

RÉPUBLIQUE ALGÉRIE POPULAIRE DÉMOCRATIQUE
MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR
ET DE LA RECHERCHE
SCIENTIFIQUE UNIVERSITÉ
KASDI MERBAH - OUARGLA
Faculté des nouvelles technologies de l'information et de la communication
Département d'électronique et de télécommunications



MEMOIRE ACADEMIQUE DE MASTER

Domaine : instrumentation et systèmes

présenté par :

Branis Abdelghani

gouni oussama

Thème :

Pronostic de défauts des batteries au lithium-ion en utilisant les techniques d'apprentissage profond

Présente publiquement dans le .22 juin 2024

Devant le jury :

Dr.Lati Abdelhai	MCA	President	UKM Ouargla
Dr.Berrak Oulaya	MCA	Examiner	UKM Ouargla
Dr.Nacira Boudraa	MCA	Supervisor	UKM Ouargla
Dr.Houari toubakh	MCA	Co-Supervisor	UKM Ouargla

Dedication

Branis Abdelghani

Je remercie Dieu Tout-Puissant qui m'a permis de terminer mes études avec ce travail. Bien qu'il soit modeste, c'est une grande réussite pour moi. C'est une dédicace à ceux qui m'ont encouragé et accompagné tout au long de ma vie. À mon père et à ma mère bien-aimée au cœur généreux et bienveillant, à mes chers frères et sœurs, à mes enseignants religieux qui n'ont jamais hésité à nous transmettre leur savoir, et à tous ceux qui m'ont soutenu et aidé dans ma quête de recherche. Merci à tous. Je tiens à vous remercier du fond de mon cœur et je vous dédie ce travail. C'est le fruit de jours consécutifs de labeur, et j'espère que Dieu l'acceptera comme une œuvre perpétuelle. Je remercie tout particulièrement mes chers professeurs : Houari Tabakh, Boubaker Rouabah, et Boudraâ Nassira, ainsi que mon ami Oussama Gouni et tous mes camarades de classe en (instrumentation et Systèmes).

Dedication

gouni oussama

Tout d'abord, nous rendons grâce à Dieu, qui nous a permis d'être en bonne santé et de faire ce travail du début à la fin. Nous remercions les chers membres de notre famille pour leur soutien tout au long de ce chemin difficile. Un merci spécial à notre encadrant, le Dr houari toubakh, pour sa disponibilité, ses conseils et ses critiques constructives afin de mener à bien ce projet. Tout cela merci à Mme Boudraa Nacira pour sa présence, ses conseils et sa grande contribution à la réussite de ce projet. Nous remercions les membres du jury d'avoir accepté de juger notre modeste projet et pour leurs remarques, critiques, orientations et conseils qui nous ont été très utiles. Et enfin, nous remercions tous les enseignants de l'Université Kasdi Merbah pour leurs efforts et également nos amis pour leur aide précieuse. Je voudrais dédier mon essai de fin d'études aux personnes incroyables qui ont été à mes côtés tout au long de ce voyage. À ma mère aimante, dont le soutien indéfectible et les encouragements sans fin ont fait de moi la personne que je suis aujourd'hui. Vos sacrifices et votre confiance en moi ont été mon phare et je vous serai éternellement reconnaissant pour votre amour et votre dévouement. À mes formidables sœurs et frères, qui ont été mes piliers de force et mes meilleurs amis. Votre présence dans ma vie m'a apporté de la joie, des rires et d'innombrables souvenirs. Merci de m'avoir toujours poussé à viser l'excellence et d'être là à travers chaque succès et chaque échec. À mes chers amis, qui m'ont soutenu contre vents et marées. Votre camaraderie, vos encouragements et vos expériences partagées ont rendu ce voyage encore plus mémorable. Nous avons célébré des victoires, surmonté des défis et grandi ensemble, et je suis reconnaissant pour les liens durables que nous avons noués. Chacun d'entre vous a joué un rôle unique dans l'élaboration de mon parcours éducatif, en apportant soutien, amour et motivation lorsque j'en avais le plus besoin. Cet essai de fin d'études est dédié à vous, ma mère bien-aimée, mes sœurs, mes frères et mes amis. Votre présence dans ma vie a été un cadeau et je vous serai éternellement reconnaissant pour votre amour et votre soutien indéfectibles.

Avec toute ma gratitude

Remerciements :

Louange à Dieu pour Son succès et Sa grâce. Je tiens à exprimer ma profonde gratitude à tous ceux qui ont contribué à la réalisation de ce mémoire de fin d'études. Je commence par remercier Dieu Tout-Puissant, puis mes chers professeurs Houari Tabakh, Boubaker Rouabah, et Boudraa Nassira pour leur soutien et leurs conseils continus. Je remercie également mes amis Bourogaa Mohamed Amine et Ridouane Slimani et Yacine Charaf pour leur aide et leur encouragement, ainsi que tous les membres de notre faculté en général. Merci beaucoup à vous tous

abstract

Our study concentrated on a sophisticated battery system designed for fault prognosis and the prediction of the remaining useful life (RUL) of lithium-ion batteries through the application of artificial intelligence. By leveraging advanced deep learning models, we aimed to create highly effective and accurate methods for estimating battery life. Our models were rigorously tested using the comprehensive NASA battery dataset, ensuring their reliability and precision in predicting the RUL of lithium-ion batteries. This approach not only enhances battery management but also significantly contributes to the development of more efficient and safer energy storage systems.

Keywords: lithium battery-fault prediction - estimating the remaining life of a lithium battery-artificial intelligence-deep learning-NASA data

Résumé

Notre étude s'est concentrée sur un système de batterie sophistiqué destiné à la prédiction de pannes et à l'estimation de la durée de vie utile restante (RUL) des batteries au lithium-ion grâce à l'intelligence artificielle. En utilisant des modèles avancés de deep learning, nous avons cherché à créer des méthodes hautement efficaces et précises pour estimer la durée de vie des batteries. Nos modèles ont été rigoureusement testés à l'aide de l'ensemble de données complet de la NASA sur les batteries, garantissant leur fiabilité et leur précision dans la prédiction de la RUL des batteries au lithium-ion. Cette approche non seulement améliore la gestion des batteries, mais contribue également de manière significative au développement de systèmes de stockage d'énergie plus efficaces et plus sûrs.

Les Mots clés: batterie au lithium-prédiction des pannes-estimation de la durée de vie restante d'une batterie au lithium-intelligence artificielle-apprentissage en profondeur-données de la NASA

الملخص

تركزت دراستنا على نظام بطاريات متطور مخصص للتنبؤ بالأعطال وتقدير العمر المتبقي للبطاريات الليثيوم-أيون باستخدام الذكاء الاصطناعي. باستخدام نماذج متقدمة من التعلم العميق، سعينا إلى إنشاء طرق فعالة ودقيقة للغاية لتقدير عمر البطاريات. تم اختبار نماذجنا بدقة باستخدام مجموعة بيانات شاملة من ناسا عن البطاريات، مما يضمن موثوقيتها ودقتها في التنبؤ بالعمر المتبقي للبطاريات الليثيوم-أيون. هذه المقاربة لا تحسن فقط إدارة البطاريات، ولكنها تساهم أيضًا بشكل كبير في تطوير أنظمة تخزين الطاقة الأكثر فعالية وأمانًا.

الكلمات المفتاحية: بطارية الليثيوم - التنبؤ بالأعطال - تقدير العمر المتبقي لبطارية الليثيوم - الذكاء الاصطناعي - التعلم العميق - بيانات ناسا

Table des matières

1 chapitre 01 : Généralités sur les batteries au lithium-ions	2
1.1 introduction :	3
1.2 Lithium-ion : Comparaison entre Batteries Rechargeables et Non-Rechargeables :	4
1.2.1 Éléments constitutifs de cellules au lithium-ion :	5
1.2.2 Formats et configuration de cellules au lithium-ion :	5
1.3 Principe de fonctionnement de batterie lithium-ion :	7
1.4 Grandeurs caractéristiques des batteries lithium-ion :	7
1.4.1 Tension à vide, nominale, chute de tension :	7
1.4.2 Capacité nominale, résiduelle :	8
1.4.3 L'état de charge (SOC) :	8
1.4.4 Le nombre de cycle (Nb Cycles) :	8
1.4.5 L'état de santé (SOH) :	8
1.4.6 Résistance interne :	9
1.4.7 La durée de vie restante de batterie RUL	9
1.5 Vieillessement des batteries Lithium-ion :	9
1.6 Les profils de charge et de décharge des batteries lithium-ion :	9
1.6.1 Technique de Charge :	9
1.6.2 Technique de décharge :	11
1.7 Système de management de batterie (BMS) :	11
1.8 modélisation des batteries lithium ion :	12
1.8.1 Modèles électrochimiques :	12
1.8.2 Modèles à circuits électriques équivalents (CEE)	13
1.8.3 Modélisation de type "boite noire" :	14
1.9 conclusion :	14
2 chapitre 02 :Pronostic des défauts et prédiction de la durée de vie restante (RUL) des batteries lithium-ion par IA."	15
2.1 introduction :	16
2.2 Prognostic et gestion de la santé des batteries au lithium-ion :	16
2.2.1 La durée de vie restante de batterie(remaining useful life) RUL :	17
2.2.2 Les approches de prédiction de la durée de vie restante (RUL) pour les batteries au lithium-ion	17
2.3 De l'intelligence artificielle au apprentissage profond	19
2.3.1 Intelligence artificielle	20
2.3.2 L'apprentissage automatique	20
2.3.3 Apprentissage Profond (Deep Learning)	21
2.4 conclusion :	22

3	chapitre 03 :Modèles de Deep Learning Proposé pour la Prédiction de RUL des lithium-ion Batteries	23
3.1	introduction :.....	24
3.2	Description de NASA dataset :.....	24
3.3	Description et Design du Modèle LSTM Proposé :	25
3.3.1	Description et Définition de LSTM	25
3.3.2	architecture de modèle LSTM pour RUL prediction.....	26
3.4	Description et Design du Modèle CNN Proposé.....	28
3.4.1	Description et Définition de CNN.....	28
3.4.2	Architecture de modèle CNN pour la prédiction de RUL	28
3.5	conclusion :.....	29
4	chapitre 04 :résultats et discussions	30
4.1	introduction :.....	31
4.2	Expériences et résultats :.....	31
4.2.1	Google colab :.....	31
4.2.2	Les critères d'évaluation pour la prédiction de RUL en utilisant le modèle de LSTM	32
4.2.3	Les critères d'évaluation pour la prédiction de RUL en utilisant le modèle de CNN :.....	35
4.2.4	Les critères d'évaluation pour la prédiction de RUL en utilisant le modèle de CNN-LSTM :.....	37
4.2.5	Les résultats :.....	37
4.3	conclusion :.....	39

Table des figures

1.1	comparaison de différentes technologies de batteries en termes de densité d'énergie massique et volumique	4
1.2	lithium-ion batterie materials	5
1.3	constituants et principaux formats des cellules au lithium :a :cylindrique,b :bou- tin,c :prismatique,d :en dzchet souple.....	5
1.4	Configuration en séries	6
1.5	Configuration en parallèle	6
1.6	Configuration en série-parallèle	7
1.7	pendant charge et décharge	7
1.8	profil type de charge à courant constant, à tension constant.....	10
1.9	system BMS.....	12
1.10	structure d'une cellule au lithium support du modèle de newman.....	12
1.11	modèle de thévenin pour une cellule li-ion.....	13
1.12	modèle dynamique CEE d'une cellule électrochimique	13
1.13	modèle de thévenin modifié pour inclure l'autodécharge de la cellule.....	14
2.1	Le nombre de publications dans des journaux sur la PHM dans Web of Science.	16
2.2	Exemple de la durée de vie restante(RUL) de batterie.....	17
2.3	Approches de prédiction RUL	19
2.4	Intelligence Artificielle vs Machine Learning vs Deep Learning.....	20
2.5	Les catégories de l'apprentissage automatique	21
2.6	Illustration d'un réseau de neurones avec 2 couches cachées	22
3.1	capacity en fonction de cycles.....	24
3.2	LSTM architecture	25
3.3	Division des données et architecture du modèle LSTM.....	27
3.4	exemple de CNN architecture	28
3.5	Division des données et architecture du modèle CNN	29
4.1	platform de google colab.....	32
4.2	Les résultats prédits par le LSTM sur la batterie B0005 au point de départ de 50	34
4.3	Les résultats prédits par le LSTM sur la batterie B0005 au point de départ de 80	34
4.4	Les résultats prédits par le CNN sur la batterie B0005 au point de départ de 50	36
4.5	Les résultats prédits par le CNN sur la batterie B0005 au point de départ de 80	36
4.6	Les résultats prédits par le CNN-LSTM sur la batterie B0005 au point de départ de 50.....	38
4.7	Les résultats prédits par le CNN-LSTM sur la batterie B0005 au point de départ de 80.....	38

Liste des tableaux

3.1	Spécification de la batterie B0005	24
4.1	Hyperparamètres du modèle LSTM.....	33
4.2	Mesures de performance pour différents points de départ	33
4.3	Hyperparamètres du modèle CNN.....	35
4.4	Mesures de performance pour différents points de départ	35
4.5	Mesures de performance pour différents points de départ LSTM - CNN.....	37

Introduction général

Le développement des systèmes de sto-

ckage d'énergie constitue un enjeu majeur dans le contexte actuel de croissance du secteur énergétique. Avec la demande croissante en énergie et les défis posés par l'intermittence des sources d'énergie renouvelables telles que les panneaux solaires et les éoliennes, il est crucial d'améliorer les performances et la sécurité des systèmes de stockage d'énergie. Les batteries jouent un rôle central dans ce contexte, car leur disponibilité est essentielle pour les performances du système, l'autonomie, la capacité électrique et le coût du stockage de l'énergie. Cependant, les technologies de batteries rechargeables actuellement disponibles, telles que les batteries au plomb et au nickel-hydrure métallique, n'ont pas reçu suffisamment d'attention en raison de leur poids élevé et de leur taille peu pratique comparée aux batteries au lithium. Les batteries au lithium sont largement utilisées dans de nombreux appareils électriques en raison de leurs caractéristiques supérieures. Cependant, elles peuvent être exposées à des conditions instables pendant leur fonctionnement, ce qui rend la détection des défauts difficile. Il convient de noter que les batteries lithium-ion présentent généralement un risque potentiel pour la sécurité, car elles peuvent conduire à des situations dangereuses si elles sont mal manipulées ou défectueuses. Des mesures strictes visant à améliorer la fiabilité et la sécurité des batteries au lithium et lithium-ion sont essentielles, en mettant l'accent sur la détection précoce des problèmes potentiels et la prévention des accidents liés aux batteries défectueuses. Cependant, détecter et diagnostiquer les défauts des batteries est une tâche complexe en raison de la nature interconnectée des défauts potentiels et de la complexité de leur comportement. L'objectif principal de ce travail est de Dans le premier chapitre du projet, nous présentons un aperçu des batteries lithium-ion, en abordant leurs caractéristiques, leur historique récent et leurs concepts de base. Dans le deuxième chapitre, nous discutons du pronostic des défauts et des différentes approches pour la prédiction de la durée de vie restante (RUL) des batteries. Le troisième chapitre est consacré à la prédiction de la RUL des batteries en utilisant différents modèles d'apprentissage profond. Enfin, le quatrième chapitre traite des résultats obtenus et des discussions les concernant

Chapitre 1

chapitre 01 : Généralités sur les batteries au lithium-ions

1.1 introduction :

Ce premier chapitre examine en détail les éléments constitutifs et les principales caractéristiques des cellules Li-ion. Il décrit les différents composants, tels que les électrodes positive et négative, l'électrolyte et le séparateur. En outre, il explique en profondeur les caractéristiques clés des cellules Li-ion. L'objectif est de fournir une compréhension complète des cellules Li-ion et de leurs propriétés essentielles, afin de garantir une utilisation efficace et sécurisée.

