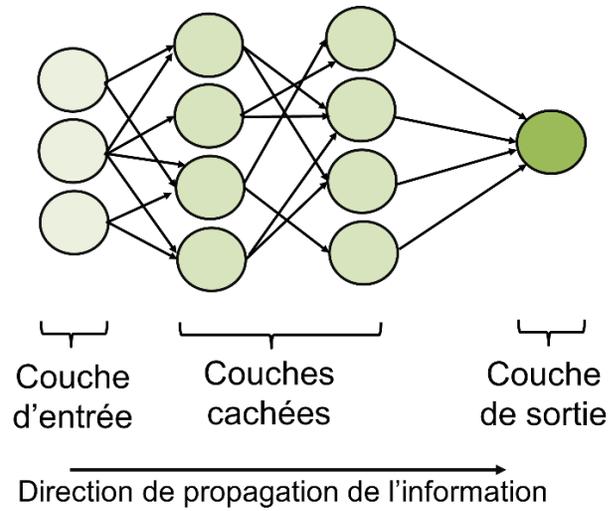


Figure 11 : Structure générale d'un réseau de neurones à action directe (modifiée) [85]

○ **Les Machines à Vecteurs de Support (SVM)**

Les machines à vecteurs de support sont des méthodes d'apprentissage automatique prometteuses, développées à l'origine pour les problèmes de classification binaire ou à deux classes, sur la base du principe de minimisation du risque structurel [87, 88]. Dans le cadre d'une classification binaire [89], on admet que $((x_1, y_1), \dots, (x_n, y_n))$ soient des données d'entraînement où x_i sont les vecteurs de caractéristiques représentant les instances et $y_i \in \{-1, +1\}$ sont les étiquettes de ces instances. À l'aide de l'ensemble d'apprentissage, le SVM construit un hyperplan optimal. La solution du SVM est obtenue en minimisant la fonction objective primaire suivante :

$$\min_{\omega, b} J(\omega, b) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i, \quad (2.15)$$

$$\text{avec } \forall_i \begin{cases} y_i(\omega \cdot \Phi(x_i) + b) \geq 1 - \xi_i \\ \xi_i \geq 0 \end{cases}, \quad (2.16)$$

où ω est le vecteur normal de l'hyperplan, b est le décalage, y_i sont les étiquettes, $\Phi(\cdot)$ est la cartographie de l'espace d'entrée à l'espace des caractéristiques et les ξ_i sont les variables qui permettent le cas non séparable en autorisant une mauvaise classification des instances d'apprentissage.

Sun et al. 2022 [90] ont extrait des caractéristiques efficaces et représentatives de la courbe de réponse à l'impulsion de tension en combinant différentes méthodes d'extraction de caractéristiques. Ensuite, les machines à vecteurs de support (*support-vector machine* : *SVM*) sont introduites pour estimer simultanément le *SoH* et le *SoC*. Li et al. 2021 [91] ont proposé dans un premier temps quatre nouvelles caractéristiques basées sur l'analyse de la capacité incrémentale. Le *SVM* est ensuite utilisé pour modéliser la fonction non linéaire entre les caractéristiques et le *SoH*. Les machines à vecteurs de support (*SVM*) ont la capacité de valider efficacement les théories avec un ensemble de données relativement restreint, fournissant des résultats satisfaisants pour des problèmes non linéaires et de haute dimension [92]. Par conséquent, elles répondent aux limites des méthodes d'apprentissage statistique conventionnelles.

La régression vectorielle de support (*SVR*) est un algorithme de régression basé sur la machine à vecteur de support (*SVM*). Il consiste à cartographier le vecteur de caractéristiques d'entrée dans un espace de caractéristiques à haute dimension [93]. Un hyperplan linéaire ou non linéaire est ensuite construit dans cet espace pour s'adapter aux données. L'hyperplan optimal est celui qui minimise l'erreur entre les échantillons d'entraînement et les valeurs prédites. Le *SVR* présente les avantages d'une bonne généralisation et d'une vitesse de convergence rapide, ainsi que des avantages spécifiques pour la gestion des petits échantillons et des problèmes non linéaires.

❖ Les réseaux de neurones récurrents

Comparé au réseau de neurones à action directe, un réseau de neurones récurrents (*RNR*) est un réseau dynamique qui peut montrer les caractéristiques dynamiques non linéaires d'un système en utilisant la rétroaction de l'état interne du réseau tel que présenté à la figure 12 inspiré de [94].

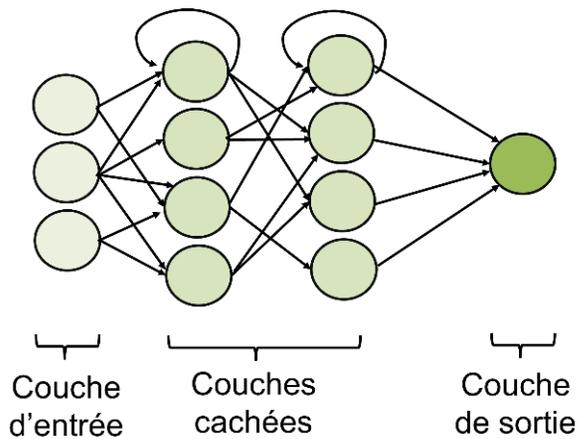


Figure 12 : Structure générale d'un réseau de neurones récurrents (modifiée) [94]

La structure du réseau récurrent dynamique est cependant complexe et la vitesse de convergence de l'algorithme d'apprentissage est lente [94]. Aussi, ce type de réseau de neurones souffre de l'apprentissage des dépendances à long terme [95]. En effet, le *RNR* n'est plus capable d'apprendre lorsqu'il stocke des informations pendant un certain temps. C'est là que le réseau de mémoire à long terme (*Long Short Term memory : LSTM*) prend tout son sens. Le réseau *LSTM* est utilisée par Nguyen et al. 2023 [96] pour estimer d'abord le *SoH*. Ensuite, le *SoH* estimée est utilisée comme entrée en plus de U , I et T_b pour l'estimation de la résistance. Des modèles de *LSTM* basés sur l'optimisation bayésienne des hyperparamètres [97] ou combinés à un perceptron multicouche [98] ont également été utilisés pour l'estimation du *SoH*.

Dans les travaux présentés ci-dessous, les paramètres et les méthodes utilisées pour estimer la résistance ou le *SoH* ont été identifiés. Dans la section 2.4, une analyse de la perspective de recherche est présentée.

2.4 ANALYSE DE LA PERSPECTIVE DE RECHERCHE

À l'issue de la revue de littérature, il ressort que les données utilisées pour l'estimation du *SoH* et de la résistance sont souvent acquises à une température ambiante fixe au-dessus de 273K avec une seule valeur de courant de décharge. Cela ne reflète pas les conditions réelles de fonctionnement de la batterie. En outre, les données de *SoH* varient entre 100% et 65% ; cependant, pour les applications secondaires, les valeurs de *SoH* sont généralement inférieures à 65%. L'analyse du tableau 2 qui fait le récapitulatif des travaux de recherche pour l'estimation de la résistance et du *SoH* révèle que pour les travaux [19], [86], [96] et [97] la température de la batterie est un paramètre non négligeable pris comme une entrée. En effet, pendant le fonctionnement de la batterie, deux sources interviennent dans la génération de la chaleur. La première est générée par effet Joule, considérée comme source irréversible, et la deuxième source de nature réversible, qui correspond à la chaleur produite à l'interface entre l'électrolyte et les électrodes, est d'origine thermodynamique [99]. Cependant, au cours de son vieillissement, la batterie est de plus en plus sensible à la température. Ainsi, cette intolérance est due à un cumul de phénomènes d'origine thermique qui pourrait plus impacter la batterie par rapport à la température instantanée considérée généralement dans les travaux. De ce fait, une hypothèse de recherche est élaborée dans ce sens afin de connaître l'impact de l'effet cumulé de la température de la batterie sur l'estimation de sa résistance et de son *SoH*. Par ailleurs, les travaux du tableau 2 révèle également que seul Nguyen et al. 2022 [96] ont utilisé le *SoH* comme une des entrées d'un réseau *LSTM* pour estimer la résistance.

TABLEAU 2 : Différence entre l'approche proposée et la revue littéraire

		Données		Méthode	Entrées	Sortie	Base de données	Plage de SoH
		Courant de décharge	Température ambiante					
Notre approche		10 A, 20 A, 27 A, 55 A	- 40°C, -25°C, 0°C, 25°C	Perceptron multicouches	-	SoH	Simulation	100% - 20%
1	Aicha DEGLA et al.2023 [18]	Variable	-	Perceptrons multicouches	V, I, SoC	SoH	Expérimentales	100% - 80%
2	Chi Nguyen Van et al. 2023 [96]	2A	24 °C	LSTM	V, I, T _b V, I, T _b , SoH	SoH R _e R _{ct}	NASA Ames Prognostics and Panasonic 18650PF Li-Ion Battery Data Repository	100% - 60%
3	Jamila Hemdani et al. 2023 [100]	3C à 0,5C	-	Réseaux de neurones profonds et réseaux de neurones convolutifs	V, I, SoC	C	Simulation du comportement de la batterie pour la création de la base de données	100% - 60%
4	Shaffa Ali Memon et al. 2022 [86]	2A	24 °C	Perceptron multicouches	V, I, T _b	SoH, SoC	NASA Ames Prognostics and Panasonic 18650PF Li-Ion Battery Data Repository	100% - 60%

		Données		Méthode	Entrées	Sortie	Base de données	Plage de SoH
		Courant de décharge	Température ambiante					
5	T.G. T. A. Bandara et al. 2021 [97]	2A	24 °C	Perceptron multicouches et LSTM dans un flux d'entraînement à 2 étapes	V, I, T _b poids en sortie du perceptron multicouches	SoH	NASA Ames Prognostics Center of Excellence (PCOE)	100% - 60%
6	Riya Sharma et al. 2023 [101]	25 A	-	LSTM basé sur l'optimisation bayésienne des hyperparamètres		SoH	-	100 - 65%
7	Shrinidhi Patil et al. 2023[19]	2A	24 °C	SVR	V, I, T _b	SoH	NASA Ames Prognostics Center of Excellence (PCOE)	100 - 65%

2.5 CONCLUSION

En résumé, cette revue de la littérature a exploré les différentes approches et perspectives sur l'estimation de la résistance et du *SoH* d'une batterie. Ainsi, après l'analyse des études récentes, il ressort qu'il est important de combiner plusieurs techniques pour améliorer la précision de l'estimation de la résistance et du *SoH*. Par exemple, l'intégration de modèles physiques avec des algorithmes d'apprentissage automatique permet de tirer parti des avantages de chaque approche. Aussi, les travaux de recherche analysés montrent une tendance générale vers l'utilisation de la tension, du courant, de l'état de charge et de la température de la batterie comme des paramètres d'entrée.

En conclusion, bien que des progrès significatifs aient été réalisés dans l'estimation de la résistance et du *SoH* des batteries, il reste encore beaucoup à faire pour atteindre des solutions optimales. Les futures recherches devraient se concentrer sur l'amélioration de la précision, la réduction de la complexité et l'augmentation de la robustesse des méthodes d'estimation. Ces efforts contribueront à la mise en place de systèmes de gestion de l'énergie plus efficaces et fiables, répondant aux besoins croissants des applications modernes. C'est ainsi qu'en se basant sur la revue de littérature, deux hypothèses de recherche sont posées et la méthodologie adoptée pour atteindre les objectifs du projet est proposée au chapitre 3.

CHAPITRE 3 MÉTHODOLOGIE

3.1. INTRODUCTION

L'estimation précise de la résistance interne et de l'état de santé (*SoH*) des batteries est cruciale pour garantir leur performance, leur sécurité et leur longévité, en particulier dans les applications critiques telles que les véhicules électriques et les systèmes de stockage d'énergie. La résistance interne d'une batterie influence directement son efficacité énergétique et sa capacité à fournir une puissance instantanée, tandis que le *SoH* reflète la capacité restante de la batterie par rapport à sa capacité initiale, indiquant ainsi son vieillissement et son usure. Ce chapitre présente la méthodologie utilisée pour estimer la résistance interne et le *SoH* d'une batterie. L'acquisition des données et leur prétraitement, les modèles aussi bien paramétriques que ceux basés sur les réseaux de neurones ainsi que les critères d'évaluation des performances des différentes approches sont abordés.

3.2. HYPOTHÈSES DE RECHERCHE

La revue de la littérature présentée dans le chapitre 2 a révélé que certains paramètres sont privilégiés au profit d'autres pour l'estimation de la résistance et du *SoH*. De plus, la plupart des travaux sont réalisés à une température ambiante constante ou variable mais au-dessus de 273K. Ceci ne reflète pas les conditions météorologiques réelles en Amérique du Nord. Aussi, les études sont réalisées non seulement avec un faible courant de décharge mais aussi avec des données de *SoH* utilisées qui sont comprises entre 100% et 65%. Pour finir, les recherches portant sur l'estimation de la résistance et du *SoH* considèrent les valeurs instantanées de la température de la batterie. Pour atteindre les objectifs de ce projet, deux hypothèses sont élaborées de la façon suivante :

- ❖ **Hypothèse 1** : la résistance et le *SoH* de la batterie peuvent être estimés à partir d'un modèle prenant en compte la température de la batterie ou son effet cumulé ;
- ❖ **Hypothèse 2** : le *SoH* est supposé être lié à un paramètre physique pouvant être décrit par un modèle de diffusion en phase solide.

Dans les prochaines sections, la méthodologie adoptée pour l'atteinte des objectifs du projet est exposée.

3.3 MÉTHODOLOGIE

Dans cette section consacrée à la méthodologie, les approches utilisées pour estimer la résistance interne et l'état de santé sont décrites. Cette méthodologie permet de fournir une compréhension détaillée des approches adoptées pour atteindre des résultats précis et fiables. Ainsi, les trois grandes parties constituant notre approche sont illustrées à la figure 13. Il s'agit de l'acquisition des données, l'estimation de la résistance et estimation du *SoH*.

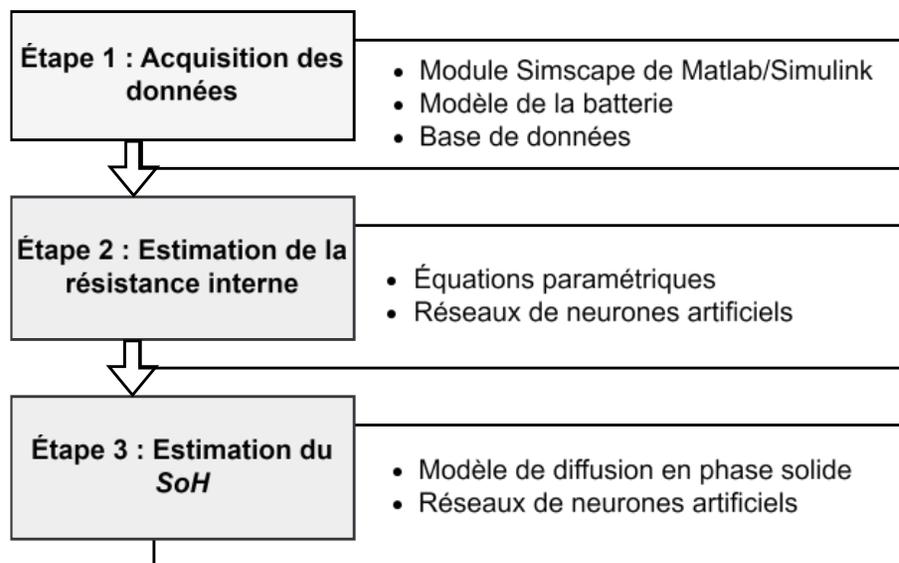


Figure 13 : Grandes étapes de la méthodologie adoptée

3.3.1 ACQUISITION ET PRÉTRAITEMENT DES DONNÉES

Le module *Simscape battery* de Matlab/simulink (version 2023b) fournit des outils de conception et des modèles paramétrés pour la conception de systèmes de batteries. Dans le cadre de notre projet, une batterie au lithium de 27Ah a été modélisée en utilisant le modèle de circuit électrique équivalent de premier ordre de Thevenin [52]. La charge s'effectue en mode courant constant (CC) avec un courant de 15A. Les grandes composantes du schéma *Simulink* sont présentées à la figure 14.

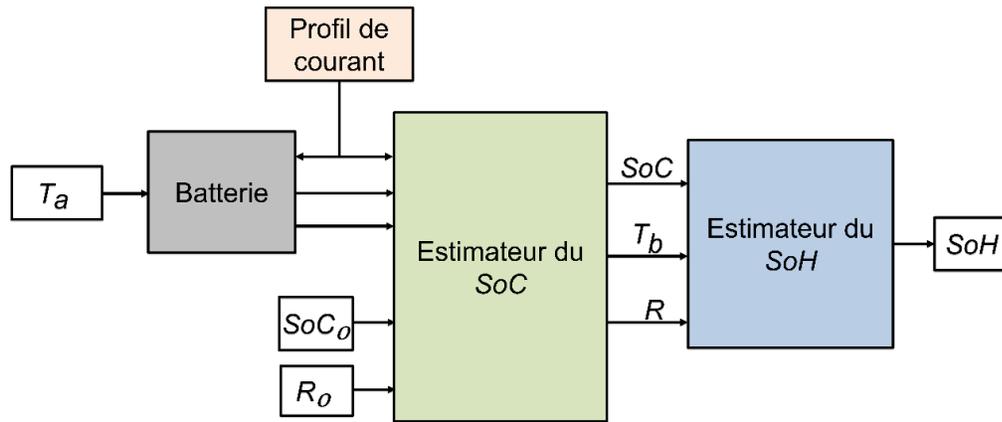


Figure 14 : Illustration du schéma *Simulink* du simulateur de batterie dans la Simscape de Mathworks

Le modèle de circuit équivalent de la batterie utilisée est illustré à la figure 15 et basé sur les travaux de Chiang et al. 2011 [52].

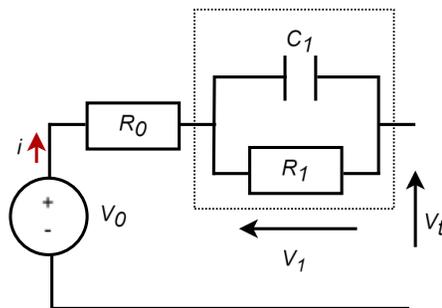


Figure 15 : Modèle de circuit équivalent de *Simscape* batterie (modifié) [52].

Ce modèle est régi par les équations (3.1) et (3.2) et le *SoH* est estimé en utilisant l'équation (2.13) ou (2.14).

$$\frac{dV_1}{dt} = \frac{i}{C_1} - \frac{V_1}{R_1 C_1} \quad (3.1)$$

$$V_t = V_0 - iR_0 - V_1 \quad (3.2)$$

R_0 et R_1 sont respectivement la résistance terminale et la résistance de polarisation; C_1 est la première capacité parallèle RC, V_0 , V_t et V_1 sont les tensions. Ainsi, à partir du module *Simscape* de Matlab/Simulink et du modèle de batterie, la base de données est créée. Elle est constituée par des données acquises aux températures ambiantes (T_a) de 233K, 253K, 273K et de 293K et pour des courants de décharge (I_d) de 10A, 20A, 27A et de 55A.

Les principales opérations de prétraitement des données consistent au nettoyage des données, à leur conversion, et leur amélioration.

❖ **Le nettoyage des données**

Cette action vise généralement à filtrer les données erronées selon certaines règles, à supprimer les données dupliquées et les valeurs aberrantes, et à compléter les valeurs manquantes. Ainsi, les valeurs précises sont obtenues dans la première étape du prétraitement des données [102, 103]. Dans l'exemple présenté à la figure 16, sur l'ensemble des données de résistance avant le prétraitement, trois (03) parmi elles se démarquent par rapport aux autres. Ces trois valeurs de résistance ne suivent pas la tendance générale des données. Il s'agit des données erronées qui sont remplacées par la valeur moyenne entre l'instant précédant la valeur incorrecte et l'instant d'après. Ceci permet d'obtenir une tendance plus réaliste après ce traitement tel que présenté sur la courbe de résistance de la deuxième colonne de la figure 16. Par ailleurs, sur les courbes de *SoH*, deux (02) valeurs ne suivent pas la tendance générale des données. Aussi, il y'a une donnée de *SoH* dont la valeur est supérieure à un. Cependant, il est reconnu que la valeur maximale du *SoH* est de 1. Alors, les données ont été corrigées en utilisant la moyenne tel que décrit précédemment.

