

Prédiction de l'état de santé d'une batterie lithium-ion à l'aide d'algorithmes d'apprentissage automatique

Jamila Hemdani^{1,2}, Laid Degaa², Moez Soltani¹, Nassim Rizoug², Achraf Jabeur Telmoudi¹ et Abdelkader Chaari¹

1 Ecole nationale supérieure des ingénieurs de Tunis (ENSIT)

2 École supérieure des techniques aéronautiques et de construction automobile (ESTACA)

RÉSUMÉ – Ces dernières années, on a constaté une augmentation de l'utilisation de véhicules électriques (VE). Afin de garantir un fonctionnement sûr et fiable, il est nécessaire de surveiller l'état de santé de la batterie. Cet article présente une méthode d'apprentissage en profondeur qui utilise un réseau de neurones profonds (DNN) pour estimer la capacité au niveau de la cellule en se basant sur la tension, le courant et l'état de charge. Tout d'abord, un modèle multi-phérique de la batterie est réalisé pour extraire les données d'entrée et de sortie pour les différentes phases d'apprentissage et de test. Ensuite, deux algorithmes d'apprentissage automatique, DNN et Convolution Neural Network (CNN), sont utilisés pour prédire l'état de santé. L'erreur absolue moyenne et l'erreur quadratique moyenne sont sélectionnées comme indices d'évaluation. Les résultats montrent que l'algorithme proposé DNN a l'erreur la plus faible, ce qui permet de prédire avec précision le SOH et d'avoir une meilleure stabilité.

Mots-clés – Apprentissage en profondeur, lithium-ion batterie, DNN, CNN, état de santé, modèle multi-phérique de la batterie.

1. INTRODUCTION

Au cours des dernières années, une attention particulière a été portée à l'utilisation d'énergies totalement propres et renouvelables afin de réduire ou d'éliminer définitivement les sources d'émissions de CO₂ [4, 5, 6]. Dans ce contexte, plusieurs Véhicules Electriques (VE), respectueux de l'environnement, sont apparus sur le marché mondial et leur nombre a continué d'augmenter, notamment en raison du changement climatique. D'ici 2030, le marché mondial des VE devrait atteindre 39 208 000 unités, contre environ 8 151 000 unités en 2022, à un taux de croissance annuel composé de 21,7% [7][8]. Aujourd'hui, les grands constructeurs automobiles évoluent de manière rapide vers un avenir électrique afin de remplacer les moteurs à combustion interne utilisant des carburants fossiles, mais le succès du secteur dépend toujours d'une évolution parallèle de la technologie des batteries [9, 10]. L'hybride nickel-métal (NiMH), le nickel-cadmium (NiCd), le plomb-acide et les lithium-ions (li-ion) sont des technologies de batteries généralement adoptées dans l'industrie automobile. Actuellement, la technologie la plus établie et la plus fiable disponible sur le marché pour les systèmes de stockage d'énergie par batterie est le lithium-ion, qui offre un rendement élevé, une longue durée de vie et capable de fournir une densité d'énergie élevée et qui réduit les coûts par rapport aux autres technologies [1]. La prédiction de l'état de santé d'une batterie lithium-ion est un domaine de recherche important dans le domaine des batteries rechargeables, car il permet d'estimer la durée de vie restante de la batterie et d'optimiser son utilisation en conséquence [11][12]. Plusieurs approches ont été proposées pour prédire l'état de santé d'une batterie, allant des modèles physiques aux méthodes d'apprentissage automatique. Les modèles physiques sont basés sur les équations mathématiques qui décrivent le comportement de la batterie, tels que le modèle électrochimique de Doyle-Fuller-Newman [16, 17, 19, 22, 23]. Ces modèles peuvent être précis, mais ils nécessitent des connaissances détaillées sur la compo-

sition de la batterie et les conditions d'utilisation, ce qui peut rendre leur utilisation difficile en pratique. Les méthodes d'apprentissage automatique, en revanche, sont basées sur l'analyse de données de mesure de la batterie, telles que la tension, le courant et la température, pour prédire l'état de santé de la batterie. Ces méthodes sont souvent plus faciles à mettre en œuvre que les modèles physiques et peuvent fournir des prévisions plus précises en utilisant des algorithmes tels que les réseaux de neurones, les arbres de décision et les méthodes de régression. Ces dernières années, les méthodes d'apprentissage automatique ont connu un intérêt croissant dans la prédiction de l'état de santé des batteries lithium-ion. Les modèles basés sur l'apprentissage profond, tels que les réseaux de neurones profonds, ont montré des performances élevées dans la prédiction de l'état de santé des batteries, en utilisant des données de mesure de la batterie collectées en temps réel. Ces modèles sont capables d'apprendre des caractéristiques complexes à partir des données de mesure de la batterie, ce qui peut améliorer la précision de la prédiction.

Ces études [40]-[44], il est démontré que les réseaux de neurones restent un domaines de recherche très actifs, offrant un grand potentiel pour estimer l'état de santé (SOH) des batteries dans des conditions de vieillissement complexes, en particulier lorsque les données sont abondantes. Les approches d'estimation du SOH basées sur le machine learning sont donc des domaines de recherche prometteurs qui auront un impact significatif sur l'avenir de l'électrification des transports. Selon la littérature, les réseaux de neurones feed-forward (FNN), les réseaux de neurones convolutifs (CNN) et les réseaux de mémoire à long terme (LSTM) sont les plus performants. Une étude comparative menée par Sungwoo Jo et al. [45] montre que les LSTM ont les meilleures performances par rapport aux deux autres types. Cependant, leur utilisation peut être coûteuse en termes de calcul et de mémoire en raison de la complexité de leur structure et de leur cellule mémoire. En effet, les contraintes d'embarquabilité pour le déploiement temps réel d'une approche d'intelligence artificielle pour la prédiction de l'état de santé d'une batterie dépendent de plusieurs facteurs, tels que la taille du modèle, la complexité des algorithmes utilisés, la capacité de traitement et de stockage du matériel embarqué, ainsi que les exigences en termes de temps de latence et de précision. C'est pourquoi nous avons utilisé les modèles CNN et DNN afin de minimiser les coûts de calcul et de maximiser la fiabilité.