Les Avantages Clés des Batteries au Lithium dans les Applications Modernes :

Les batteries au lithium sont largement utilisées dans divers domaines en raison de leurs propriétés uniques :

1. **Caractère réducteur prononcé** : Le potentiel standard du lithium (Li/Li+) est très bas, ce qui le rend fortement réducteur. Cela permet de générer une force électromotrice élevée en associant le lithium à un oxydant.
2. **Haute densité énergétique massique et volumique** : En raison de sa faible masse molaire et de sa densité volumique, le lithium offre une capacité spécifique élevée en tant que matériau de stockage d'énergie électrochimique, avec une densité énergétique supérieure à celle de la plupart des autres couples électrochimiques.
3. **Utilisation répandue** : Les batteries au lithium sont largement utilisées dans divers domaines tels que l'électronique portable, les applications médicales, les systèmes portables, les satellites et les véhicules électrifiés.
4. **Avantage comparatif** : Les batteries au lithium offrent une densité énergétique massique et volumique supérieure à celle de leurs concurrents, ce qui en fait un choix privilégié pour de nombreuses applications.

Les batteries au lithium ont pris une place prépondérante, comme sources d'énergie dans divers domaines tels que l'électronique portable et les applications médicales. Actuellement, ces batteries alimentent les systèmes portables, les satellites et les véhicules électrifiés. Leur principal avantage réside dans leur forte densité énergétique massique et volumique comparé à leur concurrente comme l'illustre la Figure 1.1. En effet, le lithium est le plus léger des métaux (6,94 g.mol⁻¹ pour une densité volumique de 0,53 g.cm⁻³) et le plus électropositif (-3,04V relativement au potentiel standard de l'hydrogène) . Il confère à la batterie une densité énergétique élevée (supérieure à 150Wh.kg⁻¹ et à 200Wh.l⁻¹). Les batteries au lithium regroupent trois principales technologies : le lithium-ion, le lithium polymère et le lithium métal .

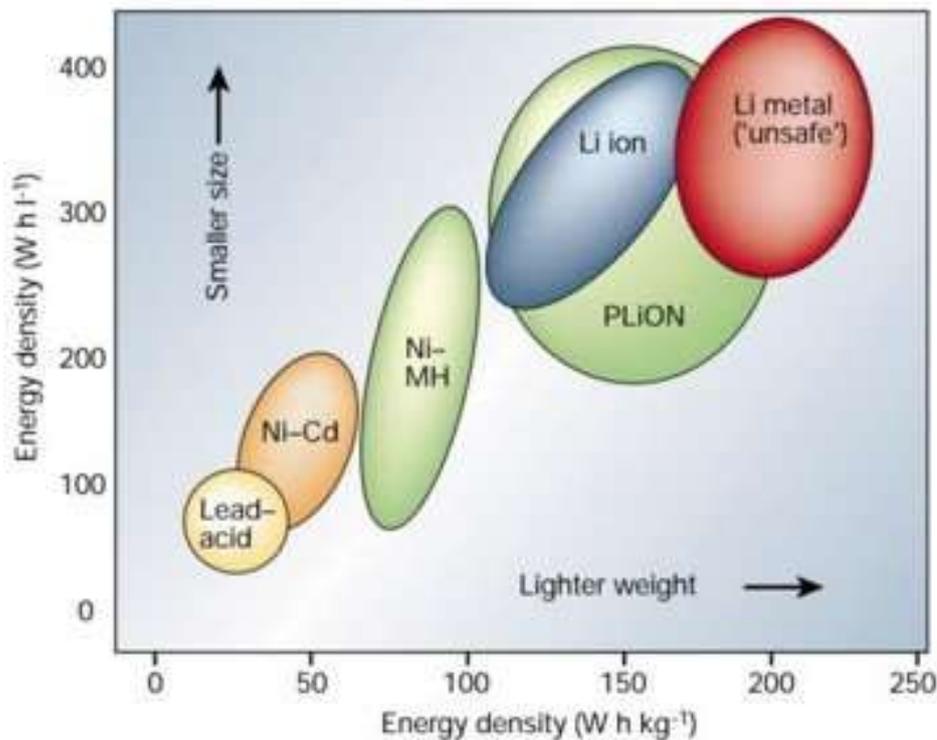


FIGURE 1.1 – comparaison de différentes technologies de batteries en termes de densité d'énergie massique et volumique

1.2 Lithium-ion : Comparaison entre Batteries Rechargeables et Non-Rechargeables :

Les batteries se regroupent sous deux grandes classes : accumulateurs primaires (non-rechargeable) et autres secondaires (rechargeable) :

– Batteries non -rechargeable (primaires) :

Une batterie non rechargeable, également connue sous le nom de batterie primaire, est un dispositif de stockage électrochimique conçu pour fournir de l'énergie électrique de manière ponctuelle. Contrairement aux batteries rechargeables, ces cellules ne peuvent pas être rechargées après avoir été complètement déchargées. Elles sont conçues pour être utilisées une seule fois et doivent être remplacées une fois que leur capacité de stockage d'énergie est épuisée. Les batteries non rechargeables sont couramment utilisées dans une variété d'applications, telles que les appareils électroniques grand public, les dispositifs médicaux, et d'autres équipements où une alimentation électrique portable et peu coûteuse est nécessaire[7].

Les avantages principaux d'une batterie primaire sont : une énergie spécifique Très élevée, durée de vie appréciable, aucune maintenance à prévoir, et une facilité d'utilisation.

– **Batteries rechargeable (secondaire) :** Un accumulateur, ou batterie secondaire, est un dispositif électrochimique conçu pour stocker de l'électricité et la restituer selon les besoins. Lorsqu'il est déchargé, il peut être rechargé électriquement en inversant le courant à travers ses électrodes. Cela lui confère sa fonction de stockage d'énergie électrique, communément appelée "accumulateur". En termes de terminologie, les accumulateurs peuvent être appelés "cellules" lorsqu'ils sont considérés individuellement. Une batterie, quant à elle, est composée d'un ou plusieurs accumulateurs. Ainsi, une batterie contient un ensemble de cellules ou d'accumulateurs, chacun contribuant à stocker et à fournir

de l'énergie électrique.

1.2.1 Éléments constitutifs de cellules au lithium-ion :

Une cellule Li-ion est composée principalement, comme l'illustre la Figure 1.2 [6]

- **Les électrodes négatives** : Les trois matériaux d'électrode négative utilisés dans les batteries secondaires au lithium sont le graphite, le lithium métal et le titanate de lithium. Parmi ces trois, le graphite est actuellement le matériau le plus utilisé.
- **Les électrodes positives** : Les matériaux d'insertion utilisés pour les électrodes positives peuvent être classifiés en trois familles en fonction de leur structure (figure 1.2) : les oxydes lamellaires, les structures spinelles et les structures olivines. Les oxydes lamellaires permettent généralement des densités d'énergie plus importantes tandis que les structures spinelles et olivines offrent de bonnes caractéristiques de puissance.
- **Le séparateur** : Le séparateur est utilisé pour garantir l'isolation électrique et assurer la conduction ionique des électrodes.
- **L'électrolyte** : Les électrolytes sont répartis en deux groupes : liquides ou gélifiés d'une part et solides D'autre part. Les électrolytes solides sont utilisés pour les microbatteries sous forme de films Minces ou sous forme polymère pour les batteries lithium polymères. Les électrolytes liquides ou gélifiés sont utilisés dans les batteries Li-ion.

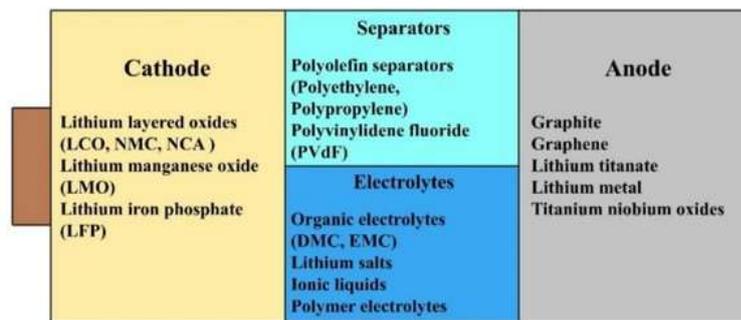


FIGURE 1.2 – lithium-ion batterie materials

1.2.2 Formats et configuration de cellules au lithium-ion :

la Figure 1.3 illustre les différents formats : cylindrique, prismatique, pile bouton et sachet souple (pouch). Outre le coût de fabrication, le choix du format agit sur la densité énergétique de la cellule ainsi que sur la constitution et la compacité du module batterie.

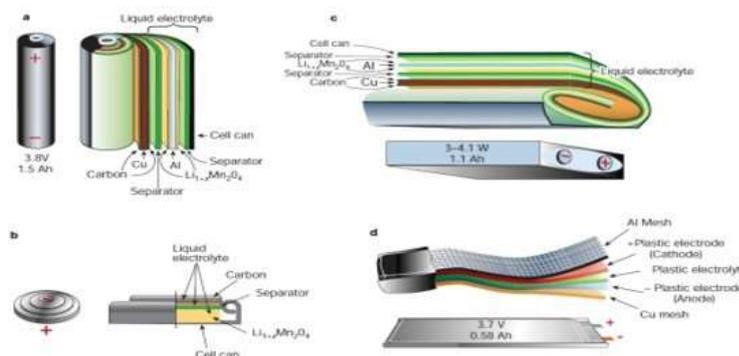


FIGURE 1.3 – constituants et principaux formats des cellules au lithium : a :cylindriaue, b :boutin, c :prismatique, d :en dzchet souple

- **Configuration en série** : La configuration en série est utilisée lorsque la tension d'une seule cellule n'est pas suffisante. La configuration en série est réalisée en connectant le pôle positif d'une cellule au pôle négatif d'une autre cellule, comme illustré dans la figure 1.4 . Les quatre cellules lithium-ion de 3,6 V connectées en série fourniront une tension de 14,4 V, et cette configuration est appelée 4S car quatre cellules sont connectées en série 1.4.

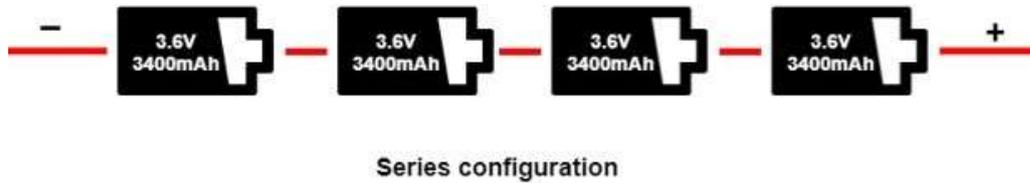


FIGURE 1.4 – Configuration en s éries

- **Configuration en parallèle** : Les cellules sont connectées en parallèle pour répondre aux exigences de capacité de courant plus élevées si l'appareil nécessite un courant plus élevé mais qu'il n'y a pas suffisamment d'espace disponible pour la batterie. Cet appareil peut utiliser la configuration en parallèle pour obtenir une capacité de courant élevée dans un petit espace. La configuration de quatre cellules en parallèle est appelée P4 comme dans la figure 1.5, et trois cellules connectées en configuration parallèle sont appelées P3. L'image ci-dessous montre une configuration P4. La tension dans le pack reste la même, mais la capacité de courant (Ah) est augmentée.

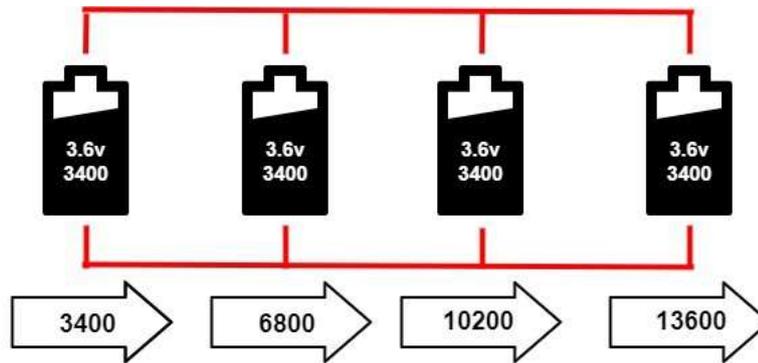


FIGURE 1.5 – Configuration en parallèle

- **Configuration en serie-parallèle** : Dans cette configuration, les cellules sont connectées à la fois en série et en parallèle (figure 1.6). La configuration série-parallèle permet d'obtenir une tension et une capacité souhaitées dans la taille le plus petit possible. Vous pouvez voir deux cellules de 3,6 V et 3400 mAh connectées en parallèle dans la figure 1.6 , ce qui double la capacité de courant de 3400 mAh à 6800 mAh. Étant donné que ces packs en parallèle sont connectés en série, la tension double également de 3,6 V à 7,2 V. La puissance totale de ce pack est maintenant de 48,96 Wh. Cette configuration est appelée 2SP2. Si la configuration comprend huit cellules avec la configuration de 4SP2, deux cellules sont en parallèle et quatre packs de cette combinaison parallèle sont connectés en série. La puissance totale produite par ce pack est de 97,92 Wh.

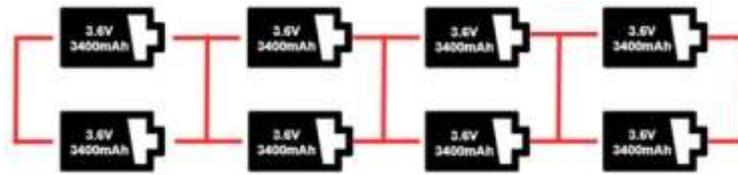


FIGURE 1.6 – Configuration en serie-parallel

1.3 Principe de fonctionnement de batterie lithium-ion :

Son principe de fonctionnement repose sur l'échange réversible d'ions lithium, entre ses deux électrodes poreuses . Lors d'une décharge de la cellule, la réaction d'oxydation qui se produit à l'anode libère un ou des électrons dans le circuit extérieur. Ces électrons circulent alors jusqu'à la cathode où ils participent à la réaction de réduction (gain d'un ou plusieurs électrons) figure 1.7. Simultanément, les anions et les cations migrent dans la solution électrolytique entre les deux électrodes afin de préserver l'équilibre des charges. Lorsque l'anode est complètement oxydée (ou la cathode totalement réduite), ces réactions s'achèvent et la batterie est déchargée. Quant à la charge, elle est réalisée en appliquant un courant électrique aux électrodes afin d'engendrer les réactions inverses. En décharge, l'anode est la borne négative de la batterie et la cathode est la borne positive. Par contre, en phase de charge l'électrode négative est la cathode et le positif est l'anode, les électrons circulant alors dans l'autre sens.

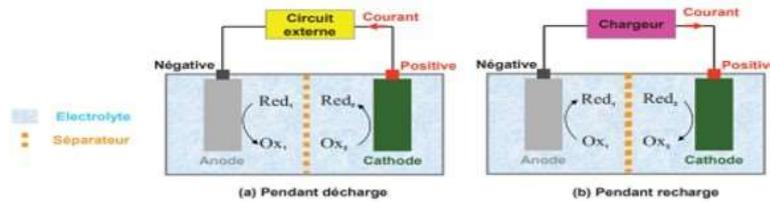


FIGURE 1.7 – pendant charge et décharge

1.4 Grandeurs caractéristiques des batteries lithium-ion :

Les grandeurs caractéristiques d'une cellule Li-ion peuvent se classer en deux groupes : internes et externes. Les grandeurs caractéristiques internes (physiques et chimiques) comme les paramètres géométriques (taille des particules, épaisseur des électrodes) ou de conception (chimie des matériaux, concentration des espèces chimiques, électrolytes) sont importantes pour modéliser. Les grandeurs externes sont donc dérivées de la relation entre la tension et le courant, à différentes conditions de test :

1.4.1 Tension à vide, nominale, chute de tension :

La tension à vide d'une batterie Li-ion :est la différence de potentiel mesurée lorsque la batterie est en circuit ouvert. Elle est influencée par le couple électrochimique des électrodes, la température et l'état de charge de la batterie. La tension nominale d'une batterie Li-ion : fournie par les fabricants, correspond à la tension à vide mesurée à température ambiante avec un état de charge de 50 pourcent. La chute de tension dans une batterie Li-ion : est due à des

phénomènes tels que la polarisation, le transfert de charge, la diffusion et les contacts ohmiques. Ces phénomènes contribuent aux pertes lors de la décharge ou de la charge de la batterie.