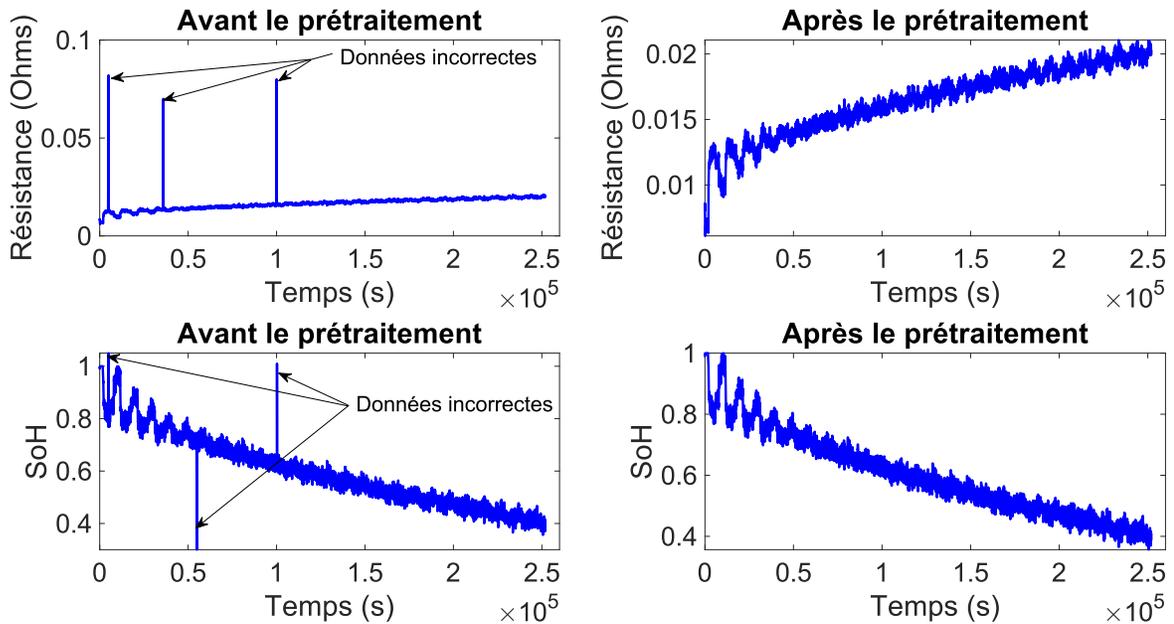


Figure 16 : Illustration du prétraitement en utilisant la valeur moyenne

❖ Conversion des données

Pour normaliser et standardiser les données autant que possible, les données sont intégrées, transformées et converties en une forme numérique plus facile à manipuler. La méthode min-max est celle utilisée pour la normalisation des données grâce à la formule (3.3) :

$$X_n(i) = \frac{X(i) - X_{min}}{X_{max} - X_{min}}, \quad (3.3)$$

où X_n est la valeur normalisée de la variable X dont les valeurs maximale et minimale sont respectivement X_{min} et X_{max} . Dans le cas précis de notre étude, la tension, le SoC, la température ont différent ordre de grandeur. Il est donc nécessaire de procéder à une normalisation. L'exemple de la figure 17 illustre la normalisation des données de tension en utilisant la méthode min-max.

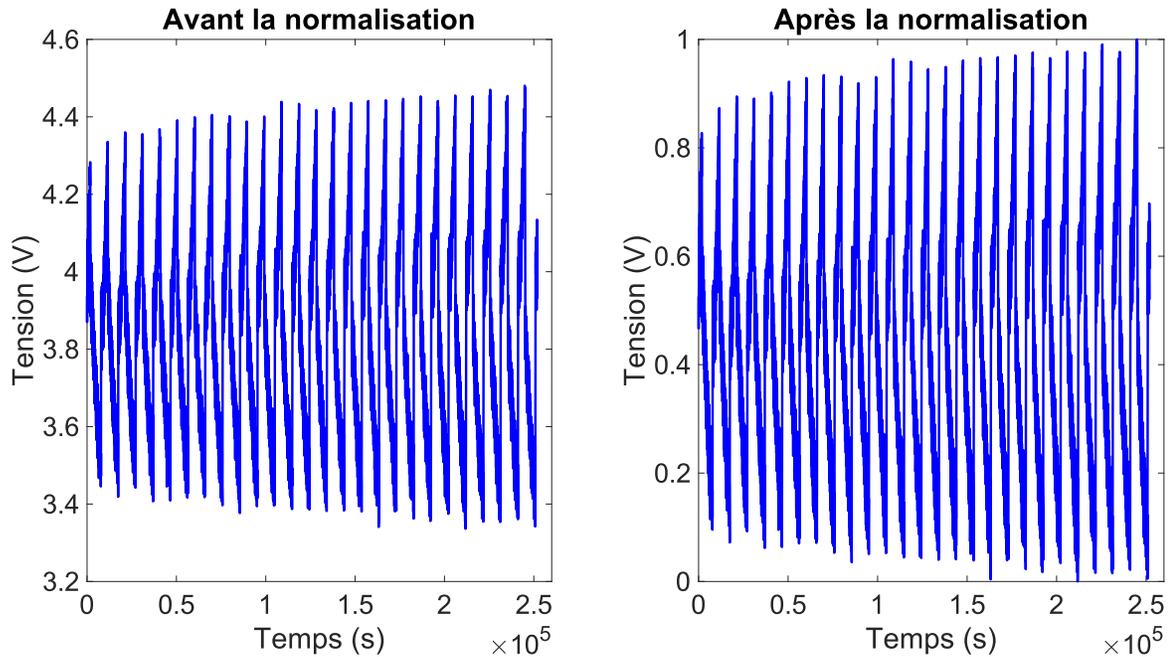


Figure 17 : Illustration de la normalisation des données de tension

❖ **Augmentation des données**

Lorsque les données originales sont manquantes ou peu nombreuses, il est souvent nécessaire de mettre en œuvre des actions d'amélioration sur les données, de concevoir des stratégies d'amélioration, de mettre en œuvre des transformations sur les données de séries temporelles, d'apprendre les lois et les caractéristiques intégrées dans les données et de générer de nouveaux ensembles de données afin d'améliorer la capacité de généralisation du modèle [104, 105]. Dans le cadre de cette étude, cette étape n'a pas été nécessaire car les données sont suffisantes et comprennent les données de *SoH* comprises entre 1 et 0,1.

3.3.2 ESTIMATION DE LA RÉSISTANCE INTERNE EN UTILISANT DES MODÈLES BASÉS SUR LES ÉQUATIONS PARAMÉTRIQUES

La tension, le courant, le *SoC*, et la température de la batterie sont quelques paramètres identifiés dans la revue de la littérature pour l'estimation de la résistance. Par conséquent, dans cette étude, la résistance interne de la batterie est estimée à l'aide de huit équations paramétriques ((3.4)

à (3.11)). L'étude de l'influence des différents paramètres sur l'estimation de la résistance interne et le choix de la meilleure équation sont faits à partir de ces équations :

$$R = \alpha_1 U + \beta_1 I + \gamma_1 SoC + \lambda_1 T_c , \quad (3.4)$$

$$R = \alpha_1 U + \beta_1 I + \lambda_1 T_c , \quad (3.5)$$

$$R = \alpha_1 U + \gamma_1 SoC + \lambda_1 T_c , \quad (3.6)$$

$$R = \beta_1 I + \gamma_1 SoC + \lambda_1 T_c , \quad (3.7)$$

$$R = \alpha_2 U + \beta_2 I + \gamma_2 SoC + \lambda_2 T_b , \quad (3.8)$$

$$R = \alpha_2 U + \beta_2 I + \lambda_2 T_b , \quad (3.9)$$

$$R = \alpha_2 U + \gamma_2 SoC + \lambda_2 T_b , \quad (3.10)$$

$$R = \beta_2 I + \gamma_2 SoC + \lambda_2 T_b , \quad (3.11)$$

α_i , β_i , γ_i et λ_i sont les coefficients de l'équation paramétrique. U , I , SoC , T_b sont respectivement la tension, le courant, l'état de charge et la température de la batterie. Comme souligné dans les travaux de Bako et al. 2019 [99], la source de chaleur dans la batterie est due à l'effet Joule et à la chaleur produite à l'interface entre l'électrolyte et les électrodes connue sous le nom de l'effet Peltier. Ainsi, la détérioration de la batterie étant une conséquence de petits changements répétés au fil des cycles de charges et de décharges, une température cumulée T_c peut être définie. Il s'agit d'une température qui est la résultante des petits changements passés qui est définie en fonction de la température ambiante T_a et de la température de la batterie T_b en utilisant l'équation (3.12).

$$T_c(i) = 0,1 \times (\sum_{i=1}^N T_b(1:i) - T_a) , \quad (3.12)$$

3.3.3 ESTIMATION DU SoH À PARTIR D'UN MODÈLE DE DIFFUSION EN PHASE SOLIDE

La détérioration de la batterie est souvent dû à plusieurs facteurs notamment la perte de mobilité des ions. Ceci engendre l'augmentation de la résistance des matériaux actifs qui réduit la diffusion des ions de l'intérieur de l'électrode vers l'interface électrode/électrolyte. Par conséquent, le

SoH peut être estimé en utilisant un modèle de diffusion considérant la résistance. Par ailleurs, la rétention de l'eau dans le sol est similaire au phénomène de diffusion des ions en phase solide dans la batterie. Pour décrire avec précision la courbe de rétention de l'eau dans le sol, le modèle Van Genuchten-Gupta [106] est couramment utilisé. C'est une fonction sigmoïde inversée qui lie le rendement des cultures à la salinité du sol. Ainsi, par similitude, une version modifiée de ce modèle a été utilisée pour estimer le *SoH* qui est inversement proportionnelle à la résistance interne. Partant du principe que la résistance interne est l'un des indicateurs de la dégradation de la batterie d'après l'expression mathématique (2.13) du *SoH* en fonction de la résistance [49], l'équation modifiée (3.13) basée sur le modèle de Van Genuchten-Gupta est utilisée pour estimer le *SoH* :

$$SoH_G = \frac{p_1}{p_2 + \left(\frac{R}{R_{50\%}}\right)^{p_3}}, \quad (3.13)$$

où p_1 , p_2 , et p_3 , sont les paramètres du modèle, R est la résistance actuelle, $R_{50\%}$ est la valeur de résistance pour un $SoH = 50\%$. Les paramètres (p_i) de l'équation proposée peuvent être estimés à partir de la température ambiante (T_a) en utilisant l'équation (3.14).

$$p_i = a_i T_a^3 + b_i T_a^2 + c_i T_a + d_i \quad (3.14)$$

3.3.4 ESTIMATION DE LA RÉSISTANCE ET DU *SoH* À PARTIR D'UN RÉSEAU DE NEURONES ARTIFICIELS

Parmi les techniques d'apprentissage automatique présentées dans la revue littéraire, les réseaux de neurones à action directe semblent mieux adaptés à notre problématique. En effet, compte tenu de l'existence des liaisons cycliques des réseaux récurrents, leur vitesse de convergence est lente [94] par rapport au réseau à action directe. Ainsi, l'estimation de la résistance et du *SoH* en utilisant un réseau de neurones artificiels (*RNA*) implique la construction d'un modèle

qui apprend à partir des données historiques de la batterie, englobant les paramètres de la batterie avec les valeurs correspondantes de la résistance ou du *SoH* [107]. À partir des ajustements itératifs des poids et des biais, les *RNA* modélisent les relations complexes entre les caractéristiques d'entrée, la résistance et le *SoH*. L'architecture du réseau, les fonctions d'activation et les hyperparamètres tels que le nombre de couches et le taux d'apprentissage sont affinés pour optimiser les prédictions de la résistance et du *SoH* [108]. Le *RNA* formé peut prédire les valeurs de la résistance et du *SoH* sur la base des données actuelles de la batterie, contribuant ainsi à la maintenance proactive et à la prise de décision dans les systèmes dépendants de la batterie [109]. Les *RNA* présentent l'avantage de saisir des relations complexes entre les données, ce qui les rend appropriés pour l'estimation de la résistance et du *SoH*. Cependant, une conception minutieuse de l'architecture du réseau et un prétraitement sont essentiels pour obtenir des résultats optimaux [110]. Dans le cadre de ce projet, un réseau de neurones à action directe dont les détails sont présentés dans la section 3.4.1 a été utilisé.

3.3.4.1 PRINCIPE DE FONCTIONNEMENT D'UN RÉSEAU DE NEURONES À ACTION DIRECTE

Le fonctionnement de ce type de réseau de neurones est présenté dans les travaux de Ren et al. 2023 [111] et dont la structure est illustrée à figure 18 qui est inspiré des mêmes travaux.

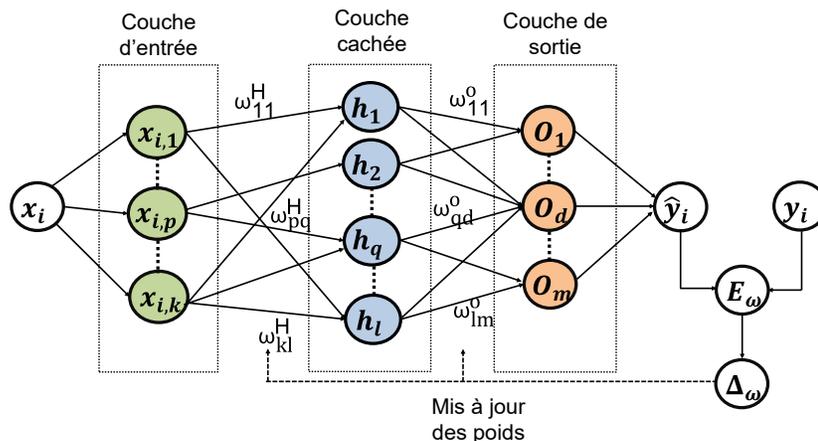


Figure 18 : Structure d'un réseau de neurones à action directe (modifiée) [111]

En effet, l'ensemble de données d'apprentissage est constitué de N vecteurs d'entrée à k dimensions $X = (\{x_i\}_i^N, x_i \in \mathbf{R}^k)$ et les vecteurs de sortie de dimensions m correspondants $Y = (\{y_i\}_i^N, y_i \in \mathbb{R}^m)$. Le processus de propagation de l'information des neurones d'entrée, s'explique comme suit. Tout d'abord, les sorties des neurones de la couche cachée sont exprimées à travers les équations (3.15) et (3.16) :

$$net_q = (\sum_{p=1}^k \omega_{pq}^H x_{i,p} + b_q, q = 1, \dots, l), \quad (3.15)$$

$$f_h(net_q) = \frac{1}{1 + e^{-(net_q)}}, \quad (3.16)$$

où $x_{i,p}$ est la $p^{\text{ième}}$ caractéristique du $i^{\text{ième}}$ échantillon de données dans la couche d'entrée ; ω_{pq}^H est le poids reliant le $p^{\text{ième}}$ neurone d'entrée et le $q^{\text{ième}}$ neurone caché ; b_q est le biais du $q^{\text{ième}}$ neurone caché ; net_q est la $q^{\text{ième}}$ composante du vecteur d'entrée de la couche cachée ; $f_h(net_q)$ est la fonction d'activation des neurones de la couche cachée, la fonction sigmoïde étant la plus largement utilisée, comme le montre l'équation (3.16) ; et l est le nombre de neurones dans la couche cachée. D'autres fonctions d'activation populaires, notamment la tangente hyperbolique ($tanh$), le nœud linéaire ($ReLU$) rectifié et le $ReLU$ fuyant, peuvent être sélectionnées en fonction des différentes exigences de l'application spécifique. Deuxièmement, de la couche cachée à la couche de sortie, les expressions sont les suivantes :

$$net_d = (\sum_{p=1}^k \omega_{qd}^0 h_q + b_d, d = 1, \dots, l), \quad (3.17)$$

$$f_0(net_d) = \frac{1}{1 + e^{-(net_d)}}, \quad (3.18)$$

où h_q est la $q^{\text{ième}}$ sortie de la couche cachée, net_d est la $d^{\text{ième}}$ composante de la couche de sortie, ω_{qd}^0 est le poids reliant le $q^{\text{ième}}$ neurone caché et le $d^{\text{ième}}$ neurone de sortie, $f_0(net_d)$ est la fonction d'activation des neurones de la couche de sortie, et m est le nombre de neurones dans la couche de sortie. Le processus d'apprentissage vise à trouver les valeurs optimales des poids et des biais afin

de minimiser la fonction de perte. Jusqu'à présent, l'algorithme le plus utilisé est la rétropropagation. Le processus de l'algorithme de rétropropagation peut être divisé en deux phases : la phase avant et la phase rétrospective. Plus précisément, la phase avant est la même que celle formulée à travers les équations (3.15) à (3.18) et calcule la sortie estimée. La phase rétrospective utilise les équations (3.19) et (3.20) pour mettre à jour les poids à chaque itération en calculant le gradient d'une fonction de perte arbitraire (E_ω).

$$\frac{\partial E_\omega}{\partial \omega_{ij}} = \frac{\partial E_\omega}{\partial S_{ij}} \frac{\partial S_{ij}}{\partial net_i} \frac{\partial net_i}{\partial \omega_{ij}} \quad (3.19)$$

où ω_{ij} représente le poids, tel que ω_{qd}^0 et ω_{pq}^H ; S_i représente la sortie du neurone, tel que $f_h(net_q)$ et $f_0(net_d)$; et net_i est l'entrée du neurone, tel que net_q et net_d . Une fois que la dérivée partielle de chaque poids est connue, les poids à l'étape actuelle ($n + 1$) peuvent être mis à jour à l'aide de l'étape précédente (n), comme suit :

$$\omega_{ij}(n+1) = \omega_{ij}(n) + \alpha \frac{\partial E_\omega}{\partial \omega_{ij}(n)}, \quad (3.20)$$

où α est le taux d'apprentissage. En fonction des paramètres spécifiques de l'algorithme de rétropropagation, différentes conditions, telles que le nombre d'itérations et le taux d'amélioration de l'erreur peuvent être considérées comme le critère d'arrêt du processus d'apprentissage.

3.3.4.2 APPRENTISSAGE PAR LA MÉTHODE DE VALIDATION CROISÉE

L'ajustement des poids du réseau de neurones en fonction de la sortie désirée permet le plus souvent d'améliorer ses performances. Cependant, une autre technique qui permet de réduire le biais entre la sortie réelle et estimée est la méthode d'apprentissage par validation croisée en k-jeux de

données. Il s'agit d'une méthode d'évaluation des modèles d'apprentissage automatique qui consiste à entraîner sur des sous-ensembles distincts des données d'entrée disponibles, puis à les valider sur l'autre groupe. La validation croisée permet de détecter le surapprentissage qui se produit lorsqu'un modèle ne parvient pas à se généraliser [112]. Ainsi, dans le cadre de notre projet, les données acquises pour chaque température ambiante constituent un sous-ensemble utilisé dans la méthode de la validation croisée. Quatre sous-ensembles ont été alors définis en fonction des températures ambiantes 233K, 253K, 273K et 293K. À chaque itération, trois (03) jeux de données sont utilisées pour l'entraînement et le jeu de données restant est consacré à la validation. En effet, à la première itération, les sous jeux de données 2,3,4 sont utilisés pour l'apprentissage et le jeu de donnée 1 pour la validation. L'apprentissage à l'itération 2 est effectuée avec les jeux de donnée 1, 3, 4 et la validation avec le jeu de donnée 2. Ce processus est répété jusqu'à ce que tous les jeux de données soient utilisés pour la validation tel que présenté à la figure 19.

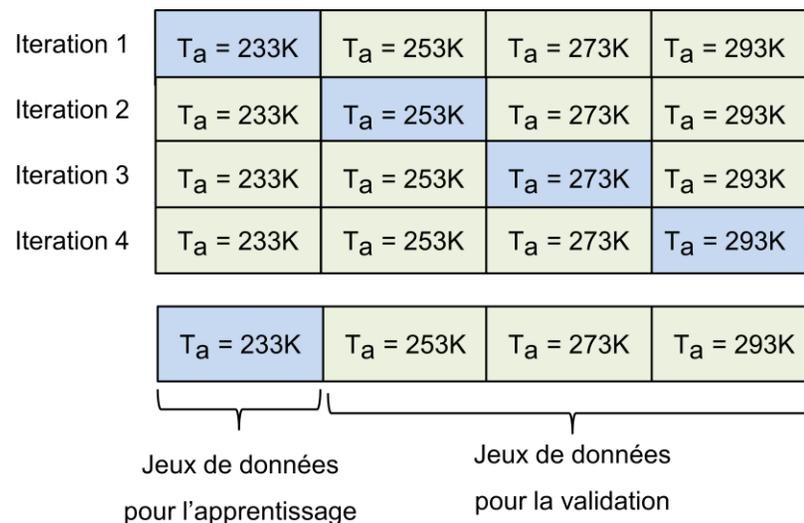


Figure 19 : Principe de l'apprentissage par la validation croisée en k-jeux de données

Par ailleurs, grâce aux modèles paramétriques des équations 3.4 à 3.11, les caractéristiques pertinentes ont été identifiées afin d'aider le modèle à mieux comprendre les données. Aussi le nombre d'itération est ajusté afin de permettre au modèle d'apprendre davantage. Ces actions permettent d'éviter le sous apprentissage et le sur-apprentissage.

3.4.3 ESTIMATION DE LA RÉSISTANCE et du *SoH* EN UTILISANT UN RÉSEAU DE NEURONES

À partir des équations paramétriques utilisées pour estimer la résistance interne de la batterie, les paramètres de la meilleure équation ont été retenus. Ainsi, ces meilleurs paramètres sont utilisés comme entrées d'un réseau de neurones à action directe pour estimer la résistance. La résistance estimée est ensuite utilisée comme seule entrée d'un autre réseau de neurones pour l'estimation du *SoH*. La figure 20 illustre la méthodologie adoptée et est basé sur l'article de Foussemi et al. 2024 [113].