Cet article est structuré comme suit : dans la section 2, nous présentons une brève description des technologies de stockage d'énergie. Ensuite, nous détaillons la modélisation de la batterie permettant d'extraire une base de données pour les différentes phases d'apprentissage et de test. Nous présentons ensuite la méthodologie proposée pour le pronostic de la capacité de la batterie et décrivons le processus d'apprentissage automatique ainsi que les différents algorithmes utilisant le modèle multi-phérique. Finalement, nous comparons les résultats de prédiction de capacité obtenus avec les algorithmes DNN et CNN. Les conclusions sont présentées dans la section 7.

2. TECHNOLOGIES DES SYSTEMES DE STOCKAGE D'ENERGIE

Ces dernières années, les véhicules électriques gagnent beaucoup en popularité en raison de leur succès et de leur efficacité. En particulier, l'augmentation des VE est corrélée au développement des batteries qui en sont le composant clé. Le graphique de Ragone pour les technologies de stockage d'énergie de batterie disponibles est présenté dans la Figure 1.

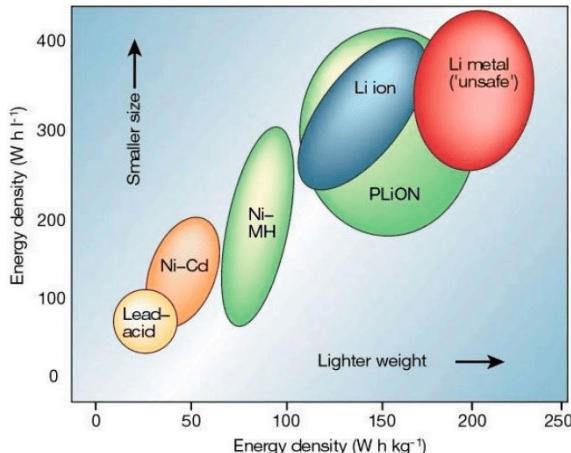


FIG. 1. Ragone de plusieurs technologies de batterie utilisées dans les véhicules électriques

La majorité des fabricants actuels de VE utilisent des batteries Li-ion en raison de leur haute énergie spécifique, de leur densité énergétique élevée, stabilité et de leur faible taux de décharge par rapport aux autres batteries rechargeables. Dans le marché, les batteries les plus utilisées sont les batteries Li-ion (LIB) comprenant le phosphate de fer au lithium (LFP), le nickel cobalt aluminium au lithium (NCA), le nickel manganèse cobalt au lithium (NMC), le spinelle de manganèse au lithium (LMO) et l'oxyde de titanate de lithium (LTO). Le diagramme de Kiviat [2, 3], présente leurs caractéristiques. Le NMC est le plus utilisé et étudié dans les VE, il présente le meilleur compromis entre sécurité, performances électriques (puissance spécifique et énergie spécifique) et coût, comme indiqué dans la figure 2. En effet, c'est ce qui caractérise les batteries NMC dans le laboratoire ESTACA'LAB [18].

3. MODÈLES DE BATTERIE

Dans les applications des VE, une estimation précise de l'état de santé maximise le confort des clients. Le point de départ est de créer un bon modèle de batterie pour prédire l'état des batteries avec une grande précision. Il existe plusieurs types de modèles électriques représentant des batteries qui sont des composants électrochimiques complexes avec des propriétés non linéaires et non stationnaires. Une première approche, physico-chimique, consiste à utiliser des lois électrochimiques. Ce modèle, qui caractérise les interactions intracellulaires, permet d'obtenir des résultats précis [20, 21], mais nécessite une connaissance parfaite de la composition de chaque élément de la cellule (électrodes, électrolyte, etc.) chimiquement et structurellement.

L'approche systémique est une autre approche, avec une vision en boîte noire de la batterie. Ce modèle est basé soit sur des résultats expérimentaux, soit par assimilation du système à un circuit électrique équivalent dont les paramètres seront déterminés à partir des résultats des tests [24]. Cependant, la majorité des modèles distincts de batterie sont le modèle multi-physique basé sur les circuits équivalents et le modèle basé sur les données.