1.4.2 Capacité nominale, résiduelle :

La capacité est définie comme la quantité de charge, exprimée en Ah, qu'il est possible d'obtenir d'un accumulateur, initialement chargé, lors d'une décharge complète de l'accumulateur avec un courant constant. Pour un type d'accumulateur donné, la valeur de la capacité varie en fonction de la température et du courant.

$$C[Ah] = \frac{1}{3600} \int_{t_0}^t i(t) dt \quad (1.1)$$

La capacité nominale C_n correspond à la capacité annoncée par le constructeur, obtenue à un régime de décharge nominal et respectant les critères initiaux et finaux du constructeur. La capacité résiduelle est la quantité de charge qu'il est possible d'obtenir lors d'une décharge complète de l'accumulateur, qui n'est pas forcément totalement chargé, avec un courant constant.

1.4.3 L'état de charge (SOC) :

La batterie peut être vue comme un réservoir d'énergie dont la quantité évolue constamment. En conséquence, son état de charge est identifié comme la capacité contenue dans cette batterie, elle est affectée par les conditions d'opération (le courant, la température...etc.). L'unité de SOC est 100pourcent ou 1 pour une batterie pleinement chargée et 0pourcent ou 0 pour une batterie dite vide.

$$SOC = SOC \times 100 = \frac{\text{Lacapacitéactuelle(Ah)}}{C_x(Ah)} \quad (1.2)$$

Comme solution simple, l'évolution du SOC peut être traquée selon l'équation :

$$\Delta SOC = SOC(t) - SOC(t_0) = \frac{1}{\text{Capacité(Ah)}} \int_{t_0}^t i(T) dT \quad (1.3)$$

1.4.4 Le nombre de cycle (Nb Cycles) :

Défini comme le nombre de cycles (charge / décharge) que la batterie peut fournir durant sa vie tout en maintenant sa tension de coupure au-dessus de $V_{Cut-Off}$.

1.4.5 L'état de santé (SOH) :

SOH est un paramètre qui reflète l'état général de la batterie/cellule et sa capacité à fournir les performances spécifiées par rapport à une batterie neuve. C'est un indicateur important pour suivre la dégradation des performances de la batterie afin d'estimer la durée de vie (Nb Cycles) qui reste.

1.4.6 Résistance interne :

L'ensemble : électrodes, électrolyte, séparateur et collecteurs opposent une certaine résistance au passage du courant. Une polarisation se fait entre la tension de la batterie et la tension à vide au niveau des électrodes. Cette polarisation peut se caractériser par le comportement d'une résistance globale qui constitue la résistance interne de l'accumulateur. Cette résistance dépend du SOC, du régime de charge/décharge, de la température et aussi de l'état de santé de la batterie.

1.4.7 La durée de vie restante de batterie RUL :

La durée de vie restante (Remaining useful life) RUL d'une batterie lithium-ion fait référence à la quantité de temps pendant laquelle une batterie peut fonctionner avant de devoir être remplacée. Cette durée de vie est souvent exprimée en termes de cycles de charge et de décharge, c'est-à-dire le nombre de fois que la batterie peut être complètement chargée et déchargée avant que sa capacité ne diminue significativement.

1.5 Vieillessement des batteries Lithium-ion :

Le vieillissement des batteries Li-ion est un processus complexe et diversifié, avec des dégradations qui peuvent varier en fonction de l'utilisation de la batterie. Il est difficile de prédire précisément la durée de vie d'une batterie en raison des différentes causes de vieillissement. Les conséquences du vieillissement incluent une augmentation de l'impédance interne, une diminution de la puissance maximale disponible et une perte de capacité de la batterie. Les mécanismes de dégradation se produisent au niveau des électrodes négative et positive, ainsi qu'au niveau de l'électrolyte.

- **Vieillessement calendaire :** Le vieillissement calendaire se détermine en mesurant la perte de capacité irréversible entre le moment où l'accumulateur a été stocké et sa capacité après une recharge complète et en mesurant l'augmentation de la résistance série.
- **Vieillessement en cyclage :** Le vieillissement en cyclage se détermine en mesurant la perte de capacité irréversible entre le début et la fin d'une série de N cycles de charge/décharge et l'augmentation de la résistance série

1.6 Les profils de charge et de décharge des batteries lithium-ion :

La sécurité, la durabilité et les performances d'une batterie dépendent fortement de la façon dont elle est chargée ou déchargée. Un abus peut réduire considérablement sa durée de vie et peut être dangereux. Réduire considérablement sa durée de vie et peut être dangereux.

1.6.1 Technique de Charge :

De nos jours, une variété de chargeurs est utilisée, chacun reposant sur des techniques de charge programmées dans un microcontrôleur pour assurer une recharge efficace. Parmi les méthodes de charge les plus courantes, on trouve la charge à courant constant (CC) à plusieurs étages, la charge par impulsions et la charge à courant et tension constants.

- **Charge à courant constant (CC) à plusieurs étages :** La méthode de charge à plusieurs étages est utilisée pour réduire le temps de charge et augmenter la durée de vie des cellules. Elle implique plusieurs étapes où la batterie est chargée avec un courant constant faible et différent pendant un certain temps. La tension de la batterie augmente progressivement jusqu'à atteindre une valeur prédéfinie, moment où le chargeur passe à l'étape suivante. La valeur du courant de charge à chaque étape est réglée sur une valeur préétablie.
- **Charge par impulsions :** La charge par impulsions utilise des courants pulsés pour charger la batterie après la phase de courant constant. La batterie se charge entre 40pourcent et 70pourcent de SoC pendant la phase de courant constant, puis la tension atteint son niveau maximum. Le chargeur émet ensuite des impulsions d'une seconde avec la même amplitude que le courant de charge initial jusqu'à ce que la tension de la batterie chute en dessous de la tension maximale. Ce temps de veille augmente progressivement si la batterie s'approche de 100pourcent du SoC et elle se charge quand le cycle de service devient inférieur à 5pourcent à 10pourcent.
- **Charge à courant constant et tension constante :**

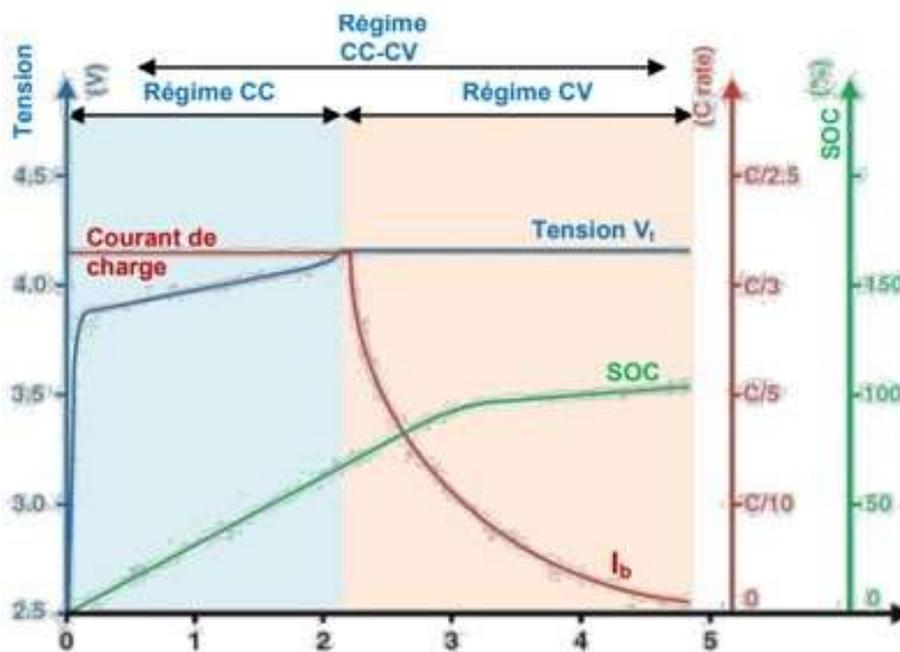


FIGURE 1.8 – profil type de charge à courant constant, à tension constante

Pendant le processus de charge de la batterie cette méthode combine entre la technique de Charge à tension constante et celle à courant constant. La figure 1.8 montre le profil de charge. Cette méthode de charge combine la tension constante et le courant constant pendant le processus de charge d'une batterie. Au début, la batterie peut être pré-chargée à un faible courant constant, puis elle est chargée avec un courant constant plus élevé (phase de charge rapide). Lorsque la tension de la batterie atteint un seuil prédéfini ($V_t = 4.2$ ou $\text{SOC} = 80\text{pourcent}$), la charge passe à une tension constante (phase de charge saine). La charge à tension constante est utilisée pour maintenir la tension de la batterie (phase de maintien de charge). Un profil de tension constante à faible courant peut être utilisé pour l'entretien de la batterie, tandis qu'un circuit externe d'autodécharge est utilisé pour prévenir toute dégradation de la batterie

1.6.2 Technique de décharge :

Il est à noter que le régime de décharge d'une batterie dépend de la demande en puissance imposée par l'application, il peut varier d'une simple décharge à courant constant jusqu'à un profil aléatoire. Toutefois le protocole de contrôle de décharge implémenté dans le BMS, lors du dimensionnement du système de puissance, doit limiter la dégradation de la batterie tout en assurant la mission et cela par la fixation de la plage des courants tolérés, tension fin de décharge, pour la mission et la plage de la température de fonctionnement.

1.7 Système de management de batterie (BMS) :

Le système de gestion de batterie (BMS) est un composant essentiel d'un module de stockage de batteries, qui comprend plusieurs cellules. Le BMS permet d'optimiser les performances de la batterie en fonction des exigences de la mission tout en réduisant les risques de dégradation. Il interagit avec d'autres modules embarqués et fonctionne en temps réel pour contrôler la charge et la décharge de la batterie. Durant toute la mission, un BMS figure 1.9 a pour rôle d'assurer les tâches suivantes :

- Collection des informations des capteurs installés sur les cellules de la batterie (tensions, courant, température, état de thermostat. . .etc).
- Contrôle de la charge batterie pour assurer une phase de charge la plus courte possible à de conditions seines, sur la base d'algorithmes intégrés dans le BMS.
- Le rééquilibrage des cellules est essentiel pour garantir des performances optimales d'un module de batterie. Dans les batteries composées de plusieurs cellules en série ou en parallèle, le rééquilibrage est nécessaire pour éviter qu'une cellule stressée limite les performances globales du module. Le BMS contrôle ce processus de rééquilibrage en utilisant des capteurs et une stratégie prédéterminée implémentée dans le système de gestion de batterie (BMS).
- La protection de la batterie est essentielle pour prévenir les risques tels que la surcharge, la décharge excessive et d'autres anomalies majeures, notamment l'augmentation de la température dans le cas des batteries Li-ion. Cette protection peut être assurée par des dispositifs physiques tels que des relais d'urgence ou en envoyant des alertes à l'utilisateur pour signaler les problèmes potentiels liés à la batterie ou à l'environnement.
- Monitoring l'état de la batterie et communication d'information (SOC, DOD, température, alarmes, jauge. . .etc).

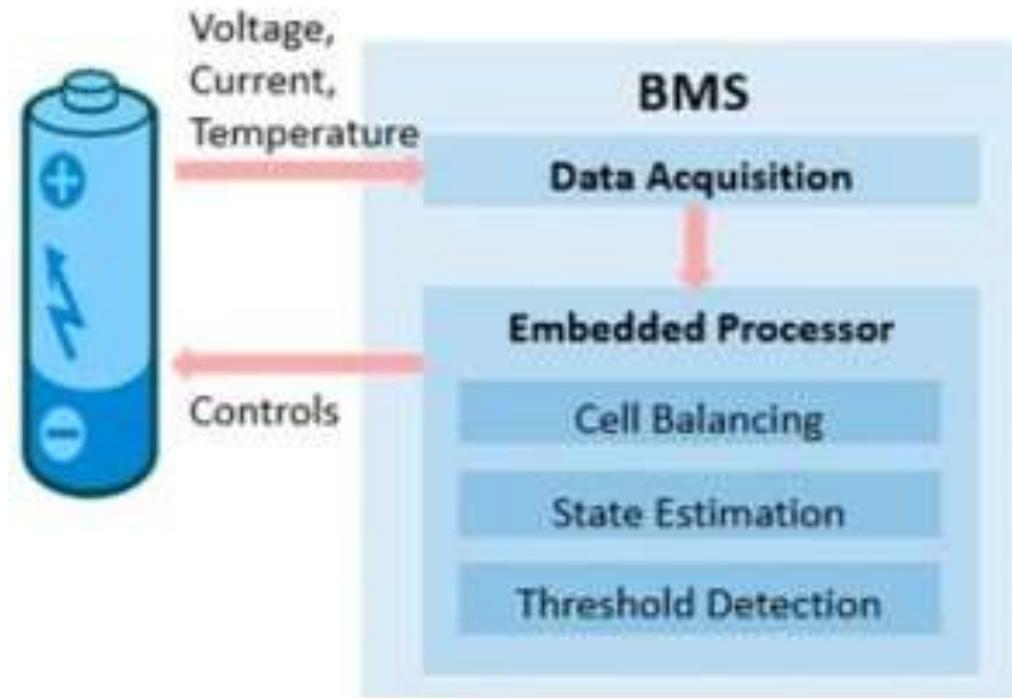


FIGURE 1.9 – system BMS

1.8 modélisation des batteries lithium ion :

Il existe dans la littérature plusieurs modèles capables de décrire le comportement d'une cellule Li-ion. Ces modèles diffèrent en termes d'approche, du nombre de variables ou d'équations résoudre, du nombre de paramètres, et du temps de calcul

1.8.1 Modèles électrochimiques :

Les modèles électrochimiques de batteries sont basés sur la théorie de l'électrode poreuse. Cette théorie a été adaptée aux batteries par Newman et Tiedemann, en 1975 et le modèle est désormais connu sous le nom de "modèle de Newman". La cellule est modélisée par analogie aux réacteurs électrochimiques et la structure du modèle est présentée dans la Figure 1.10.

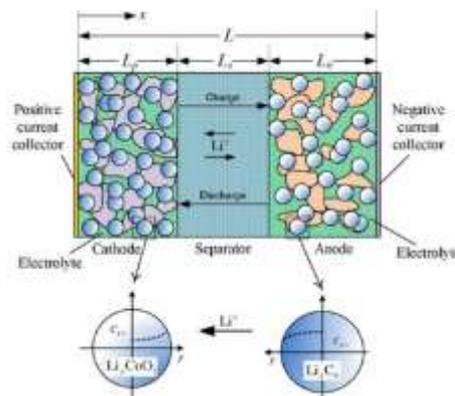


FIGURE 1.10 – structure d'une cellule au lithium support du modèle de newman

Les principaux paramètres du modèle sont les suivants : les paramètres géométriques et de design de la cellule comme les épaisseurs des électrodes et du séparateur, la taille des particules de la matière active et les surfaces des électrodes. Les différents phénomènes physico-chimiques, comme les effets électrochimiques, thermiques et de vieillissement sont mis en relation à travers des équations à dérivées partielles spatio-temporelles. Ces différentes équations sont liées entre elles et sont en relation avec le circuit extérieur par l'intermédiaire des conditions aux limites, de types Dirichlet et Newman.

1.8.2 Modèles à circuits électriques équivalents (CEE)

: Un cellule Li-ion peut être modélisée l'aide de circuits électriques équivalents (CEE) afin de représenter de manière globale un comportement physico-chimique équivalent. À la différence du modèle de Newman, les modèles CEE permettent de reproduire le comportement électrique de la cellule sans nécessairement faire la distinction entre les contributions de ses différents composants, comme les électrodes, l'électrolyte et le séparateur. Dans une certaine mesure, cette équivalence électrique est une traduction purement mathématique des phénomènes et n'a pas de lien direct avec la physique. Les modèles CEE existant présentent différents niveaux de complexité figure 1.12, allant du simple modèle de Thévenin (les figure 1.11 et 1.13 jusqu'au circuit équivalent au modèle d'électrode poreuse de Newman.