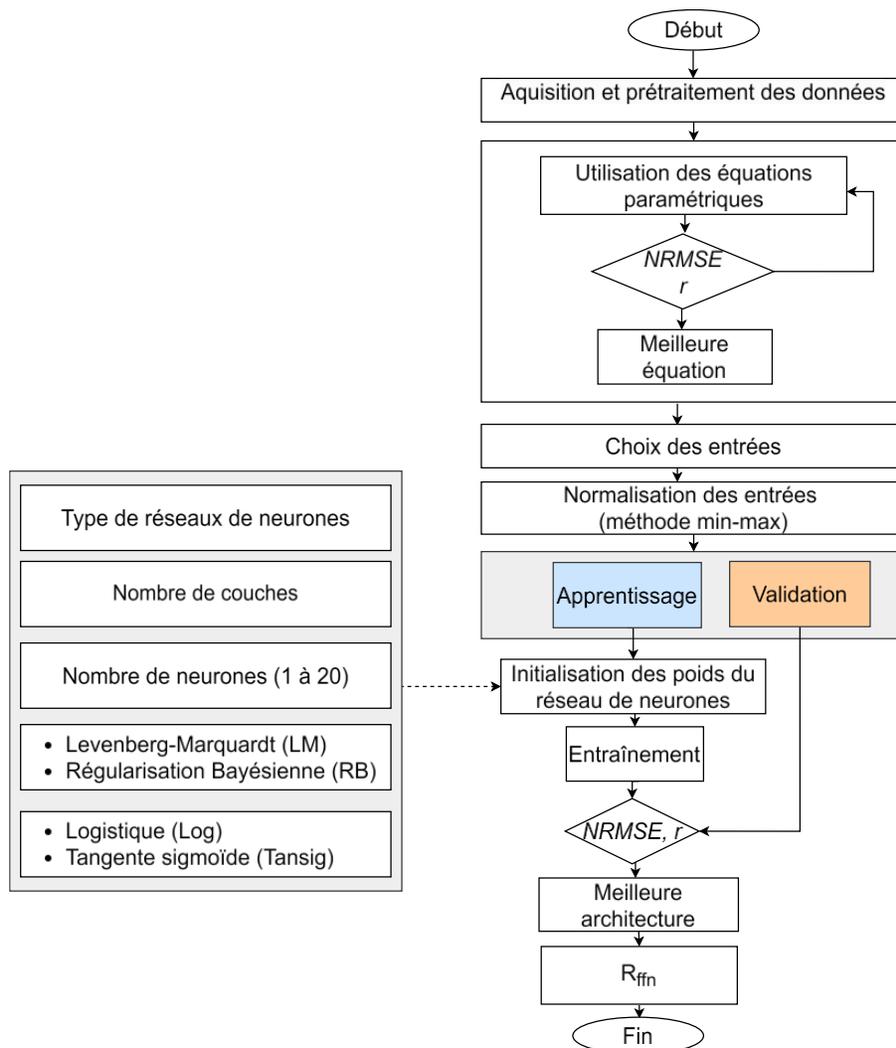


Figure 20 : Méthodologie pour l'estimation de la résistance (modifiée) [113]

Pour mieux identifier les meilleurs modèles et pour une bonne interprétation des résultats, deux métriques de performances ont été utilisées. Ces métriques sont définies à la section 3.4.4 de ce document.

3.4.4 ÉVALUATION DES PERFORMANCES

La racine carrée de l'erreur quadratique moyenne normalisée (*Normalized Root Mean Square Error : NRMSE*) et le coefficient de corrélation r ont été utilisés pour évaluer les performances de nos modèles. Le *NRMSE* est une métrique qui indique la distance moyenne entre les valeurs estimées par le modèle et les valeurs réelles. Le coefficient r est la mesure de la force de la relation entre deux variables. Les formules décrivant ces métriques sont données par les équations (3.21) et (3.22) où Y_i et T_i sont respectivement les valeurs estimées et les valeurs réelles, \bar{Y} et \bar{T} sont leur moyenne respective, Y_{max} et Y_{min} leur valeur maximale et minimale.

$$NRMSE = \frac{\sqrt{\left(\frac{1}{N} \sum_{i=1}^N (Y_i - T_i)^2\right)}}{Y_{max} - Y_{min}}, \quad (3.21)$$

$$r = \frac{\sum_{i=1}^N (Y_i - \bar{Y})(T_i - \bar{T})}{\sqrt{\sum_{i=1}^N (Y_i - \bar{Y})^2} \sqrt{\sum_{i=1}^N (T_i - \bar{T})^2}}, \quad (3.22)$$

3.5 CONCLUSION

Dans ce chapitre, les méthodologies utilisées pour estimer la résistance interne et le *SoH* d'une batterie au lithium ont été explorées. Ces deux paramètres sont cruciaux pour évaluer la performance et la longévité des batteries, particulièrement dans les applications critiques telles que les véhicules électriques et les systèmes de stockage d'énergie. Ainsi, les méthodes basées sur l'utilisation des équations paramétriques et d'un réseau de neurones à action directe pour l'estimation de la résistance interne ont discutées. L'identification des paramètres pertinents pouvant être utilisés

comme entrée du réseau de neurones et l'ajustement du nombre d'itération sont connus pour éviter le sous apprentissage. La méthode de validation croisée en k-jeux de données par contre est une technique pouvant être appliquée dans notre cas d'étude pour éviter le sous apprentissage et le surapprentissage. En ce qui concerne le *SoH* plusieurs approches ont été examinées notamment un modèle de diffusion en phase solide et un réseau de neurones. Le prochain chapitre présentera les résultats obtenus à partir des méthodologies discutées. Dans ce prochain chapitre, les données collectées seront analysées et la précision des estimations de la résistance interne et du *SoH* seront évaluées. Les résultats permettront de valider les approches méthodologiques et de proposer des recommandations pour l'amélioration des systèmes de gestion de batteries.

CHAPITRE 4 RÉSULTATS ET DISCUSSIONS

4.1 INTRODUCTION

Dans ce chapitre, les résultats obtenus sur les données de validation à partir des méthodologies d'estimation de la résistance interne et du *SoH* sont présentés et discutés. Ces résultats sont essentiels pour valider les approches méthodologiques et pour proposer des recommandations visant à améliorer les systèmes de gestion de batteries. Les données sont dans un premier temps présentées et analysées. Cette analyse permet de comprendre les tendances et les variations observées dans les performances des batteries. Ensuite, une estimation de la résistance interne à partir de différentes approches est réalisée. Les résultats des différentes méthodologies sont comparés afin d'évaluer leur précision et leur fiabilité. Cette évaluation est cruciale pour déterminer quelles méthodes offrent les estimations les plus exactes et les plus cohérentes. Pour finir, les résultats d'estimation du *SoH* sont présentés et discutés.

4.2 PRÉSENTATION DES DONNÉES

La figure 21 issue des travaux de Fousseni et al. 2024 [113] présente les données de *SoH* et de résistance interne de la batterie pour plusieurs températures ambiantes et pour un courant de décharge de 10A. L'analyse de la figure 21 révèle une variation du *SoH* et de la résistance en fonction de la température ambiante. En effet, pour les températures ambiantes très basses ($T_a = 233\text{K}$ et $T_a = 253\text{K}$), les réactions chimiques à l'intérieur de la batterie ralentissent. Une augmentation de la résistance interne de la batterie est ainsi observée. Toutefois, dans les environnements chauds ($T_a = 273\text{K}$ et $T_a = 293\text{K}$), les réactions chimiques dans la batterie s'accélèrent entraînant sa dégradation rapide. Cette dégradation se manifeste par des valeurs de *SoH* plus basses pour des températures chaudes par rapport aux températures froides.

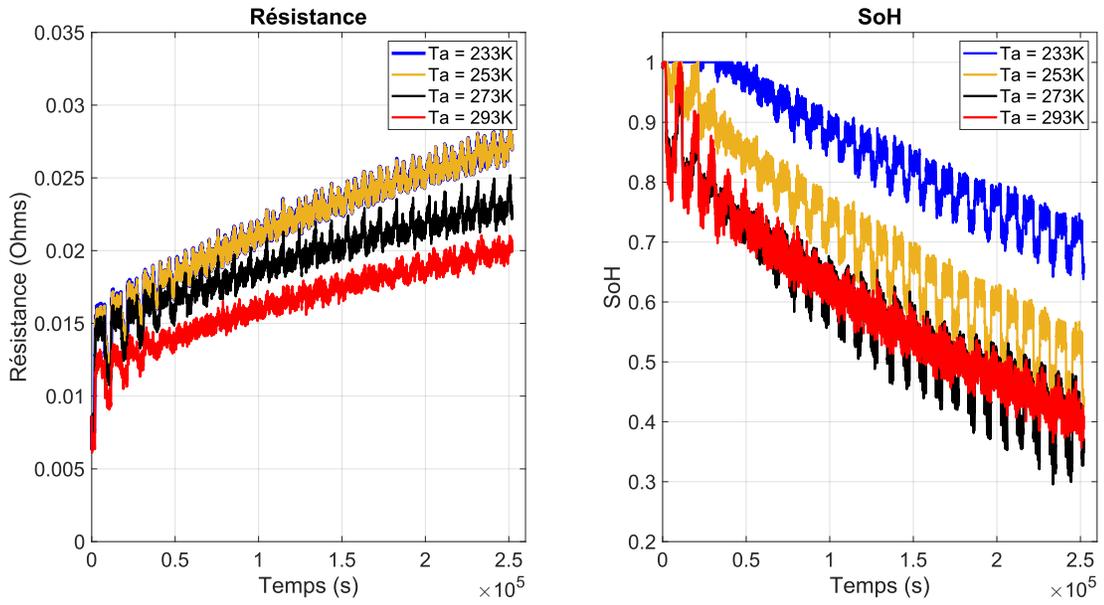


Figure 21 : *SoH* et résistance $I_d = 10A$ pour plusieurs températures ambiantes [113]

Les performances d'une batterie sont également influencées par le courant de décharge. La figure 22 présente la résistance et le *SoH* de la batterie sous plusieurs courants de décharge et à une température ambiante $T_a = 293K$.

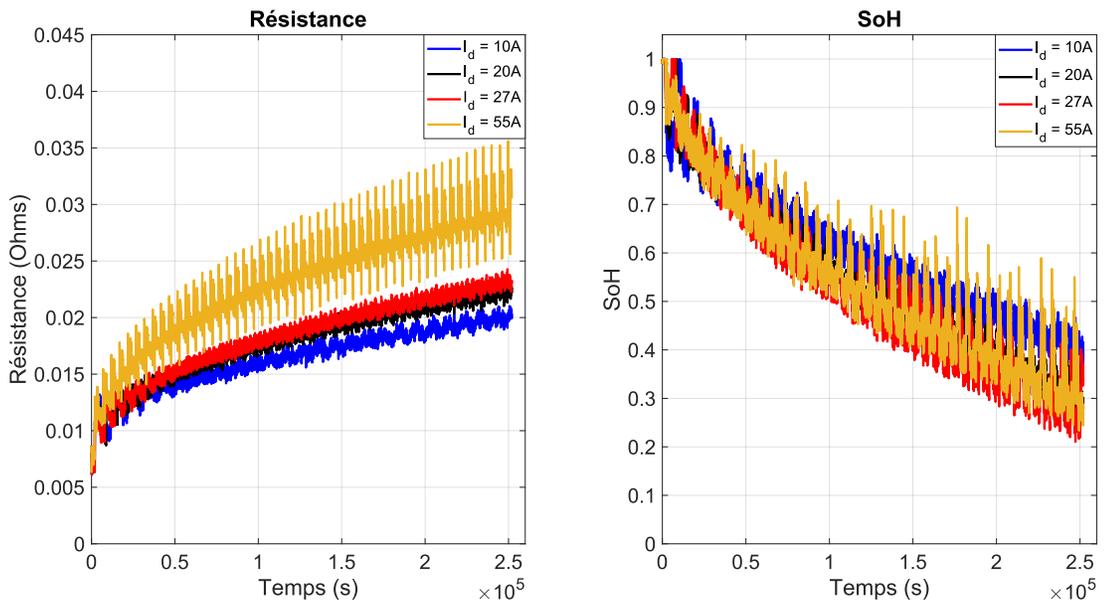


Figure 22 : *SoH* et résistance à $T_a = 293K$ pour plusieurs courants de décharge [113]

Sur cette figure, pour des courants de décharge élevés, la batterie s'échauffe plus rapidement causant une augmentation de sa résistance interne. Par conséquent, la batterie subit un vieillissement accéléré qui est illustré par une diminution rapide de son *SoH*.

Les figure 21 et figure 22 ont révélé non seulement que la résistance interne et le *SoH* dépendent de la température et du courant de décharge mais aussi que leur variation est en accord avec la théorie. Ceci confirme l'exploitabilité de ces données. Ainsi, dans la suite de ce document les résultats d'estimation de la résistance et du *SoH* seront présentés tout en considérant les autres paramètres qui les impactent.

4.3 ESTIMATION DE LA RÉSISTANCE INTERNE DE LA BATTERIE

La résistance interne est un indicateur clé de l'efficacité énergétique et de la capacité de la batterie à fournir des courants élevés sans perte significative de tension. Dans les sous-sections ci-dessous, les résultats des approches basées sur l'utilisation des équations paramétriques et un réseau de neurones sont tour à tour présentées.

4.3.1 ESTIMATION DE LA RÉSISTANCE INTERNE DE LA BATTERIE EN UTILISANT LES ÉQUATIONS PARAMÉTRIQUES

Les métriques de performance de l'estimation de la résistance interne de la batterie à partir des équations paramétriques pour un courant de décharge de 10A sont présentées à la figure 23. L'analyse de cette figure révèle d'une part que parmi les équations paramétriques prenant en compte l'effet cumulé de la température T_c , celle considérant U , I , SoC et T_c présente des valeurs de *NRMSE* inférieures à 5%. Pour les autres équations considérant T_c , le *NRMSE* augmente avec la température et atteint 21% pour $T_a = 293K$.

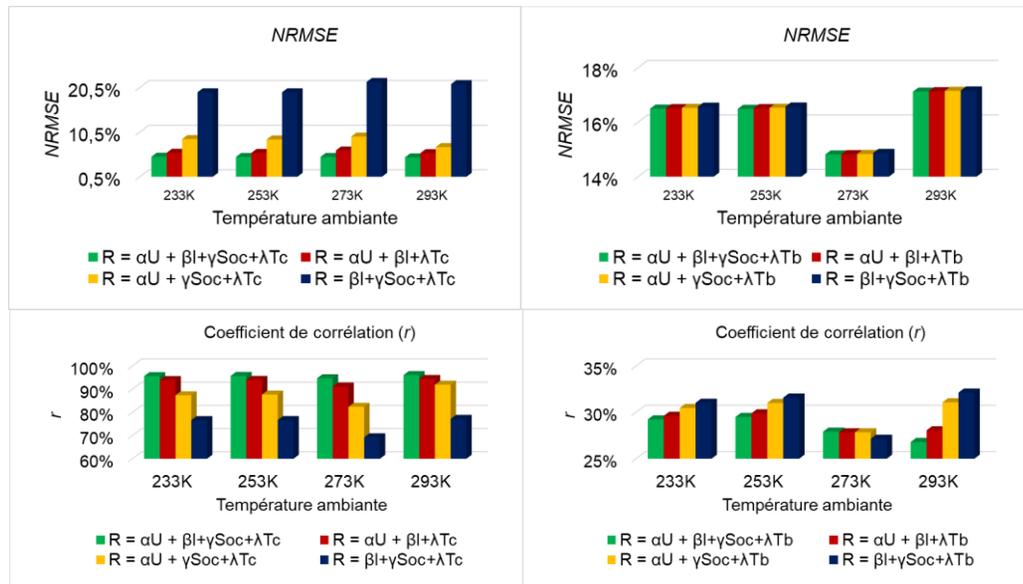


Figure 23 : Performances des équations paramétriques pour $I_d = 10 A$

La résistance est estimée avec l'équation 3.4 avec un coefficient de corrélation supérieur à 90% pour toutes les températures ambiantes considérées dans le cadre de cette étude. D'autre part, les équations prenant en compte la température de la batterie T_b permettent d'estimer la résistance avec des valeurs de *NRMSE* autour de 16% excepté pour une température ambiante $T_a = 273K$. Leur coefficient de corrélation est inférieur à 35%. Ainsi, en considérant la température T_b , la résistance estimée dans le temps varie autour d'une valeur moyenne fixe (0.022 Ohms).

Les valeurs de résistance estimées par les meilleurs équations paramétriques (3.4) et (3.8) pour un courant de décharge $I_d = 10A$ sont présentées à la figure 24. Ainsi, les données estimées par l'équation (3.4) qui prend en compte U , I , SoC et T_c suivent les données réelles de résistance par rapport à l'équation (3.8) qui considère U , I , SoC et T_b . La présence de T_c dans l'équation renforce la capacité du modèle à suivre les données réelles de résistance dans le temps. Cependant, les non-linéarités en début de courbe ne sont pas bien illustré par l'équation paramétrique (3.4). Ce phénomène est lié aux conditions initiales des données réelles qui pourrait également être à l'origine des écarts d'amplitudes observés pour $T_a = 233K$.

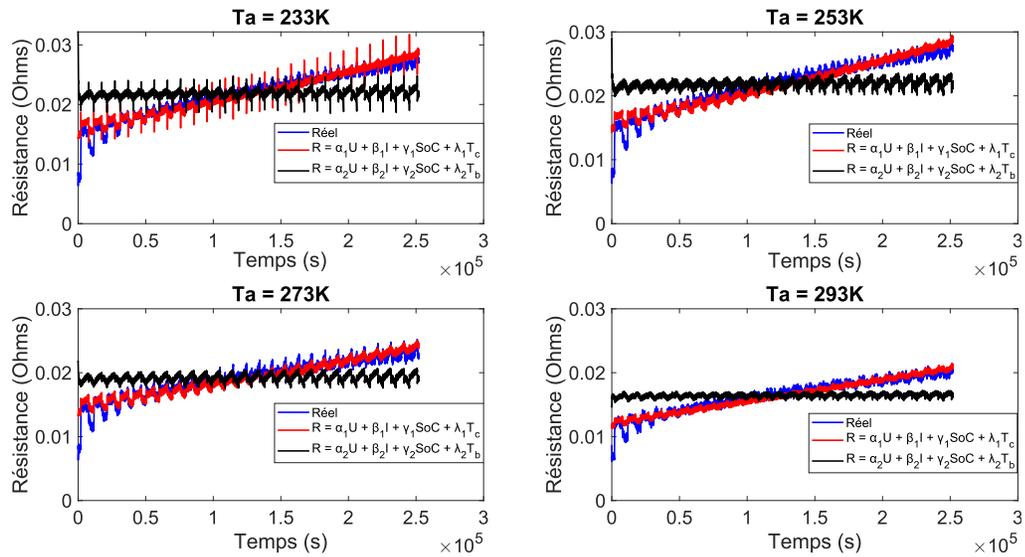


Figure 24 : Résistance estimée à partir d'une équation paramétrique pour $I_d = 10A$

Pour un courant de décharge de 20A, les performances de l'équation paramétrique (3.4) qui est fonction de U , I , SoC et T_c sont meilleures que les autres équations telles qu'illustré sur les diagrammes en bar de la figure 25. En effet, pour cette équation, la résistance est estimée avec un $NRMSE$ qui varie entre 3% et 5% tandis que le coefficient de corrélation r est supérieur à 95% pour toutes températures ambiantes considérées.

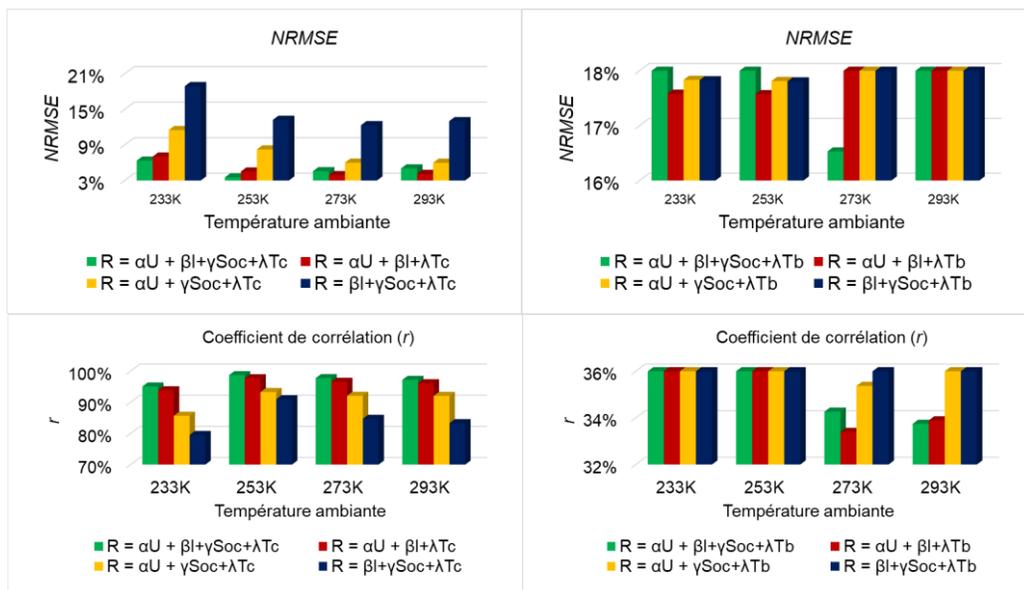


Figure 25 : Performances des équations paramétriques pour $I_d = 20 A$

La figure 26 présente les courbes d'estimation de la résistance pour un courant de décharge de 20A. L'équation (3.4) prenant en compte U , I , SoC et T_c offre une meilleure illustration de la variation de la résistance interne de la batterie en fonction du temps. En effet, la courbe en rouge est parfaitement alignée avec la courbe des données réelles en bleu. Néanmoins, les écarts d'amplitudes pour $T_a = 233K$ et la mauvaise estimation des non-linéarités en début de courbe sont également observés dans ce cas d'étude.

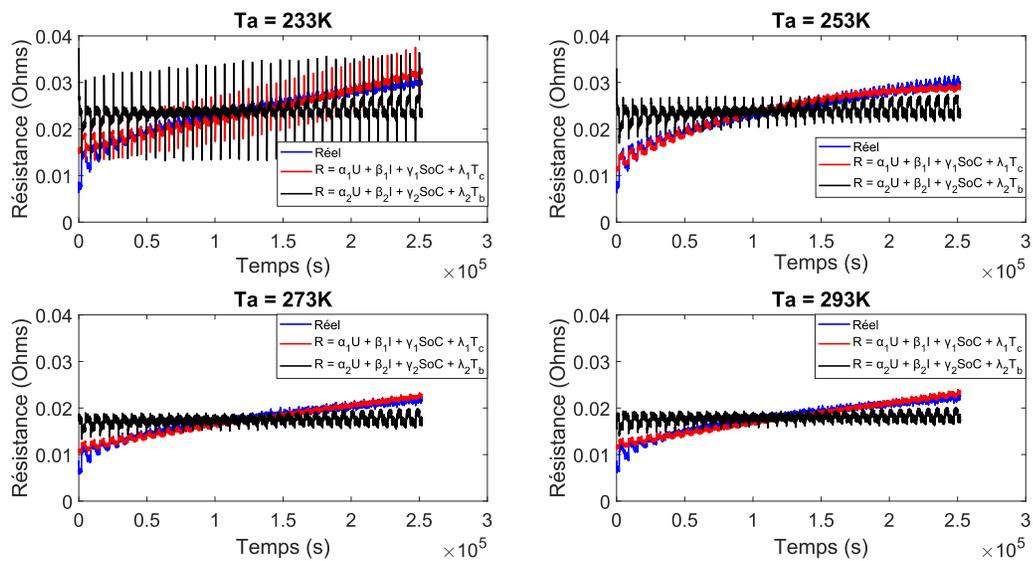


Figure 26 : Résistance estimée à partir d'une équation paramétrique pour $I_d = 20A$

À un courant de décharge de 27A, la résistance est estimée avec une valeur de $NRMSE$ qui se situe entre 5% et 6% en utilisant l'équation paramétrique (3.4). Le coefficient de corrélation quant à lui est supérieur à 90%. La figure 27 présente les valeurs des métriques de performance des différentes équations paramétriques.