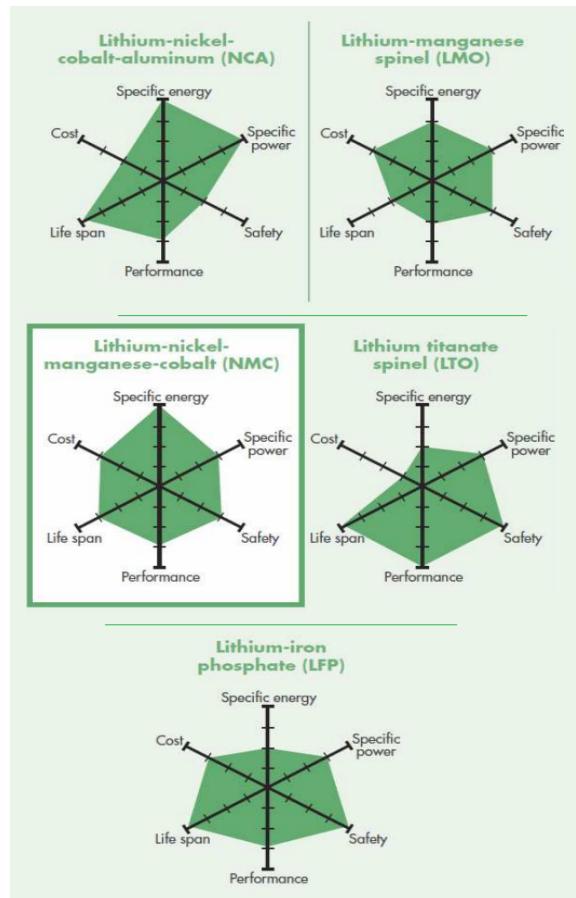


FIG. 2. Les différentes technologies de batterie Li-ion

3.1. Modèle multi-physique

La modélisation multi-physique a pour objectif de représenter le fonctionnement des systèmes de stockage pendant l'utilisation des véhicules électriques à l'aide de composants électriques tels que des résistances, des sources de tension et des condensateurs. Par conséquent, un modèle multi-physique est requis, qui se compose de trois sous-modèles comme indiqué dans la figure 3. Un modèle électrique pour estimer les pertes, un modèle thermique qui permet de déterminer l'évolution de la température de la batterie en fonction de la température ambiante et des pertes identifiées dans le modèle électrique, et un modèle de vieillissement qui est influencé par la température de la batterie, le niveau d'énergie mais aussi le profil de courant.

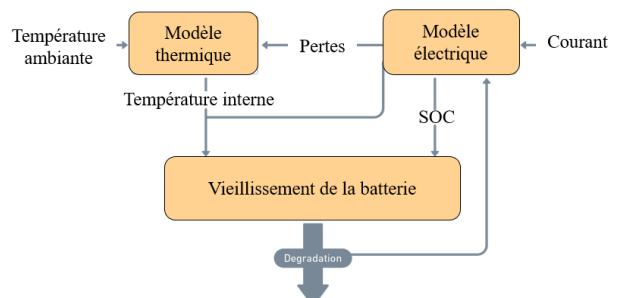


FIG. 3. Modèle multi-physique

3.1.1. Modèle électrique

La figure 7 montre le modèle électrique décrit dans la littérature [25, 26, 27], qui est composé de circuits électriques équivalents. En effet, ils se composent d'une source de tension (U_{OCV}), d'une résistance interne variable (R_Ω) qui représente la chute de tension induite par le courant de charge, et de deux circuits R/C série-parallèle qui représentent le comportement de l'effet de double couche R_{dl}, C_{dl} et le comportement de diffusion d'ions dans la batterie R_{dif}, C_{dif} .

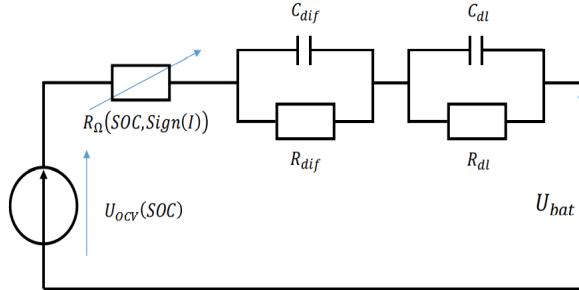


FIG. 4. Modèle électrique équivalent de la batterie

$$U_{ocv} = x_{(1)} + x_{(2)}.e^{c_{(1)}(1-SOC)} + x_{(3)}.e^{c_{(2)}.SOC} + x_{(4)}.e^{c_{(3)}.(1-SOC)^2} + x_{(5)}.e^{c_{(4)}.SOC^2} + x_{(6)}.e^{c_{(5)}.(1-SOC)^3} + x_{(7)}.e^{c_{(6)}.SOC^3} \quad (1)$$

Les coefficients d'optimisation $c_{(j)}$ et $x_{(i)}$ sont fixés avec un algorithme PSO-NM (Optimisation d'essaim particulier Nelder-Mead) pour s'adapter à la tension cellulaire expérimentale.

Le comportement de la résistance interne R_Ω est exprimé par 2.

$$R_\Omega = \frac{x_{(8)}}{\sqrt{SOC(1 + c_{(7)}.sign(I))} + c_{(8)}} \quad (2)$$

De plus, les coefficients d'optimisation $c_{(8)}$ et $c_{(7)}$ sont déterminés en adaptant le modèle aux résultats expérimentaux à l'aide d'un algorithme PSO-NM, de même que pour R_{dl}, C_{dl}, R_{dif} et C_{dif} .

3.1.2. Modèle thermique

Le modèle thermique permet de déterminer la propagation et la génération de chaleur à l'intérieur de la cellule. En effet, les réactions électrochimiques lors des cycles de charge/décharge et le transport de charge génèrent de la chaleur à l'intérieur de la batterie. On trouve différentes approches pour la modélisation thermique des accumulateurs, telles que les équations aux dérivées partielles, les systèmes linéaires à paramètres variables ou les circuits électriques équivalents. Cependant, ces modèles nécessitent de nombreux tests pour déterminer les paramètres et des calculs longs pour simuler rapidement le comportement sur la durée de vie actuelle. Par conséquent, un circuit électrique équivalent est un meilleur modèle pour notre étude.

Le schéma de l'équivalent modèle thermique représenté sur la figure 5 décrit la dissipation de chaleur due aux pertes dans la batterie. La puissance thermique provient précisément des pertes de puissance ohmique de R_Ω et est calculée par l'équation 3.

Ce circuit est composé :

- une source de puissance thermique P_{th} ,
- une capacité thermique C_{th} qui accumule la chaleur,
- et une résistance thermique R_{th} qui limite le transfert de chaleur à l'extérieur de la cellule.

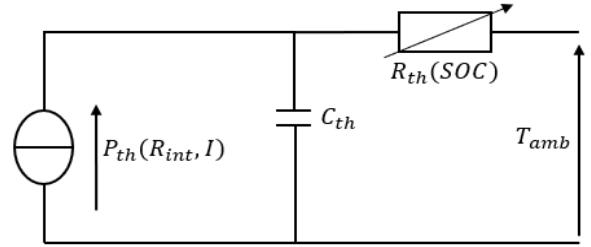


FIG. 5. Modèle thermique équivalent de la batterie

En effet, la résistance thermique est calculée à l'aide de l'équation 4.

$$P_{th} = R_{int}I^2 = (U_{ocv} - U).I \quad (3)$$

$$R_{th} = a_1 + a_2.SOC^3 \quad (4)$$

où a_1 et a_2 sont deux paramètres qui sont déterminés par l'expérimentation et l'optimisation de l'algorithme de réglage.