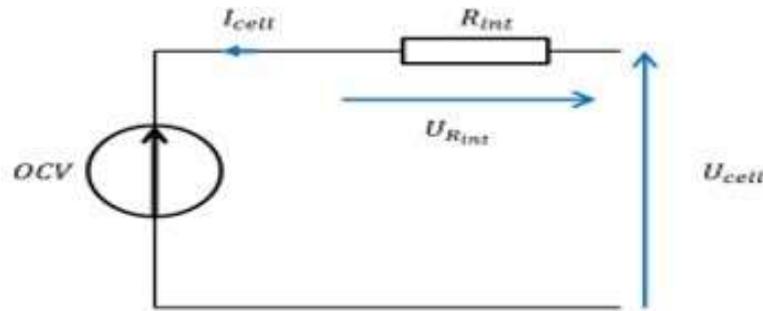


FIGURE 1.11 – modèle de thévenin pour une cellule li-ion

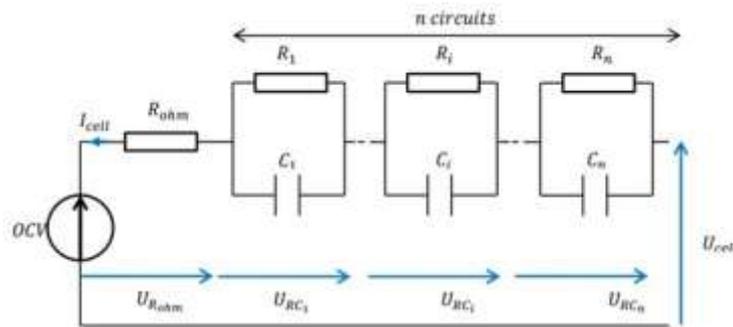


FIGURE 1.12 – modèle dynamique CEE d'une cellule électrochimique

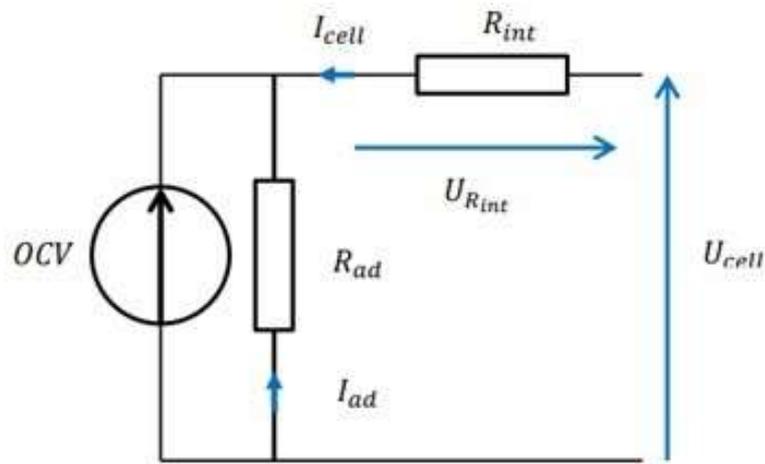


FIGURE 1.13 – modèle de thévenin modifié pour inclure l'autodécharge de la cellule

1.8.3 Modélisation de type "boite noire" :

Il s'agit de représenter l'accumulateur par une boîte noire ayant des entrées et des sorties constituées des grandeurs physiques liées au fonctionnement et aux conditions d'usage. En général, les entrées se composent du courant, de l'état de charge, de la température et de l'état de vieillissement quand il est possible de l'estimer. La grandeur qu'on cherche à estimer en sortie est généralement la tension. La boîte est constituée d'un estimateur capable de prédire les valeurs des sorties en fonction des entrées. Dans la littérature, plusieurs types d'estimateurs existent. Ils peuvent être basés sur des méthodes de régression mathématique non linéaire comme par exemple les machines à vecteurs supports, sur les réseaux de neurones ou encore sur le principe de la logique floue. Les méthodes sont donc variées, mais le fonctionnement reste le même. Il est basé sur le principe d'apprentissage supervisé à partir des données expérimentales.

1.9 conclusion :

En conclusion du premier chapitre, nous avons présenté les bases des batteries lithium-ion, donné un aperçu de leurs caractéristiques et expliqué quelques concepts fondamentaux. Dans le chapitre suivant, nous discuterons en détail du principe de pronostic de défaut et des différentes approches utilisées dans la prédiction de la durée de vie restante des batteries.

Chapitre 2

chapitre 02 :Pronostic des défauts et prédiction de la durée de vie restante (RUL) des batteries lithium-ion par IA.”

2.1 introduction :

Ce chapitre met l'accent sur l'importance du pronostic et de la gestion de la santé des défauts (Prognostics and Health Management (PHM)) dans un système de batterie, ainsi que sur les différentes méthodes utilisées pour effectuer le prediction de la durée de vie restante de batterie (RUL).

2.2 Prognostic et gestion de la santé des batteries au lithium-ion :

En raison des caractéristiques électrochimiques complexes et des conditions de fonctionnement complexes, les batteries lithium-ion révèlent des caractéristiques hautement dynamiques et non linéaires. Pour garantir les performances opérationnelles requises des batteries lithium-ion, il est nécessaire d'estimer avec précision l'état de la batterie. De plus, pour éviter les incidents inattendus et les pertes ultérieures, il est utile de réaliser des prévisions de performance des batteries. Pour répondre aux exigences d'exactitude et d'applicabilité des consommateurs de batteries, les méthodes de pronostics et de gestion de la santé sont extrêmement importantes. Battery PHM fait référence aux activités visant à appliquer des approches de PHM dans le domaine des batteries, ce qui inclut les pronostics et la gestion de la santé des batteries. En adoptant le PHM des batteries, les ingénieurs peuvent obtenir et prédire l'état de santé des batteries et prendre des mesures de manière proactive pour maintenir la disponibilité requise des batteries. Une estimation précise de l'état de charge (SOC), de l'état de santé (SOH) et de la durée de vie restante (RUL) des batteries revêt une importance capitale pour obtenir la charge restante, la capacité et la durée de vie des batteries. Par conséquent, cela permet aux utilisateurs de planifier en temps voulu des stratégies de maintenance et de mener des opérations de mise au rebut et de remplacement[8].

La prognostic vise à prédire l'état futur d'un système, tandis que le processus de gestion de la santé utilise les informations générées comme conseil pour mettre en place des actions visant à ramener le système à un état sain. Avec les exigences croissantes en matière de fiabilité élevée des systèmes modernes d'ingénierie, la PHM reçoit une attention croissante de la part des communautés académique et industrielle. Un nombre significatif d'études sur la PHM des batteries ont été publiées. Nous avons récupéré les publications de revues sur la PHM à partir de la base de données Web of Science au cours des dix dernières années (2009-2018), comme indiqué dans la Figure 2.1. Nous avons constaté que les travaux de recherche sur la PHM ont augmenté régulièrement de 2010 à 2014 et plus rapidement de 2014 à 2018.

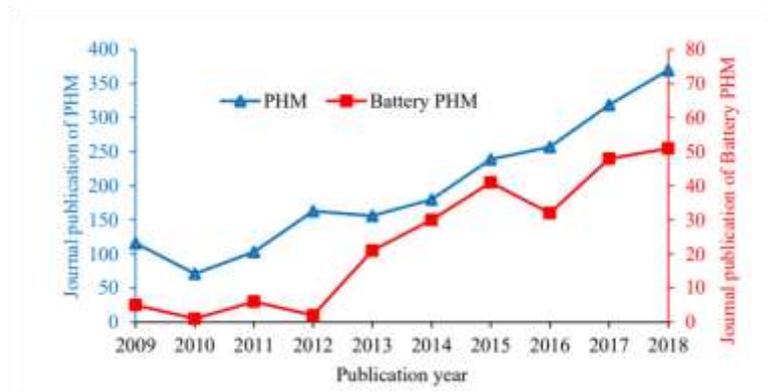


FIGURE 2.1 – Le nombre de publications dans des journaux sur la PHM dans Web of Science.

2.2.1 La durée de vie restante de batterie(remaining useful life) RUL :

La durée de vie restante (RUL) est une mesure cruciale pour évaluer la période pendant laquelle une batterie continue de fonctionner efficacement avant d'atteindre le seuil de défaillance. La méthode de pronostic fournit des informations essentielles qui avertissent des défaillances futures, facilitant ainsi une estimation précise de la RUL pour divers systèmes techniques, y compris les batteries. La RUL d'une batterie est définie comme la période allant de l'instant présent jusqu'à l'épuisement de sa durée de vie utile, où elle ne peut plus répondre aux exigences opérationnelles.

L'objectif principal de l'estimation de la RUL pour les batteries est de prévoir la période restante avant que la batterie ne tombe en dessous de sa capacité fonctionnelle optimale comme la Figure 2.2. Cela est fondé sur des spécificités issues de la surveillance continue de l'état de la batterie, telles que la capacité restante, la résistance interne, le taux de décharge et d'autres paramètres de performance.

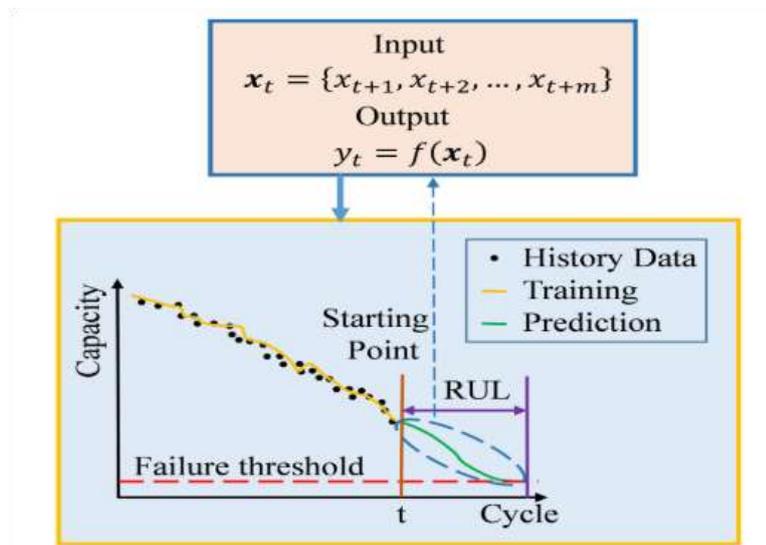


FIGURE 2.2 – Exemple de la durée de vie restante(RUL) de batterie

2.2.2 Les approches de prédiction de la durée de vie restante (RUL) pour les batteries au lithium-ion

La prédiction de la durée de vie restante (RUL) consiste à analyser le processus de dégradation. Pour traiter les données de surveillance, des procédures de filtrage sont couramment utilisées. Une méthode conventionnelle pour traiter les informations d'observation est le filtrage de Kalman, qui est une approche numérique périodique pour prédire l'état d'un système dynamique. Une version étendue de la méthode de filtrage de Kalman a été proposée dans [4]. Pour mettre en œuvre une opération de densité de pronostic conditionnel pour le RUL d'une partie du système, la méthode de filtrage de Kalman a été combinée avec les détails de surveillance de l'état.

2.2.2.1 Approches basées sur des modèles statistiques

Les modèles statistiques anticipent l'initiation des défauts ainsi que leur progression en se basant sur les résultats des observations antérieures sur des systèmes similaires. Cette méthode

ne requiert pas de données spécifiques sur le vieillissement du système, mais exige une quantité substantielle de jeux de données efficaces [4]. Les techniques de modélisation statistique sont largement employées dans la prédiction de la RUL afin d'analyser les données collectées précédemment ainsi que pour mener des études observationnelles sur les données existantes. Ces modèles statistiques peuvent décrire la prédictibilité de l'approche de dégradation et son impact sur l'estimation du RUL. Cette méthode de prédiction représente l'approche la plus couramment utilisée parmi les quatre présentées dans la figure 2.3

2.2.2.2 Approches basées sur l'intelligence artificielle (IA)

Les méthodes basées sur l'intelligence artificielle (IA) pour la prédiction de la durée de vie des batteries utilisent des modèles de détérioration du système en intégrant des techniques d'IA sur les observations disponibles. Voici une explication détaillée des approches de machine learning et de deep learning utilisées pour cette prédiction :

- Machine Learning Les algorithmes de machine learning, tels que les réseaux de neurones (NN), les arbres de décision (DT), les k-plus proches voisins (KNN), les naïfs bayésiens (NB) et les machines à vecteurs de support (SVM), sont utilisés pour prédire la durée de vie des batteries. Ces algorithmes sont entraînés avec des données collectées à partir des capteurs de batterie, tels que la tension, le courant et la température, pour identifier les tendances et les patterns de détérioration. Par exemple, un modèle de machine learning peut être entraîné avec des données de batterie pour prédire la capacité restante en fonction des paramètres de charge et de décharge
- Deep Learning Les approches de deep learning, telles que les réseaux de neurones convolutionnels (CNN) et les réseaux de neurones à longue mémoire (LSTM), sont également utilisées pour prédire la durée de vie des batteries. Ces modèles sont entraînés avec des données de batterie pour identifier les patterns de détérioration complexes et les relations entre les paramètres de batterie. Par exemple, un modèle de deep learning peut être entraîné avec des données de batterie pour prédire la capacité restante en fonction des paramètres de charge et de décharge, ainsi que des caractéristiques de batterie telles que la tension, le courant et la température

2.2.2.3 Approches basées sur la physique

Les approches basées sur la physique pour modéliser le fonctionnement des batteries au lithium-ion se concentrent sur les phénomènes chimiques et physiques spécifiques qui influencent leurs performances. Cependant, il est difficile de créer un modèle parfait pour simuler une batterie, car de nombreux composants interagissent entre eux et impactent la dégradation de son fonctionnement, d'autant plus que cette dégradation est active et non linéaire. Deux types de modèles physiques sont principalement utilisés :

- Les modèles électrochimiques, qui décrivent les réactions d'oxydo-réduction aux électrodes et le transport des ions lithium dans l'électrolyte. Ils permettent de prédire les performances en puissance et en énergie.
- Les modèles thermiques, qui simulent la production et la dissipation de chaleur au sein de la batterie. Ils sont essentiels pour estimer la durée de vie et la sécurité. Ces modèles sont basés sur des équations différentielles couplées décrivant les phénomènes multi-physiques (électrochimie, thermique, mécanique...). Ils nécessitent de nombreux paramètres d'entrée (propriétés des matériaux, conditions d'utilisation...) et sont souvent complexes à mettre en œuvre.

Étant donné la difficulté d'observer en temps réel les conditions internes d'une batterie, obtenir un modèle physique exact demeure complexe. Des techniques innovantes comme l'utili-

sation de fibres optiques en verre de chalcogénure permettent désormais de suivre les réactions chimiques à l'intérieur des batteries commerciales, ouvrant la voie à des modèles plus prédictifs.

2.2.2.4 Approches hybrides

L'approche hybride repose sur une combinaison de plusieurs modèles afin de tirer parti de leurs avantages respectifs et de surmonter leurs limitations individuelles, dans le but d'améliorer la précision des prédictions de durée de vie restante. En général, cette approche comprend deux catégories : l'hybridation des procédures basées sur les données et celles basées sur les modèles, ainsi que l'intégration de divers processus basés sur les données [4].