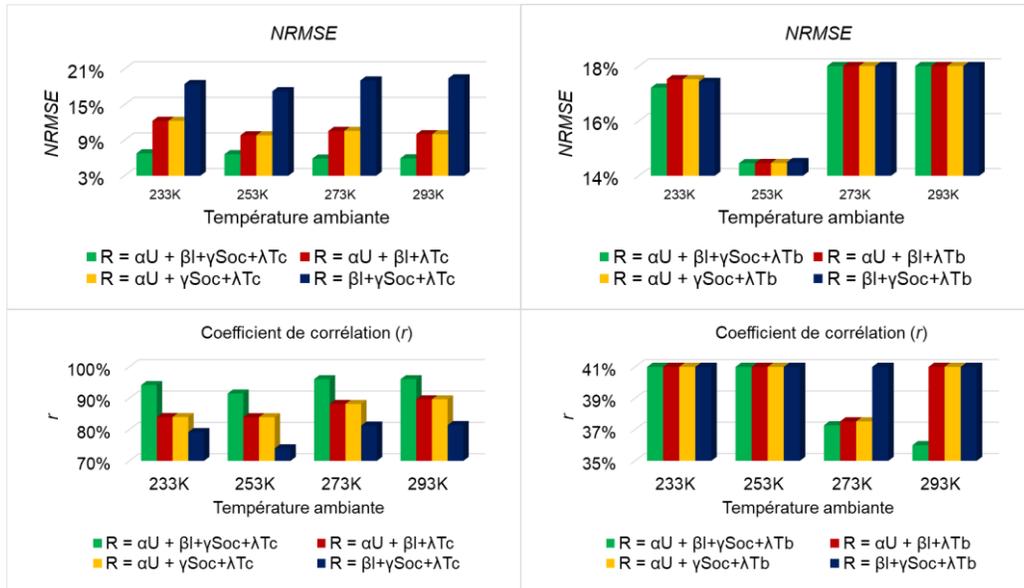


Figure 27 : Performances des équations paramétriques pour $I_d = 27$ A

Malgré la présence des différences d'amplitudes pour les températures ambiantes $T_a = 233$ K et de $T_a = 253$ K, la courbe en rouge représentant l'estimation de la résistance interne à partir de l'équation (3.4) suit la même tendance que les données réelles tel qu'illustrée à la figure 28. L'impossibilité de notre meilleure équation paramétrique à bien modéliser les non-linéarités en début de courbe est également présente pour un courant de décharge de 27A.

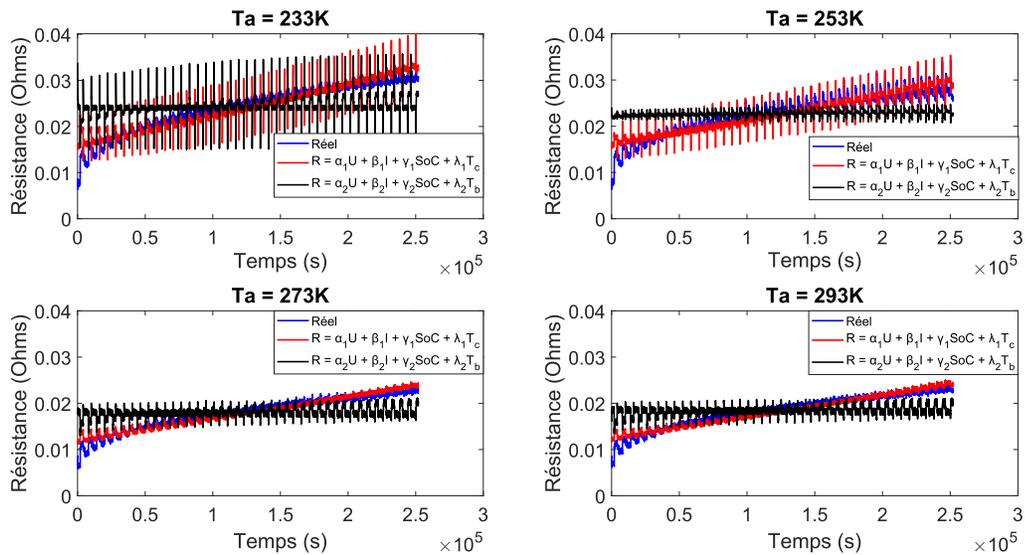


Figure 28 : Résistance estimée à partir d'une équation paramétrique pour $I_d = 27$ A

Dans ce dernier cas pour lequel la résistance est estimée pour un courant de décharge de 55A, l'équation (3.4) présente toujours des erreurs faibles avec des coefficients de corrélation supérieur à 85%. Ainsi, la considération de T_c dans l'équations paramétriques donne des résultats plus satisfaisant que lorsque T_b est considéré. La figure 29 présente les performances pour un courant de décharge de 55A.

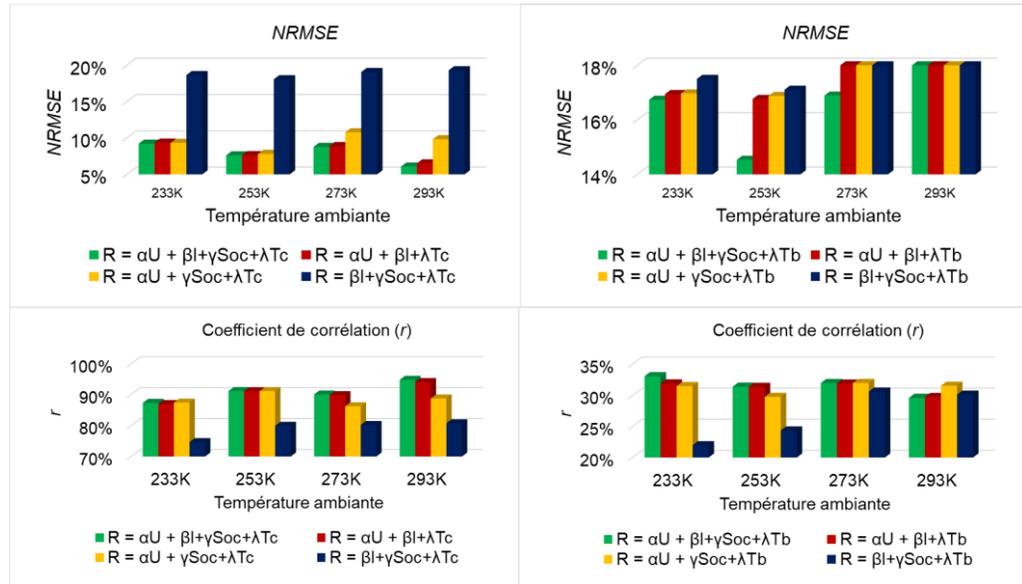


Figure 29 : Performances des équations paramétriques pour $I_d = 55$ A

L'équation (3.4) permet de mieux estimer la résistance interne de la batterie tel que présenté à la figure 30. Pour toutes les températures ambiantes considérées dans le cadre de cette étude, les données de résistance estimées en considérant U , I , SoC et T_c sont parfaitement alignées avec les données réelles.

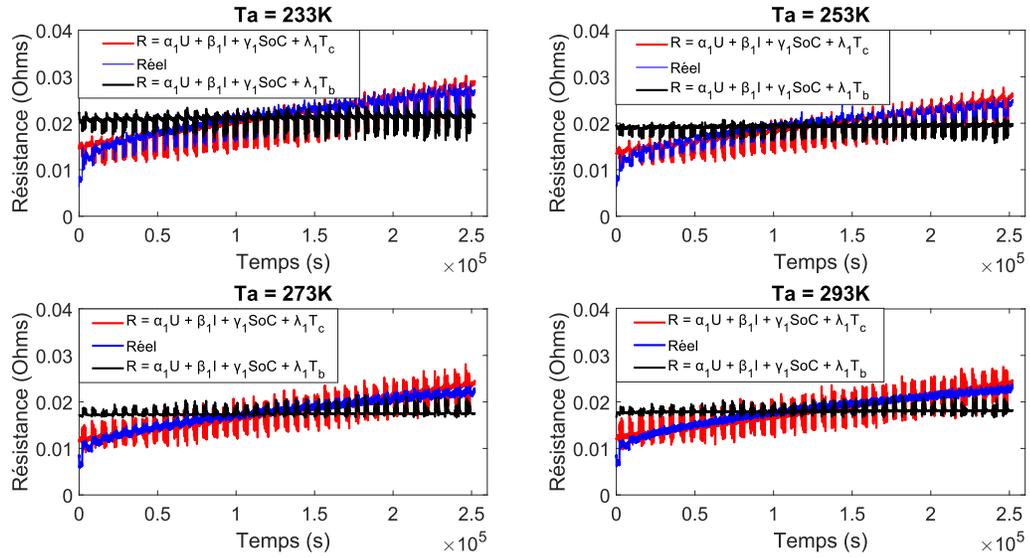


Figure 30 : Résistance estimée à partir d'une équation paramétrique pour $I_d = 55A$

Les courbes d'estimation de la résistance interne à partir de la meilleure équation paramétrique pour différentes températures ambiantes et à des courants de décharge de 10A, 20A, 27A et 55A sont présentées respectivement sur les figure 24, figure 26, figure 28 et figure 30. Les coefficients des différentes équations paramétriques utilisées pour l'estimation de la résistance interne de la batterie sont présentés au tableau 3.

TABLEAU 3 : Coefficients des équations paramétriques

$I_d = 10A$	$R = \alpha_1 U + \beta_1 I + \gamma_1 SoC + \lambda_1 T_c$				$R = \alpha_2 U + \beta_2 I + \gamma_2 SoC + \lambda_2 T_b$			
	α_1 (10^{-3})	β_1 (10^{-4})	γ_1 (10^{-3})	λ_1 (10^{-8})	α_2 (10^{-3})	β_2 (10^{-5})	γ_2 (10^{-3})	λ_2 (10^{-4})
233K	4,95	-1,45	-4,58	6,63	-5,37	7,24	2,11	1,71
253K	4,95	-1,43	-4,57	6,64	-6,19	9,58	2,70	1,68
273K	4,71	-1,32	-4,98	5,59	-4,48	4,86	1,26	1,27
293K	3,67	-0,661	-3,11	1,36	-3,73	4,80	1,76	0,932

$I_d = 20A$	$R = \alpha_1 U + \beta_1 I + \lambda_1 T_c$			$R = \alpha_2 U + \beta_2 I + \lambda_2 T_b$		
	α_1 (10^{-3})	β_1 (10^{-4})	λ_1 (10^{-8})	α_2 (10^{-3})	β_2 (10^{-5})	λ_2 (10^{-4})
233K	4,20	-1,26	6,72	-3,05	2,12	1,39
253K	4,21	-1,25	6,74	-3,15	2,81	1,30
273K	3,89	-1,13	5,70	-3,01	1,90	1,10
293K	3,16	-0,572	1,38	-1,63	1,45	0,712
$I_d = 27A$	$\alpha_1 U + \gamma_1 SoC + \lambda_1 T_c$			$R = \alpha_2 U + \gamma_2 SoC + \lambda_2 T_b$		
	α_1 (10^{-3})	γ_1 (10^{-3})	λ_1 (10^{-5})	α_2 (10^{-3})	γ_2 (10^{-4})	λ_2 (10^{-4})
233K	4,28	-1,22	8,57	-2,24	-1,48	1,27
253K	4,29	-1,26	6,35	-2,08	-2,56	1,15
273K	4,15	-2,20	5,75	-2,17	-4,30	0,991
293K	3,44	-1,97	5,13	-8,96	-3,09	0,629
$I_d = 55A$	$R = \beta_1 I + \gamma_1 SoC + \lambda_1 T_c$			$R = \beta_2 I + \gamma_2 SoC + \lambda_2 T_b$		
	β_1 (10^{-5})	γ_1 (10^{-2})	λ_1 (10^{-8})	β_2 (10^{-5})	γ_2 (10^{-3})	λ_2 (10^{-5})
233K	-2,00	2,05	9,85	-4,52	-1,75	9,52
253K	-1,86	2,05	9,85	-4,15	-1,73	8,78
273K	-2,61	1,87	9,05	-4,16	-2,01	7,30
293K	-1,25	1,51	2,11	-1,14	-0,957	5,34

Une bonne estimation de la résistance interne pour tous les cas a été obtenue en utilisant l'équation paramétrique (3.4). Ainsi, ces premiers résultats valide partiellement notre première hypothèse selon laquelle la résistance est plus impactée par l'effet cumulé de la température T_c . Cependant, l'équation (3.4) n'illustre pas correctement les non-linéarités observées en début de courbe. Les réseaux de neurones à action directe sont connus pour bien résoudre ces problèmes. Ainsi, les résultats d'estimation de la résistance basée sur les réseaux de neurones artificiels sont présentés à la section 4.3.2.

4.3.2 ESTIMATION DE LA RÉSISTANCE INTERNE DE LA BATTERIE EN UTILISANT UN RÉSEAU DE NEURONES À ACTION DIRECTE

Le problème de non-linéarité de la résistance interne de la batterie est adressé à un réseau de neurones artificiels. À l'issue de l'estimation de la résistance en utilisant les équations paramétriques,

le modèle considérant U , I , SoC , et T_c s'est avéré meilleur que les autres et permet d'estimer au mieux la résistance interne. Ainsi, ces paramètres sont utilisés en entrée d'un réseau de neurones à action directe. Le tableau 4 définit les différents paramètres utilisés pour l'estimation de la résistance. Les algorithmes d'apprentissage retenus se sont révélés meilleurs parmi un ensemble de quatre algorithmes que sont : 1- Levenberg-Marquardt, 2- régularisation bayésienne, 3- rétropropagation de quasi-Newton et 4- rétropropagation résiliente. Le nombre de neurones est varié entre 1 et 20 pour chacun des algorithmes et pour chaque fonction d'activation.

TABLEAU 4 : Paramètres utilisés pour l'estimation de la résistance

Entrées	<ul style="list-style-type: none"> • Tension (U) • Courant (I) • État de charge (SoC) • Température cumulé (T_c)
Sortie	Résistance (R)
Algorithmes d'apprentissage	<ul style="list-style-type: none"> • Levenberg-Marquardt (LM) • Régularisation bayésienne (BR)
Fonction d'activation	<ul style="list-style-type: none"> • Tangente sigmoïde (tansig) • Logistique (log)
Nombre de neurones	1 à 20
Taux d'apprentissage	0,1
Nombre maximal d'itération	5000

Sur un total de 80 architectures, celle formée d'une fonction d'activation tangente sigmoïde, d'un algorithme d'apprentissage de Levenberg-Marquardt et de 4 neurones donne de meilleurs résultats.

Les valeurs réelles et estimées de la résistance interne de la batterie sont représentées sur la figure 31, figure 32, figure 33, et figure 34. Sur ces figures, les problèmes de non-linéarité aperçus en utilisant les équations paramétriques sont résolus par le réseau de neurones. De plus, la courbe de la résistance estimée est parfaitement alignée à celle de la résistance réelle pour toutes les températures et les courants de décharge.

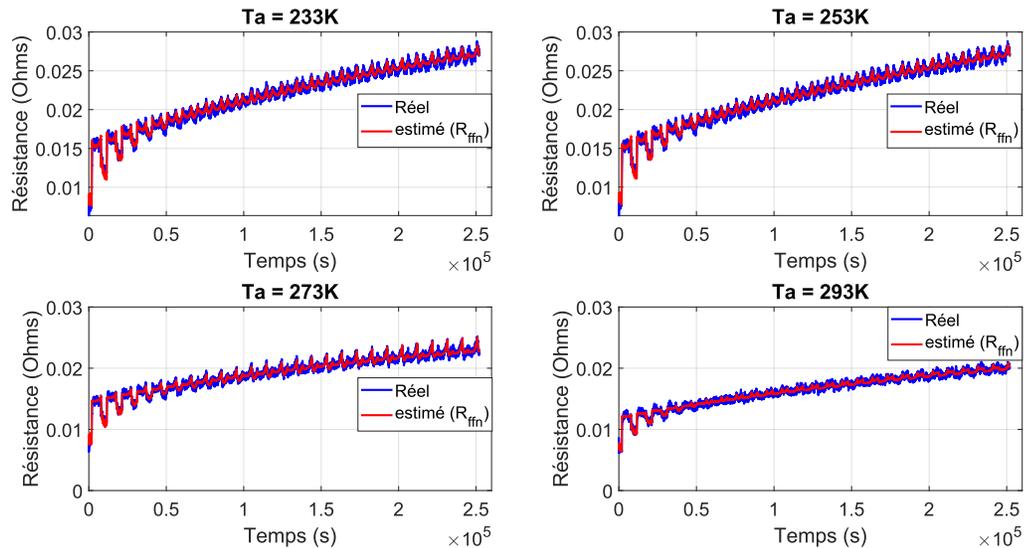


Figure 31 : Résistance réelle et estimée par un réseau de neurones à $I_d = 10A$

Pour un courant de décharge de 20A tel que représenté sur la figure 32, la résistance est estimée avec un coefficient de corrélation autour de 99,7% pour $T_a = 233K$ et $T_a = 253K$. Pour ces températures, il n'y a quasiment pas d'écart d'amplitude contrairement aux données estimées $T_a = 273K$ et $T_a = 293K$ pour lesquelles l'écart d'amplitude augmente avec le vieillissement de la batterie.

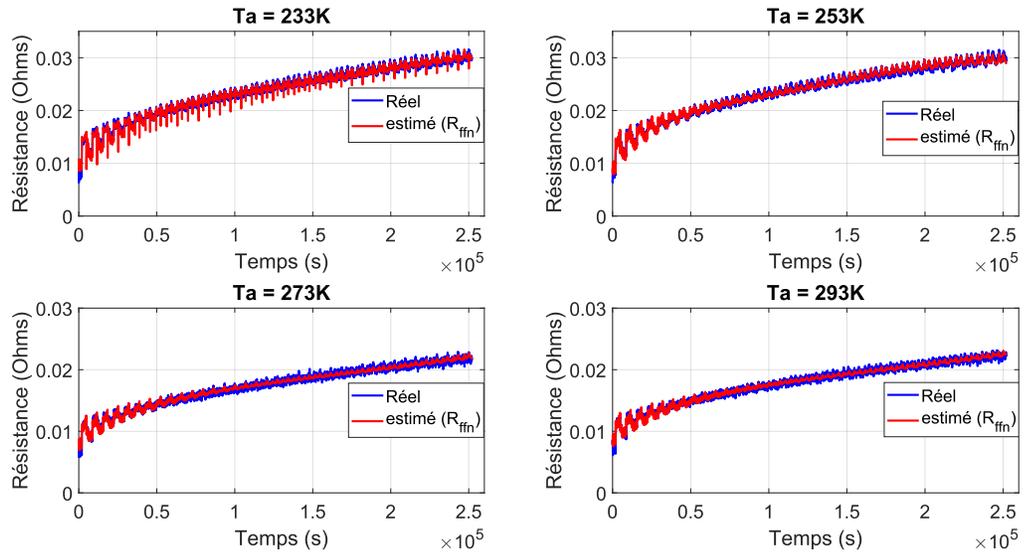


Figure 32 : Résistance réelle et estimée par un réseau de neurones à $I_d = 20A$

Pour les courants de 27A et de 55A tel que présenté respectivement sur les figure 33 et figure 34, l'écart d'amplitude est plus observé pour $T_a = 273K$ et $T_a = 293K$.