3.2. Modèle de vieillissement

Le modèle de vieillissement est la dernière partie qui se compose de deux sous-modèles : un modèle de vieillissement par calendrier et un modèle de vieillissement par cyclage.

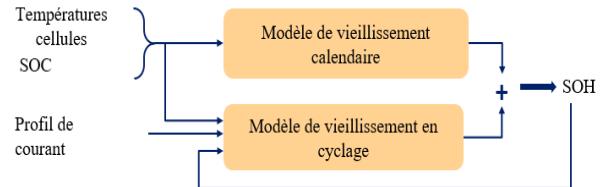


FIG. 6. Modèle de vieillissement équivalent

Le vieillissement du calendrier correspond au vieillissement de la cellule au repos tandis que le vieillissement par cyclage correspond à l'utilisation de la cellule et la somme du modèle de cyclage et de calendrier représente la dégradation totale des performances de la cellule.

$$a_{bat}(t, T, SOC) = c_1.t^{\frac{3}{4}}.c_T^{\frac{T-T_0}{\delta T}} + c_S SOC^{\frac{SOC-SOC_0}{\delta SOC}} \quad (5)$$

4. JEU DE DONNÉES DE LA BATTERIE

Le modèle multi-physique développé est utilisé pour créer une base de données pour la phase d'apprentissage et de test. L'objectif principal de la création d'une base de données est de prédire l'évolution du vieillissement en fonction de l'historique d'utilisation des composants.

Plusieurs tests sont effectués pour différentes valeurs de courant, d'état de charge et de capacité initiale. À chaque test, nous faisons varier un seul paramètre pour construire une base de données très riche. Le courant varie de 3C à 0,5C, le SOC initial de 80 % à 70 % et la capacité initiale de 100 %C à 60 %C. Après avoir extrait les données du modèle multiphysique, la dernière étape consiste à estimer avec précision l'état de santé de la batterie afin de prédire son état de dégradation. Les figures 7,8 et 9 présentent les résultats des entrées-sorties obtenus à partir du modèle multiphysique de la batterie.

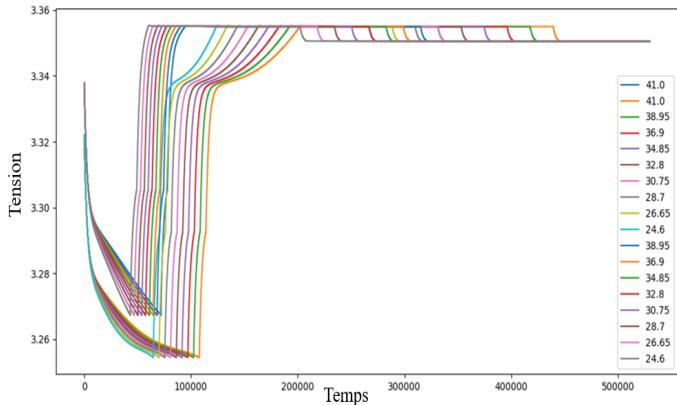


FIG. 7. Variation de tension en fonction de la variation de capacité et du SOC

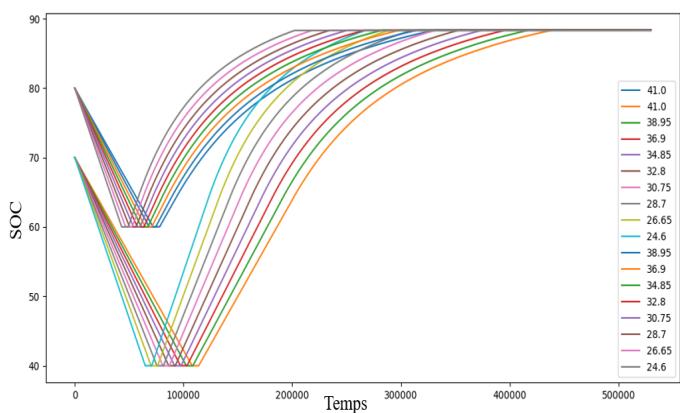


FIG. 8. Variation du SOC en fonction de la variation de capacité

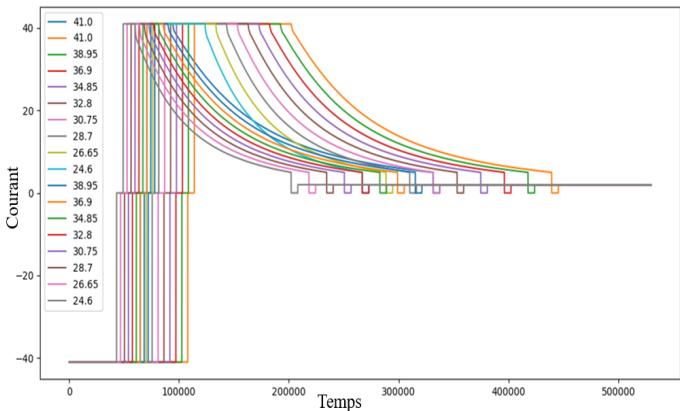


FIG. 9. Variation de courant en fonction de la variation de capacité et du SOC

5. PROCESSUS D'APPRENTISSAGE

La batterie est le composant principal des véhicules électriques, il est donc important d'estimer leur état de santé (SOH) pour assurer leur efficacité et leur sécurité. Les performances des batteries lithium-ion, en tant que source d'énergie, sont affectées par l'environnement, par exemple, la température ambiante, l'âge, les cycles de charge/décharge et leur composition chimique, ce qui résulte en des calculs complexes de leur SOH. Comme il s'agit d'une quantité d'état interne qui ne peut être directement mesurée, les méthodes de prédiction du SOH basées sur l'intelligence artificielle (IA) ont été largement utilisées. En raison de son application facile et de son indépendance par rapport à la connaissance détaillée des mécanismes