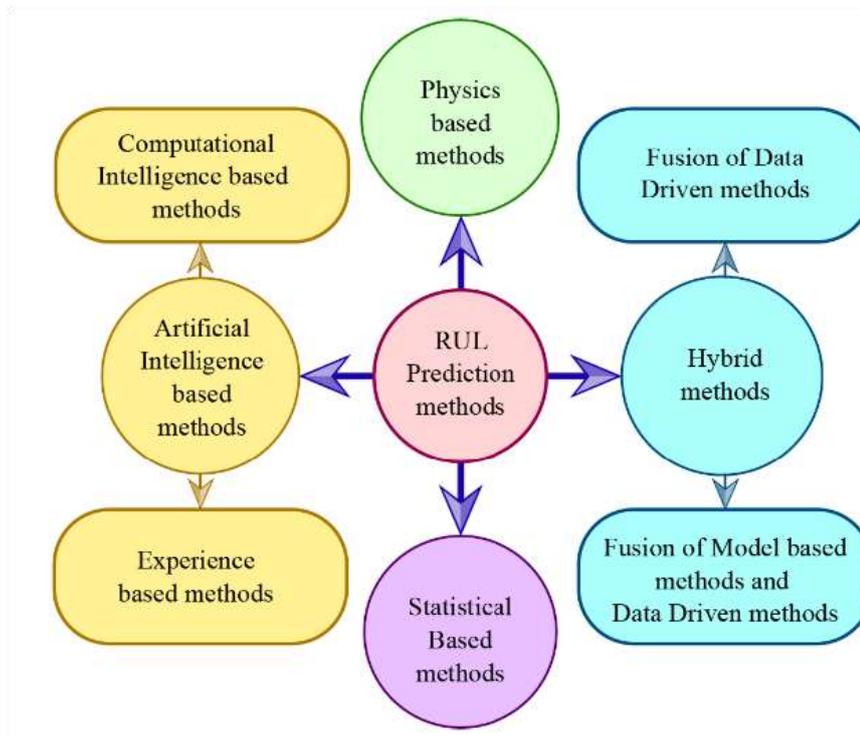


FIGURE 2.3 – Approches de prédiction RUL

2.3 De l'intelligence artificielle au apprentissage profond

L'intelligence artificielle (IA) est un champ de recherche qui vise à reproduire le fonctionnement du cerveau humain en utilisant des techniques et méthodes pour comprendre et simuler les processus cognitifs. En effet, l'apprentissage automatique (Machine Learning) constitue un sous-domaine essentiel de l'IA, permettant aux machines d'apprendre automatiquement des règles à partir de données. De plus, l'apprentissage profond (Deep Learning), qui représente une technique avancée de Machine Learning, utilise des réseaux neuronaux pour simuler le comportement du cerveau humain. Notamment, en utilisant des dizaines ou des centaines de couches de neurones, cette approche établit des règles complexes. Ainsi, l'apprentissage profond permet aux machines de traiter des données de manière plus précise, simulant des tâches autrefois réservées à l'intelligence humaine, comme la reconnaissance d'images, la traduction linguistique et la conduite autonome. voir la figure 2.4

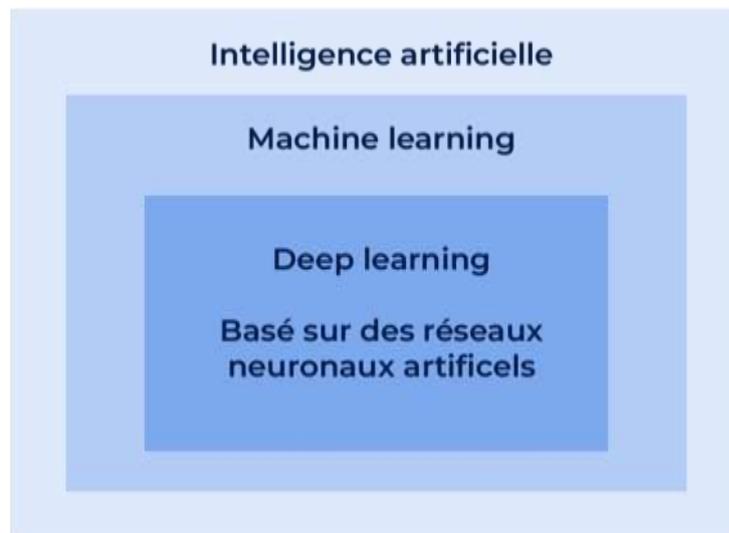


FIGURE 2.4 – Intelligence Artificielle vs Machine Learning vs Deep Learning

2.3.1 Intelligence artificielle

L'intelligence artificielle (IA) est un domaine de l'informatique consacré à la création et à la gestion de technologies capables de prendre des décisions et d'agir de manière similaire à un être humain[11]. Elle englobe des capacités telles que la compréhension, la réflexion, la résolution de problèmes, la perception et la prise de décision. Voici quelques caractéristiques essentielles de l'IA :

- Apprentissage : Dans l'IA, l'apprentissage fait référence à la capacité des machines à améliorer automatiquement leurs performances en fonction de l'expérience ou des données historiques [11].

- Raisonnement : Les systèmes d'IA peuvent utiliser la logique et le raisonnement pour prendre des décisions et résoudre des problèmes.

- Perception : Les systèmes d'IA peuvent percevoir et interpréter le monde à l'aide de capteurs, de caméras et d'autres dispositifs d'entrée.

- Prise de décision : Les systèmes d'IA peuvent prendre des décisions basées sur des données et des algorithmes, souvent sans intervention humaine. La caractéristique idéale de l'IA est sa capacité à rationaliser et à prendre des Mesures qui ont les meilleures chances d'atteindre un objectif précis [1, 11]

2.3.2 L'apprentissage automatique

L'apprentissage automatique, une branche de l'intelligence artificielle (IA), développe des algorithmes et modèles statistiques permettant aux ordinateurs d'apprendre et de prendre des décisions ou de faire des prédictions sans être explicitement programmés. Cette approche axée sur les données forme les machines à partir de grands ensembles de données pour reconnaître des tendances, extraire des informations et prendre des décisions éclairées en fonction des données d'entrée. Il existe trois principales catégories d'apprentissage automatique : supervisé, non supervisé et par renforcement, comme illustré à la figure 2.5.

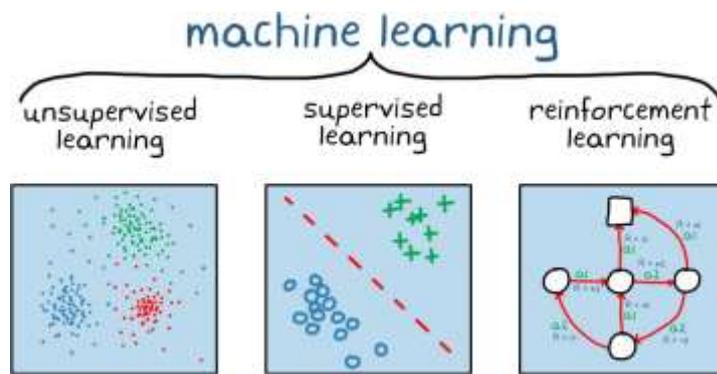


FIGURE 2.5 – Les catégories de l'apprentissage automatique

2.3.2.1 Apprentissage supervisé

Cette catégorie comprend des algorithmes qui apprennent à partir d'un ensemble de données d'entraînement étiquetées. Les deux principales sous-catégories sont :

Classification : Le modèle prédit une étiquette de classe à partir de données d'entrée [2, 5]. (par exemple, classifier des emails en spam ou non-spam).

Régression : Le modèle prédit une valeur continue (par exemple, prédire les prix de l'immobilier).

2.3.2.2 Apprentissage non supervisé

Les algorithmes de cette catégorie cherchent des structures ou des motifs dans des données non étiquetées. Les sous-catégories incluent :

Clustering : Regrouper des données en clusters ou groupes basés sur leurs similarités (par exemple, segmenter des clients en groupes de comportement similaire). **Réduction de dimensions** : Réduire le nombre de variables dans les données tout en conservant leur variation la plus importante (par exemple, PCA - analyse en composantes principales).

2.3.2.3 Apprentissage par Renforcement

Dans cette catégorie, un agent apprend à prendre des décisions en interagissant avec un environnement. L'agent reçoit des récompenses ou des punitions en fonction des actions qu'il effectue, et son objectif est de maximiser la somme des récompenses sur le long terme. Cela est souvent utilisé dans des domaines tels que les jeux, la robotique et la prise de décision autonome.

Ces catégories couvrent les principales approches de l'apprentissage automatique, chacune ayant ses propres techniques et applications spécifiques.

2.3.3 Apprentissage Profond (Deep Learning)

L'apprentissage profond, une branche du machine learning, utilise des réseaux neuronaux multicouches pour générer automatiquement des représentations à partir de données non structurées, réduisant ainsi la nécessité d'ingénierie manuelle des fonctionnalités. Cette approche a permis des avancées majeures en vision par ordinateur et traitement du langage naturel, transformant des processus tels que la catégorisation d'images et la reconnaissance vocale. Les architectures populaires incluent les CNN, les RNN et les transformateurs, soutenus par des frameworks comme TensorFlow et PyTorch. L'expansion rapide de l'apprentissage profond est

due à l'accessibilité accrue des grands ensembles de données, à l'amélioration du matériel informatique et des algorithmes. Cette technologie continue de repousser les limites de la recherche en IA et favorise les progrès dans de nombreuses industries.

2.3.3.1 Les Réseaux de Neurones

Un réseau neuronal est un modèle de calcul inspiré par la structure et le fonctionnement du cerveau humain. Il est constitué de neurones artificiels interconnectés et superposés en couches. Les données sont introduites dans le réseau, traversent plusieurs couches cachées et produisent une sortie. Chaque neurone effectue des calculs sur son entrée avant de transmettre le résultat à la couche suivante. L'apprentissage, souvent réalisé par rétropropagation, permet au réseau d'ajuster les poids et les biais de ses neurones pour optimiser ses performances sur une tâche spécifique. Voici quelques concepts clés des réseaux neuronaux, comme illustré à la figure 2.6 :

Neurone : L'élément fondamental d'un réseau neuronal qui recueille des informations, effectue des calculs et fournit une sortie.

Fonction d'activation : Une fonction mathématique ajoutant de la non-linéarité à la sortie d'un neurone, permettant de représenter des relations complexes et de faire des prédictions non linéaires.

Couche : Un groupe de neurones dans un réseau neuronal qui traite les entrées, calcule les résultats et génère des sorties. Les couches sont généralement hiérarchisées en couches d'entrée, cachées et de sortie.

Fonction de perte : Une fonction mathématique mesurant la différence entre la sortie attendue et la sortie réelle, servant de guide pour ajuster les paramètres du réseau.

Poids : Les paramètres qui donnent de l'importance aux éléments utiles à l'apprentissage, ajustés par multiplication scalaire entre la valeur d'entrée et la matrice de poids

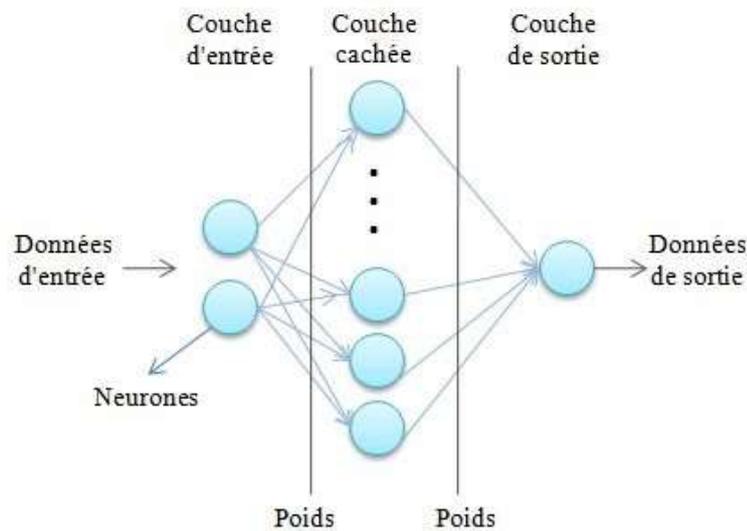


FIGURE 2.6 – Illustration d'un réseau de neurones avec 2 couches cachées

2.4 conclusion :

À la fin du chapitre 2, nous avons décrit l'importance du pronostic de défaut et cité les différentes approches existantes pour la prédiction de la durée de vie des batteries (RUL) , Dans le chapitre suivant, nous discuterons des modèles proposés pour la prédiction de la durée de vie restante (RUL) des batteries .

Chapitre 3

chapitre 03 :Modèles de Deep Learning Proposé pour la Prédiction de RUL des lithium-ion Batteries

3.1 introduction :

Dans ce troisième chapitre, nous avons décrit un ensemble de données de batteries lithium-ion du NASA Dataset, ainsi que les architectures des modèles LSTM et CNN proposés pour la prédiction de la durée de vie restante (RUL) des batteries.

3.2 Description de NASA dataset :

Nous avons utilisé les ensembles de données de vieillissement des batteries B0005 obtenus auprès du Centre d'Excellence en Prognostics de la NASA Ames (PCOE) [3] pour évaluer

l'efficacité de la méthode proposée. La charge de la batterie a été effectuée à température ambiante, spécifiquement à 25 degrés Celsius (C), en utilisant le principe de courant constant et de tension constante (CCCV). Le processus de charge impliquait le maintien d'un courant constant de 1.5A jusqu'à ce que la tension atteigne la limite de 4.2V. Ensuite, la tension était maintenue constante jusqu'à ce que le courant tombe à 20mA. Pour la décharge, un courant constant de 2A a été appliqué jusqu'à ce que la tension de la cellule diminue à 2.7V. Un résumé des ensembles de données est fourni dans le Tableau I.

TABLE 3.1 – Spécification de la batterie B0005

Paramètres de la batterie	Description
Capacité initiale	1.86 A.h
Courant de charge	1.5 A
Courant de décharge	2 A
Tension de coupure à la charge	4.2 V
Tension de coupure à la décharge	2.7 V
Température	25 C

Nous avons utilisé les données de capacité pour chaque cycle afin de prédire la durée de vie restante(RUL) de la batterie.la figure 3.1

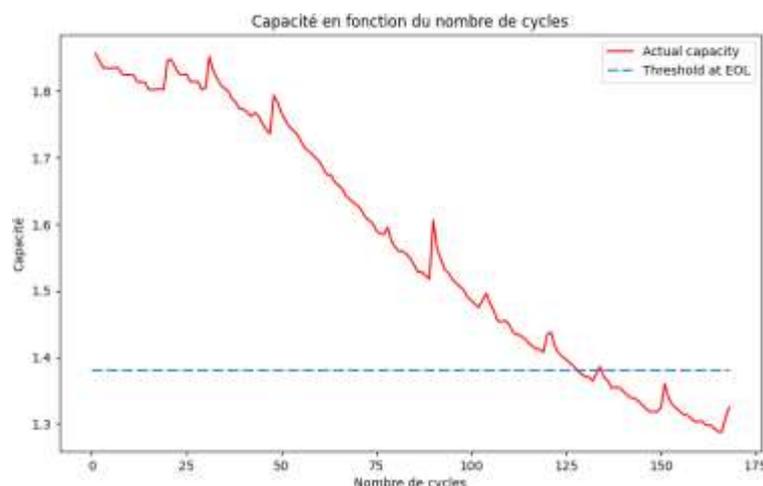


FIGURE 3.1 – capacity en fonction de cycles

3.3 Description et Design du Modèle LSTM Proposé :

3.3.1 Description et Définition de LSTM

Les réseaux de neurones récurrents (RNN) sont une catégorie de réseaux de neurones particulièrement adaptés au traitement des données séquentielles, comme les séries temporelles. Cependant, les RNN classiques souffrent du problème de l'explosion ou de la disparition du gradient, rendant difficile l'apprentissage des dépendances à long terme. Pour surmonter ces limitations, les cellules LSTM (Long Short-Term Memory) ont été introduites. Les LSTM sont conçues pour mieux capturer les dépendances à long terme grâce à leur architecture interne spécifique comprenant des mécanismes de portes (input gate, forget gate, et output gate) qui régulent le flux d'informations. Les LSTM sont particulièrement avantageux pour la prédiction de la durée de vie restante (RUL) des batteries car elles peuvent efficacement apprendre les relations complexes et non linéaires dans les données de séries temporelles. La capacité des LSTM à maintenir l'information sur de longues séquences permet de modéliser plus précisément la dégradation progressive de la batterie et les facteurs influençant sa durée de vie [9]. Une cellule LSTM se compose de plusieurs composants comme la figure 3.3.2

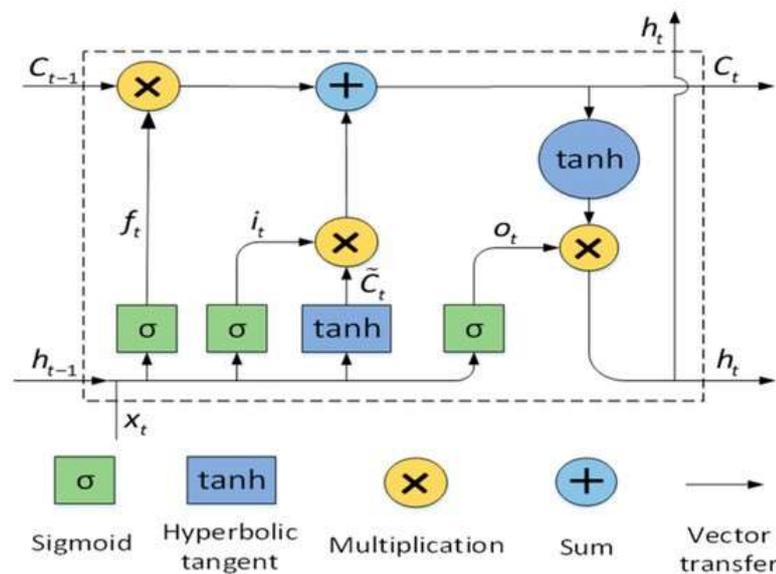


FIGURE 3.2 – LSTM architecture

— Forget Gate (Porte d'Oubli)

La porte d'oubli décide quelles informations de l'état précédent doivent être oubliées. Elle utilise une fonction sigmoïde pour générer une valeur entre 0 et 1 pour chaque numéro de l'état de cellule C_{t-1} , où 1 signifie "conserver complètement" et 0 signifie "oublier complètement".