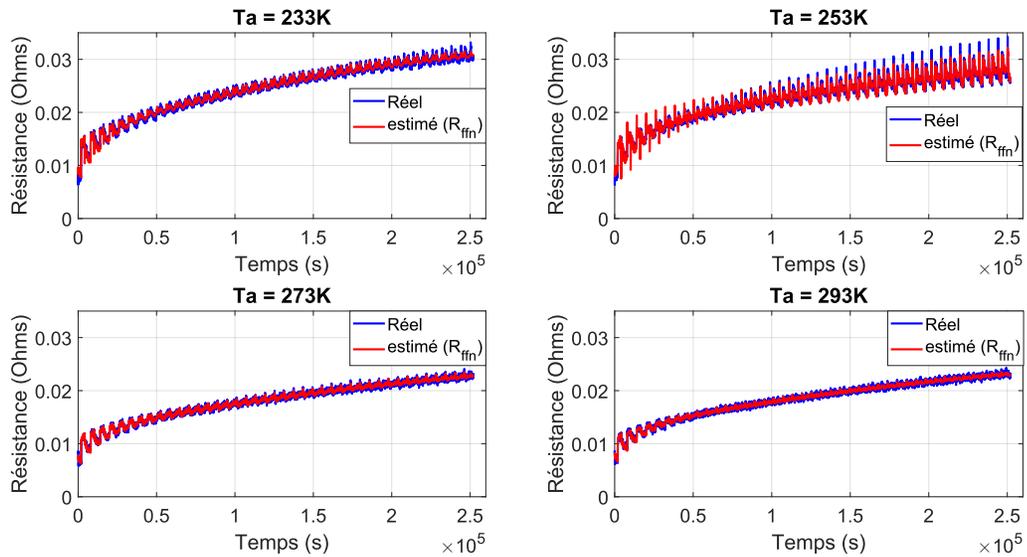


Figure 33 : Résistance réelle et estimée par un réseau de neurones à $I_d = 27A$

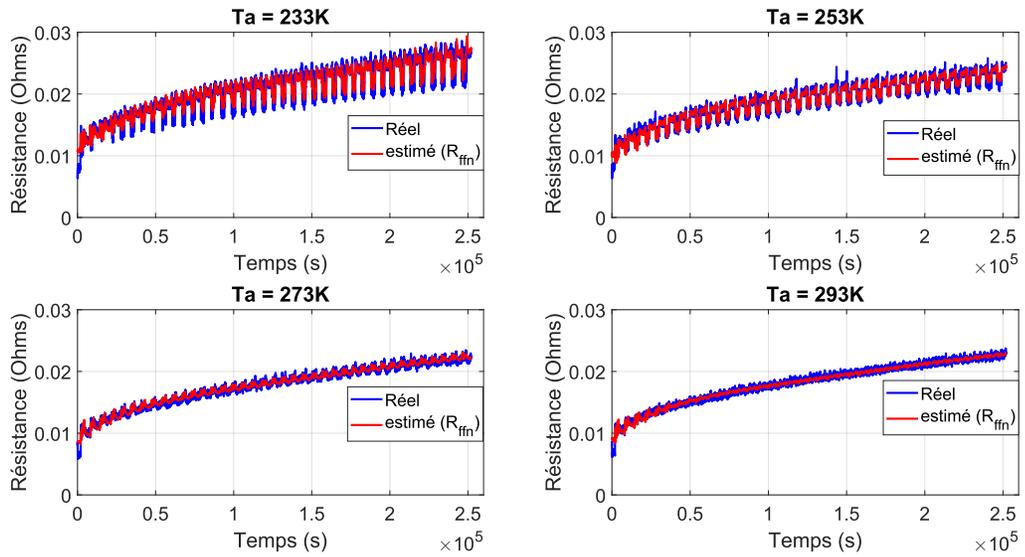


Figure 34 : Résistance réelle et estimée par un réseau de neurones à $I_d = 55A$

En somme, l'estimation de la résistance interne en utilisant une équation paramétrique d'une part et un réseau de neurones d'autre part permet d'avoir de bons résultats. Sur la figure 35 basé sur les travaux de Foussemi et al. 2024 [113], les courbes d'estimation de la résistance par un réseau de neurones suivent mieux les données réelles par rapport aux courbes en noires qui représentent les données estimées par la meilleure équation paramétrique.

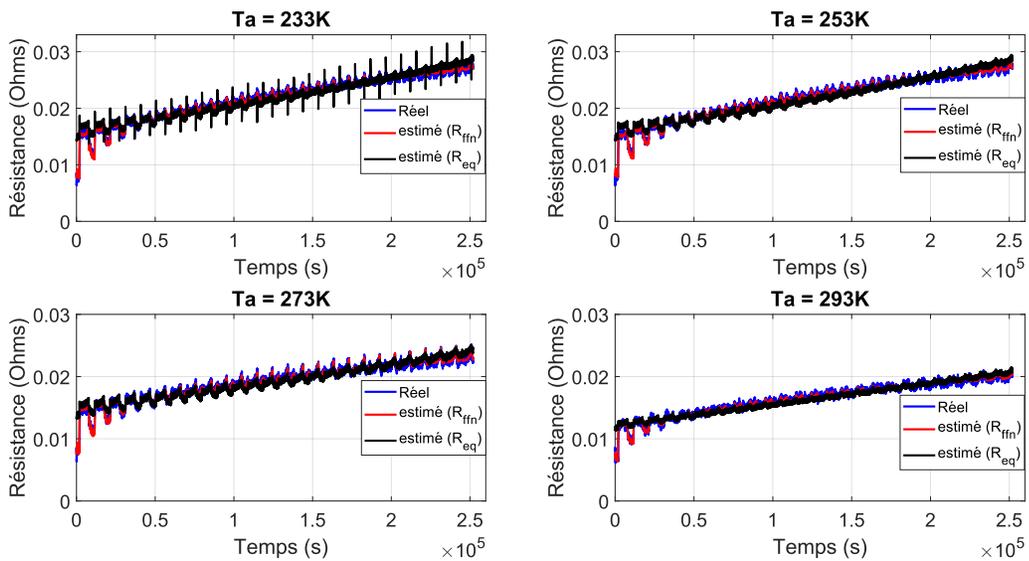


Figure 35 : Résistances réelle et estimée par les deux approches proposées ($I_d = 10A$) [113]

Pour un courant de décharge de 20A tel que présenté à la figure 36, les réseaux de neurones illustrent mieux les non-linéarités par rapport à l'équation paramétrique.

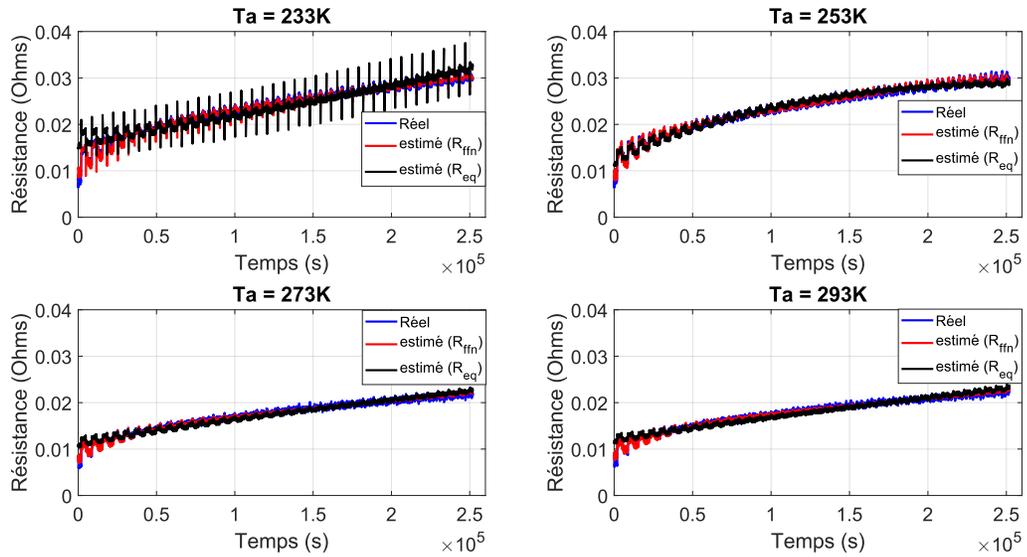


Figure 36 : Résistances réelle et estimée par les deux approches proposées ($I_d = 20A$) [113]

Les mêmes observations sont faites pour les courants de décharge de 27A et de 55A (figure 37 et figure 38). La différence entre les deux approches proposées est clairement observée sur ces figures.

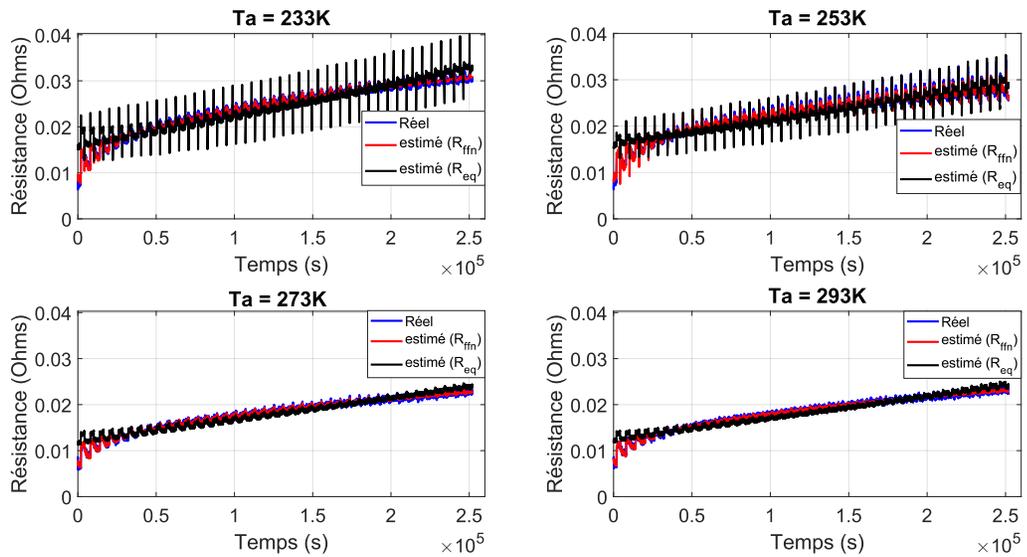


Figure 37 : Résistances réelle et estimée par les deux approches proposées ($I_d = 27A$) [113]

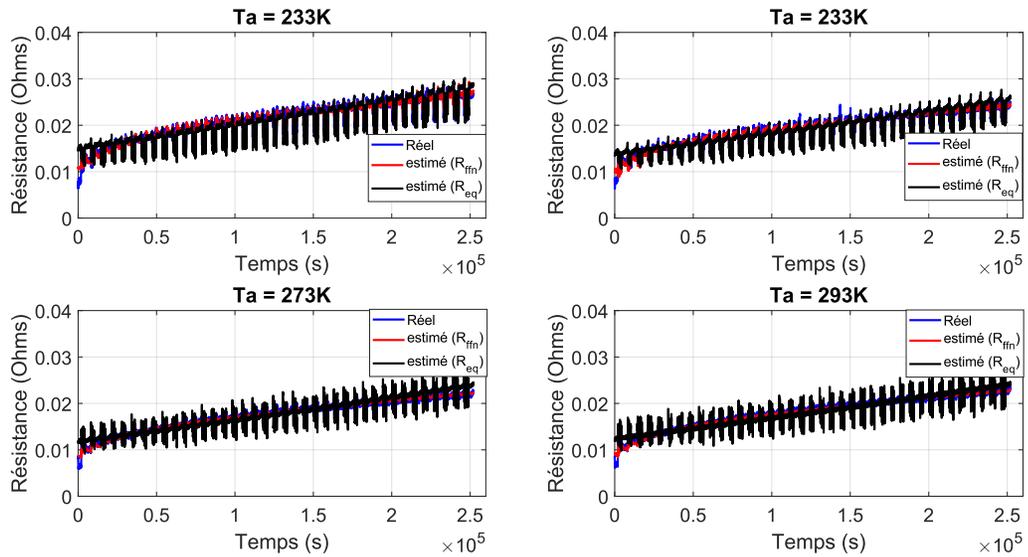


Figure 38 : Résistances réelle et estimée par les deux approches proposées ($I_d = 55A$) [113]

4.4 ESTIMATION DU SoH

Le méthodologie d'estimation du SoH de la batterie est illustrée sur la figure 39. Le modèle modifié de Van Genuchten-Gupta est utilisé pour estimer le SoH_G à partir de la meilleure équation paramétrique (équation 3.4). Ensuite, à partir des données de résistance estimée en utilisant un réseau de neurones à action directe, le SoH_{ffn} est estimé. Dans les sous-sections à venir, l'estimation du SoH en utilisant les deux approches est présentée.

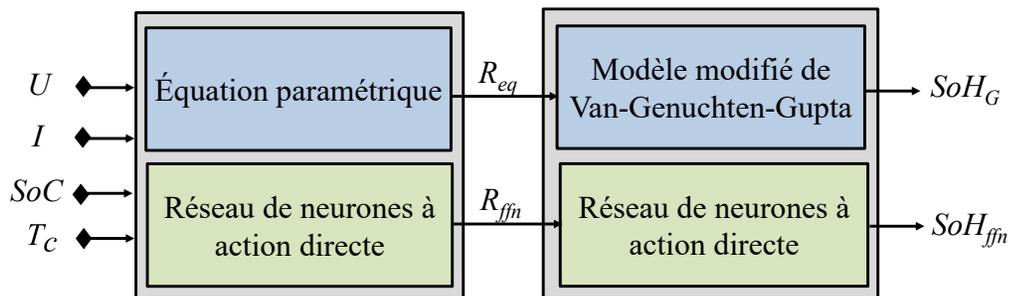


Figure 39 : Illustration générale de la méthode d'estimation de la résistance et du SoH

4.4.1 ESTIMATION DU SoH EN UTILISANT UN MODÈLE DE DIFFUSION EN PHASE SOLIDE

Dans ce paragraphe, les résultats d'estimation de la résistance de la batterie à partir de la meilleure équation paramétrique sont utilisés pour estimer le SoH à partir du modèle modifié de Van Genuchten-Gupta tel que présenté à la figure 40. Ce SoH est noté SoH_G .

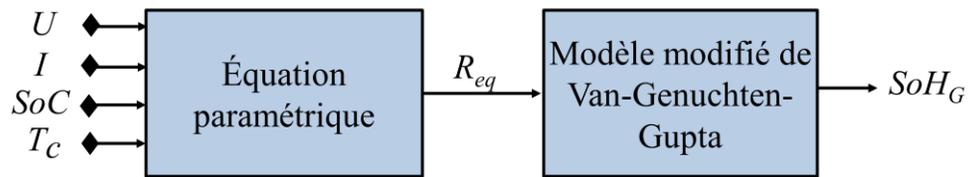


Figure 40 : Illustration de l'estimation de SoH_G

Les performances de cette approche présentée à la figure 41 montrent que pour une même température ambiante, les valeurs de SoH estimées pour les courants de décharge de 10A et de 20A présentent des erreurs faibles comparativement à celles de 27A et de 55A. En effet, le $NRMSE$ varie entre 2,13% et 7,86% pour les courants de décharge de 10A et 20A et entre 4,12% et 16,14% pour les courants de 27A et 55A. Le coefficient de corrélation est quant à lui supérieur à 90% pour les courants de décharge de 27A et 55A et pour des températures ambiantes de 273K et de 293K.



Figure 41 : Performances du modèle modifié de Van Genuchten-Gupta pour estimer le SoH_G

Par ailleurs, les coefficients de l'équation modifiée de Van Genuchten-Gupta sont reliés à la température ambiante par un polynôme de degré 3 tel que formulé aux équations (4.1) à (4.12).

❖ Pour un courant de décharge de 10A

$$p_1 = -0,332 \times T_a^3 - 0,02457 \times T_a^2 + 0,6082 \times T_a + 0,22, \quad (4.1)$$

$$p_1 = -0,653 \times T_a^3 - 0,04676 \times T_a^2 + 1,2 \times T_a - 0,5661, \quad (4.2)$$

$$p_1 = -1,6 \times T_a^3 - 0,13 \times T_a^2 + 1,858 \times T_a + 0,6776, \quad (4.3)$$

❖ Pour un courant de décharge de 20A

$$p_1 = -0,0967 \times T_a^3 - 0,131 \times T_a^2 - 0,08656 \times T_a + 0,6664, \quad (4.4)$$

$$p_1 = -0,481 \times T_a^3 - 0,4852 \times T_a^2 - 0,4465 \times T_a + 0,5889, \quad (4.5)$$

$$p_1 = 2,87 \times T_a^3 - 1,998 \times T_a^2 - 3,362 \times T_a + 4,065, \quad (4.6)$$

❖ Pour un courant de décharge de 27A

$$p_1 = -0,89 \times T_a^3 + 0,02847 \times T_a^2 + 1,417 \times T_a - 0,1346, \quad (4.7)$$

$$p_1 = -2,77 \times T_a^3 + 0,6981 \times T_a^2 + 4,176 \times T_a - 1,443, \quad (4.8)$$

$$p_1 = -3,52 \times T_a^3 + 0,3945 \times T_a^2 + 5,512 \times T_a + 0,345, \quad (4.9)$$

❖ Pour un courant de décharge de 55A

$$p_1 = 0,2917 \times T_a^3 - 0,03608 \times T_a^2 - 0,5123 \times T_a + 0,6663 \quad (4.10)$$

$$p_1 = 0,3519 \times T_a^3 - 0,05921 \times T_a^2 - 0,733 \times T_a + 0,4377 \quad (4.11)$$

$$p_1 = 0,925 \times T_a^3 - 0,5024 \times T_a^2 - 1,424 \times T_a + 2,601 \quad (4.12)$$

Les valeurs des coefficients de l'équation modifiée de Van Genuchten-Gupta sont présentées au tableau 5.

TABEAU 5 : Coefficients de l'équation modifiée de Van Genuchten-Gupta

Courant de décharge (I_d)	Température ambiante (T_a)	p_1	p_2	p_3
$I_d = 10A$	233K	$1,71 \times 10^{-4}$	-1	$1,52 \times 10^{-4}$
	253K	$-1,26 \times 10^{-5}$	-1	$-2,04 \times 10^{-5}$
	273K	0,433	-0,146	1,316
	293K	0,373	-0,259	1,004
$I_d = 20A$	233K	0,439	-0,300	0,769
	253K	0,675	0,661	4,900
	273K	0,619	0,371	2,630
	293K	0,541	0,170	1,965
$I_d = 27A$	233K	$-2,41 \times 10^{-5}$	-1	$-5,29 \times 10^{-5}$
	253K	-0,589	-2,78	-1,53
	273K	0,405	0,128	2,33
	293K	0,499	0,0191	1,76
$I_d = 55A$	233K	0,755	0,657	2,127
	253K	0,842	0,692	3,024
	273K	0,479	0,165	2,028
	293K	0,480	0,058	1,719

La figure 42 présente les données réelles et estimée du SoH pour un courant de décharge de 10A. Le modèle modifié de Van Genuchten-Gupta utilisé dans ce cas permet de faire une bonne estimation du SoH avec des valeurs de $NRMSE$ variant entre 2% pour $T_a = 293K$ et 7% pour $T_a = 233K$. Le coefficient de corrélation quant à lui varie entre 96% et 99%. Pour $T_a = 233K$, les écarts d'amplitudes sont observés. Ceux-ci sont dus aux valeurs de résistance utilisées pour estimer le SoH qui présentaient déjà ces écarts.

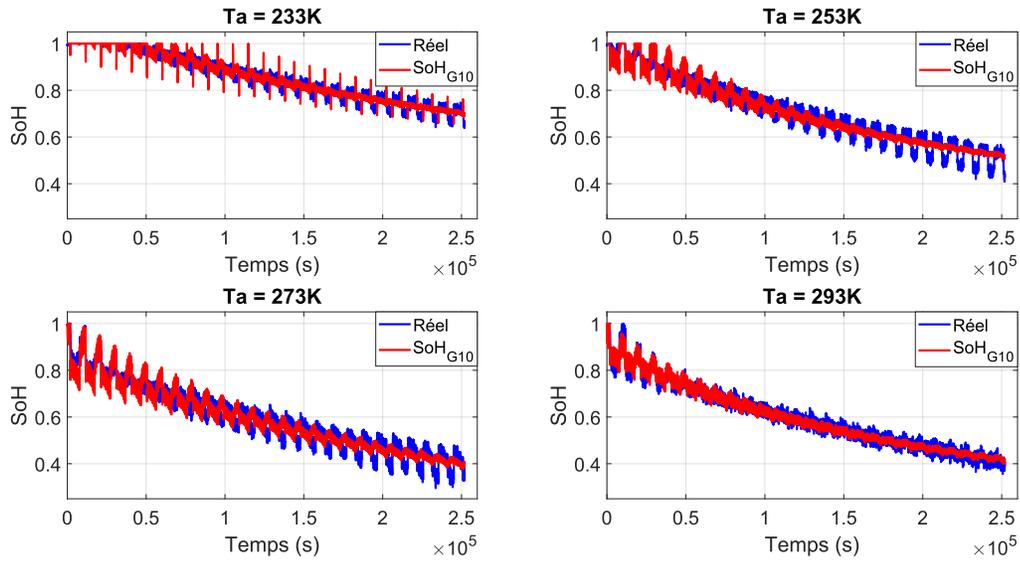


Figure 42 : SoH estimé par le modèle modifié de Van Genuchten-Gupta ($I_d = 10A$)

Pour un courant de décharge de 20A tel que présenté sur la figure 43, les pics sont observés pour $T_a = 233K$. Néanmoins pour les autres températures ambiantes, les données estimées sont alignées avec les données réelles. Les données de SoH estimées pour des températures ambiantes de 233K et 253K et pour un courant de décharge de 27A sont celles qui présentent des erreurs élevées ($NRMSE = 15,09\%$ et $NRMSE = 16,17\%$ respectivement). Ceci vient confirmer le fait que les divergences observées lors de l'estimation du SoH_G sont causées par les valeurs de résistances qui étaient préalablement mal estimées.