de dégradation, les méthodes basées sur l'apprentissage automatique (ML) sont largement étudiées pour l'estimation du SOH [28, 29, 30, 31, 32]. Dans cette section, nous présentons la méthodologie proposée et les données collectées à partir d'un modèle multi-physique pour la prévision de la capacité des batteries Li-Ion, ainsi qu'une étude comparative des algorithmes d'apprentissage artificiel. La Figure 4 montre l'extraction des données et l'utilisation des valeurs de tension, de courant, d'état de charge (SOC) et de capacité en tant que données d'entrée lors de la phase d'apprentissage pour apprendre les entrées/sorties, puis prédire avec précision la capacité de la batterie. Il existe plusieurs méthodes pour prédire l'état de santé (SOH) dans la littérature, parmi lesquelles nous trouvons le réseau de neurones artificiels (ANN), le réseau de neurones convolutionnels (CNN) [33][34], la mémoire à court terme (LSTM) [35][36] et le réseau de neurones profonds (DNN) [37][38], qui décrivent le comportement d'une batterie sans connaissance préalable de la structure interne de la batterie.

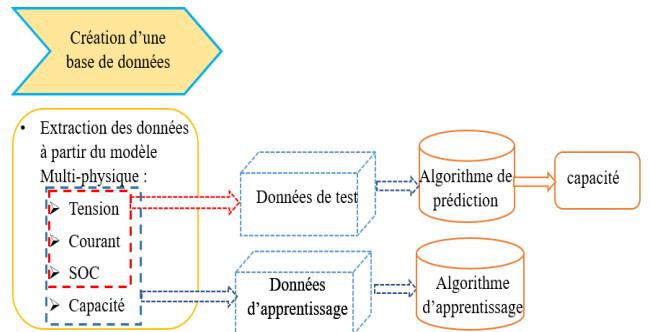


FIG. 10. Procédure de création de base de données

Voici les caractéristiques de chaque algorithme de deep learning. Le réseau de neurones profond (DNN) est généralement une pile de multiples couches cachées plutôt qu'une seule couche cachée dans l'architecture standard du réseau de neurones artificiels (ANN). Les couches cachées de DNN sont les multiples couches d'alimentation directe qui sont entraînées avec une descente de gradient stochastique de rétropropagation. Les couches cachées se composent de nœuds de neurones avec des fonctions d'activation tanh, rectifieur (ReLU) et maxout. Le réseau de neurones convolutif (CNN) gère mieux les données multidimensionnelles, car il a adopté des types de techniques de convolution. De plus, comme mentionné précédemment, les couches de CNN et de RNN sont beaucoup plus complexes que celles de DNN. Par conséquent, CNN et RNN prennent plus de temps pour entraîner le modèle, ce qui est leur principal inconvénient. Ces raisons font que DNN est plus adapté à une utilisation dans des applications réelles dans la plupart des cas.

5.1. Formation de modèle

Comme le montre la Figure 11, le processus proposé pour l'estimation de l'état de santé (SOH) de la batterie se composait de trois étapes : la création d'une base de données, la formation du modèle et la validation du modèle.

Les données de caractéristiques ont été divisées en un ensemble d'entraînement et un ensemble de test. Nous avons entraîné des DNN et des CNN à l'aide des données d'entraînement. À l'étape de test, le modèle entraîné a été testé à l'aide de l'ensemble de test, et sa performance a été évaluée à l'aide de l'erreur absolue moyenne (MAE) et de l'erreur quadratique moyenne (MSE).

5.1.1. Réseau de neurones convolutionnels

CNN est un extracteur de caractéristiques largement utilisé dans différents domaines. Il se compose généralement de

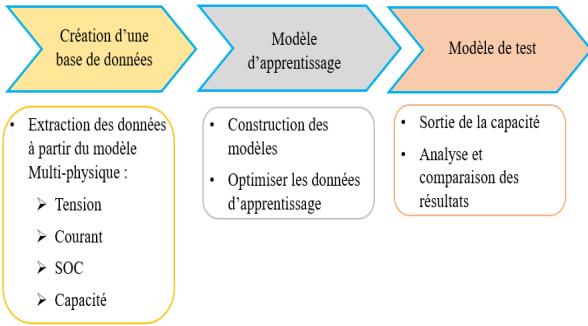


FIG. 11. Organigramme de la méthodologie proposée

couches de convolution, de couches de regroupement et de couches entièrement connectées. La couche de convolution effectue un traitement de convolution sur les données d'origine à travers le glissement de la convolution, ce qui peut améliorer certaines de ses caractéristiques et réduire le bruit [39].

5.1.2. Réseau de neurones profonds

Le DNN, qui est essentiel pour l'apprentissage automatique pour former la base de nombreuses architectures, se compose de plusieurs couches de perceptrons avec une fonction d'activation non linéaire. Nous avons utilisé la structure du DNN, qui avait une structure de cinq couches, composée d'une couche d'entrée, de trois couches cachées et de sortie. Les couches cachées contenaient 32 neurones cachés, et la fonction ReLU était utilisée comme activation [23].

5.2. Évaluation des performances

Les indices de performance utilisés pour évaluer la qualité d'approximation et de prédiction des algorithmes sont : l'erreur quadratique moyenne (en anglais Mean Squared Error (MSE)) et l'erreur absolue moyenne (en Mean Absolute Error (MAE)).

$$MAE = \frac{1}{n} \cdot \sum_{i=1}^n |\hat{y}_i - y_i| \quad (6)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (7)$$

6. RÉSULTATS ET DISCUSSION

Pour valider la méthode proposée, les résultats d'estimation de capacité ont été comparés dans cette section. Afin de comparer et de déduire quelle méthode offre de meilleures performances entre les deux algorithmes.