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

où :

- f_t est le vecteur de la porte d'oubli.
- σ est la fonction sigmoïde.
- W_f est la matrice de poids pour la porte d'oubli.
- h_{t-1} est l'état caché précédent.
- x_t est l'entrée actuelle.

- b_f est le biais de la porte d'oubli.
- **Input Gate (Porte d'Entrée)** La porte d'entrée décide quelles nouvelles informations seront stockées dans l'état de cellule. Elle comprend deux parties : une fonction sigmoïde qui décide quelles valeurs seront mises à jour et une fonction tanh qui crée un vecteur de nouvelles valeurs candidates \tilde{C}_t .

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C)$$

où :

- i_t est le vecteur de la porte d'entrée.
- \tilde{C}_t est le vecteur des nouvelles valeurs candidates.
- W_i et W_C sont les matrices de poids.
- b_i et b_C sont les biais.
- **Output Gate (Porte de Sortie)**
La porte de sortie décide quelle partie de l'état de cellule sera sortie. La sortie est basée sur l'état de cellule filtré par une fonction tanh, et une fonction sigmoïde décide quelles parties de l'état de cellule seront sorties.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

$$h_t = o_t \cdot \tanh(C_t)$$

où :

- o_t est le vecteur de la porte de sortie.
- h_t est l'état caché actuel (aussi la sortie).
- W_o est la matrice de poids.
- b_o est le biais.
- **Mise à Jour de l'État de la Cellule** Finalement, l'état de cellule C_t est mis à jour en combinant les informations retenues et les nouvelles informations candidates pondérées par la porte d'entrée.

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t$$

Ces mécanismes permettent aux cellules LSTM de conserver des informations sur de longues périodes et d'apprendre des dépendances à long terme dans les séries temporelles.

3.3.2 architecture de modèle LSTM pour RUL prediction

Le processus d'entraînement et de test du modèle LSTM pour prédire la capacité en fonction du nombre de cycles implique plusieurs étapes interconnectées est montrée dans la figure 3.3 est ces étapes sont décrit comme suit :

Lithium ion Data collection : Collecter les données de capacité Q_i pour chaque cycle i pour la batterie B0005.

Dataset Split and normalization : Les données sont divisées en ensembles distincts en fonction du nombre de cycles : les données avec moins de 50 cycles sont utilisées pour l'entraînement, tandis que celles avec 50 cycles ou plus sont réservées pour le test. Ensuite, les valeurs de la capacité sont normalisées entre 0 et 1 à l'aide de la méthode de min-max

normalisation, ce qui standardise les données pour les rendre appropriées à l'entraînement du modèle.

Construction du modèle LSTM : Une fois les données préparées, la création des séquences temporelles nécessaires à l'entraînement du modèle LSTM est réalisée en utilisant une séquence glissante de taille 1. Cette séquence utilise la valeur précédente à chaque instant t pour prédire la valeur à l'instant $t + 1$. Un modèle LSTM avec deux couches, chacune comprenant 200 unités, est utilisé pour prédire des séquences temporelles. Chaque couche LSTM est suivie d'une régularisation par Dropout à un taux de 30% pour éviter le surapprentissage. La sortie est traitée par une couche Dense à une unité pour la régression. Le modèle est compilé avec l'optimiseur Adam et utilise la fonction de perte "mean squared error" pour minimiser les écarts entre les prédictions et les valeurs réelles et il se calcule (voir Equation 3.1) :

$$MSE = \frac{1}{K} \sum_{i=1}^K (Q_i - Q_i^*)^2 \quad (3.1)$$

où Q_i représente la capacité prédite et Q_i^* représente la capacité réelle pour le i -ème cycle, et K est le nombre total de cycles.

LSTM model Evaluation : Une fois que le modèle est entraîné, il est utilisé pour prédire sur l'ensemble de test. Les performances du modèle sont évaluées en utilisant les mesures d'erreur quadratique moyenne (RMSE), d'erreur absolue moyenne (MAE) et l'erreur de RUL (RULerror) et sont calculées en 3.2 et 3.3 et 3.4.

$$MAE = \frac{1}{K} \sum_{i=1}^K |Q_i - Q_i^*| \quad (3.2)$$

$$RMSE = \sqrt{\frac{1}{K} \sum_{i=1}^K (Q_i - Q_i^*)^2} \quad (3.3)$$

$$RULerror = |RUL_{true} - RUL_{pred}| \quad (3.4)$$

où Q_i représente la capacité prédite et Q_i^* représente la capacité réelle pour le i -ème cycle, et K est le nombre total de cycles. ou RUL_{true} et RUL_{pred} représentent respectivement la durée de vie restante réelle (RUL réelle) et la durée de vie restante prédite (RUL prédite)

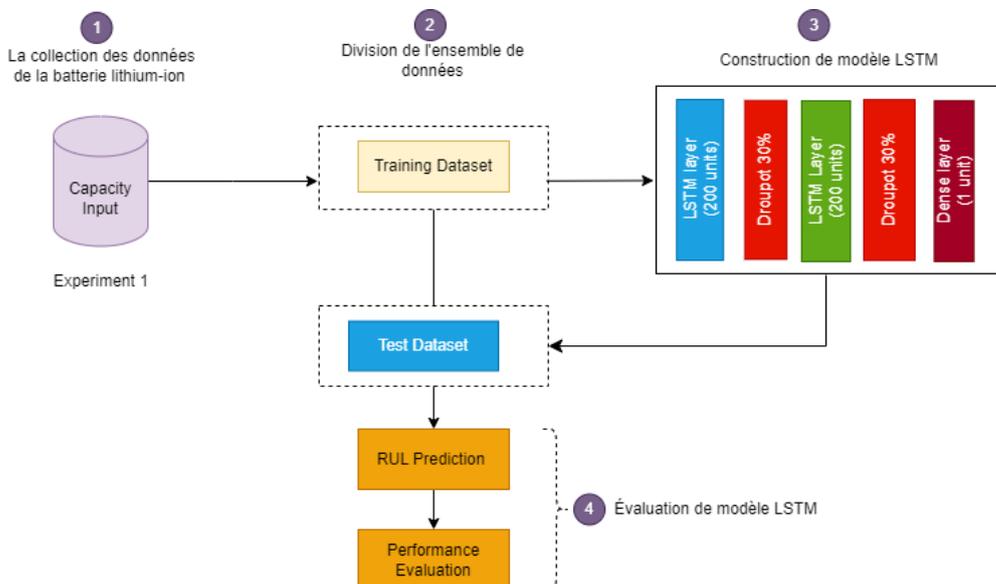


FIGURE 3.3 – Division des données et architecture du modèle LSTM

3.4 Description et Design du Modèle CNN Proposé :

3.4.1 Description et Définition de CNN

Convolutional Neural Networks (CNNs), ou réseaux de neurones convolutionnels, sont une classe de réseaux de neurones profonds conçus spécifiquement pour traiter des données ayant une structure en grille, telle que les images[10]. Les CNNs sont particulièrement efficaces pour la reconnaissance d'images, mais ils peuvent également être appliqués à d'autres types de données structurées. Principales Composantes d'un CNN, voir la figure 3.4 :

- Couches Convolutionnelles (Conv1D, Conv2D, etc.) : Ces couches appliquent des filtres (ou noyaux) qui glissent sur les données d'entrée, détectant ainsi des motifs locaux. Dans le cas des images, ces motifs peuvent être des bords, des textures, ou d'autres caractéristiques visuelles.
- Fonction d'Activation (ReLU, Sigmoid, etc.) : Après chaque convolution, une fonction d'activation est appliquée pour introduire de la non-linéarité dans le réseau. La fonction ReLU (Rectified Linear Unit) est la plus couramment utilisée.
- Couches de Pooling (MaxPooling, AveragePooling, etc.) : Ces couches réduisent la dimensionnalité des données tout en conservant les caractéristiques essentielles, ce qui permet de diminuer la complexité computationnelle et de limiter le sur-apprentissage.
- Couches Fully Connected (Dense) : Vers la fin du réseau, des couches entièrement connectées (denses) sont utilisées pour combiner les caractéristiques extraites par les couches convolutionnelles et effectuer la prédiction finale.
- Dropout : Une technique de régularisation où des neurones sont aléatoirement désactivés pendant l'entraînement, ce qui aide à prévenir le sur-apprentissage.

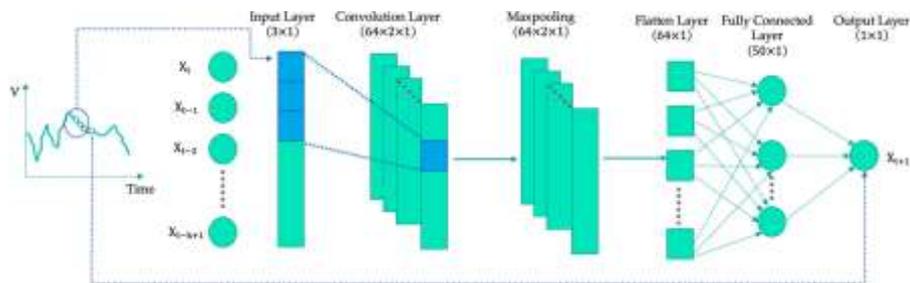


FIGURE 3.4 – exemple de CNN architecture

*

3.4.2 Architecture de modèle CNN pour la prédiction de RUL

En suivant les mêmes étapes que celles utilisées précédemment pour le LSTM dans la collection et la division des données et l'évaluation du modèle, nous constatons que le modèle CNN mesure également l'exactitude des prédictions en comparant les valeurs attendues aux valeurs réelles de capacité. Un réseau neuronal convolutif (CNN) a été utilisé, comprenant deux couches convolutives avec la fonction d'activation ReLU, suivies de couches de MaxPooling et Flatten, puis de deux couches Dense et d'une couche de sortie pour prédire une valeur continue. comme la figure illustre 3.5

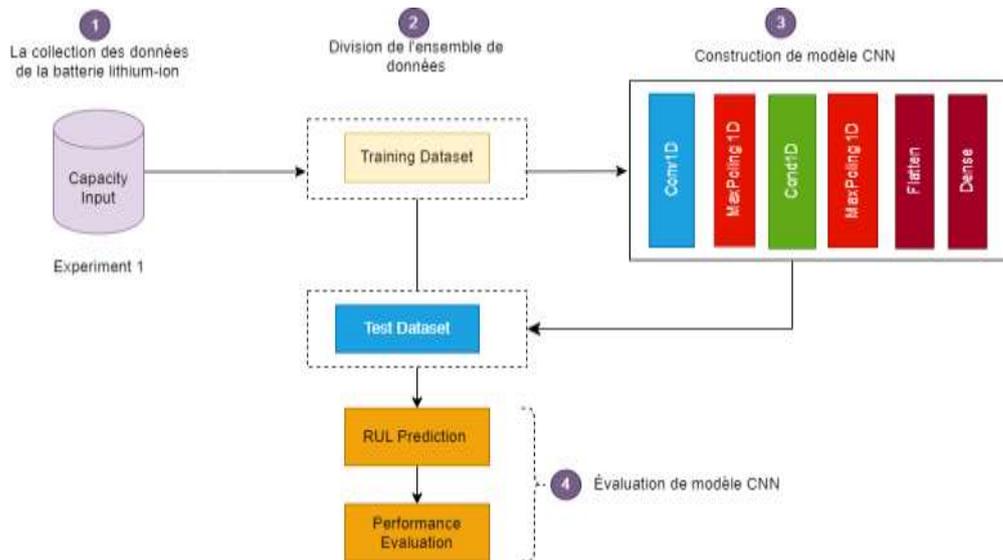


FIGURE 3.5 – Division des données et architecture du modèle CNN

3.5 conclusion :

Dans ce chapitre, nous avons d'abord décrit les deux modèles profonds, à savoir le CNN et le LSTM. Ensuite, nous avons présenté la description de l'architecture des modèles CNN et LSTM proposés pour la prédiction de la durée de vie restante (RUL) des batteries. Dans le chapitre suivant, nous discuterons des résultats obtenus pour la prédiction de la RUL des batteries en utilisant les deux modèles précédemment décrits.

Chapitre 4

chapitre 04 : résultats et discussions

4.1 introduction :

Il s'agit d'un chapitre consacré à la présentation et à la discussion des résultats empiriques obtenus grâce à la formation de modèles d'apprentissage automatique pour la surveillance et le diagnostic de la batterie au lithium basée sur la base de données de Naza ainsi que la surveillance continue de la cellule par l'application.

4.2 Expériences et résultats :

Nos expériences visaient à comparer différentes approches dans le même but : La première section de Hda Al Shabbar montrera comment le modèle le plus approprié a été évalué et choisi parmi cinq modèles d'apprentissage automatisés afin d'estimer les paramètres de la deuxième section sera également une évaluation de quatre modèles d'apprentissage automatisés pour la classification de les pannes et enfin comment tout cela est affiché sur l'application mobile, Pour étudier cette question, nous avons utilisé les données de Naza et les données matérielles créées pour former, tester et évaluer les modèles utilisés, nous avons choisi les critères évaluation d'estimation et classification suivants :

4.2.1 Google colab :

Google Colab est une plateforme puissante basée sur le cloud qui permet aux utilisateurs de créer, d'exécuter et de partager du code Python de manière transparente. Elle offre une interface web intégrée aux cahiers Jupyter, permettant aux utilisateurs d'écrire et d'exécuter du code dans un environnement collaboratif. L'une de ses caractéristiques principales est l'accès illimité aux ressources GPU et TPU, ce qui accélère considérablement les tâches intensives en calcul, notamment dans les domaines de la science des données et de l'apprentissage automatique.

En utilisant le langage de programmation Python, Google Colab offre aux utilisateurs un accès à l'infrastructure cloud de Google, éliminant ainsi le besoin d'installations de logiciels locaux. Cette approche basée sur le cloud non seulement simplifie le processus de codage, mais facilite également la formation de modèles d'apprentissage automatique complexes en exploitant la puissance de calcul évolutive de l'infrastructure de Google.

Nous avons mis en œuvre l'approche proposée en utilisant Python 3.9 sur un système Windows 10 64 bits avec un processeur Intel Core i5 vPro et 16,00 Go de mémoire. L'environnement de développement utilisé pour cette implémentation était Google Colab comme la figure 4.1 illustre :

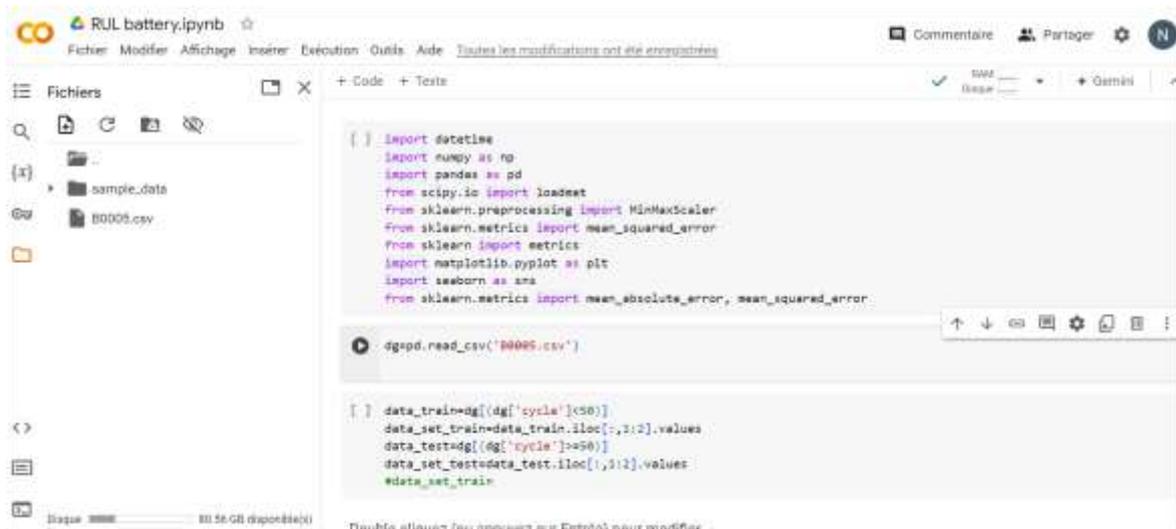


FIGURE 4.1 – platform de google colab

Pour les expériences menées avec les modèles LSTM et CNN, nous avons utilisé un jeu de données comprenant des valeurs de capacité Q_i , couvrant un total de 168 cycles. Il est à noter que le jeu de données incluait les valeurs de capacité. Afin de garantir la robustesse de nos modèles, nous avons méticuleusement partitionné les données en ensembles d'entraînement et de test pour chaque expérience. Cette division nous a permis d'entraîner nos modèles sur un sous-ensemble des données, puis d'évaluer leur performance sur des données non vues, offrant ainsi une évaluation fiable de leurs capacités de généralisation.