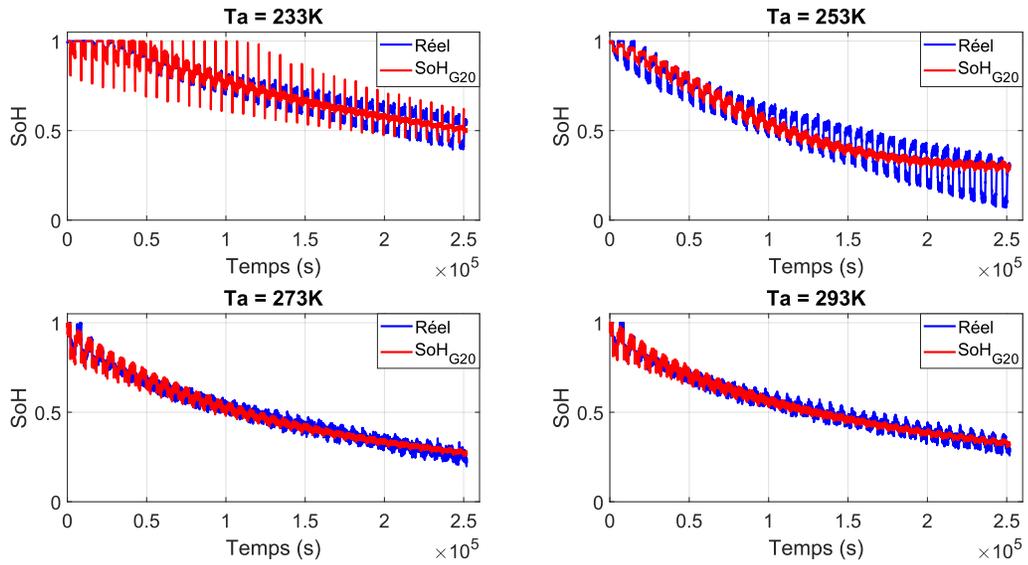


Figure 43 : SoH estimé par le modèle modifié de Van Genuchten-Gupta ($I_d = 20A$)

Pour un courant de 27A, l'erreur est considérable pour $T_a = 233K$ et $T_a = 253K$ à cause du fait que c'est pour ces mêmes paramètres qu'on avait une résistance mal estimée. Par ailleurs, le modèle modifié de Van Genuchten-Gupta permet de bien estimer le SoH pour $T_a = 273K$ et $T_a = 293K$ tel que présenté à la figure 44.

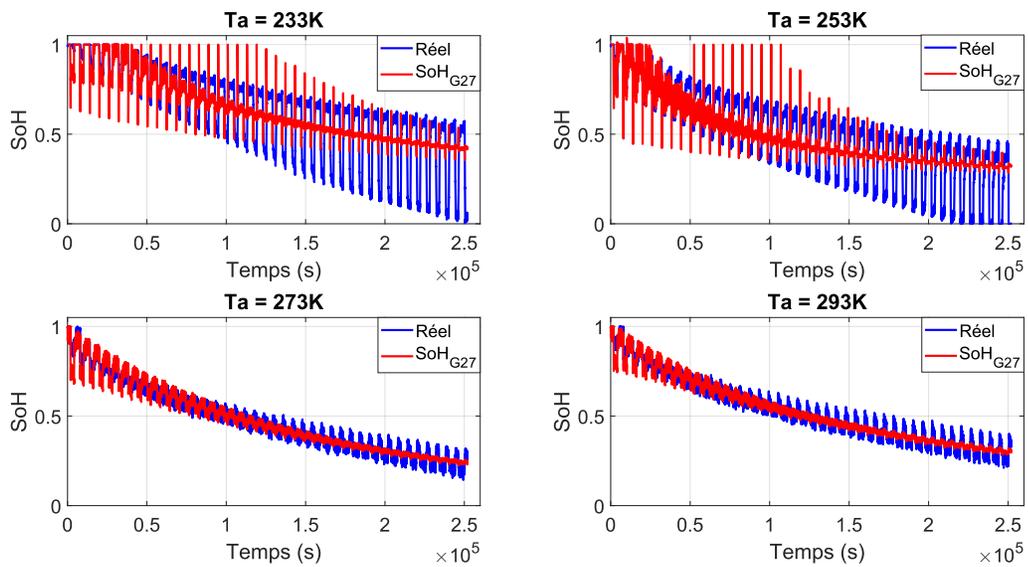


Figure 44 : SoH estimé par le modèle modifié de Van Genuchten-Gupta ($I_d = 27A$)

Pour un courant de décharge de 55A, le SoH est estimé avec des coefficients de corrélation de l'ordre de 98% pour $T_a = 253K$, $T_a = 273K$ et $T_a = 293K$. Pour la température $T_a = 233K$, les performances sont moins satisfaisantes avec un $NRMSE = 5,81\%$ et un coefficient de corrélation $r = 96,21\%$. Sur la figure 45, les données réelles et estimées de SoH pour un courant de décharge de 55A sont présentées.

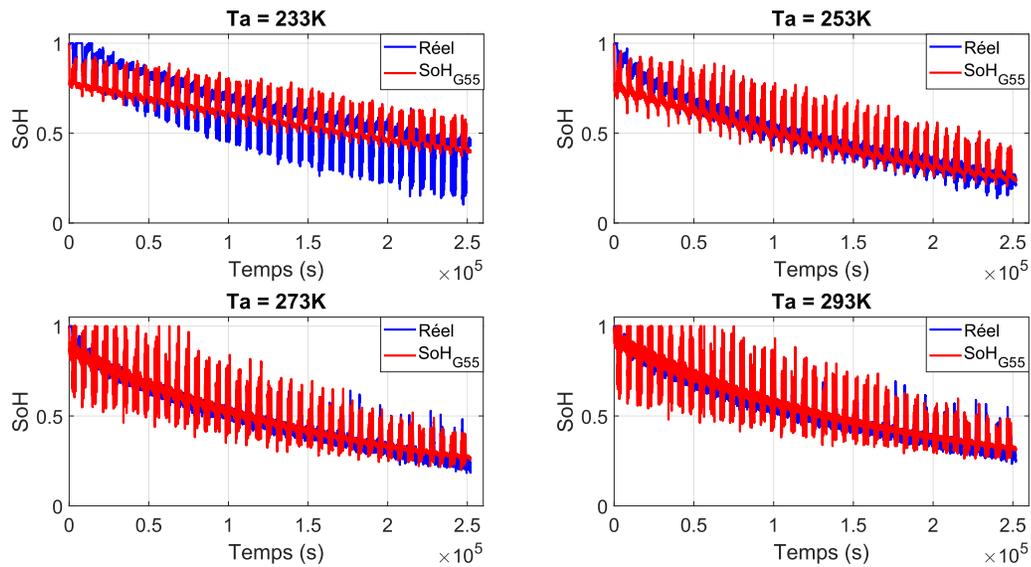


Figure 45 : SoH estimé par le modèle modifié de Van Genuchten-Gupta ($I_d = 55A$)

Dans cette section, il a été montré que le SoH peut être estimé à partir du modèle modifié de Van Genuchten-Gupta proposé. Ceci vient valider notre seconde hypothèse selon laquelle le SoH peut être estimé à partir d'un modèle de diffusion en phase solide. Cependant, l'analyse des différents résultats révèle que cette approche est plus adaptée pour les températures ambiantes de $T_a = 273K$ et $T_a = 293K$. Les mauvaises performances obtenues pour $T_a = 233K$ et $T_a = 253K$ sont causées par les données de résistances qui étaient mal estimées au préalable.

4.4.2 ESTIMATION DU SoH EN UTILISANT UN RÉSEAU DE NEURONES À ACTION DIRECTE

Les données de résistance estimées en utilisant un réseau de neurones sont considérées comme une entrée d'un nouveau réseau de neurones à action directe pour estimer le SoH tel que présenté à la figure 46.

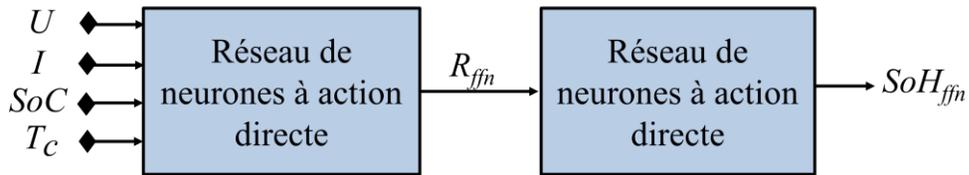


Figure 46 : Illustration de l'estimation de SoH_{ffn}

La meilleure architecture constituée de quatre (04) neurones sous la couche cachée, d'une fonction de transfert tangente sigmoïde et d'un algorithme d'apprentissage de Levenberg-Marquardt est utilisée pour estimer le SoH . Les performances de cette approche sont présentées au tableau 6.

TABLEAU 6 : Performances d'estimation du SoH par un réseau de neurones artificiels

Courant de décharge (I_d)	Température ambiante (T_a)	$NRMSE$	r
$I_d = 10A$	233K	7,12%	97,60%
	253K	6,07%	97,10%
	273K	5,69%	96,07%
	293K	2,61%	99,25%
$I_d = 20A$	233K	7,45%	96,7%
	253K	7,43%	95,5%
	273K	2,56%	99,3%
	293K	2,64%	99,3%
$I_d = 27A$	233K	15,09%	82,0%
	253K	16,17%	77,6%
	273K	4,26%	98,2%
	293K	4,23%	98,2%

Courant de décharge (I_d)	Température ambiante (T_a)	<i>NRMSE</i>	<i>r</i>
$I_d = 55A$	233K	5,81%	96,21%
	253K	3,19%	98,85%
	273K	3,75%	98,53%
	293K	3,64%	98,65%

Dans le tableau 6, les valeurs de coefficient de corrélation sont supérieures à 95% excepté pour les données dont le courant de décharge est de 27A et pour $T_a = 233K$ et $T_a = 253K$. Le *NRMSE* varie en revanche entre 2% et 16% avec des valeurs inférieures à 4% pour les températures $T_a = 273K$ et $T_a = 293K$. Les meilleures performances observées pour les températures ambiantes chaudes ($T_a = 273K$ et $T_a = 293K$) par rapport aux températures ambiantes froides ($T_a = 233K$ et $T_a = 253K$) peut s'expliquer par la saturation des données réelles à 1. En effet, plus le temps de saturation est élevé, moins le modèle performe. Ce constat peut être fait en analysant les figure 47 et figure 48 qui présentent les données estimées de *SoH* en utilisant un réseau de neurones à action directe pour des courants de décharge de 10A et 20A respectivement. Sur ces figures, les données estimées ont la même allure que les données réelles. Cependant des petites différences d'amplitudes peuvent être observées à cause de la saturation à 1 en début de courbe.

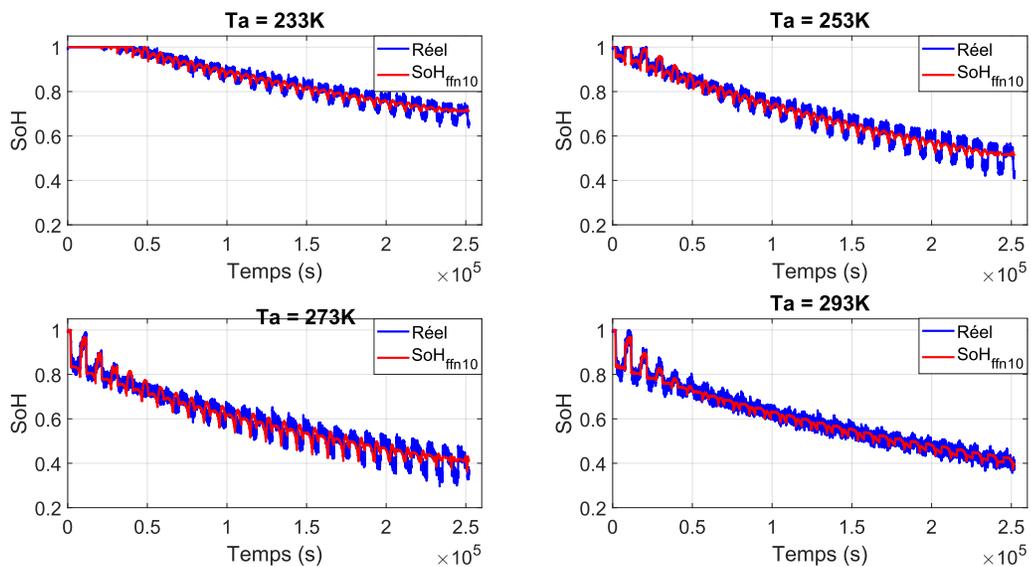


Figure 47 : *SoH* estimé par réseau de neurones ($I_d = 10A$)

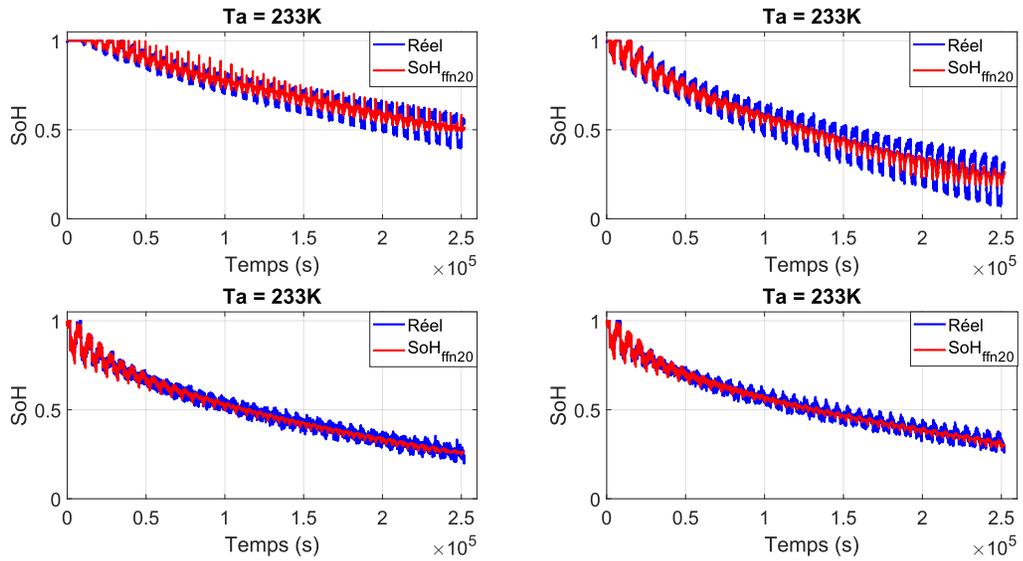


Figure 48 : SoH estimé par réseau de neurones ($I_d = 20A$)

Les écarts d'amplitudes sont plus prononcés pour les données estimées sous un courant de décharge de 27A tel qu'illustré sur la figure 49. Spécifiquement pour la température ambiante $T_a = 253K$, les données estimées semblent diverger lors du vieillissement de la batterie. Ceci peut être dû à la considération de la résistance estimée comme unique variable d'entrée du réseau de neurones pour l'estimation du SoH . Pour corriger cela, des paramètres comme U ou le SoC peuvent être ajoutés en entrée.

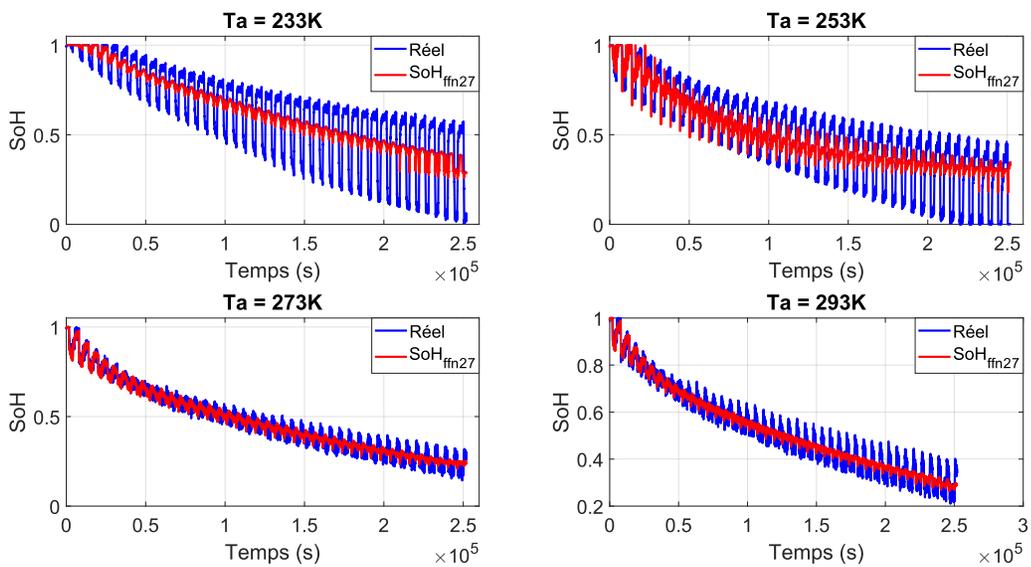


Figure 49 : SoH estimé par réseau de neurones ($I_d = 27A$)

Pour les données acquises sous un courant de décharge de 55A, le SoH estimé est parfaitement alignées aux données réelles tel que présenté à figure 50.

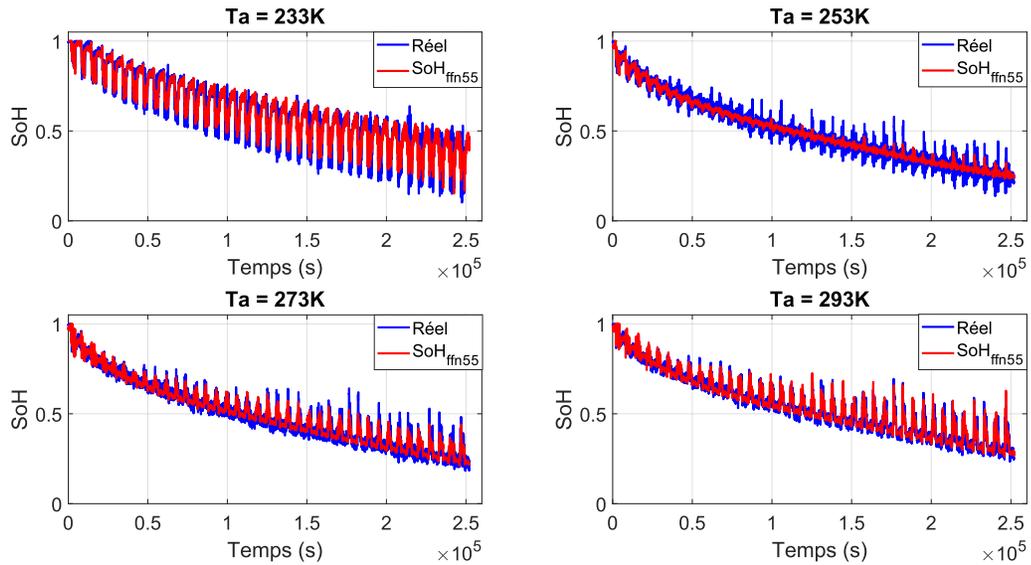


Figure 50 : SoH estimé par réseau de neurones ($I_d = 55A$)

4.4.3 ESTIMATION DU SoH EN UTILISANT UNE MÉTHODE HYBRIDE

L'estimation du SoH à partir d'un modèle de diffusion a montré des limites en termes d'écart d'amplitude entre les données réelles et les données estimées car la résistance utilisée est issue d'un modèle paramétrique qui présentait quelques limites au préalable. En réalité, l'erreur commise lors de l'estimation de cette résistance a entraîné une divergence plus prononcée des résultats de SoH . Malgré la performance des réseaux de neurones qui donnent des résultats satisfaisants par rapport au modèle de diffusion, ils nécessitent un temps de calcul élevé. En effet, un premier réseau de neurones est utilisé pour estimer la résistance interne puis un second pour le SoH en considérant la résistance estimée au préalable. Pour tirer les avantages de chacune des deux approches, la figure 51 illustre la méthode hybride utilisée pour estimer le SoH . Elle consiste dans un premier temps à

estimer la résistance à partir du meilleur modèle paramétrique. La résistance estimée est alors utilisée pour estimer le SoH .

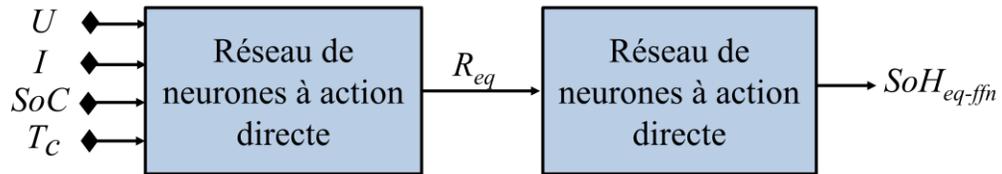


Figure 51 : Illustration de la méthode hybride pour l'estimation du SoH

Pour un courant de décharge de 10A, la méthode hybride permet non seulement de supprimer les pics observés lorsque le modèle de diffusion est utilisé mais également les amplitudes des données réelles et estimées sont de même ordre de grandeur. Ceci est bien illustré sur la figure 52 sur laquelle les courbes des données réelles et estimées de SoH sont superposées.

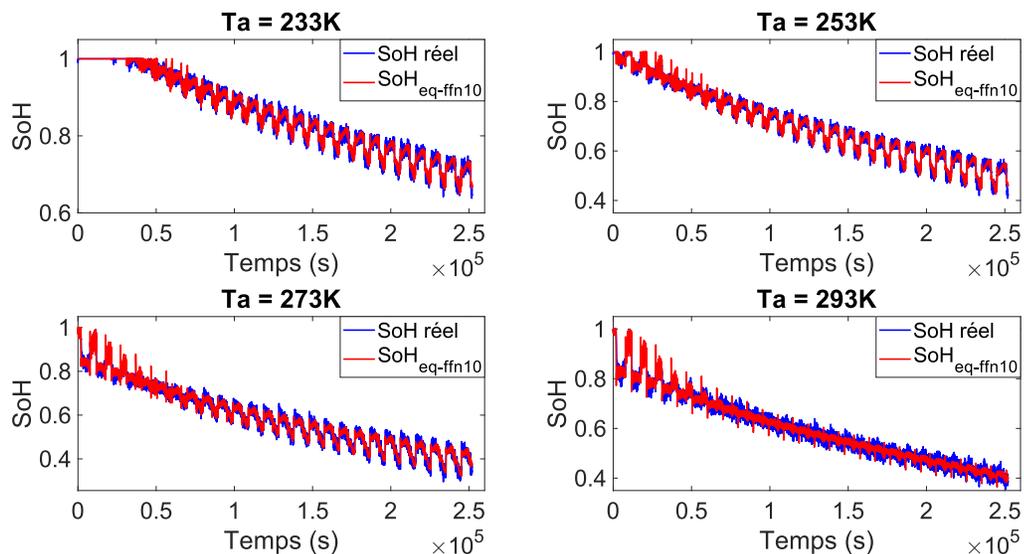


Figure 52 : Estimation du SoH par une méthode hybride ($I_d = 10A$)

À 20A de courant de décharge, la méthode hybride qui consiste à estimer le SoH à partir de la résistance obtenue en utilisant un modèle paramétrique donne des résultats plus satisfaisants par rapport aux données de SoH estimées en utilisant la résistance calculée par réseau de neurones.