Les figures 12,13 montrent les résultats d'estimation de capacité utilisant les algorithmes CNN et DNN.

Les résultats d'estimation de l'État de Santé (SOH) obtenus avec le CNN ont montré une tendance similaire à ceux obtenus avec le DNN, comme indiqué dans les figures 12,13. Pour effectuer une comparaison plus simple, nous avons calculé l'erreur quadratique moyenne (MSE) et l'erreur absolue moyenne (MAE) de l'estimation de l'État de Santé, comme indiqué dans le Tableau 1.

TABLEAU 1. Indices de performance des algorithmes DNN et CNN

| - | MAE | MSE |
|-----|--------|--------|
| DNN | 0.2253 | 0.0875 |
| CNN | 0.7220 | 0.5860 |

Le modèle DNN avait la plus faible MAE de 0,2253 et MSE de 0,0875 par rapport au modèle CNN. En effet, le CNN prend

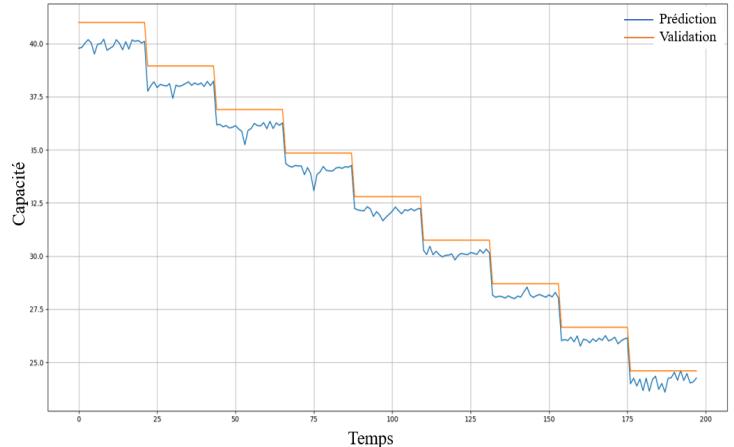


FIG. 12. Évolution de la capacité réelle et estimée par l'algorithme CNN

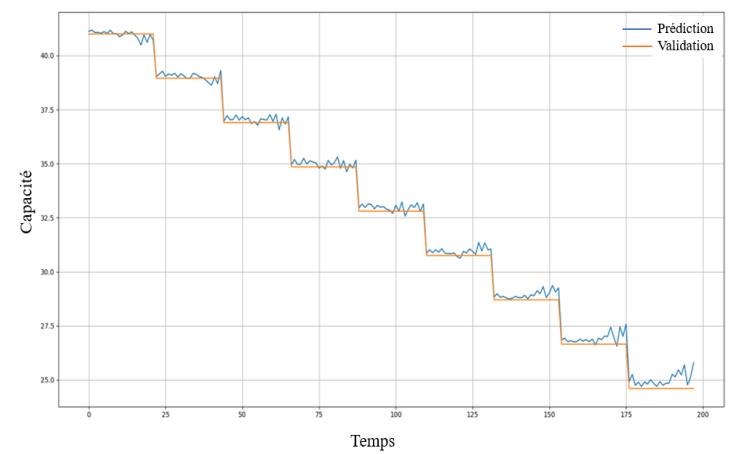


FIG. 13. Évolution de la capacité réelle et estimée par l'algorithme DNN

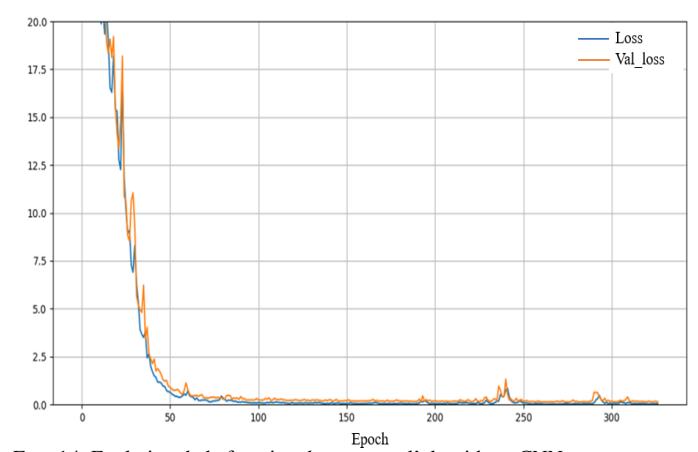


FIG. 14. Evolution de la fonction de perte par l'algorithme CNN

plus de temps pour entraîner le modèle, ce qui est son principal inconvénient. Ces raisons rendent le DNN plus approprié pour une utilisation dans des applications réelles dans la plupart des cas.

7. CONCLUSION

Cet article a présenté une méthodologie d'estimation et de pronostic de la capacité des batteries Li-ion des véhicules électriques.