De plus, dans l'expérience de prédiction de la durée de vie résiduelle (RUL), nous avons intégré une étape cruciale de normalisation des données en utilisant la méthode de mise à l'échelle Min-Max. Cette méthode consiste à transformer les données de manière à ce que les valeurs soient comprises entre 0 et 1, 0 représentant la valeur minimale observée dans le jeu de données et 1 représentant la valeur maximale.

4.2.2 Les critères d'évaluation pour la prédiction de RUL en utilisant le modèle de LSTM :

Après la phase d'entraînement utilisant les données d'entraînement, Le tableau 4.1 ci-dessous présente les principaux hyperparamètres utilisés dans le modèle LSTM proposé. la précision et la robustesse du modèle ont été testées en réalisant des prédictions de la Durée de Vie Restante (RUL) pour B0005. Deux scénarios ont été considérés : l'un à partir du 50ème cycle et l'autre à partir du 80ème cycle. Cette approche stratégique vise à évaluer les performances du modèle tout au long des différentes phases du cycle de vie, garantissant ainsi son efficacité dans la prévision de la RUL dans diverses conditions. Notamment, la Fin de Vie (EOL) spécifiée pour B0005 à $Q=1,38$ A.h sert de référence pour évaluer la précision des prédictions. Pour quantifier la précision du modèle, des métriques telles que l'Erreur Absolue Moyenne (MAE), la Racine de l'Erreur Quadratique Moyenne (RMSE), et l'erreur absolue de la RUL sont calculées en suivant les équations en 3.3.2.

Le tableau 4.2 une comparaison des performances de prédiction de la Remaining Useful Life (RUL) des batteries pour deux points de départ différents. Le premier point de départ, situé à 50, affiche un Root Mean Square Error (RMSE) de 0.024, un Mean Absolute Error (MAE) de 0.029 et une erreur de prédiction de la RUL de 14. En revanche, le deuxième point de départ, établi à 80, présente des mesures de performance nettement améliorées. Son RMSE est réduit à 0.007, son MAE à 0.014 et l'erreur de prédiction de la RUL diminue considérablement à

TABLE 4.1 – Hyperparamètres du modèle LSTM

Hyperparameters	Values
Input features	1
Output	1
Dropout Rate	30%
Sequence Length	1
Optimization Algorithm	Adam
Number of Epochs	200
Batch Size	34
Loss Function	MSE

seulement 1. Ces résultats indiquent que le deuxième point de départ offre une précision de prédiction bien supérieure par rapport au premier. Cette amélioration significative suggère que le choix du point de départ peut jouer un rôle crucial dans l'exactitude des prévisions de la RUL des batteries, avec des valeurs initiales plus élevées conduisant à des performances de prédiction considérablement améliorées.

Point de départ	RMSE	MAE	RUL Error
50	0.024	0.029	14
80	0.007	0.014	1

TABLE 4.2 – Mesures de performance pour différents points de départ

La Figure 4.2 et la Figure 4.3 présentent une comparaison entre la capacité réelle et prédite dans des conditions opérationnelles standard aux points de départ 50 et 80. Le critère de fin de vie est fixé à 1,38 A.h. La courbe bleue représente la capacité réelle, tandis que la courbe rouge représente la capacité prédite par les modèles LSTM. Notamment, pendant les états de défaut, la durée de vie restante diminue rapidement par rapport aux états normaux, avec une précision de prédiction plus élevée observée au point de départ de 80 par rapport à 50.

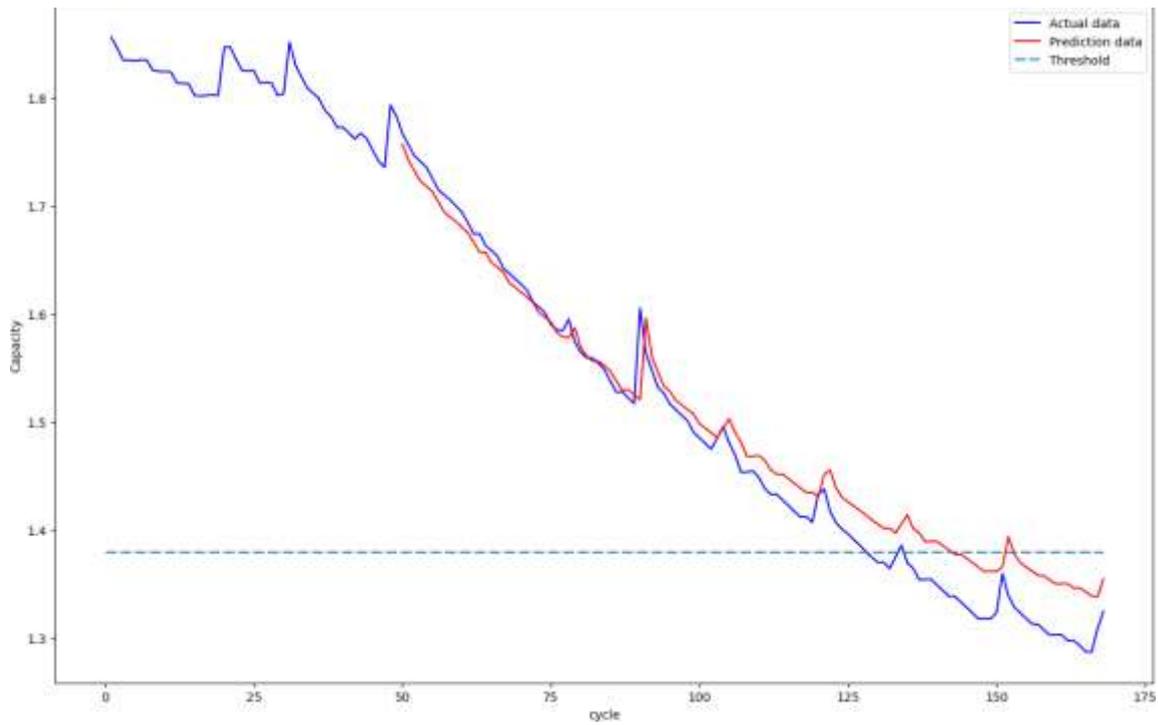


FIGURE 4.2 – Les résultats prédits par le LSTM sur la batterie B0005 au point de départ de 50

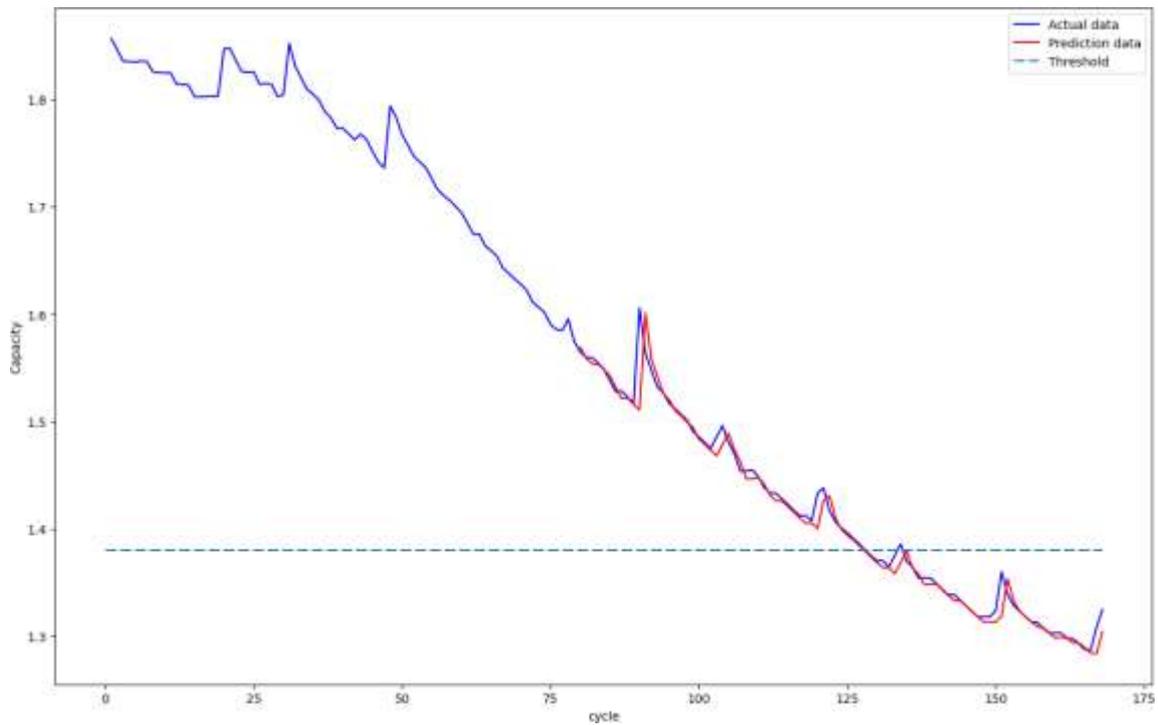


FIGURE 4.3 – Les résultats prédits par le LSTM sur la batterie B0005 au point de départ de 80

4.2.3 Les critères d'évaluation pour la prédiction de RUL en utilisant le modèle de CNN :

Après la phase d'entraînement utilisant les données d'entraînement, le modèle CNN a commencé à prédire la Durée de Vie Restante (RUL) de la batterie B0005. Cela inclut l'utilisation des hyperparamètres principaux présentés dans le tableau 4.3. La précision du modèle a été testée à travers des prédictions commençant au 50^{ème} cycle et au 80^{ème} cycle, afin d'évaluer les performances du modèle à différentes phases du cycle de vie. La Fin de Vie (EOL) à $Q=1,38$ A.h est utilisée comme référence pour évaluer la précision des prédictions. La précision du modèle est mesurée à l'aide de métriques telles que l'Erreur Absolue Moyenne (MAE), la Racine de l'Erreur Quadratique Moyenne (RMSE) et l'erreur absolue de la RUL

Le tableau 4.4 une La comparaison des performances de prédiction de la Durée de Vie Restante (RUL) des batteries pour deux points de départ différents révèle des résultats contrastés. Pour le premier point de départ à 50 cycles, les mesures montrent un Root Mean Square Error (RMSE) de 0.034, un Mean Absolute Error (MAE) de 0.024 et une erreur de prédiction de

la RUL de 3. En revanche, au deuxième point de départ, fixé à 80 cycles, les performances s'améliorent nettement avec un RMSE de 0.014, un MAE de 0.008 et une erreur de prédiction de la RUL réduite à 1. Ces résultats démontrent que le deuxième point de départ permet une prédiction beaucoup plus précise comparée au premier. Cette amélioration significative indique que le choix du point de départ est crucial pour la précision des prévisions de la RUL des batteries, les valeurs initiales plus élevées entraînant des performances de prédiction nettement supérieures équations en

TABLE 4.3 – Hyperparamètres du modèle CNN

Hyperparameters	Values
Input features	1
Output	1
Sequence Length	1
Optimization Algorithm	Adam
Number of Epochs	200
Batch Size	34
Loss Function	MSE

seulement 2. Les résultats suggèrent que le deuxième point de départ donne des prévisions beaucoup plus précises que le premier. Cette amélioration importante souligne l'importance majeure du choix initial dans la précision des prévisions de Durée de Vie Restante (RUL) pour les batteries. Des valeurs de départ plus élevées entraînent des améliorations significatives des performances de prédiction. .

Point de départ	RMSE	MAE	RUL Error
50	0.034	0.024	3
80	0.014	0.008	1

TABLE 4.4 – Mesures de performance pour différents points de départ

La Figure 4.4 et la Figure 4.5 Le nombre de formats de texte pour le modèle CNN dans ce contexte spécifique est de deux. La deuxième figure présente une comparaison entre la capacité réelle et prédite des batteries dans des conditions opérationnelles standard, avec un point de départ de 50 cycles. La deuxième figure montre la même comparaison, mais avec un

point de départ de 80 cycles. Dans les deux cas, le critère de fin de vie est fixé à 1,38 A.h. La courbe bleue représente la capacité réelle, tandis que la courbe rouge représente la capacité prédite par les modèles CNN. Ces formats de texte décrivent visuellement les performances des prédictions de durée de vie restante des batteries, fournissant ainsi une comparaison significative entre les deux points de départ.

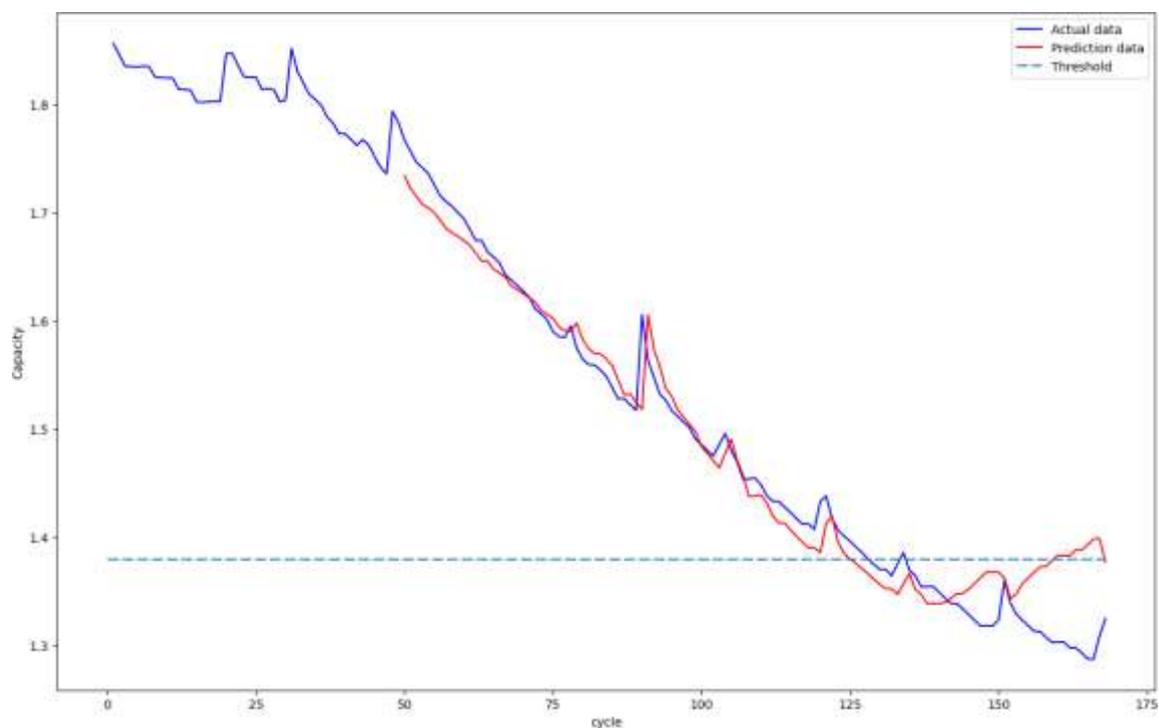


FIGURE 4.4 – Les résultats prédits par le CNN sur la batterie B0005 au point de départ de 50