Sur la figure 53 les données de SoH estimées sont parfaitement alignées aux données réelles surtout pour les températures ambiantes de 233K et de 253K. Aux températures ambiantes de 273K et de 293K, les écarts d'amplitudes mineurs sont observés.

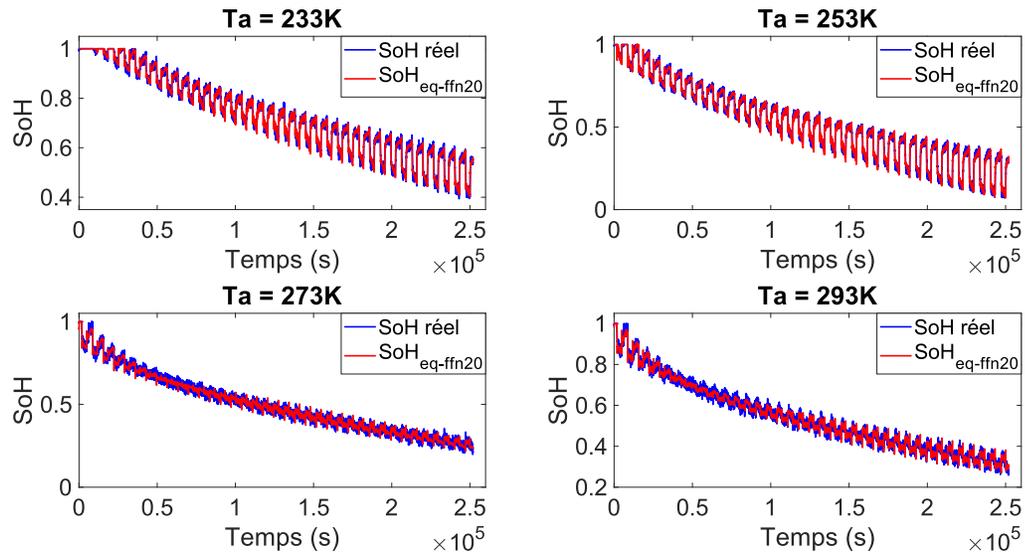


Figure 53 : Estimation du SoH par une méthode hybride ($I_d = 20A$)

Les figure 52 et figure 53 ont permis de faire une analyse visuelle des performances de la méthode hybride. La section 4.4 ci-dessous fait une comparaison des différentes approches proposées en se basant sur les critères de performance préalablement décrits dans la méthodologie.

4.4 COMPARAISON DES DIFFÉRENTES APPROCHES

Les sections précédentes ont fait l'objets de présentation des résultats d'estimation de la résistance et du SoH d'une batterie. Dans cette section, une comparaison des différentes approches est faite. L'objectif de cette comparaison est d'évaluer les différentes méthodes d'estimation de la résistance et du SoH des batteries selon des critères de performance tels que la racine carrée de l'erreur quadratique moyenne normalisée ($NRMSE$) et le coefficient de corrélation (r).

Le tableau 7 présente les performances des équations paramétriques et celles d'un réseau de neurones à action directe pour l'estimation de la résistance. L'analyse de ce tableau révèle que parmi

les équations paramétriques (3.4) à (3.11), l'estimation de la résistance interne à partir de l'équation (3.4) considérant U , I , SoC et T_c d'une part et de l'équation (3.11) considérant U , I , SoC et T_b d'autre part donnent des résultats satisfaisants. Cependant, les performances de l'équation (3.4) sont bien meilleures par rapport à l'équation (3.11) avec des coefficients de corrélation variant entre 91,5% et 98,7% pour toutes les conditions de fonctionnement présentées dans cette étude. En appliquant un réseau de neurones à action directe considérant U , I , SoC et T_c , la résistance est estimée avec une valeur de $NRMSE$ inférieure à 3% et un coefficient de corrélation compris entre 95% et 99,8%. Ainsi, parmi les approches proposées pour l'estimation de la résistance interne, celle basée sur l'utilisation d'un réseau de neurones à action directe permet d'obtenir de meilleurs résultats malgré le temps de calcul élevé que cela pourrait impliquer.

TABLEAU 7 : Comparaison des approches proposées pour estimer la résistance

		Équations paramétriques				Réseau de neurones à action directe	
		Utilisation de l'équation (3.4)		Utilisation de l'équation (3.8)		$NRMSE$ (%)	r (%)
		$NRMSE$ (%)	r (%)	$NRMSE$ (%)	r (%)		
Décharge : 10A	$T_a= 233K$	4,99	95,6	16,50	29,2	1,59	99,6
	$T_a= 253K$	4,94	95,7	16,49	29,5	1,57	99,6
	$T_a= 273K$	4,94	94,7	14,81	27,9	1,81	99,3
	$T_a= 293K$	4,84	96,1	17,12	26,8	2,06	99,3
Décharge:20A	$T_a= 233K$	5,84	95,1	19,63	40,5	1,71	99,7
	$T_a= 253K$	3,02	98,7	19,52	39,9	1,63	99,7
	$T_a= 273K$	4,06	97,7	16,53	34,3	1,85	99,4
	$T_a= 293K$	4,54	97,2	20,87	33,7	2,44	99,4
Décharge:27A	$T_a= 233K$	6,28	94,2	20,56	41,3	1,50	99,8
	$T_a= 253K$	6,12	91,5	17,94	44,8	2,49	99,1
	$T_a= 273K$	5,39	96,0	17,54	37,3	1,52	99,7
	$T_a= 293K$	5,42	96,0	22,25	36,0	1,84	99,7

		Équations paramétriques				Réseau de neurones à action directe	
		Utilisation de l'équation (3.4)		Utilisation de l'équation (3.8)			
		<i>NRMSE</i> (%)	<i>r</i> (%)	<i>NRMSE</i> (%)	<i>r</i> (%)	<i>NRMSE</i> (%)	<i>r</i> (%)
Décharge: 55A	$T_a = 233K$	9,22	87,3	16,74	33,1	5,38	95,3
	$T_a = 253K$	7,61	91,2	14,53	31,4	2,97	98,1
	$T_a = 273K$	8,78	90,0	16,89	32,0	2,08	99,3
	$T_a = 293K$	6,07	94,8	21,50	29,6	2,32	99,5

Le tableau 8 présente les performances du modèle de diffusion, du réseau de neurones à action directe et de la méthode hybride pour l'estimation du *SoH* à partir des résistances estimées. Le réseau de neurones se présente comme une approche meilleure que celle basées sur le modèle de diffusion. Dans certaines conditions comme pour $I_d = 20A$ et $T_a = 233K$ les performances des deux méthodes sont quasiment similaires. De plus, de grandes différences peuvent être observées surtout pour $I_d = 55A$ et $T_a = 233K$ où la différence de coefficient de corrélation est de l'ordre de 30% et la différence de *NRMSE* de l'ordre de 10%. Cependant, la méthode hybride surclasse les deux autres approches en termes de performance pour des courants de décharge de 10A, 20A et de 27A. Pour un courant de décharge assez élevé (55A), le réseau de neurones est préféré à la méthode hybride.

TABLEAU 8 : Comparaison des approches proposées pour estimer le *SoH*

	Température ambiante (T_a)	Modèle Modifié de Van Genuchten-Gupta		Réseau de neurones		Méthode hybride	
		<i>NRMSE</i> (%)	<i>r</i> (%)	<i>NRMSE</i> (%)	<i>r</i> (%)	<i>NRMSE</i> (%)	<i>r</i> (%)
Décharge: 10A	$T_a = 233K$	8,35	96,67	7,12	97,60	3,69	99,36
	$T_a = 253K$	7,12	95,99	6,07	97,10	2,89	99,35
	$T_a = 273K$	6,71	94,50	5,69	96,07	2,62	99,18
	$T_a = 293K$	3,32	98,78	2,61	99,25	2,54	99,29

	Température ambiante (T_a)	Modèle Modifié de Van Genuchten-Gupta		Réseau de neurones		Méthode hybride	
		<i>NRMSE</i> (%)	<i>r</i> (%)	<i>NRMSE</i> (%)	<i>r</i> (%)	<i>NRMSE</i> (%)	<i>r</i> (%)
Décharge:20A	$T_a= 233K$	7,87	96,26	7,45	96,7	2,90	99,50
	$T_a= 253K$	8,45	94,16	7,43	95,5	2,41	99,54
	$T_a= 273K$	3,20	98,99	2,56	99,3	1,85	99,66
	$T_a= 293K$	3,26	98,96	2,64	99,3	1,92	99,64
Décharge:27A	$T_a= 233K$	15,87	80,01	15,09	82,0	5,23	98,01
	$T_a= 253K$	16,14	77,66	16,17	77,6	3,97	98,79
	$T_a= 273K$	5,21	97,22	4,26	98,2	2,17	99,52
	$T_a= 293K$	5,21	97,33	4,23	98,2	2,50	99,39
Décharge:55A	$T_a= 233K$	16,58	62,72	5,81	96,21	16,14	65,19
	$T_a= 253K$	9,65	88,95	3,19	98,85	9,44	89,45
	$T_a= 273K$	7,10	94,62	3,75	98,53	6,92	94,90
	$T_a= 293K$	6,80	95,23	3,64	98,65	6,66	95,43

4.5 CONCLUSION

Les résultats d'estimation de la résistance et du *SoH* ont été présentés et discutés dans ce chapitre. Ainsi, l'utilisation des équations paramétriques pour l'estimation de la résistance interne a permis d'identifier les paramètres idéaux qui permettent une bonne estimation. Il s'agit de la tension (U), le courant (I), l'état de charge (*SoC*), la température de la batterie (T_b) et l'effet cumulé de la température (T_c). Cependant, le modèle paramétrique souffre de l'incapacité à reproduire les zones non-linéaires des courbes de résistance. Pour corriger ce phénomène, le réseau de neurones à

action directe s'est montré plus efficace avec des valeurs de coefficient de corrélation supérieures à 99% pour la majorité des cas ainsi qu'un NRMSE variant entre 1,92% et 16,14 % selon les cas.

En outre, la nouvelle approche proposée pour l'estimation du *SoH* et qui se base sur un modèle de diffusion a donné des résultats satisfaisants. Ces résultats suggèrent que pour des températures de 233K et de 253K et pour un courant de décharge de 10A, le modèle de diffusion proposé donne des résultats quasi similaires à ceux d'un réseau de neurones. Néanmoins, l'estimation du *SoH* en utilisant le modèle de diffusion proposé engendre des pics et certains écarts d'amplitudes. Ces pics représentent une faiblesse de cette méthode. Pour une meilleure estimation du *SoH*, une méthode hybride qui consiste à estimer la résistance à partir d'un modèle paramétrique puis le *SoH* à partir d'un réseau de neurones se trouve bien est bien adaptée pour un courant de décharge inférieur ou égal à 27A.

CHAPITRE 5 CONCLUSION

Dans cette étude, une analyse de l'impact des paramètres d'une batterie sur l'estimation de la résistance et du *SoH* a été effectuée. Cette analyse est basée sur huit (08) équations paramétriques considérant la tension (U), le courant (I), l'état de charge (*SoC*), la température de la batterie (T_b) et l'effet cumulé de la température (T_c). Ces équations sont ensuite utilisées pour l'estimation de la résistance interne de la batterie. Au sortir de cette analyse, il ressort que l'effet cumulé de la température a plus d'impact sur la résistance par rapport à la température de la batterie. La meilleure équation paramétrique permettant d'estimer au mieux la résistance est celle considérant U , I , *SoC* et T_c . Ceci a permis de valider la première hypothèse selon laquelle la résistance est plus liée à l'effet cumulé de la température. Ces paramètres idéaux sont ensuite utilisés comme entrées d'un réseau de neurones à action directe pour estimer la résistance. Sur un total de quatre-vingts (80) architectures prenant en compte la variation de la fonction d'activation, de l'algorithme d'apprentissage ou encore du nombre de neurones sous la couche cachée, la meilleure est celle basée sur une fonction d'activation tangente sigmoïde et un algorithme d'apprentissage de Levenberg-Marquardt avec quatre (04) neurones. Les résultats ont révélé une meilleure performance de cette configuration de réseau de neurones à action directe en général avec un coefficient de corrélation supérieur à 95% lors de l'estimation de la résistance interne et du *SoH*. Le NRMSE est quant à lui inférieur à 6% pour la résistance et comprise entre 2% et 16% pour le *SoH*. Néanmoins, des petits écarts d'amplitude peuvent être observés entre les valeurs réelles et estimées de *SoH*. La résistance étant une donnée d'entrée pour l'estimation du *SoH*, une erreur liée à l'estimation de la résistance engendre également une erreur au niveau du *SoH*.

Les performances de l'estimation du *SoH* en utilisant le modèle modifié de Van Genuchten-Gupta proposé ont permis de valider la seconde hypothèse selon laquelle le *SoH* est lié à un paramètre physique de la batterie qui peut être décrit par un modèle de diffusion en phase solide. Les meilleurs résultats sont obtenus pour des températures ambiantes de 273K et de 293K avec des

coefficients de corrélation supérieurs à 94% pour des courants de décharge de 10A et de 20A. Cependant, la méthode hybride proposée dans cette étude et qui consiste à estimer le *SoH* en utilisant un réseau de neurones à partir de la résistance calculée par le modèle paramétrique est meilleurs que chacune des deux approches prise individuellement (l'utilisation de la résistance obtenue par réseaux de neurones pour l'estimation du *SoH* à partir d'un réseau de neurones et l'utilisation de la résistance calculée par les équations paramétriques puis calcul du *SoH* en utilisant le modèle de diffusion). Malgré les meilleures performances des approches proposées, cette étude présentes quelques limites. En effet, dans cette étude, la résistance est considérée comme une valeur réelle alors qu'en réalité, la résistance est complexe. Aussi, dans les conditions réelles de fonctionnement d'une batterie, le courant de décharge et la température ambiante sont variables. Dans cette étude, plusieurs températures ambiantes et courant de décharge constant ont été utilisés.

La résistance est une valeur d'impédance complexe qui peut être estimée à l'aide de la spectroscopie d'impédance électrochimique (*EIS*). Comme travaux futurs, les courbes *EIS* (tracés de Nyquist) peuvent améliorer l'estimation de la *SoH*. Bien entendu, l'extraction de cette courbe prend du temps car elle nécessite l'application d'un signal composé de plusieurs fréquences à la batterie. Comme solution, elles peuvent être intégrées dans le processus de charge. L'estimation et la mise à jour de la résistance à l'aide de la courbe *EIS*, puis estimation du *SoH* à l'aide de la méthode proposée dans cette étude devrait améliorer les résultats. La mise à jour de la valeur actuelle de la résistance dans le temps est une étape essentielle. Aussi, les données utilisées dans le cadre de cette étude sont temporelles et peuvent être transformées en fonction du nombre de cycle en utilisant les réseaux monocouches compétitifs, connus sous le nom de cartes auto-organisatrices de Kohonen.

LISTE DE RÉFÉRENCES

- [1] G. Pistoia, *Battery Operated Devices and Systems : From Portable Electronics to Industrial Products*. 2009.
- [2] D. Anseán, M. González, J. C. Viera, J. C. Álvarez, C. Blanco, and V. M. García, "Evaluation of LiFePO₄ batteries for Electric Vehicle applications," in *2013 International Conference on New Concepts in Smart Cities: Fostering Public and Private Alliances (SmartMILE)*, 2013, pp. 1-8.
- [3] Z. Miao, L. Xu, V. R. Disfani, and L. Fan, "An SOC-Based Battery Management System for Microgrids," *IEEE Transactions on Smart Grid*, vol. 5, no. 2, pp. 966-973, 2014.
- [4] I. Baek *et al.*, "An experimental investigating on the effect of contact resistance for pouch-type lithium-ion batteries on the performance and safety," in *2022 IEEE Energy Conversion Congress and Exposition (ECCE)*, 2022, pp. 1-5.
- [5] I. E. A. International Energy Agency, "CO₂ Emissions in 2023," Paris, 2024.
- [6] X. Ding, D. Zhang, J. Cheng, B. Wang, and P. C. K. Luk, "An improved Thevenin model of lithium-ion battery with high accuracy for electric vehicles," *Applied Energy*, vol. 254, p. 113615, 2019.
- [7] J. M. Tabora *et al.*, "Assessing Energy Efficiency and Power Quality Impacts Due to High-Efficiency Motors Operating Under Nonideal Energy Supply," *IEEE Access*, vol. 9, pp. 121871-121882, 2021.
- [8] R. Namuli and P. Pillay, "A computer programme for the analysis of conversion of organic waste to energy," in *Power and Energy Society General Meeting*, 2011, pp. 1-5.
- [9] M. G. Molina, "Dynamic modelling and control design of advanced energy storage for power system applications," *Dynamic Modelling*, vol. 300, 2010.
- [10] Z. Dong, D. Yang, T. Reindl, and W. M. Walsh, "A novel hybrid approach based on self-organizing maps, support vector regression and particle swarm optimization to forecast solar irradiance," *Energy*, vol. 82, pp. 570-577, 2015.
- [11] J. Lacap, J. W. Park, and L. Beslow, "Development and Demonstration of Microgrid System Utilizing Second-Life Electric Vehicle Batteries," *Journal of Energy Storage*, vol. 41, p. 102837, 2021.
- [12] B. Saha, S. Poll, K. Goebel, and J. Christophersen, "An integrated approach to battery health monitoring using bayesian regression and state estimation," in *IEEE Autotestcon*, 2007 2007, pp. 646-653.
- [13] A. Barré, B. Deguilhem, S. Grolleau, M. Gérard, F. Suard, and D. Riu, "A review on lithium-ion battery ageing mechanisms and estimations for automotive applications," *Journal of Power Sources*, vol. 241, pp. 680-689, 2013/11/01/ 2013.
- [14] Z. J. Zhixing Zhou, Zhiguo Lei, "Lithium-ion battery life research review," *Mechanical and electrical technology*, vol. 03, no. 117-120, 2019.
- [15] F. G. Honglian Qin, "Effect of temperature on Performance of LiFePO₄ Lithium-ion Power Battery," *Power Supply World*, vol. 12, no. 32-34, 2015.

- [16] A. Masakure, A. Gill, and M. Singh, "The Impact of Battery Charging and Discharging Current Limits on EV Battery Degradation and Safety," in *3rd Asian Conference on Innovation in Technology (ASIANCON)*, 2023 2023, pp. 1-5.
- [17] J. Christophersen *et al.*, "Advanced Technology Development Program for Lithium-Ion Batteries: Gen 2 Performance Evaluation Final Report," 2006.
- [18] A. Degla, M. Chikh, M. B. Danoune, S. Boumecheta, and Y. Rehouma, "An Enhanced Neural Network Application for a Lithium-ion Battery Pack State-of-Health Estimator," in *2023 Second International Conference on Energy Transition and Security (ICETS)*, 2023, pp. 1-5.
- [19] S. Patil, S. M. Havaldar, R. K. B. S. Mathad, and K. R. Patil, "Lithium-ion Battery State of Health Estimation Using Support Vector Regression(SVR)," in *International Conference on Ambient Intelligence, Knowledge Informatics and Industrial Electronics (AIKIIIE)*, 2023, pp. 1-6.
- [20] J. Ming *et al.*, "Simulation of diffusion polarization in LiMn₂O₄/graphite Li-ion battery during discharge process," *The Chinese Journal of Nonferrous Metals*, 2013.
- [21] H. He *et al.*, "China's battery electric vehicles lead the world: achievements in technology system architecture and technological breakthroughs," *Green Energy and Intelligent Transportation*, vol. 1, no. 1, p. 100020, 2022.
- [22] J. T. Frith, M. J. Lacey, and U. Ulissi, "A non-academic perspective on the future of lithium-based batteries," *Nature Communications*, vol. 14, no. 1, p. 420, 2023.
- [23] Z. Zhou, Y. Liu, M. You, R. Xiong, and X. Zhou, "Two-stage aging trajectory prediction of LFP lithium-ion battery based on transfer learning with the cycle life prediction," *Green Energy and Intelligent Transportation*, vol. 1, no. 1, p. 100008, 2022.
- [24] Y. Zhang and M. Zhao, "Cloud-based in-situ battery life prediction and classification using machine learning," *Energy Storage Materials*, vol. 57, pp. 346-359, 2023.
- [25] S. Mateo, "Procédure pour conduire avec succès une revue de littérature selon la méthode PRISMA," *Kinésithérapie, la Revue*, vol. 20, no. 226, pp. 29-37, 2020.
- [26] X. Liu, Y. Li, N. Wang, Q. Zhuo, and T. Li, "The diffusion polarization model of lithium-ion battery relaxation effect," in *2015 12th IEEE International Conference on Electronic Measurement & Instruments (ICEMI)*, 2015, vol. 01, pp. 131-135.
- [27] S. Tamilselvi *et al.*, "A Review on Battery Modelling Techniques," *Sustainability*, vol. 13, no. 18, p. 10042, 2021.
- [28] J. Tian, R. Xiong, and Q. Yu, "Fractional-Order Model-Based Incremental Capacity Analysis for Degradation State Recognition of Lithium-Ion Batteries," *IEEE Transactions on Industrial Electronics*, vol. 66, no. 2, pp. 1576-1584, 2019.
- [29] C. Zou, L. Zhang, X. Hu, Z. Wang, T. Wik, and M. Pecht, "A review of fractional-order techniques applied to lithium-ion batteries, lead-acid batteries, and supercapacitors," *Journal of Power Sources*, vol. 390, pp. 286-296, 2018.
- [30] J. Wang *et al.*, "Lithium-Ion Battery State-of-Charge Estimation Using Electrochemical Model with Sensitive Parameters Adjustment," *Batteries*, vol. 9, no. 3, p. 180, 2023.