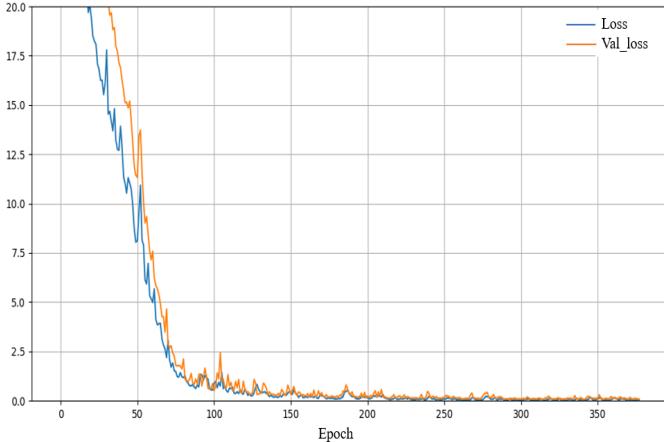


FIG. 15. Evolution de la fonction de perte par l'algorithme DNN

triques. Le cadre comprend l'utilisation d'algorithmes DNN et CNN pour prédire l'avenir du comportement de la batterie sur la base de l'utilisation du modèle multi-phérique pour extraire l'entrée et la sortie du modèle. Les performances de l'approche proposée sont évaluées à travers une étude comparative sur les données collectées à partir du modèle multi-phérique de batterie. Les résultats obtenus montrent une forte ressemblance entre les valeurs réelles et celles prédictives par la méthodologie proposée pour les différents cycles. Par conséquent, la méthode proposée suit l'évolution du comportement réel de la batterie avec une précision satisfaisante. Cependant, nous avons des défis pour améliorer la méthode développée dans ce travail pour une prédition plus puissante de la capacité de la batterie en tenant compte de l'effet de la température.

8. RÉFÉRENCES

- [1] A.Chakrabarti, N.Marati, A.K.Bhoi, V.H.C.De Albuquerque and A.Kalam, “AI Enabled IoT for Electrification and Connected Transportation,” Springer, 2022.
- [2] G.Saldaña, J.I.S.Martín, I.Zamora,F.J.Asensio, and O.Oñederra, “Analysis of the Current Electric Battery Models for Electric Vehicle Simulation,” Energies, 2019.
- [3] A.Babin, “Optimisation du coût de revient global (TCO) d'un véhicule utilitaire électrique 3,5t; modélisation multi-phérique, dimensionnement et recharge intelligente,” 2018.
- [4] W.Yosafat, P.Ofita, S.Wiwik and T.Bambang, “Zero emission and clean energy concept for campus area in hot-humid tropical climate,” ArchNet-IJAR, 2022.
- [5] R.Zahedi, M.Ghodusinejad, A.Aslani and C.Hachem-Vermette, “Modelling community-scale renewable energy and electric vehicle management for cold-climate regions using machine learning,” Energy Strategy Reviews, 2022.
- [6] Y.Ahoutou, A.Ilinca and M.Issa “Electrochemical Cells and Storage Technologies to Increase Renewable Energy Share in Cold Climate Conditions— A Critical Assessment,” Energies 2022.
- [7] “Electric Vehicle Market by Type, Vehicle Type, Vehicle Class, Top Speed and Vehicle Drive Type : Global Opportunity Analysis and Industry Forecast, 2021-2030,” ID : 5578613, 501 Pages, January 2022.
- [8] “Electric Vehicle Market by Component, Vehicle Type, Vehicle Class, Propulsion (BEV, PHEV, FCEV), Vehicle Drive Type (FWD, RWD, AWD), Vehicle Top Speed (125 mph), Charging Point Type, Vehicle Connectivity, End Use, Region-Global Forecast 2030,” ID : 5578613, 326 Pages, April 2022.
- [9] F.Heinrich and M.Pruckner, “Virtual experiments for battery state of health estimation based on neural networks and in-vehicle data,” Journal of Energy Storage, April 2022.
- [10] W.Cieslik, F.Szwajca, W.Golimowski and A.Berger, “Experimental Analysis of Residential Photovoltaic (PV) and Electric Vehicle (EV) Systems in Terms of Annual Energy Utilization,” Energies, 19 February 2021.
- [11] M.Al-Saadi, J.Olmos, A.Saez-de-Ibarra, J.V.Mierlo and M.Berecibar, “Fast Charging Impact on the Lithium-Ion Batteries’ Lifetime and Cost-Effective Battery Sizing in Heavy-Duty Electric Vehicles Applications,” Energies, 2022.
- [12] J.A.Sanguesa, V.Torres-Sanz, P.Garrido, F.J.Martinez and Johann M.Marquez-Barja, “A Review on Electric Vehicles : Technologies and Challenges,” Smart Cities, 2021.
- [13] Y.Zhang and Yan-Fu.Li, “Prognostics and health management of Lithium-ion battery using deep learning methods : A review,” Renewable and Sustainable Energy Reviews, June 2022.
- [14] J.Hemdani, M.Soltani, A.J.Telmoudi and A.Chaari, “Prediction of aging of battery for electric vehicles based on a modified version of neural networks,” 29th Mediterranean Conference on Control and Automation (MED), IEE, 2021.
- [15] I.Remadna, S.L.Terrissa, , M.Sayah, S.Ayad and N.Zerhouni, “Boosting RUL Prediction Using a Hybrid Deep CNN-BLSTM Architecture,” Automatic Control and Computer Sciences, 2022.
- [16] J.Hemdani, L.Degaa, M.Soltani, N.Rizoug, A.J.Telmoudi and A.Chaari, “Prediction of aging electric vehicle battery by multi-physics modeling and deep learning method,” 2022 8th International Conference on Control, Decision and Information Technologies CoDIT’22 | Istanbul, Turkey, May 2022.
- [17] P.Khumprrom and N.Yodo, “A Data-Driven Predictive Prognostic Model for Lithium-ion Batteries based on a Deep Learning Algorithm,” energies, February 2019.
- [18] A.MEDDOUR, N.RIZOUG, A.BABIN, L.DEGAA, “Optimization of Li-ion modelling for automotive application : comparison of optimization methods performances,” 2020 7th International Conference on Control, Decision and Information Technologies (CoDIT’20) | Prague, Czech Republic, July, 2020.
- [19] S.Jo, S.Jung and T.Roh , “Battery State-of-Health Estimation Using Machine Learning and Preprocessing with Relative State-of-Charge,” energies, 2021.
- [20] M. Doyle, “Modeling of Galvanostatic Charge and Discharge of the Lithium/Polymer/ Insertion Cell,” Journal of The Electrochemical Society, Jun 1993.
- [21] Eric Prada, D. Di Domenico, Yann Creff, J. Bernard, Valérie Sauvant-Moynot, et al. “Simplified Electrochemical and Thermal Model of LiFePO4-Graphite Li-Ion Batteries for Fast Charge Applications,” Journal of The Electrochemical Society, Electrochemical Society, 2012.
- [22] S.Chi, H.Jang, H.Han, S.Park, M-I.Chi and S.Park, “Artificial Intelligence-based Battery State-of-Health (SoH) Prediction through battery data characteristics analysis,” Industrial and Commercial Power Systems Technical Conference, 2022.
- [23] Y.Che, Z.Deng, P.Li, X.Tang, K.Khosravinia, X.Lin and X.Hu, “State of health prognostics for series battery packs : A universal deep learning method,” Energy, 2022.
- [24] J.Li, M.Mazzola, J.Gafford, N.Younan and all “A new parameter estimation algorithm for an electrical analogue battery model,” 2012 Twenty-Seventh Annual IEEE Applied Power Electronics Conference and Exposition (APEC), 2012.
- [25] H.Dai, X.Zhang, X.Wei, Z.Sun, J.Wang and F.Hu “Cell-BMS validation with a hardware-in-the-loop simulation of lithium-ion battery cells for electric vehicles,” International Journal of Electrical Power Energy Systems, 2013.
- [26] A.Hentunen, T.Lehmuspelto, J.Suomela and all, “Electrical battery model for dynamic simulations of hybrid electric vehicles,” 2011 IEEE Vehicle Power and Propulsion Conference, 2011.
- [27] R.Xiong, H.He, H.Guo and Y.Ding, “Modeling for Lithium-Ion Battery used in Electric Vehicles,” Procedia Engineering, 2011.
- [28] L.Yao, S.Xu, A.Tang, F.Zhou, J.Hou, Y.Xiao and Z.Fu, “A Review of Lithium-Ion Battery State of Health Estimation and Prediction Methods,” World Electric Vehicle Journal, 2021.
- [29] Y.Zhi, H.Wang and L.Wang, “A state of health estimation method for electric vehicle Li-ion batteries using GA-PSO-SVR,” Springer, 2022.
- [30] G.Li, Q.Chu, Z.Wang and L.Li, “State of Health Prediction for Battery Based on Ensemble Learning ,” International Conference on Electronics, Circuits and Information Engineering (ECIE), 2021.
- [31] H.Lin, L.Kang, D.Xie, J.Linghu and J.Li, “Online State-of-Health Estimation of Lithium-Ion Battery Based on Incremental Capacity Curve and BP