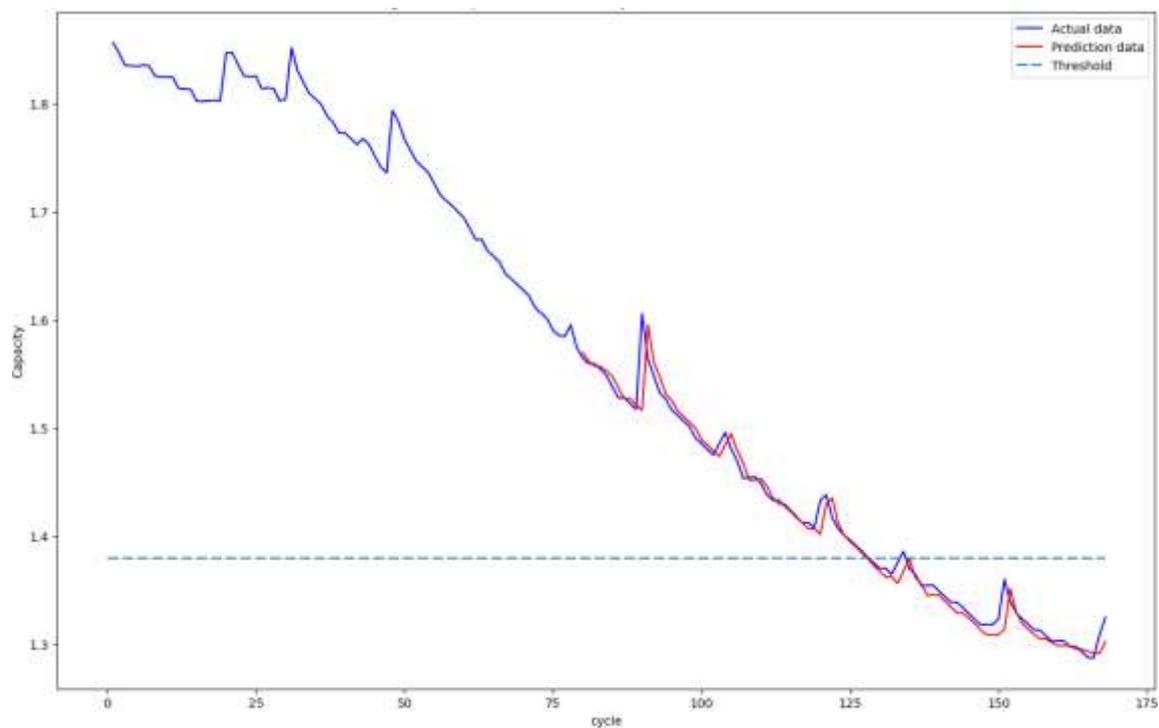


FIGURE 4.5 – Les résultats prédits par le CNN sur la batterie B0005 au point de départ de 80

4.2.4 Les critères d'évaluation pour la prédiction de RUL en utilisant le modèle de CNN-LSTM :

Le modèle LSTM, ainsi que le modèle CNN, ont été évalués dans le cadre de ce travail. La précision et la robustesse de chaque modèle ont été testées en effectuant des prédictions de Durée de Vie Restante (RUL) pour la batterie B0005. Deux scénarios ont été pris en compte :

l'un démarrant à partir du 50^{ème} cycle et l'autre à partir du 80^{ème} cycle. Cette approche stratégique vise à évaluer la performance de chaque modèle tout au long des différentes phases du cycle de vie de la batterie, assurant ainsi leur efficacité dans la prédiction de la RUL dans des conditions variées. La référence de Fin de Vie (EOL) pour la batterie B0005 reste constante à $Q=1,38$ A.h, servant de base pour évaluer la précision des prédictions. Des métriques telles que l'Erreur Absolue Moyenne (MAE), la Racine de l'Erreur Quadratique Moyenne (RMSE) et l'erreur absolue de la RUL sont calculées pour quantifier la précision de chaque modèle. Cette analyse comparative entre le LSTM et le CNN permet d'évaluer et de comparer leurs performances respectives en matière de prédiction de la RUL.

Le tableau 4.5 La comparaison des performances de prédiction de la Durée de Vie Restante (RUL) des batteries pour deux points de départ différents met en évidence des résultats distincts pour les modèles LSTM et CNN. Au point de départ initial de 50, cycles le modèle affiche un Root Mean Square Error (RMSE) de 0.034, un Mean Absolute Error (MAE) de 0.017 et une erreur de prédiction de la RUL de 1. En revanche, avec un point de départ de 80 cycles, les performances du modèle sont nettement améliorées. Son RMSE est réduit à 0.014, son MAE à 0.009, et l'erreur de prédiction de la RUL diminue considérablement à 0. Cette comparaison souligne l'impact significatif du point de départ sur la qualité des prédictions pour les deux modèles, avec des résultats améliorés observés pour le modèle LSTM par rapport au CNN.

4.2.5 Les résultats :

Les résultats démontrent que le deuxième point de départ offre une précision de prédiction nettement supérieure à celle du premier. Cette amélioration substantielle suggère l'importance cruciale du choix du point de départ dans l'exactitude des prévisions de la Durée de Vie Restante (RUL) des batteries. Des valeurs initiales plus élevées se traduisent par des performances de prédiction considérablement améliorées, mettant en évidence l'impact significatif du point de départ sur la qualité des prévisions, que ce soit pour les modèles LSTM ou CNN.

Point de départ	RMSE	MAE	RUL Error
50	0.034	0.017	1
80	0.014	0.009	0

TABLE 4.5 – Mesures de performance pour différents points de départ LSTM - CNN.

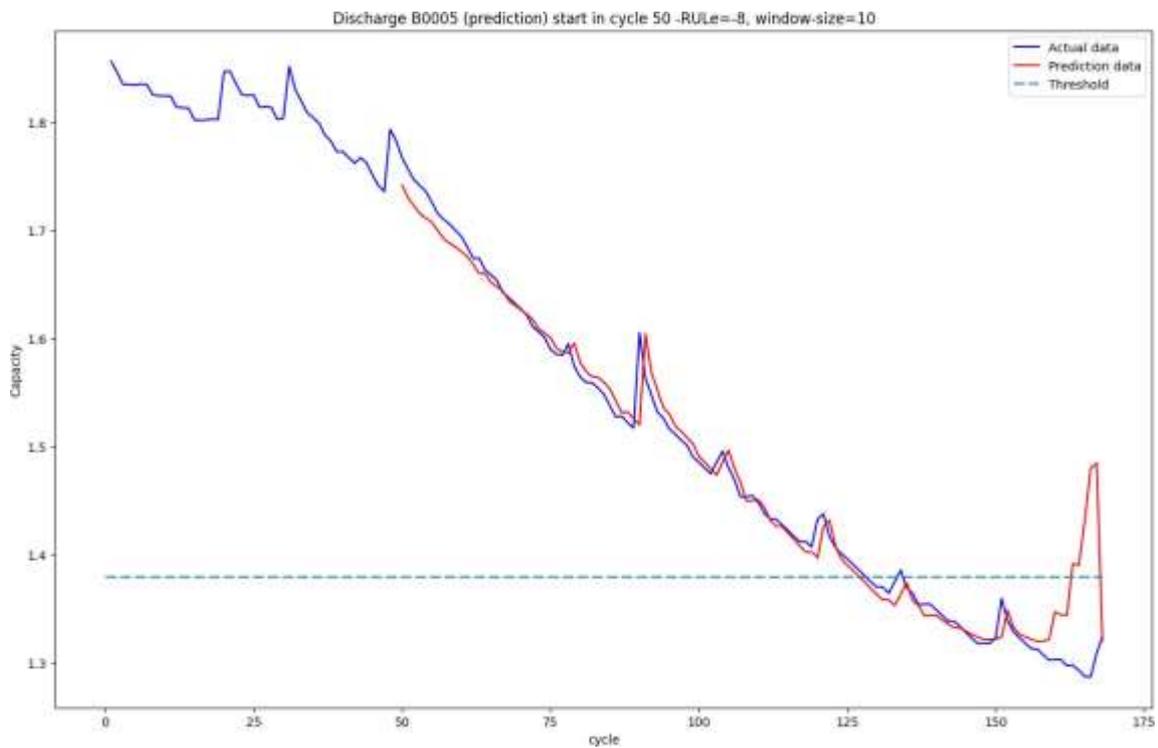


FIGURE 4.6 – Les résultats prédits par le CNN-LSTM sur la batterie B0005 au point de départ de 50

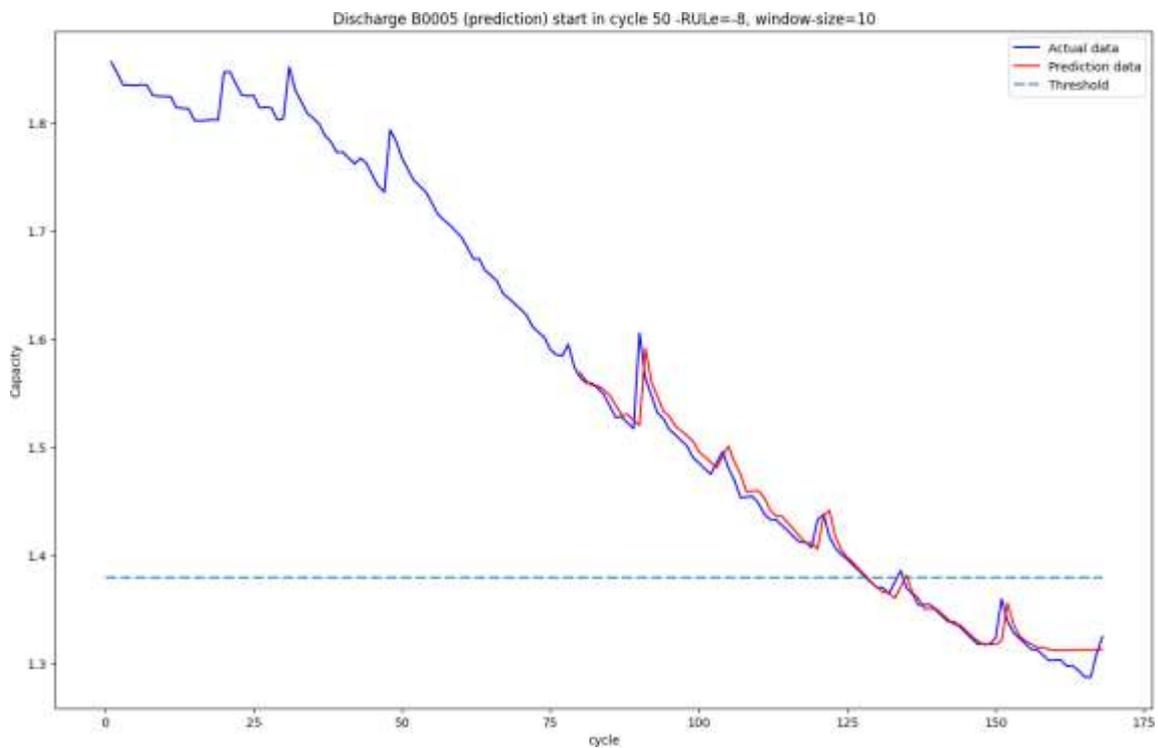


FIGURE 4.7 – Les résultats prédits par le CNN-LSTM sur la batterie B0005 au point de départ de 80

4.3 conclusion :

En général, nos résultats mettent en évidence le succès de l'élaboration d'un modèle de classification pour la défaut des cellules de lithium-ion à l'aide de l'algorithme spécifique. Cette étude contribue à la compréhension et à la prévision de telles défauts, facilitant ainsi l'amélioration de la sécurité et de la fiabilité dans les applications de cellules au lithium-ion. D'autres recherches et applications du modèle peuvent avoir des répercussions importantes sur les industries qui dépendent de la technologie des cellules au batterie lithium-ion.

conclusion général

Les batteries lithium-ion, reconnues pour leur haute densité énergétique, leur faible auto-décharge et leur longue durée de vie, sont devenues indispensables dans de nombreuses applications, notamment les appareils électroniques et les systèmes de stockage d'énergie renouvelable. Malgré ces avantages, elles présentent des défis en matière de sécurité, de coût et de gestion thermique.

Leurs principaux atouts comprennent une densité énergétique élevée, un faible besoin de maintenance et une flexibilité de conception. Cependant, des problèmes de fiabilité et de sécurité persistent. Pour assurer un fonctionnement sûr et fiable des systèmes énergétiques modernes, il est crucial de pouvoir diagnostiquer les défauts et prédire la durée de vie restante (RUL) des batteries lithium-ion.

L'intelligence artificielle (IA) joue un rôle essentiel dans l'analyse des données complexes et la détection précoce des anomalies, ce qui permet de prévenir les défaillances et de réduire les risques et les coûts associés. Les modèles de Deep Learning, en particulier les réseaux neuronaux récurrents (RNN), les réseaux de neurones convolutionnels (CNN) et les modèles hybrides, se révèlent particulièrement efficaces pour améliorer la précision des prédictions de la RUL. Ces modèles sont capables de traiter de grandes quantités de données et d'identifier des motifs complexes.

En conclusion, notre recherche montre que l'utilisation de modèles de Deep Learning, tels que les réseaux de neurones à longue mémoire à court terme (LSTM), les réseaux de neurones convolutionnels (CNN) et les modèles hybrides LSTM-CNN, améliore considérablement la précision et la fiabilité des prédictions de la durée de vie restante des batteries lithium-ion. Ces modèles permettent de capturer les séquences temporelles et les motifs complexes des données de performance des batteries, facilitant ainsi une gestion proactive et une maintenance optimisée. Les résultats confirment le potentiel des techniques de Deep Learning pour relever les défis de fiabilité et de sécurité des batteries lithium-ion, tout en soulignant l'importance de disposer de données d'entraînement de haute qualité et de modèles optimisés pour diverses conditions d'utilisation.

Bibliographie

- [1] Margaret A Boden. *Artificial intelligence*. Elsevier, 1996.
- [2] Nadia Burkart and Marco F Huber. A survey on the explainability of supervised machine learning. *Journal of Artificial Intelligence Research*, 70 :245–317, 2021.
- [3] Gonçalo Dos Reis, Calum Strange, Mohit Yadav, and Shawn Li. Lithium-ion battery data and where to find it. *Energy and AI*, 5 :100081, 2021.
- [4] Shahid A Hasib, S Islam, Ripon K Chakraborty, Michael J Ryan, Dip Kumar Saha, Md H Ahamed, Sumaya I Moyeen, Sajal K Das, Md F Ali, Md R Islam, et al. A comprehensive review of available battery datasets, rul prediction approaches, and advanced battery management. *Ieee Access*, 9 :86166–86193, 2021.
- [5] Juan Jovel and Russell Greiner. An introduction to machine learning approaches for biomedical research. *Frontiers in Medicine*, 8 :2534, 2021.
- [6] Jianlin Li, Claus Daniel, and David Wood. Materials processing for lithium-ion batteries. *Journal of Power Sources*, 196(5) :2452–2460, 2011.
- [7] Matthew Li, Jun Lu, Zhongwei Chen, and Khalil Amine. 30 years of lithium-ion batteries. *Advanced Materials*, 30(33) :1800561, 2018.
- [8] Huixing Meng and Yan-Fu Li. A review on prognostics and health management (phm) methods of lithium-ion batteries. *Renewable and Sustainable Energy Reviews*, 116 :109405, 2019.
- [9] Kyungnam Park, Yohwan Choi, Won Jae Choi, Hee-Yeon Ryu, and Hongseok Kim. Lstm- based battery remaining useful life prediction with multi-channel charging profiles. *Ieee Access*, 8 :20786–20798, 2020.
- [10] Lei Ren, Jiabao Dong, Xiaokang Wang, Zihao Meng, Li Zhao, and M Jamal Deen. A data-driven auto-cnn-lstm prediction model for lithium-ion battery remaining useful life. *IEEE Transactions on Industrial Informatics*, 17(5) :3478–3487, 2020.
- [11] Patrick Henry Winston. *Artificial intelligence*. Addison-Wesley Longman Publishing Co., Inc., 1984.