- [31] M. Doyle, T. F. Fuller, and J. Newman, "Modeling of Galvanostatic Charge and Discharge of the Lithium/Polymer/Insertion Cell," *Journal of The Electrochemical Society*, vol. 140, no. 6, p. 1526, 1993.
- [32] M. Doyle, J. Newman, A. S. Gozdz, C. N. Schmutz, and J. M. Tarascon, "Comparison of Modeling Predictions with Experimental Data from Plastic Lithium Ion Cells," *Journal of The Electrochemical Society*, vol. 143, no. 6, p. 1890, 1996.
- [33] T. F. Fuller, M. Doyle, and J. Newman, "Simulation and Optimization of the Dual Lithium Ion Insertion Cell," *Journal of The Electrochemical Society*, vol. 141, no. 1, p. 1, 1994.
- [34] B. S. Haran, B. N. Popov, and R. E. White, "Determination of the hydrogen diffusion coefficient in metal hydrides by impedance spectroscopy," *Journal of Power Sources*, vol. 75, no. 1, pp. 56-63, 1998.
- [35] X. Zhu, Q. Lin, S. You, S. Chen, and Y. Hong, "A Review of Battery State of Health Estimation," in *2019 4th International Conference on Intelligent Green Building and Smart Grid (IGBSG)*, 2019, pp. 456-460.
- [36] S. Susanna, B. R. Dewangga, O. Wahyungoro, and A. I. Cahyadi, "Comparison of Simple Battery Model and Thevenin Battery Model for SOC Estimation Based on OCV Method," in *2019 International Conference on Information and Communications Technology (ICOIACT)*, 2019, pp. 738-743.
- [37] K. c. Bae, S. c. Choi, J. h. Kim, C. y. Won, and Y. c. Jung, "LiFePO₄ dynamic battery modeling for battery simulator," in *2014 IEEE International Conference on Industrial Technology (ICIT)*, 2014, pp. 354-358.
- [38] N. Nagaoka and A. Ametani, "An estimation method of Li-ion battery impedance using z-transform," in *2012 IEEE 13th Workshop on Control and Modeling for Power Electronics (COMPEL)*, 2012, pp. 1-6.
- [39] H. K, Y. Wang, and F. J, "Research on equivalent circuit Model of Lithium-ion battery for electric vehicles," in *2020 3rd World Conference on Mechanical Engineering and Intelligent Manufacturing (WCMEIM)*, 2020, pp. 492-496.
- [40] M. Chen and G. A. Rincon-Mora, "Accurate electrical battery model capable of predicting runtime and I-V performance," *IEEE Transactions on Energy Conversion*, vol. 21, no. 2, pp. 504-511, 2006.
- [41] Y. Wu, H. Chen, L. Cao, J. Duan, X. Chen, and J. Zhai, "Research on Online Identification of Lithium-ion Battery Equivalent Circuit Model Parameters," in *2022 9th International Forum on Electrical Engineering and Automation (IFEEA)*, 2022, pp. 130-136.
- [42] V. H. Johnson, "Battery performance models in ADVISOR," *Journal of Power Sources*, vol. 110, no. 2, pp. 321-329, 2002.
- [43] P. Shrivastava, P. A. Naidu, S. Sharma, B. K. Panigrahi, and A. Garg, "Review on technological advancement of lithium-ion battery states estimation methods for electric vehicle applications," *Journal of Energy Storage*, vol. 64, p. 107159, 2023.
- [44] X. Zhou, J. L. Stein, and T. Ersal, "Battery state of health monitoring by estimation of the number of cyclable Li-ions," *Control Engineering Practice*, vol. 66, pp. 51-63, 2017.

- [45] R. Dorn, R. Schwartz, and B. Steurich, "Battery management system," in *Lithium-Ion Batteries: Basics and Applications*, R. Korthauer Ed. Berlin, Heidelberg: Springer Berlin Heidelberg, 2018, pp. 165-175.
- [46] W. Waag and D. U. Sauer, "SECONDARY BATTERIES – LEAD– ACID SYSTEMS | State-of-Charge/Health," in *Encyclopedia of Electrochemical Power Sources*, J. Garche Ed. Amsterdam: Elsevier, 2009, pp. 793-804.
- [47] J. T. Warner, *The handbook of lithium-ion battery pack design: chemistry, components, types and terminology*. Elsevier, 2015.
- [48] S. Yang, C. Zhang, J. Jiang, W. Zhang, L. Zhang, and Y. Wang, "Review on state-of-health of lithium-ion batteries: Characterizations, estimations and applications," *Journal of Cleaner Production*, vol. 314, p. 128015, 2021.
- [49] X. Hu, L. Xu, X. Lin, and M. Pecht, "Battery Lifetime Prognostics," *Joule*, vol. 4, no. 2, pp. 310-346, 2020.
- [50] B. V. Ratnakumar, M. C. Smart, L. D. Whitcanack, and R. C. Ewell, "The impedance characteristics of Mars Exploration Rover Li-ion batteries," *Journal of Power Sources*, vol. 159, no. 2, pp. 1428-1439, 2006.
- [51] A.-I. Stroe, "Analysis of Performance and Degradation fo Lithium Titanate Oxide Batteries," PhD, Aalborg University, 2018.
- [52] Y.-H. Chiang, W.-Y. Sean, and J.-C. Ke, "Online estimation of internal resistance and open-circuit voltage of lithium-ion batteries in electric vehicles," *Journal of Power Sources*, vol. 196, no. 8, pp. 3921-3932, 2011.
- [53] A. Hentunen, T. Lehmuspelto, and J. Suomela, "Time-Domain Parameter Extraction Method for Thévenin-Equivalent Circuit Battery Models," *IEEE Transactions on Energy Conversion*, vol. 29, no. 3, pp. 558-566, 2014.
- [54] H. He, R. Xiong, X. Zhang, F. Sun, and J. Fan, "State-of-Charge Estimation of the Lithium-Ion Battery Using an Adaptive Extended Kalman Filter Based on an Improved Thevenin Model," *IEEE Transactions on Vehicular Technology*, vol. 60, no. 4, pp. 1461-1469, 2011.
- [55] P. Mauracher and E. Karden, "Dynamic modelling of lead/acid batteries using impedance spectroscopy for parameter identification," *Journal of Power Sources*, vol. 67, no. 1, pp. 69-84, 1997.
- [56] B. Yann Liaw, G. Nagasubramanian, R. G. Jungst, and D. H. Doughty, "Modeling of lithium ion cells—A simple equivalent-circuit model approach," *Solid State Ionics*, vol. 175, no. 1, pp. 835-839, 2004.
- [57] G. Lijun, L. Shengyi, and R. A. Dougal, "Dynamic lithium-ion battery model for system simulation," *IEEE Transactions on Components and Packaging Technologies*, vol. 25, no. 3, pp. 495-505, 2002.
- [58] A. Sedighfar and M. R. Moniri, "Battery state of charge and state of health estimation for VRLA batteries using Kalman filter and neural networks," in *2018 5th International Conference on Electrical and Electronic Engineering (ICEEE)*, 2018, pp. 41-46.
- [59] G. Erlangga, A. Perwira, and A. Widyotriatmo, "State of charge and state of health estimation of lithium battery using dual Kalman filter method," in *2018 International Conference on Signals and Systems (ICSigSys)*, 2018, pp. 243-248.

- [60] Q. Zhang, "Research on Evaluating the Health of Lithium-ion Battery Based on Double Kalman Filter Algorithm," in *2020 IEEE International Conference on Artificial Intelligence and Computer Applications (ICAICA)*, 2020, pp. 1324-1327.
- [61] L. Wan *et al.*, "Joint Estimation of State of Charge and State of Health and Fault Early Warning for Energy Storage Power Station based on Double Unscented Kalman Filter Algorithm," in *2022 Power System and Green Energy Conference (PSGEC)*, 2022, pp. 137-143.
- [62] K. ArulKumar, R. Gowthami, V. P. K. Arapirala, P. Ramanathan, and V. Arun, "Estimating Lithium-Ion Battery State of Health with Least Squares Approach for Accurate Assessment," in *2024 Second International Conference on Emerging Trends in Information Technology and Engineering (ICETITE)*, 2024, pp. 1-7.
- [63] J. Wei and C. Chen, "State of Charge and Health Estimation For Lithium-Ion Batteries Using Recursive Least Squares," in *2020 5th International Conference on Advanced Robotics and Mechatronics (ICARM)*, 2020, pp. 686-689.
- [64] Y. Li, H. Zhu, J. Zheng, and Y. Chen, "A Multivariate Regression Method for Battery Remaining Capacity Based on Model Parameter Identification," in *2021 3rd International Academic Exchange Conference on Science and Technology Innovation (IAECST)*, 2021, pp. 1120-1124.
- [65] Q. Zhou, E. Hellström, D. Anderson, and J. Sun, "Sensitivity Analysis of Support Vector Regression-Based Incremental Capacity Analysis for Battery State of Health Estimations," in *2023 IEEE Conference on Control Technology and Applications (CCTA)*, 2023, pp. 1122-1127.
- [66] W. M. U. I. Fernando, H. Ganesh, J. Alsheikh, and J. G. A. L. Jeyabalan, "A Review of Techniques for State of Charge and State of Health Estimation in Battery Management Systems," in *2023 IEEE 21st Student Conference on Research and Development (SCOReD)*, 2023, pp. 316-320.
- [67] M. Dubarry, V. Svoboda, R. Hwu, and B. Yann Liaw, "Incremental Capacity Analysis and Close-to-Equilibrium OCV Measurements to Quantify Capacity Fade in Commercial Rechargeable Lithium Batteries," *Electrochemical and Solid-State Letters*, vol. 9, no. 10, p. A454, 2006.
- [68] A. Krupp, E. Ferg, F. Schuldt, K. Derendorf, and C. Agert, "Incremental capacity analysis as a state of health estimation method for lithium-ion battery modules with series-connected cells," *Batteries*, vol. 7, no. 1, p. 2, 2020.
- [69] A. X. Liu *et al.*, "SOH Estimation Method for Lithium-ion Batteries Based on Partial Charging Voltage Segments," in *2023 11th International Conference on Power Electronics and ECCE Asia (ICPE 2023 - ECCE Asia)*, 2023, pp. 1597-1602.
- [70] A. Gismero, K. Nørregaard, B. Johnsen, L. Stenhøj, D.-I. Stroe, and E. Schaltz, "Electric vehicle battery state of health estimation using Incremental Capacity Analysis," *Journal of Energy Storage*, vol. 64, p. 107110, 2023.
- [71] Y. Li, H. Sheng, and Y. Cheng, "Battery State of Health Estimation with Incremental Capacity Analysis Technique," in *2020 International Conference on Sensing, Measurement & Data Analytics in the era of Artificial Intelligence (ICSMD)*, 2020, pp. 384-389.

- [72] J. Peng *et al.*, "State of Health Estimation of Li-Ion Battery via Incremental Capacity Analysis and Internal Resistance Identification Based on Kolmogorov–Arnold Networks," *Batteries*, vol. 10, no. 9, p. 315, 2024.
- [73] L. Wang, C. Pan, L. Liu, Y. Cheng, and X. Zhao, "On-board state of health estimation of LiFePO₄ battery pack through differential voltage analysis," *Applied Energy*, vol. 168, pp. 465-472, 2016.
- [74] Z. Zhou, B. Duan, Y. Kang, Q. Zhang, Y. Shang, and C. Zhang, "Online State of Health Estimation for Series-Connected LiFePO₄ Battery Pack Based on Differential Voltage and Inconsistency Analysis," *IEEE Transactions on Transportation Electrification*, vol. 10, no. 1, pp. 989-998, 2024.
- [75] J. P. Schmidt, "Verfahren zur Charakterisierung und Modellierung von Lithium-Ionen Zellen," 2013.
- [76] M. Kwiecien, J. Badeda, M. Huck, K. Komut, D. Duman, and D. U. Sauer, "Determination of SoH of Lead-Acid Batteries by Electrochemical Impedance Spectroscopy," *Applied Sciences*, vol. 8, no. 6, p. 873, 2018.
- [77] A. Fly and R. Chen, "Rate dependency of incremental capacity analysis (dQ/dV) as a diagnostic tool for lithium-ion batteries," *Journal of Energy Storage*, vol. 29, p. 101329, 2020.
- [78] X. Hu, J. Jiang, D. Cao, and B. Egardt, "Battery health prognosis for electric vehicles using sample entropy and sparse Bayesian predictive modeling," *IEEE Transactions on Industrial Electronics*, vol. 63, no. 4, pp. 2645-2656, 2015.
- [79] K. K. Sadabadi, X. Jin, and G. Rizzoni, "Prediction of remaining useful life for a composite electrode lithium ion battery cell using an electrochemical model to estimate the state of health," *Journal of Power Sources*, vol. 481, p. 228861, 2021.
- [80] K. W. Knehr, T. Hodson, C. Bommier, G. Davies, A. Kim, and D. A. Steingart, "Understanding full-cell evolution and non-chemical electrode crosstalk of Li-ion batteries," *Joule*, vol. 2, no. 6, pp. 1146-1159, 2018.
- [81] P. Mohtat, S. Lee, J. B. Siegel, and A. G. Stefanopoulou, "Comparison of expansion and voltage differential indicators for battery capacity fade," *Journal of Power Sources*, vol. 518, p. 230714, 2022.
- [82] N. A. Samad, Y. Kim, J. B. Siegel, and A. G. Stefanopoulou, "Battery capacity fading estimation using a force-based incremental capacity analysis," *Journal of The Electrochemical Society*, vol. 163, no. 8, p. A1584, 2016.
- [83] Y. Wu and A. Jossen, "Entropy-induced temperature variation as a new indicator for state of health estimation of lithium-ion cells," *Electrochimica Acta*, vol. 276, pp. 370-376, 2018.
- [84] S. Sharma, P. D. Achlerkar, P. Shrivastava, A. Garg, and B. K. Panigrahi, "Combined SoC and SoE Estimation of Lithium-ion Battery using Multi-layer Feedforward Neural Network," in *2022 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES)*, 2022, pp. 1-6.
- [85] M. Loussif, S. K. E. Khil, L. Charaabi, and S. Sayahi, "Performance Analysis of GRU, LSTM and Feedforward Neural Networks for the State of Charge Estimation of a Lithium-Ion Battery for e-Bike Applications," in *2023 14th International Renewable Energy Congress (IREC)*, 2023, pp. 1-6.

- [86] S. A. Memon, A. Hamza, S. S. H. Zaidi, and B. M. Khan, "Estimating State of Charge and State of Health of Electrified Vehicle Battery by Data Driven Approach: Machine Learning," in *2022 International Conference on Emerging Technologies in Electronics, Computing and Communication (ICETECC)*, 2022, pp. 1-9.
- [87] M. A. Hearst, S. T. Dumais, E. Osuna, J. Platt, and B. Scholkopf, "Support vector machines," *IEEE Intelligent Systems and their Applications*, vol. 13, no. 4, pp. 18-28, 1998.
- [88] C. Cortes and V. Vapnik, "Support-vector networks," *Machine Learning*, vol. 20, no. 3, pp. 273-297, 1995/09/01 1995.
- [89] S. Ertekin, L. Bottou, and C. L. Giles, "Nonconvex Online Support Vector Machines," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 33, no. 2, pp. 368-381, 2011.
- [90] S. Sun, Q. Lin, H. Li, Y. Zhan, and Y. Dai, "Simultaneous Estimation of SOH and SOC of Batteries Based on SVM," in *2022 4th International Conference on Smart Power & Internet Energy Systems (SPIES)*, 2022, pp. 1934-1938.
- [91] L. Li, W. Cui, X. Hu, and Z. Chen, "A State-of-Health Estimation Method of Lithium-ion Batteries using ICA and SVM," in *2021 Global Reliability and Prognostics and Health Management (PHM-Nanjing)*, 2021, pp. 1-5.
- [92] L. Qianglong, Z. Xiaowei, Z. Kun, S. Jianrui, and W. Kai, "State of Health Estimation of Lithium-ion Battery Based on Ant Lion Optimization and Support Vector Regression," in *2021 IEEE International Conference on Electrical Engineering and Mechatronics Technology (ICEEMT)*, 2021, pp. 334-337.
- [93] Z. Li, D. Chen, J. Lu, W. Zhang, and C. Deng, "Li-ion Battery SOH Estimation Based on BO-SVR Model," in *2023 IEEE 7th Conference on Energy Internet and Energy System Integration (EI2)*, 2023, pp. 3737-3742.
- [94] W. Yang, D. Zhang, and Y. Fu, "Research of a Diagonal Recurrent Neural Network and Artificial Neural Networks," in *2016 International Symposium on Computer, Consumer and Control (IS3C)*, 2016, pp. 374-377.
- [95] T. Oji, Y. Zhou, S. Ci, F. Kang, X. Chen, and X. Liu, "Data-Driven Methods for Battery SOH Estimation: Survey and a Critical Analysis," *IEEE Access*, vol. 9, pp. 126903-126916, 2021.
- [96] C. Nguyen Van and D. T. Quang, "Estimation of SoH and internal resistances of Lithium ion battery based on LSTM network," *International Journal of Electrochemical Science*, vol. 18, no. 6, p. 100166, 2023.
- [97] T. G. T. A. Bandara, J. C. Á. Antón, M. González, D. Anseána, and J. C. Viera, "State of Health Estimation using Machine Learning for Li-ion battery on Electric Vehicles," in *2021 IEEE Vehicle Power and Propulsion Conference (VPPC)*, 2021, pp. 1-4.
- [98] I.-S. Han and C.-B. Chung, "Performance prediction and analysis of a PEM fuel cell operating on pure oxygen using data-driven models: A comparison of artificial neural network and support vector machine," *International Journal of Hydrogen Energy*, vol. 41, no. 24, pp. 10202-10211, 2016.
- [99] Z. N. Bako, M. A. Tankari, G. Lefebvre, and A. S. Maiga, "Experiment-Based Methodology of Kinetic Battery Modeling for Energy Storage," *IEEE Transactions on Industry Applications*, vol. 55, no. 1, pp. 593-599, 2019.

- [100] J. Hemdani, L. Degaa, N. Rizoug, and A. Chaari, "State of Health Prediction of Lithium-Ion Battery Using Machine Learning Algorithms," in *2023 9th International Conference on Control, Decision and Information Technologies (CoDIT)*, 2023, pp. 2729-2733.
- [101] R. Sharma, A. Bala, A. Singh, and M. Singh, "State of Health Estimation for Li-Ion Battery Using Machine Learning," in *2023 IEEE International Conference on Metrology for eXtended Reality, Artificial Intelligence and Neural Engineering (MetroXRINE)*, 2023, pp. 406-411.
- [102] Y. Che, Y. Zheng, X. Sui, and R. Teodorescu, "Boosting battery state of health estimation based on self-supervised learning," *Journal of Energy Chemistry*, vol. 84, pp. 335-346, 2023.
- [103] Y. Che, Y. Zheng, F. E. Forest, X. Sui, X. Hu, and R. Teodorescu, "Predictive health assessment for lithium-ion batteries with probabilistic degradation prediction and accelerating aging detection," *Reliability Engineering and System Safety*, Article vol. 241, 2024, Art no. 109603.
- [104] Q. Xie, R. Liu, J. Huang, and J. Su, "Residual life prediction of lithium-ion batteries based on data preprocessing and a priori knowledge-assisted CNN-LSTM," *Energy*, vol. 281, p. 128232, 2023.
- [105] M. Li *et al.*, "Effect of data enhancement on state-of-charge estimation of lithium-ion battery based on deep learning methods," *Journal of Energy Storage*, vol. 82, p. 110573, 2024.
- [106] M. Van Genuchten, "A Closed-form Equation for Predicting the Hydraulic Conductivity of Unsaturated Soils1," *Soil Science Society of America Journal*, vol. 44, 09/01 1980.
- [107] Y.-F. Luo and K.-Y. Lu, "An online state of health estimation technique for lithium-ion battery using artificial neural network and linear interpolation," *Journal of Energy Storage*, vol. 52, p. 105062, 2022.
- [108] D. Andre, A. Nuhic, T. Soczka-Guth, and D. U. Sauer, "Comparative study of a structured neural network and an extended Kalman filter for state of health determination of lithium-ion batteries in hybrid electricvehicles," *Engineering Applications of Artificial Intelligence*, vol. 26, no. 3, pp. 951-961, 2013.
- [109] K. M. V. Atamuradov, P. Dersin, B. Lamoureux, N. Zerhouni, *IJPHM Special Issue on Railway Systems & Mass Transportation* (IJPHM, International Journal of Prognostics and Health Management). 2017.
- [110] P. Eleftheriadis, S. Giazitzis, C. Ozmalatyallilar, S. Leva, and R. Zich, "An Overview of Data-Driven Methods for the State of Health Estimation," in *2023 IEEE International Conference on Environment and Electrical Engineering and 2023 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe)*, 2023, pp. 1-6.
- [111] Z. Ren and C. Du, "A review of machine learning state-of-charge and state-of-health estimation algorithms for lithium-ion batteries," *Energy Reports*, vol. 9, pp. 2993-3021, 2023.
- [112] B. V. S. Vardhan, M. Khedkar, and P. Thakre, "A Comparative Analysis of Hold Out, Cross and Re-Substitution Validation in Hyper-Parameter Tuned Stochastic Short Term Load Forecasting," in *2022 22nd National Power Systems Conference (NPSC)*, 17-19 Dec. 2022, pp. 448-453.
- [113] A. Foussemi, K. Ziane, and M. J. D. Otis, "Battery internal resistance and state of health estimation based on modified Van Genuchten-Gupta model compared to a feedforward neural network," in *2024 IEEE Vehicle Power and Propulsion Conference (VPPC)*, 2024, pp. 1-6.