Neural Network," Batteries, 2022.

- [32] Y.Li, K.Li, X.Liu, Y.Wang and L.Zhang, "Lithium-ion battery capacity estimation — A pruned convolutional neural network approach assisted with transfer learning," Applied Energy, 2021.
- [33] C.Wang, R.Xiong, J.Tian, J.Lua and C.Zhang, "Rapid ultracapacitor life prediction with a convolutional neural network," Applied Energy, January 2022.
- [34] Y.Li, K.Li, X.Liu, Y.Wang and L.Zhang "Lithium-ion battery capacity estimation — A pruned convolutional neural network approach assisted with transfer learning," Applied Energy, March 2021.
- [35] P.Li, Z.Zhang, Q.Xiong, B.Ding, J.Hou and D.Luo, Y.Rong, S.Li "State-of-health estimation and remaining useful life prediction for the lithium-ion battery based on a variant long short term memory neural network," Journal of Power Sources, May 2020.
- [36] S.Wang, S.Jinb, D.Bai, Y.Fan, H.Shi and C.Fernandez "A critical review of improved deep learning methods for the remaining useful life prediction of lithium-ion batteries," Energy Reports, November 2021.
- [37] J.Tian, R.Xiong, W.Shen, J.Lu and X.Yang "Deep neural network battery charging curve prediction using 30 points collected in 10 min," Sciedirect, June 2021.
- [38] K.Phillip, C.Vidal, M.Naguib, and Michael Skells. "LG 18650HG2 Li-Ion Battery Data and Example Deep Neural Network XEV SOC Estimator Script." Mendeley, March 2020.
- [39] M.Haris, G.Student, M.N.Hasan and S.Qin, "Degradation Curve Prediction of Lithium-Ion Batteries Based on Knee Point Detection Algorithm and Convolutional Neural Network," IEEE Transactions on Instrumentation and Measurement, 2022.
- [40] X.Sui, S.He, S.B.Vilsen, J.Meng, R.Teodorescu and D.Stroe. "A review of non-probabilistic machine learning-based state of health estimation techniques for Lithium-ion battery". Appl. Energy 2021.
- [41] Z.Bao, J.Jiang, C.Zhu and M.Gao. "New Hybrid Neural Network Method for State-of-Health Estimation of Lithium-Ion Battery". Energies 2022.
- [42] J.Zhou, Z.He, M.Gao and Y.Liu. "Battery state of health estimation using the generalized regression neural network". In Proceedings of the 2015 8th International Congress on Image and Signal Processing (CISP), October 2015.
- [43] J.Qu, F.Liu, Y.Ma and J.Fan. "A Neural-Network-based Method for RUL Prediction and SOH Monitoring of Lithium-Ion Battery". IEEE Access 2019.
- [44] Y.Fan, H.Wu, W.Chen, Z.Jiang, X.Huang and S.Chen. "A Data Augmentation Method to Optimize Neural Networks for Predicting SOH of Lithium Batteries". In Proceedings of the International Conference on Robotics Automation and Intelligent Control (ICRAIC 2021), November 2021.
- [45] S.Jo, S.Jung and T.Roh . "Battery State-of-Health Estimation Using Machine Learning and Preprocessing with Relative State-of-Charge". Energies 2021.